

UNIVERSIDAD DE GRANADA



Departamento de Ciencias de la Computación  
e Inteligencia Artificial

*Aprendizaje Evolutivo de Reglas Difusas  
para Descripción de Subgrupos*

Tesis Doctoral

Pedro González García

Granada, Noviembre de 2007





UNIVERSIDAD DE GRANADA



*Aprendizaje Evolutivo de Reglas Difusas  
para Descripción de Subgrupos*

MEMORIA QUE PRESENTA

Pedro González García

PARA OPTAR AL GRADO DE DOCTOR EN INFORMÁTICA

Granada, Noviembre de 2007

DIRECTORES

**Dr. D. Francisco Herrera Triguero**

**Dra. D<sup>a</sup>. María José del Jesus Díaz**

Departamento de Ciencias de la Computación  
e Inteligencia Artificial



Tesis Doctoral parcialmente subvencionada por la Comisión  
Interministerial de Ciencia y Tecnología con el proyecto  
TIN2005-08386-C05-03



**CICYT**

**TIN2005-08386-C05-03**



La memoria titulada “*Aprendizaje Evolutivo de Reglas Difusas para Descripción de Subgrupos*”, que presenta D. Pedro González García para optar al grado de doctor, ha sido realizada dentro del programa de doctorado “*Diseño, Análisis y Aplicaciones de Sistemas Inteligentes*” del Departamento de Ciencias de la Computación e Inteligencia Artificial de la Universidad de Granada, bajo la dirección de los doctores D. Francisco Herrera Triguero, de la Universidad de Granada, y D<sup>a</sup> María José del Jesus Díaz, de la Universidad de Jaén.

Granada, Noviembre de 2007

El Doctorando

Los directores

Fdo: Pedro González García

Fdo: F. Herrera Triguero

Fdo: M.J. del Jesus Díaz



# Índice

---

Introducción .....	xi
Capítulo 1 Computación flexible y descubrimiento de subgrupos .....	1
1.1 Minería de Datos .....	2
1.1.1 Descubrimiento de conocimiento en bases de datos .....	3
1.1.2 Minería de datos.....	5
1.1.2.1 Tipos de algoritmos de minería de datos en función del objetivo .....	6
1.1.2.2 Componentes de los algoritmos de minería de datos .....	8
1.2 Descubrimiento de subgrupos.....	9
1.2.1 Definición de descubrimiento de subgrupos .....	9
1.2.2 Medidas de calidad para descubrimiento de subgrupos .....	12
1.2.2.1 Medidas descriptivas .....	13
1.2.2.2 Medidas predictivas .....	16
1.2.3 Revisión de los modelos existentes.....	17
1.3 Computación flexible.....	21
1.3.1 Introducción .....	21
1.3.2 Algoritmos evolutivos.....	24
1.3.2.1 Algoritmos genéticos.....	26
1.3.2.2 Algoritmos genéticos multiobjetivo .....	28
1.3.3 Lógica difusa.....	39
1.4 Algoritmos evolutivos y extracción de conocimiento.....	42
1.4.1 Esquema de representación.....	43
1.4.2 Operadores genéticos .....	46
1.4.3 Función de adaptación .....	47
1.4.4 Aplicaciones de los algoritmos genéticos en Minería de Datos .....	48
1.5 Reglas difusas y extracción de conocimiento .....	48
1.5.1 Aplicaciones de la lógica difusa en minería de de datos .....	50
1.5.1.1 Agrupamiento.....	50
1.5.1.2 Computación granular.....	50
1.5.1.3 Clasificación.....	51
1.5.1.4 Reglas de asociación .....	51
1.5.1.5 Dependencias funcionales .....	52
1.5.1.6 Sumarización de datos.....	52
1.5.2 Sistemas evolutivos difusos en minería de datos .....	52
1.5.2.1 Esquema de representación .....	53
1.5.2.2 Operadores genéticos .....	54
1.5.2.3 Función de adaptación.....	54
Capítulo 2 Un modelo evolutivo de extracción de reglas de descubrimiento de subgrupos	57
2.1 Descripción del modelo .....	57
2.1.1 Descripción del AG Híbrido .....	60
2.1.1.1 Esquema de representación .....	60
2.1.1.2 Función de adaptación.....	63
2.1.1.3 Esquema de reproducción y operadores genéticos .....	66

2.1.1.4 Etapa de post-procesamiento .....	67
2.1.2 Modelo iterativo .....	68
2.2 Análisis de componentes .....	69
2.2.1 Medidas de calidad .....	70
2.2.1 Características de la experimentación .....	72
2.2.3 Análisis de resultados .....	74
2.2.4 Conclusiones .....	89
2.3 Comparación entre el algoritmo SDIGA y otros algoritmos de descubrimiento de subgrupos .....	90
2.3.1 Características de la experimentación .....	91
2.3.2 Análisis de resultados .....	92
2.3.3 Conclusiones .....	110
2.4 Aplicaciones de SDIGA a problemas reales .....	110
2.4.1 Problema de marketing: extracción de conocimiento en certámenes feriales..	111
2.4.1.1 Experimentación sobre conjunto de datos de Marketing .....	112
2.4.1.2 Conclusiones.....	115
2.4.2 Problema de e-learning: extracción de conocimiento en datos de la plataforma Moodle sobre asignaturas de la Universidad de Córdoba.....	116
2.4.2.1 Descripción del problema .....	117
2.4.2.2 Resultados experimentales de la aplicación de los algoritmos de descubrimiento de subgrupos .....	119
2.4.2.3 Utilización de las reglas obtenidas por SDIGA .....	121
2.4.2.4 Conclusiones.....	123
2.5 Conclusiones .....	124
Capítulo 3 Un modelo evolutivo multiobjetivo de extracción de reglas de descubrimiento de subgrupos .....	125
3.1 Descripción del modelo.....	125
3.1.1 Esquema de representación .....	127
3.1.2 Definición de los objetivos del algoritmo.....	128
3.1.3 Cálculo del fitness .....	129
3.1.4 Selección de entorno.....	130
3.1.5 Esquema de reproducción y operadores genéticos .....	130
3.1.6 Generación de la población inicial .....	131
3.2 Comparación entre MESDIF y otros algoritmos de descubrimiento de subgrupos.....	131
3.2.1 Características de la experimentación .....	131
3.2.2 Análisis de resultados.....	132
3.2.3 Conclusiones .....	149
3.4 Aplicaciones.....	150
3.4.1 Extracción de conocimiento en certámenes feriales .....	150
3.4.1.1 Resultados de la experimentación sobre el dataset de marketing .....	150
3.4.1.2 Conclusiones.....	156
3.4.2 Extracción de conocimiento en datos de la plataforma Moodle sobre asignaturas de la Universidad de Córdoba .....	157
3.5 Conclusiones .....	161
Capítulo 4 Conclusiones .....	163
4.1 Resultados obtenidos.....	163

---

4.1.1 Algoritmo evolutivo de extracción de reglas difusas de descripción de subgrupos .....	163
4.1.2 Algoritmo evolutivo multiobjetivo para la extracción de reglas difusas de descripción de subgrupos .....	165
4.2 Publicaciones asociadas al trabajo desarrollado en esta memoria .....	166
4.3 Trabajos futuros .....	168
Apéndices .....	171
Apéndice A. Descripción de los conjuntos de datos sintéticos del repositorio UCI utilizados en las experimentaciones .....	171
Apéndice B. Tablas de la experimentación sobre los distintos conjuntos de datos sintéticos del repositorio UCI .....	175
Apéndice C. El algoritmo CN2-SD .....	228
Apéndice D. Descripción de las variables del problema de extracción de conocimiento en certámenes feriales .....	231
Bibliografía .....	239



# Índice de figuras

---

Figura 1.1. El proceso de KDD. ....	4
Figura 1.2. Diferencia entre las tareas de clasificación y descubrimiento de subgrupos. ....	11
Figura 1.3. Algoritmo de búsqueda en un enfoque evolutivo. ....	27
Figura 1.4. Ejemplo de codificación entera de longitud fija para el antecedente de una regla. ....	45
Figura 1.5. Definición de tres funciones trapezoidales de pertenencia mediante cuatro genes. ....	54
Figura 2.1. Esquema de funcionamiento del modelo. ....	58
Figura 2.2. Ejemplo de partición difusa para una variable continua. ....	59
Figura 2.3. Esquema de codificación de una regla canónica. ....	63
Figura 2.4. Esquema de codificación de una regla DNF. ....	63
Figura 2.5. Mutación tipo 1: eliminación de la variable $V_0$ en una regla canónica. ....	67
Figura 2.6. Mutación tipo 2: valores aleatorios para la variable $V_0$ en una regla canónica. ....	67
Figura 2.7. Mutación tipo 1: eliminación de la variable $V_0$ en una regla DNF. ....	67
Figura 2.8. Mutación tipo 2: valores aleatorios para la variable $V_0$ en una regla DNF. ....	67
Figura 2.9. Fase de post-procesamiento del AG híbrido. ....	68
Figura 2.10. Modelo iterativo de extracción de reglas. ....	69
Figura 3.1. Esquema de funcionamiento del algoritmo propuesto. ....	127



# Índice de tablas

---

Tabla 2.1. Resumen del análisis de componentes para el dataset Australian .....	74
Tabla 2.2. Resumen del análisis de componentes para el dataset Breast-w.....	75
Tabla 2.3. Resumen del análisis de componentes para el dataset Bridges.....	76
Tabla 2.4. Resumen del análisis de componentes para el dataset Diabetes .....	77
Tabla 2.5. Resumen del análisis de componentes para el dataset Echo .....	78
Tabla 2.6. Resumen del análisis de componentes para el dataset German .....	79
Tabla 2.7. Resumen del análisis de componentes para el dataset Heart .....	80
Tabla 2.8. Resumen del análisis de componentes para el dataset Hepatitis.....	81
Tabla 2.9. Resumen del análisis de componentes para el dataset Hypothyroid.....	82
Tabla 2.10. Resumen del análisis de componentes para el dataset Ionosphere .....	83
Tabla 2.11. Resumen del análisis de componentes para el dataset Iris.....	84
Tabla 2.12. Resumen del análisis de componentes para el dataset Tic-Tac-Toe .....	84
Tabla 2.13. Resumen del análisis de componentes para el dataset Vote .....	85
Tabla 2.14. Resumen del análisis de componentes para el dataset Balance .....	86
Tabla 2.15. Resumen del análisis de componentes para el dataset Car .....	87
Tabla 2.16. Resumen del análisis de componentes para el dataset Glass .....	88
Tabla 2.17. Resumen del análisis de componentes para el dataset Wine .....	89
Tabla 2.18. Resumen de características de los conjuntos de ejemplos y sus resultados. ....	90
Tabla 2.19. Comparación de algoritmos de descubrimiento de subgrupos para Australian.....	93
Tabla 2.20. Comparación de algoritmos de descubrimiento de subgrupos para Breast-w ..	94
Tabla 2.21. Comparación de algoritmos de descubrimiento de subgrupos para Bridges ....	95
Tabla 2.22. Comparación de algoritmos de descubrimiento de subgrupos para Diabetes...	96
Tabla 2.23. Comparación de algoritmos de descubrimiento de subgrupos para Echo .....	97
Tabla 2.24. Comparación de algoritmos de descubrimiento de subgrupos para German....	98
Tabla 2.25. Comparación de algoritmos de descubrimiento de subgrupos para Heart.....	99
Tabla 2.26. Comparación de algoritmos de descubrimiento de subgrupos para Hepatitis	100
Tabla 2.27. Comparación de algoritmos de descubrimiento de subgrupos para Hypothyroid.....	101
Tabla 2.28. Comparación de algoritmos de descubrimiento de subgrupos para Ionosphere.....	102
Tabla 2.29. Comparación de algoritmos de descubrimiento de subgrupos para Iris .....	103
Tabla 2.30. Comparación de algoritmos de descubrimiento de subgrupos para Tic-Tac- Toe .....	104
Tabla 2.31. Comparación de algoritmos de descubrimiento de subgrupos para Vote .....	105
Tabla 2.32. Comparación de algoritmos de descubrimiento de subgrupos para Balance..	106
Tabla 2.33. Comparación de algoritmos de descubrimiento de subgrupos para Car.....	107
Tabla 2.34. Comparación de algoritmos de descubrimiento de subgrupos para Glass.....	108
Tabla 2.35. Comparación de algoritmos de descubrimiento de subgrupos para Wine.....	109
Tabla 2.36. Distribución de clases en el dataset .....	112
Tabla 2.37. Resultados para eficiencia Baja, Media y Alta .....	113
Tabla 2.38. Reglas para eficiencia Baja .....	114

Tabla 2.39. Reglas para eficiencia Media .....	114
Tabla 2.40. Reglas para eficiencia Alta .....	115
Tabla 2.41. Atributos utilizados para cada alumno .....	117
Tabla 2.42. Atributos utilizados para cada alumno .....	118
Tabla 2.43. Tabla resumen de datos en formato KEEL .....	119
Tabla 2.44. Resultados obtenidos por los distintos algoritmos sobre el conjunto de datos de e-learning .....	120
Tabla 3.1. Comparación de algoritmos de descubrimiento de subgrupos para Australian. ....	133
Tabla 3.2. Comparación de algoritmos de descubrimiento de subgrupos para Breast-w ...	134
Tabla 3.3. Comparación de algoritmos de descubrimiento de subgrupos para Bridges .....	135
Tabla 3.4. Comparación de algoritmos de descubrimiento de subgrupos para Diabetes ...	136
Tabla 3.5. Comparación de algoritmos de descubrimiento de subgrupos para Echo .....	137
Tabla 3.6. Comparación de algoritmos de descubrimiento de subgrupos para German ....	138
Tabla 3.7. Comparación de algoritmos de descubrimiento de subgrupos para Heart .....	139
Tabla 3.8. Comparación de algoritmos de descubrimiento de subgrupos para Hepatitis ...	140
Tabla 3.9. Comparación de algoritmos de descubrimiento de subgrupos para Hypothyroid .....	141
Tabla 3.10. Comparación de algoritmos de descubrimiento de subgrupos para Ionosphere .....	142
Tabla 3.11. Comparación de algoritmos de descubrimiento de subgrupos para Iris .....	143
Tabla 3.12. Comparación de algoritmos de descubrimiento de subgrupos para Tic-Tac- Toe .....	144
Tabla 3.13. Comparación de algoritmos de descubrimiento de subgrupos para Vote .....	145
Tabla 3.14. Comparación de algoritmos de descubrimiento de subgrupos para Balance ..	146
Tabla 3.15. Comparación de algoritmos de descubrimiento de subgrupos para Car .....	147
Tabla 3.16. Comparación de algoritmos de descubrimiento de subgrupos para Glass .....	148
Tabla 3.17. Comparación de algoritmos de descubrimiento de subgrupos para Wine .....	149
Tabla 3.18. Resultados para eficacia Baja. ....	151
Tabla 3.19. Resultados para eficacia Media .....	151
Tabla 3.20. Resultados para eficacia Alta .....	152
Tabla 3.21. Resultados para Baja, Media y Alta eficiencia .....	154
Tabla 3.22. Reglas para eficiencia Baja .....	155
Tabla 3.23. Reglas para eficiencia Media .....	155
Tabla 3.24. Reglas para eficiencia Alta .....	155
Tabla 3.25. Resultados de los algoritmos .....	158
Tabla A.1 Propiedades de los dataset del repositorio UCI utilizados en las experimentaciones .....	171
Tabla A.2 Resumen de la experimentación de SDIGA para Australian con reglas no DNF .....	176
Tabla A.3 Resumen de la experimentación de SDIGA para Australian con reglas DNF ..	177
Tabla A.4 Resumen de la experimentación de SDIGA para Breast-w con reglas no DNF .....	178
Tabla A.5 Resumen de la experimentación de SDIGA para Breast-w con reglas DNF ....	179
Tabla A.6 Resumen de la experimentación de SDIGA para Bridges con reglas no DNF..	180
Tabla A.7 Resumen de la experimentación de SDIGA para Bridges con reglas DNF .....	181
Tabla A.8 Resumen de la experimentación de SDIGA para Diabetes con reglas no DNF .....	182
Tabla A.9 Resumen de la experimentación de SDIGA para Diabetes con reglas DNF .....	183
Tabla A.10 Resumen de la experimentación de SDIGA para Echo con reglas no DNF .....	184

Tabla A.11 Resumen de la experimentación de SDIGA para Echo con reglas DNF .....	185
Tabla A.12 Resumen de la experimentación de SDIGA para German con reglas no DNF .....	186
Tabla A.13 Resumen de la experimentación de SDIGA para German con reglas DNF....	187
Tabla A.14 Resumen de la experimentación de SDIGA para Heart con reglas no DNF...	188
Tabla A.15 Resumen de la experimentación de SDIGA para Heart con reglas DNF .....	189
Tabla A.16 Resumen de la experimentación de SDIGA para Hepatitis con reglas no DNF .....	190
Tabla A.17 Resumen de la experimentación de SDIGA para Hepatitis con reglas DNF ..	191
Tabla A.18 Resumen de la experimentación de SDIGA para Hypothyroid con reglas no DNF .....	192
Tabla A.19 Resumen de la experimentación de SDIGA para Hypothyroid con reglas DNF .....	193
Tabla A.20 Resumen de la experimentación de SDIGA para Ionosphere con reglas no DNF .....	194
Tabla A.21 Resumen de la experimentación de SDIGA para Ionosphere con reglas DNF .....	195
Tabla A.22 Resumen de la experimentación de SDIGA para Iris con reglas no DNF .....	196
Tabla A.23 Resumen de la experimentación de SDIGA para Iris con reglas DNF .....	197
Tabla A.24 Resumen de la experimentación de SDIGA para Tic-Tac-Toe con reglas no DNF .....	198
Tabla A.25 Resumen de la experimentación de SDIGA para Tic-Tac-Toe con reglas DNF .....	199
Tabla A.26 Resumen de la experimentación de SDIGA para Vote con reglas no DNF....	200
Tabla A.27 Resumen de la experimentación de SDIGA para Vote con reglas DNF.....	201
Tabla A.28 Resumen de la experimentación de SDIGA para Balance con reglas no DNF .....	202
Tabla A.29 Resumen de la experimentación de SDIGA para Balance con reglas DNF....	203
Tabla A.30 Resumen de la experimentación de SDIGA para Car con reglas no DNF.....	204
Tabla A.31 Resumen de la experimentación de SDIGA para Car con reglas DNF.....	205
Tabla A.32 Resumen de la experimentación de SDIGA para Glass con reglas no DNF...	206
Tabla A.33 Resumen de la experimentación de SDIGA para Glass con reglas DNF .....	207
Tabla A.34 Resumen de la experimentación de SDIGA para Wine con reglas no DNF...	208
Tabla A.35 Resumen de la experimentación de SDIGA para Wine con reglas DNF.....	209
Tabla A.36 Resumen de la experimentación del algoritmo MESIF sobre el dataset Australian con reglas de ambos tipos.....	211
Tabla A.37 Resumen de la experimentación de MESDIF para Breast-w con reglas de ambos tipos. ....	212
Tabla A.38 Resumen de la experimentación de MESDIF para Bridges con reglas de ambos tipos. ....	213
Tabla A.39 Resumen de la experimentación de MESDIF para Diabetes con reglas de ambos tipos. ....	214
Tabla A.40 Resumen de la experimentación de MESDIF para Echo con reglas de ambos tipos. ....	215
Tabla A.41 Resumen de la experimentación de MESDIF para German con reglas de ambos tipos. ....	216
Tabla A.42 Resumen de la experimentación de MESDIF para Heart para reglas de ambos tipos. ....	217

Tabla A.43 Resumen de la experimentación de MESDIF para Hepatitis con reglas de ambos tipos.....	218
Tabla A.44 Resumen de la experimentación de MESDIF para Hypothyroid con reglas de ambos tipos.....	219
Tabla A.45 Resumen de la experimentación de MESDIF para Ionosphere con reglas de ambos tipos.....	220
Tabla A.46 Resumen de la experimentación de MESDIF para Iris con reglas de ambos tipos.....	221
Tabla A.47 Resumen de la experimentación de MESDIF para Tic-Tac-Toe con reglas de ambos tipos.....	222
Tabla A.48 Resumen de la experimentación de MESDIF para Vote con reglas de ambos tipos.....	223
Tabla A.49 Resumen de la experimentación de MESDIF para Balance con reglas de ambos tipos.....	224
Tabla A.50 Resumen de la experimentación de MESDIF para Car con reglas de ambos tipos.....	225
Tabla A.51 Resumen de la experimentación de MESDIF para Glass con reglas de ambos tipos.....	226
Tabla A.52 Resumen de la experimentación de MESDIF para Wine con reglas de ambos tipos.....	227
Tabla A.53 Descripción de las variables del conjunto de datos de Marketing.....	231

# Introducción

---

## Planteamiento

---

Actualmente se ha incrementado de forma paralela tanto la cantidad de información almacenada como la necesidad de desarrollar algoritmos que permitan extraer conocimiento útil de la misma de forma automática. Estos algoritmos se incluyen dentro del área de extracción de conocimiento en bases de datos (*KDD, Knowledge Discovery in Databases*) [FPS96, KZ02].

El KDD se puede abordar, en función del problema a resolver, desde dos perspectivas distintas: desde el punto de vista predictivo, en el que se intenta obtener conocimiento para clasificación o predicción, o desde el punto de vista descriptivo, como un proceso inducción descriptiva cuyo objetivo fundamental es descubrir conocimiento de interés dentro de los datos, intentando obtener información que describa el modelo que existe detrás de los datos. La inducción descriptiva se realiza bajo enfoques como la extracción de reglas de asociación [AMS+96], el descubrimiento de cláusulas [RD97], el descubrimiento de dependencias en bases de datos [FS99] o el descubrimiento de subgrupos [Klo96, Wro97], entre otros.

El objetivo de las reglas de asociación es identificar relaciones no explícitas entre variables del conjunto de datos atributos, y se suelen expresar mediante reglas del tipo “si el atributo X toma el valor  $a$ , entonces el atributo Y toma el valor  $b$ ”. El descubrimiento de dependencias funcionales es una tarea similar al descubrimiento de reglas de asociación, en la que se pretende extraer información que indique cómo obtener el valor de un atributo en función del valor de otros atributos del conjunto de datos.

El descubrimiento de subgrupos (*SD, Subgroup Discovery*) es un tipo de inducción descriptiva que ha recibido recientemente mucha atención por parte de los investigadores. El concepto fue formulado inicialmente por Klösgen en su algoritmo de aprendizaje EXPLORA [Klo96] y por Wrobel en el algoritmo MIDOS [Wro97], modelos en los que se utiliza un método de extracción de reglas basado en árboles de decisión, para obtener los mejores subgrupos de entre la población. MIDOS amplía el enfoque de EXPLORA al problema de descubrimiento en bases de datos multi-relacionales.

La idea del descubrimiento de subgrupos se basa en, dado un conjunto de datos y una propiedad de esos datos en la que esté interesado el usuario, buscar subgrupos que sean interesantes para el usuario en el sentido de que tengan una distribución estadística inusual respecto a la propiedad resaltada por el usuario.

A diferencia de la mayoría de las tareas de minería de datos, el objetivo del descubrimiento de subgrupos no es ni puramente predictivo (utilizar los resultados de la minería para predecir o clasificar casos futuros) ni exclusivamente descriptivo (utilizar los resultados de la minería de datos para describir un dominio o, más específicamente, la estructura de dependencia dominante entre las variables del dominio, de forma que sea interpretable por los usuarios finales). El objetivo del descubrimiento de subgrupos es descubrir propiedades características de subgrupos construyendo reglas individuales sencillas (con una estructura comprensible y en las que intervengan pocas variables), altamente significativas y con una alta completitud (que cubran muchas instancias de la clase objetivo).

En un algoritmo de descubrimiento de subgrupos se extraen reglas o patrones de interés que representen el conocimiento de forma simbólica y que sean lo suficientemente sencillos y descriptivos como para ser reconocibles y utilizados por el usuario final. El uso de la lógica difusa [Zad65, Zad75] para el tratamiento de variables continuas ayuda a expresar el conocimiento extraído de forma fácilmente interpretable por el experto, además de hacer posible el tratamiento de información con incertidumbre, muy común en problemas reales, y de permitir el procesamiento eficaz de la información experta disponible.

Los algoritmos evolutivos [BFM97], y en particular los algoritmos genéticos (AGs) [Gol89, Hol75] tienen un carácter de búsqueda global que hace que sean especialmente adecuados para resolver distintos problemas presentes en cualquier proceso de descubrimiento de conocimiento [Fre02]. En procesos de extracción de reglas, los AGs tratan de forma adecuada las interacciones entre atributos porque evalúan una regla como un todo mediante la función de adaptación, en lugar de evaluar el impacto de añadir o eliminar una condición de una regla, como ocurre en los procesos de búsqueda local incluidos en la mayoría de los algoritmos de inducción de reglas y árboles de decisión.

Los AGs se han utilizado mucho en procesos de inducción predictiva [DSG93, GN95, Jan93b], y en inducción descriptiva, fundamentalmente en reglas de asociación [CHT06, LHL05].

Sin embargo, hasta donde sabemos, no se han aplicado algoritmos evolutivos ni lógica difusa para la tarea de descubrimiento de subgrupos. Por este motivo, en esta memoria se abordará el diseño de algoritmos de extracción de reglas de descubrimiento de subgrupos. Para ello se utilizarán las dos herramientas mencionadas, la lógica difusa para la representación del conocimiento y razonamiento muy cercana a los esquemas humanos, y los AGs como técnica de búsqueda, en lo que se denominan modelos evolutivos de extracción de reglas difusas [CHHM01, INH04] que aúnan las ventajas de ambas herramientas.

## Objetivos

---

Los modelos desarrollados hasta ahora para realizar la tarea de inducción descriptiva de extracción de reglas de descripción de subgrupos son modificaciones de algoritmos clásicos de clasificación o de extracción de reglas de asociación para esta tarea. El objetivo de esta memoria es estudiar el problema de la extracción de reglas de descripción de subgrupos y desarrollar nuevos modelos basados en la computación flexible, concretamente modelos evolutivos de extracción de reglas difusas.

Para desarrollar este objetivo general, definimos los siguientes objetivos particulares:

- Realizar una revisión de los distintos modelos existentes de descubrimiento de subgrupos. Como el objetivo es diseñar nuevos modelos evolutivos de extracción de reglas difusas para descubrimiento de subgrupos, el estudio de los sistemas actuales servirá para determinar las características de la tarea de descubrimiento de subgrupos, sus componentes fundamentales y sus objetivos.
- Analizar los problemas a resolver en el diseño de algoritmos de extracción de reglas de descripción de subgrupos. Uno de los aspectos más relevantes son las medidas de calidad consideradas durante el proceso de extracción de reglas y en la evaluación final de las reglas obtenidas. En esta memoria se realizará un estudio sobre este problema.
- Desarrollar un modelo evolutivo de extracción de reglas difusas para el descubrimiento de reglas de descripción de subgrupos. Este modelo permitirá la extracción de dos tipos de reglas: reglas canónicas en las que el antecedente está formado por una conjunción de parejas atributo/valor, y reglas en forma normal disyuntiva (*DNF, Disjunctive Normal Form*) en las que cada atributo que interviene en la regla puede tomar más de un valor.
- Analizar los componentes del modelo desarrollado, para obtener un sistema eficiente para la tarea de descubrimiento de subgrupos. Para esto será aplicado el modelo a diversos conjuntos de datos sintéticos de prueba con distintas combinaciones de componentes y se analizarán los resultados obtenidos por cada uno de ellos.
- Diseñar y desarrollar un modelo evolutivo multiobjetivo. Este modelo servirá para resolver los inconvenientes del modelo mono-objetivo debidos a la agregación de los distintos objetivos en uno solo. Para el desarrollo del nuevo modelo, se estudiarán previamente las propuestas existentes de algoritmos evolutivos multiobjetivo.
- Aplicar los modelos desarrollados a problemas reales para comprobar la aplicabilidad de las propuestas y obtener conclusiones respecto a los resultados obtenidos.

## Resumen

---

Para abordar estos objetivos, esta memoria está dividida en cuatro capítulos cuyo contenido se describe brevemente a continuación.

En el Capítulo 1 se introduce el concepto de minería de datos y se describe en profundidad la tarea de inducción descriptiva de descubrimiento de subgrupos, incluyendo los distintos modelos existentes y las medidas de calidad utilizadas. Posteriormente, se describe la computación flexible centrándonos, dentro de las distintas técnicas que la componen, en la descripción de los algoritmos evolutivos y la lógica difusa. Finalmente, se propone el desarrollo de nuevos modelos para el desarrollo de la tarea de descubrimiento de subgrupos utilizando computación flexible.

En el Capítulo 2 presentamos una propuesta de algoritmo genético para la extracción de reglas difusas de descripción de subgrupos, que puede extraer conocimiento utilizando dos tipos de reglas, canónicas y DNF. La propuesta se ha desarrollado utilizando distintas medidas de calidad, y se ha realizado un análisis de componentes para determinar las mejores alternativas, aplicando la propuesta con distintas medidas de calidad sobre distintos conjuntos de datos sintéticos. Se han comparado además los resultados de nuestra propuesta con los obtenidos por otros algoritmos de descubrimiento de subgrupos. Finalmente hemos aplicado las propuestas sobre dos problemas reales, el primero de los cuales es un problema de *marketing* y el segundo relativo a datos de *e-learning*.

En el capítulo 3 presentamos el concepto de problema de optimización multiobjetivo, y los distintos modelos que se han aplicado para su resolución. Describimos distintos enfoques de algoritmos evolutivos multiobjetivo, y presentamos un modelo de algoritmo evolutivo multiobjetivo para la extracción de reglas difusas de descripción de subgrupos. A continuación se aplica este modelo a diferentes problemas sintéticos y reales, y comparamos el modelo propuesto con el modelo mono-objetivo, describiendo las ventajas que aporta.

En el Capítulo 4 resumimos el trabajo realizado y los resultados obtenidos en esta memoria, presentamos algunas conclusiones sobre los mismos, y planteamos trabajos futuros derivados de la misma.

Por último, los Apéndices incluyen la descripción de los conjuntos de datos sintéticos empleados, tablas adicionales de resultados, la descripción de los algoritmos empleados para las comparaciones con nuestras propuestas, y la descripción de los problemas reales a los que se han aplicado las propuestas.

# Capítulo 1

## Computación flexible y descubrimiento de subgrupos

---

Uno de los problemas con que nos enfrentamos en el mundo actual es el de trabajar con la creciente cantidad de información digital que se recoge y acumula, y que hace necesaria la utilización de métodos automáticos para su tratamiento. El enfoque clásico para convertir los datos en conocimiento consiste en su análisis e interpretación de forma manual: en cualquier campo, el análisis de los datos se confía a uno o más analistas que llegan a familiarizarse profundamente con los datos y sirven de interfaz entre los datos, los usuarios y los productos. Para estas, y muchas otras aplicaciones, esta forma de sondear los conjuntos de datos es lenta, cara, y altamente subjetiva. De hecho, como los volúmenes de datos no dejan de crecer, este tipo de análisis manual de los datos se está haciendo impracticable en muchos dominios. Esto implica que es necesario automatizar, al menos parcialmente, el trabajo de análisis mediante la utilización de herramientas de extracción de conocimiento [HRF04].

El descubrimiento de conocimiento en bases de datos (*KDD, Knowledge Discovery in Databases*) [FPS96, KZ02] está formado por un conjunto de métodos y herramientas cuyo objetivo es asistir a los usuarios en la extracción eficiente de información útil. Por lo tanto, KDD aborda un problema que la era de información digital ha convertido en un hecho en nuestras vidas: la sobrecarga de datos.

En función del problema que queramos resolver, la extracción de conocimiento se puede abordar desde dos perspectivas distintas: desde el punto de vista predictivo, en el que se intenta obtener conocimiento para clasificación o predicción, o desde el punto de vista descriptivo, donde se intenta descubrir conocimiento de interés dentro de los datos, intentando obtener información que describa el modelo que hay tras los datos. En esta memoria, nos centraremos en los procesos de inducción descriptiva.

El descubrimiento de subgrupos (*SD, Subgroup Discovery*) es un tipo de inducción descriptiva que ha recibido recientemente mucha atención por parte de los investigadores. El concepto, formulado inicialmente por Klösgen [Klo96] y Wrobel [Wro97], se basa en el descubrimiento de propiedades características de subgrupos cuyo comportamiento se desvía respecto al del conjunto de los datos. Así, los resultados obtenidos por una tarea de minería de subgrupos pueden aportar información como:

- El índice de desempleo es mayor en varones jóvenes con bajo nivel de estudios que en la media de la población.
- El índice de mortalidad del cáncer de pulmón ha aumentado considerablemente para las mujeres durante los últimos 10 años.

En un algoritmo de descubrimiento de subgrupos se extraen reglas o patrones de interés que representen el conocimiento de forma simbólica y que sean lo suficientemente sencillos y descriptivos como para ser reconocibles y utilizados por el usuario final. La computación flexible (*SC, Soft Computing*) agrupa a un conjunto de técnicas de minería de datos, como los algoritmos evolutivos o la lógica difusa, cuya característica principal es la tolerancia a imprecisión e incertidumbre, lo que ayuda a expresar el conocimiento extraído de forma fácilmente interpretable por el experto.

En este capítulo presentaremos los conceptos necesarios para el desarrollo del resto de capítulos de esta memoria. Así, comenzaremos con un breve repaso del concepto de minería de datos dentro del proceso de descubrimiento de conocimiento en bases de datos. A continuación nos centraremos en el descubrimiento de subgrupos, tarea de inducción descriptiva dentro de la minería de datos. Por último, abordaremos el concepto de computación flexible, y nos centraremos en dos de sus técnicas más destacadas, los algoritmos evolutivos, y la lógica difusa, herramientas básicas en nuestras propuestas para la extracción de reglas difusas de descripción de subgrupos.

## 1.1 Minería de Datos

---

A nivel abstracto, la extracción de conocimiento en bases de datos (o KDD) es el área de la computación que incide en el descubrimiento de patrones útiles entre los datos para ayudar en la extracción de información oculta. Históricamente, la búsqueda de patrones interesantes en los datos ha recibido distintos nombres, incluyendo minería de datos, extracción de conocimiento, descubrimiento información, arqueología de datos, o procesamiento de patrones de datos. La frase *knowledge discovery in databases* fue acuñada en el primer congreso de KDD en 1989 [Pia91] para resaltar que el conocimiento es el producto final del descubrimiento dirigido a los datos. Se ha popularizado en los campos de la inteligencia artificial y el aprendizaje automático. El término *minería de datos* (del inglés *Data Mining*) se ha usado fundamentalmente en los campos de la estadística, el análisis de datos, los sistemas de gestión de información o las bases de datos.

Aunque algunos autores utilizan KDD y minería de datos como sinónimos, actualmente se prefiere utilizar *KDD* para referirse al proceso completo de descubrimiento de conocimiento útil a partir de los datos, y *minería de datos* para referirse al paso particular de este proceso que consiste en la aplicación de algoritmos específicos para la

extracción de patrones a partir de los datos. En las siguientes Subsecciones se detallan los conceptos de KDD y minería de datos.

### 1.1.1 Descubrimiento de conocimiento en bases de datos

Se puede definir KDD como el *proceso no trivial de extracción de patrones válidos, novedosos, potencialmente útiles, y comprensibles en los datos* [FPS96].

En esta definición, los *datos* son un conjunto de hechos (como los casos de la base de datos), y un *patrón* es una expresión que describe un subconjunto de los datos o un modelo aplicable a este subconjunto. El término *proceso* implica que la extracción de conocimiento incluye distintos pasos, como la preparación de los datos, la búsqueda de patrones, la evaluación del conocimiento, y el refinamiento, todo ello repetido en múltiples iteraciones. *No trivial* implica que es necesaria cierta búsqueda o inferencia; es decir, no es un cálculo directo como puede ser calcular la media de un conjunto de números. Los patrones descubiertos deberían ser *válidos* en nuevos datos con un grado de certidumbre dado. Además, los patrones deben ser *novedosos* (al menos para el sistema y preferiblemente para el usuario) y potencialmente *útiles*, es decir, que supongan algún beneficio y cumplan las metas del usuario. Finalmente, los patrones deberían ser *comprensibles*, si no inmediatamente, si después de llevar a cabo algún tipo de post-procesamiento.

Lo anterior implica que podemos definir medidas cuantitativas para evaluar los patrones extraídos. En muchos casos, es posible definir medidas de certidumbre (como la predicción predictiva estimada sobre nuevos datos) o utilidad (como la ganancia, por ejemplo en dinero que se ha ahorrado, debido a las mejores predicciones o al menor tiempo de respuesta del sistema). Ciertos conceptos como novedad y comprensibilidad son subjetivos y por tanto son difíciles de plasmar en una medida cuantitativa. En ciertos contextos, la comprensibilidad se puede estimar mediante la simplicidad (por ejemplo el número de bits necesarios para describir un patrón). También suele utilizarse el *interés*, definido como una medida general del valor de patrón que combina validez, novedad, utilidad, y simplicidad [ST95]. Las funciones de interés se pueden definir de forma explícita o manifestarse implícitamente mediante una ordenación llevada a cabo por el sistema de KDD sobre los patrones o modelos descubiertos. Así, se puede considerar que un *patrón* es conocimiento si supera cierto umbral de interés, definido por el usuario y específico del dominio.

El KDD es un proceso de extracción de conocimiento que consta de un conjunto de etapas: en primer lugar, supone la utilización de bases de datos junto con algún tipo de selección, preprocesado y transformaciones de esta información; a continuación la aplicación de métodos de minería de datos para la extracción de los patrones; y por último la evaluación y posible interpretación de los resultados de la minería de datos para identificar el conocimiento obtenido a través del subconjunto de patrones identificados. El

proceso completo, mostrado en la Figura 1.1, es interactivo e iterativo, en el que el experto deberá tomar decisiones en distintas fases.

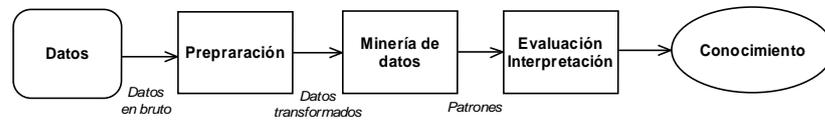


Figura 1.1. El proceso de KDD.

De forma general, el proceso involucra los siguientes pasos [FPS96b]:

- *Comprensión del dominio de la aplicación.* En esta fase se identifica el conocimiento previo relevante que debe utilizarse, junto con las metas y los requerimientos del proceso de extracción de conocimiento.
- *Preparación de los datos.* En esta fase se analizan y documentan los datos disponibles y las fuentes de conocimiento del dominio de la aplicación, para estudiar las características de los datos. Además, se aplicará preprocesamiento para mejorar la calidad de los datos disponibles para el proceso de minería, incrementando la eficiencia al reducir el tiempo de cálculo necesario. Involucra cuestiones como:
  - Limpieza de datos: consta de ciertas operaciones básicas, como la normalización, manejo de ruido y de valores incompletos o perdidos, reducción de la redundancia, etc. Los datos de fuentes del mundo real suelen contener errores, ser incompletos e inconsistentes, y este tipo de datos de baja calidad deben ser limpiados antes de la etapa de minería de datos.
  - Integración de datos: la integración juega un importante papel en KDD. Esta operación incluye la integración de conjuntos de datos múltiples y heterogéneos generados a partir de diferentes fuentes.
  - Reducción y proyección de datos: esto incluye la búsqueda de características útiles de los datos según sea el objetivo final, de forma que se puedan evaluar y desarrollar las hipótesis y modelos iniciales. También incluye la reducción del número de variables y la proyección de los datos sobre espacios de búsqueda en los que sea más fácil encontrar una solución. Esta cuestión es crítica dentro del proceso global que, con frecuencia, marca la diferencia entre el éxito o fracaso de la minería de datos.
- *Minería de Datos.* En este paso se seleccionan y aplican a los datos algoritmos de descubrimiento para encontrar patrones de interés. En primer lugar será necesario elegir el tipo de algoritmo de minería de datos a aplicar en función del objetivo del proceso de KDD (clasificación, regresión, segmentación, detección de

desviaciones, etc.), y la forma de representación del conocimiento (árboles de decisión, reglas, etc.). Es necesario también especificar un criterio de evaluación que permita definir qué modelo es mejor y la estrategia de búsqueda a utilizar (que normalmente viene impuesta por el algoritmo de minería).

- *Interpretación.* Supone interpretar y evaluar los resultados del proceso de minería de datos en términos del dominio de la aplicación, y realizar nuevos experimentos (regresando posiblemente a alguno de los pasos anteriores) si es necesario. Esto puede involucrar repetir el proceso, quizás con otros datos, otros algoritmos, otras metas y otras estrategias. Este es un paso crucial para el que se requiere conocimiento del dominio. La interpretación puede beneficiarse de procesos de visualización, y sirve también para eliminar patrones redundantes o irrelevantes. En este proceso también se comprobará (y se resolverá en su caso) la existencia de conflictos potenciales con las creencias previas o el conocimiento previamente extraído.
- *Utilización del conocimiento descubierto.* Este paso incluye la incorporación del conocimiento extraído al sistema, y llevar a cabo acciones basadas en el mismo.

El proceso de KDD puede suponer varias iteraciones y puede contener bucles entre cualesquiera dos pasos. La mayor parte del trabajo previo en extracción de conocimiento se centra en el paso de minería de datos. Sin embargo, el resto de etapas de igual importancia para la aplicación con éxito del KDD en la práctica.

### 1.1.2 Minería de datos

Una vez definidas las nociones básicas e introducido el proceso de KDD, nos centramos en el componente de minería de datos, sobre el que se ha enfocado una gran parte del trabajo en esta área. La minería de datos es la etapa de descubrimiento dentro del proceso de KDD, y consiste en el *uso de algoritmos concretos que generan una enumeración de patrones a partir de los datos preprocesados* [FPS96].

Así, la minería de datos se centra en la aplicación de análisis sobre los datos, y en el desarrollo a aplicación de algoritmos que, bajo limitaciones aceptables de eficiencia computacional, obtengan patrones (o modelos) sobre los datos. Hay que resaltar que el espacio de patrones suele ser infinito, y que la enumeración de patrones supone realizar algún tipo de búsqueda en este espacio. Las limitaciones computacionales prácticas establecen límites estrictos sobre el subespacio que puede ser explorado por un algoritmo de minería de datos.

El nombre de minería de datos se deriva de las similitudes entre buscar información valiosa en grandes bases de datos y minar una montaña para encontrar una veta de metales

valiosos. Ambos procesos requieren examinar una gran cantidad de material, o investigar de forma inteligente hasta encontrar exactamente dónde residen los valores de interés.

El primer paso dentro del proceso de minería de datos es decidir qué técnica se va a aplicar para efectuar la búsqueda de información. El siguiente paso consiste en estudiar la calidad y validez de esa técnica aplicada al problema. Tras asegurarnos que es la adecuada, procedemos a aplicarla y evaluar sus parámetros para ajustarlos. A continuación, obtendremos diversas soluciones del problema que serían analizadas antes de avanzar a la siguiente etapa. La evaluación se lleva a cabo en este momento para realimentar el conocimiento sobre la técnica aplicada, con la idea de refinar los ajustes o corregir errores, todo ello antes de avanzar a la siguiente fase dentro del proceso de KDD.

A continuación se detallan los objetivos que se pueden perseguir con el proceso de minería de datos y los tipos de algoritmos de minería de datos que podemos utilizar en función de este objetivo. Se describen por último los componentes algorítmicos fundamentales de los métodos de minería de datos.

#### **1.1.2.1 Tipos de algoritmos de minería de datos en función del objetivo**

Los objetivos de la minería de datos se definen por el uso que se pretende del sistema. Podemos distinguir dos tipos de objetivos: la *verificación* y el *descubrimiento*. En la verificación, el sistema se limita a verificar las hipótesis del usuario. En el descubrimiento, el sistema encuentra nuevos patrones de forma autónoma. El descubrimiento se puede descomponer además en:

- *predicción*, donde el sistema encuentra patrones para predecir el comportamiento futuro (utiliza un conjunto de variables de la base de datos para predecir valores futuros desconocidos de otras variables de interés); y
- *descripción*, donde sistema encuentra patrones para presentarlos a un experto en una forma comprensible para él, y que describen y aportan información de interés sobre el problema y el modelo que subyace bajo los datos.

A pesar de los muchos métodos de minería de datos que se encuentran en la bibliografía, hay que resaltar que realmente sólo existen unas pocas técnicas fundamentales. El modelo de representación utilizado en un método concreto suele ser una composición de un pequeño número de opciones bien conocidas; es decir, que muchos de los métodos se pueden ver como extensiones o híbridos de técnicas y principios básicos. De esta forma, unos algoritmos difieren de otros fundamentalmente en el criterio de calidad o el método de búsqueda utilizados para evaluar el ajuste del modelo.

Como se ha mencionado, los dos objetivos fundamentales de alto nivel en minería de datos de descubrimiento de conocimiento son predicción y descripción. A continuación se detallan los distintos tipos de tareas que se pueden realizar para ambos tipos de modelos:

- Tareas que utilizan modelos *predictivos*:
  - *Clasificación*. Los datos son objetos caracterizados por atributos que pertenecen a diferentes clases definidas. La meta es inducir un modelo para poder predecir la clase a que pertenece un objeto de datos dados los valores de los atributos [Han81, WK91]. Destaca el aprendizaje supervisado mediante reglas de clasificación [CN89, Coh95, MMHL96]. Estos algoritmos confían en la supervisión humana para entrenarse en la clasificación de datos en clases predefinidas de valores categóricos (nominales).
  - *Regresión*. En esta tarea, la variable sobre la que se quiere hacer la predicción es continua. La meta es inducir un modelo para poder predecir el valor de la clase dados los valores de los atributos [BFOS84, McL92]. La regresión asume que los valores de la variable objetivo cuadran con algún tipo de función conocida (lineal, logística, etc.) y entonces determina la mejor función de este tipo que modela a los datos disponibles.
  - *Análisis de series temporales*. En el análisis de series temporales [BD96], se examina el valor de un atributo según va cambiando con el tiempo. Los valores se suelen obtener como instantes de tiempo distribuidos de forma homogénea.
- Tareas que utilizan modelos *descriptivos*:
  - *Agrupamiento (clustering)*. Consiste en la separación de los datos en subgrupos o clases interesantes; se busca por tanto identificar un conjunto finito de categorías o *clusters* que describan los datos [JD88, TSM85]. Las clases pueden ser exhaustivas y mutuamente excluyentes o jerárquicas y con solapamientos.
  - *Sumarización*. Son métodos para proporcionar al usuario información comprensible para captar la esencia de grandes cantidades de información almacenadas en una base de datos [AMS+96, ZZ96]. Las técnicas de sumarización suelen aplicarse al análisis de datos interactivos y a la generación automatizada de informes.
  - *Asociación*. Es el descubrimiento de relaciones de asociación o correlaciones entre un conjunto de elementos [AIS93]. Suelen expresarse en forma de reglas mostrando parejas atributo-valor que ocurren frecuentemente juntas en un conjunto de datos dado. En estos casos, se utiliza un modelo no supervisado de aprendizaje [AMS+96] cuyo objetivo es encontrar reglas individuales que definan patrones interesantes en los datos.
  - *Descubrimiento de subgrupos*. En este dominio se lleva a cabo la búsqueda de subgrupos en el conjunto de datos que sean estadísticamente más interesantes, siendo tan grandes como sea posible y ofreciendo el mayor valor de atipicidad

estadística con respecto a la propiedad en que estemos interesados [Klo96, Wro97].

- *Detección de desviaciones, casos extremos y anomalías.* Consiste en detectar los cambios más significativos en los datos con respecto a valores pasados o normales [BC96, BN93, Klo96]. Sirve para filtrar grandes volúmenes de datos que son menos probables de ser interesantes. El problema está en determinar cuándo una desviación es significativa para ser de interés [GMV96, MP96].
- *Descubrimiento de secuencias.* El análisis o descubrimiento de secuencias [AS95, LL04] se utiliza para determinar patrones secuenciales en los datos. Estos patrones se basan en una secuencia temporal de acciones. Estos patrones son similares a asociaciones en las que se encuentran relaciones entre datos, pero en las que la relación está basada en el tiempo.

En esta memoria, nos centraremos en modelos de descriptivos para la tarea de descubrimiento de subgrupos.

### 1.1.2.2 Componentes de los algoritmos de minería de datos

Una vez definido el objetivo de la minería de datos, para construir algoritmos específicos que implementen los métodos generales que se ha enumerado debemos definir los tres componentes fundamentales en cualquier algoritmo de minería de datos: el lenguaje de representación del modelo, el criterio de evaluación del modelo y el método de búsqueda. Esto constituye una visión simplificada (y como tal no es completa) pero bastante útil para expresar los conceptos clave de un algoritmo de minería de datos de forma relativamente unificada y compacta.

- *Lenguaje de representación del modelo.* Es el lenguaje que se utiliza para describir los patrones que se descubren. Es muy importante conocer las restricciones y suposiciones que impone la representación empleada. Si la representación es demasiado limitada, no podremos producir un modelo adecuado de los datos aunque dediquemos mucho tiempo al entrenamiento. Es importante que el analista comprenda las suposiciones sobre la representación que pueden ser inherentes a un método particular, y que el diseñador del algoritmo establezca claramente qué representación está utilizando en el algoritmo. Hay que resaltar que un gran poder de representación para los modelos incrementa el peligro de sobreajustar los datos de entrenamiento, pudiendo obtener una precisión predictiva reducida sobre nuevos datos, lo que supone un inconveniente para los algoritmos de inducción predictiva.
- *Criterio de evaluación del modelo.* Se define en forma de función que permite establecer hasta qué punto se ajusta bien un patrón particular (un modelo y sus parámetros) a los objetivos del proceso de KDD. Por ejemplo, los modelos

predictivos suelen evaluarse por la precisión predictiva empírica sobre un conjunto de prueba, utilizando técnicas de validación cruzada [Mit97]. Los modelos descriptivos se pueden evaluar a partir de la novedad, la utilidad y la comprensibilidad del modelo. Actualmente se están utilizando con frecuencia las curvas ROC (*Receiver Operating Characteristics*) [PF01] para evaluar algoritmos.

- *Método de búsqueda.* Consta de dos componentes: la búsqueda de parámetros y la búsqueda del modelo. Una vez fijados el lenguaje de representación y el criterio de evaluación del modelo, el problema de minería de datos se reduce a una tarea de optimización: encontrar los parámetros y modelos de la familia seleccionada que optimicen el criterio de evaluación. En la búsqueda de parámetros, el algoritmo debe buscar los parámetros que optimicen el criterio de evaluación del modelo, dados los datos y un modelo fijo de representación. La búsqueda de modelos es un bucle sobre el método de búsqueda de parámetros en el que se cambia la representación del modelo para poder considerar una familia de modelos. Algunos de los métodos de búsqueda utilizados son la búsqueda exhaustiva, la vuelta atrás o la búsqueda probabilística.

## 1.2 Descubrimiento de subgrupos

---

El descubrimiento de subgrupos es un tipo de inducción descriptiva que ha recibido últimamente mucha atención por parte de los investigadores. En el descubrimiento de subgrupos se pretenden generar modelos basados en reglas cuya finalidad es descriptiva, empleando una perspectiva predictiva para obtenerlos [LKFT04], por lo que se trata de una tarea que se encuentra realmente entre la inducción predictiva y la descriptiva. Las reglas utilizadas en la tarea de descubrimiento de subgrupos tienen la forma  $Cond \rightarrow Clase$ , donde la propiedad de interés para el descubrimiento de subgrupos es el valor de la *Clase* que aparece en el consecuente de la regla [GL02, LCGF04] y el antecedente (*Cond*) es una conjunción de variables (parejas atributo-valor) seleccionadas entre las variables del conjunto de datos.

A continuación definiremos formalmente la tarea de descubrimiento de subgrupos, detallaremos las medidas de calidad utilizadas para evaluar los subgrupos obtenidos, y haremos un repaso de los distintos enfoques utilizados para llevar a cabo la tarea de descubrimiento de subgrupos.

### 1.2.1 Definición de descubrimiento de subgrupos

El concepto de descubrimiento de subgrupos (*SD*, *Subgroup Discovery*) fue formulado inicialmente por Klösgen [Klo96] y Wrobel [Wro97], y definido de la siguiente forma:

Dado un conjunto de datos y una propiedad de esos datos que sea de interés para el usuario, buscar subgrupos que sean de “mayor interés” para el usuario. En este sentido, se dice que un subgrupo es interesante cuando tiene una distribución estadística inusual respecto a la propiedad en la que estamos interesados. El objetivo es descubrir propiedades características de subgrupos construyendo reglas individuales sencillas (con una estructura comprensible y con pocas variables), altamente significativas y con completitud alta (que cubran muchas instancias de la clase objetivo).

Las reglas que se utilizan en la tarea de descubrimiento de subgrupos tienen la forma *Cond*  $\rightarrow$  *Clase*, en las que el consecuente está formado por un único valor de la propiedad de interés para el descubrimiento de subgrupos. Como las reglas se inducen a partir de instancias etiquetadas (positivamente si se cumple la propiedad de interés, la clase, y negativamente en caso contrario) el proceso de descubrimiento de subgrupos se centra en encontrar las propiedades de un conjunto de individuos objetivo de la población que satisfacen la propiedad de interés dada. En este sentido, el descubrimiento de subgrupos es una forma de aprendizaje supervisado (inducción predictiva). Sin embargo, en la mayor parte de los aspectos el descubrimiento de subgrupos es una forma de inducción descriptiva puesto que la tarea es encontrar patrones individuales interesantes en los datos. Debido a esta circunstancia, algunas consideraciones estándar que se hacen en los algoritmos de aprendizaje de reglas de clasificación como que “las reglas inducidas deben ser tan precisas como sea posible”, o “las reglas inducidas deben ser tan diferentes como sea posible, cubriendo diferentes partes de la población”, o “tan grandes como sea posible” deben ser relajadas.

Esta idea resalta la diferencia entre el descubrimiento de subgrupos y el aprendizaje de reglas de clasificación. El objetivo del aprendizaje de reglas de clasificación es generar modelos, uno por cada clase, formados por un conjunto de reglas que describen las características de la clase en términos de propiedades que ocurren en las descripciones de los ejemplos de entrenamiento. Por el contrario, como se refleja en la Figura 1.2, el descubrimiento de subgrupos pretende descubrir reglas individuales o patrones de interés, que deben ofrecerse en una representación simbólica adecuada de forma que puedan ser aplicados con efectividad por los posibles usuarios. La interpretabilidad de las reglas es por tanto un factor clave en el descubrimiento de subgrupos. Esta es la razón por la que se considera diferente el descubrimiento de subgrupos de las tareas propias de clasificación. El descubrimiento de subgrupos se centra en encontrar subgrupos de población interesantes en vez de maximizar la precisión del conjunto de reglas inducido.

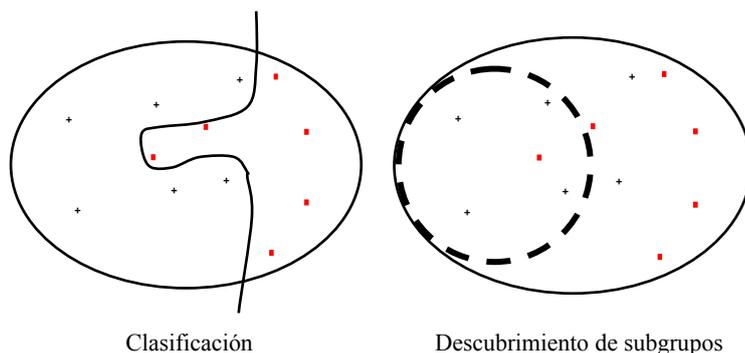


Figura 1.2. Diferencia entre las tareas de clasificación y descubrimiento de subgrupos.

A menudo, los datos son poco concluyentes, bien porque no todas las variables relevantes están disponibles, o porque el lenguaje de descripción es insuficiente, por ejemplo, para describir subgrupos de objetos. Entonces, quizá sea suficiente con identificar algunos elementos parciales de conocimiento (a menudo denominados “*pepitas*” o “*nuggets*”) mediante un método de minería [KZ02]. Esto significa que el sistema de KDD valida como interesantes algunas hipótesis individuales. Estos resultados no son completos, porque no permiten predecir todos los casos nuevos o describir todo el conjunto de datos. Pero podrían servir por ejemplo para identificar algunos subgrupos individuales de pacientes con características especiales que sufren una enfermedad sin derivar un perfil completo de la enfermedad. De esta forma, se pueden obtener resultados parciales con los que expertos en el dominio podrían realizar después análisis más detallados.

Para llevar a cabo una tarea de descubrimiento de subgrupos, es necesario definir cuatro elementos fundamentales [APB04]:

- El tipo de la variable objetivo. La variable objetivo puede ser binaria, nominal o numérica. Dependiendo del tipo de variable objetivo son posibles diferentes cuestiones analíticas. Por ejemplo, para una variable objetivo numérica podemos buscar desviaciones significativas de la media de la variable objetivo.
- El lenguaje de descripción que especifique los individuos de la población de referencia que pertenecen al subgrupo. Se suelen utilizar lenguajes conjuntivos, en el que la descripción de los subgrupos consiste en una conjunción de expresiones. En el caso más sencillo, cada expresión toma un solo valor, pero la negación o disyunciones internas (reglas DNF) son también posibles.
- La función de calidad que mide el interés de los subgrupos. Se han propuesto gran variedad de funciones de calidad [GLK03, Klo02, Klo96]. Las funciones de calidad aplicables en cada caso vienen determinadas por el tipo de variable objetivo y el problema analítico.

- La estrategia de búsqueda. La estrategia de búsqueda es muy importante, puesto que el espacio de búsqueda crece exponencialmente con el número de posibles expresiones que pueden formar parte de una descripción de subgrupo.

Uno de los aspectos más importantes de cualquier enfoque de inducción de reglas que describan subgrupos es la elección de las medidas de calidad a utilizar, tanto para seleccionar las reglas, como para valorar los resultados obtenidos en el proceso (y poder comparar con otros enfoques o algoritmos). La siguiente subsección se centra en este aspecto.

### 1.2.2 Medidas de calidad para descubrimiento de subgrupos

Se puede distinguir entre medidas objetivas de calidad y medidas subjetivas de interés [ST95], y ambas son necesarias para resolver las tareas de descubrimiento de subgrupos. Los criterios de calidad más adecuados dependen de la aplicación. Obviamente, para inducción automática de reglas sólo son aplicables los criterios de calidad objetivos. Sin embargo, para evaluar la calidad de las descripciones de los subgrupos inducidos y su utilidad como ayuda en la toma de decisiones, los criterios subjetivos son más importantes, pero también más difíciles de evaluar.

Algunas de las medidas *subjetivas* de interés que se pueden utilizar en la tarea de descubrimiento de subgrupos son:

- *Utilidad*, que es un aspecto del interés de una regla que la relaciona con los objetivos del usuario [Klo96].
- *Accionabilidad (actionability)*, donde una regla es interesante si aporta al usuario información que le permita llevar a cabo alguna acción que le suponga algún beneficio [PM94, ST95].
- *Operacionalidad*, definida como un caso especial de accionabilidad [LCGF04]. El conocimiento operacional es la forma de conocimiento inducido más valiosa, puesto que permite llevar a cabo alguna acción sobre la población objetivo. Si una regla operacional se ejecuta realmente, puede afectar a la población objetivo y modificar la cobertura de la regla.
- *Sorpresividad (unexpectedness)*. Una regla es interesante si es sorprendente para el usuario [ST95].
- *Novedad*. Una regla es interesante si se aparta del conocimiento previo del usuario [Klo96].
- *Redundancia*. La redundancia tiene en cuenta la similitud de una regla con respecto a otras; mide hasta qué punto una regla se puede derivar de otra [Klo96], o un conjunto de reglas cubren los mismos ejemplos.

Con respecto a las medidas de calidad *objetivas*, podemos distinguir entre medidas de calidad *predictivas* y *descriptivas* (en línea con la distinción entre inducción predictiva y descriptiva). Las medidas descriptivas se utilizan para evaluar la calidad de reglas individuales (patrones individuales). Estas medidas de calidad son las más apropiadas para el descubrimiento de subgrupos, puesto que la tarea de descubrimiento de subgrupos se centra en inducir patrones individuales de interés. Las medidas predictivas puras, si se usan en descubrimiento de subgrupos es para mostrar la precisión del conocimiento extraído.

En los enfoques de extracción de reglas de asociación, se suelen utilizar la completitud y la confianza para valorar la calidad de las reglas de asociación. Para valorar la calidad de las reglas de clasificación se utiliza la precisión predictiva. En descubrimiento de subgrupos el objetivo no es maximizar la precisión del conjunto de reglas inducido, sino encontrar reglas individuales o patrones de interés, que deben ofrecerse en una representación simbólica adecuada de forma que se puedan utilizar con efectividad por potenciales usuarios de esa información. La interpretabilidad de las reglas es por tanto un factor clave en el descubrimiento de subgrupos.

A continuación se proponen distintas medidas objetivas de calidad, tanto descriptivas como predictivas, utilizadas en descubrimiento de subgrupos para evaluar el interés de las reglas individuales.

### 1.2.2.1 Medidas descriptivas

Las medidas descriptivas de interés de las reglas evalúan cada subgrupo individualmente y por lo tanto son apropiadas para la evaluación del éxito del descubrimiento de subgrupos. Estas medidas de evaluación de cada regla individual se pueden complementar con sus variantes que calculan la media sobre el conjunto inducido de descripciones de subgrupos, lo que permite la comparación de diferentes algoritmos de descubrimiento de subgrupos.

- *Cobertura* [LKFT04]: La cobertura mide el porcentaje de ejemplos cubiertos en media por las reglas del conjunto inducido. La cobertura de una única regla se define:

$$Cob(R_i) = Cob(Cond_i \rightarrow Clase) = p(Cond_i) = \frac{n(Cond_i)}{N} \quad (1.1)$$

donde  $n(Cond_i)$  es el número de ejemplos cubiertos por la condición  $Cond_i$ ,  $N$  es el número total de ejemplos y  $R_i$  denota la  $i$ -ésima regla.

La cobertura media para el conjunto de reglas obtenido se calcula:

$$COB = \frac{1}{n_R} \sum_{i=1}^{n_R} Cob(R_i) \quad (1.2)$$

donde  $n_R$  es el número de reglas inducidas.

- *Soporte (o completitud)* [LKFT04]: En descubrimiento de subgrupos es interesante obtener el soporte global como el porcentaje de ejemplos positivos cubiertos por las reglas. Este índice se calcula considerando la tasa de aciertos positivos para la unión de subgrupos. El soporte de una regla se define como la frecuencia de ejemplos positivos cubiertos, de la forma:

$$Sop(R_i) = Sop(Cond_i \rightarrow Clase) = p(Clase.Cond_i) = \frac{n(Clase.Cond_i)}{N} \quad (1.3)$$

donde  $n(Clase.Cond_i)$  es el número de ejemplos cubiertos por  $Cond_i$  pertenecientes a  $Clase$ .

El soporte del conjunto de reglas se calcula:

$$SOP = \frac{1}{N} \sum_{Clase_j} n(Clase_j \cdot \bigvee_{Cond_i \rightarrow Clase_j} Cond_i) \quad (1.4)$$

donde los ejemplos cubiertos por varias reglas son enumerados una sola vez.

- *Complejidad*: Define la complejidad del conjunto de reglas. Una de las formas más comunes de definir la complejidad es utilizar el tamaño del conjunto de reglas, definido como el número de reglas inducidas:

$$TAM = N_R \quad (1.5)$$

Además, la complejidad puede medirse también por el número medio de reglas obtenidas por clase, y la media de variables por regla.

- *Relevancia (o evidencia en la terminología de [Klo96])*: La relevancia media de una regla se calcula en términos de la razón de verosimilitud (*likelihood ratio*) de una regla, normalizada con la razón de verosimilitud del umbral de relevancia (99%); la media se calcula sobre todas las reglas. La razón de verosimilitud mide la diferencia entre la distribución de probabilidad de la clase en el conjunto de ejemplos de entrenamiento cubiertos por la regla y la distribución de probabilidad de la clase en el conjunto de todos los ejemplos de entrenamiento. La relevancia refleja lo destacada que es la conclusión alcanzada por las reglas empleando este criterio estadístico. La relevancia de una regla se calcula:

$$\begin{aligned} Rel(R_i) &= Rel(Cond_i \rightarrow Clase) \\ &= 2 \cdot \sum_j n(Clase_j.Cond_i) \cdot \log \frac{n(Clase_j.Cond_i)}{n(Clase_j) \cdot p(Cond_i)} \end{aligned} \quad (1.6)$$

donde para cada  $Clase_j$ ,  $n(Clase_j.Cond_i)$  es el número de instancias de la clase  $j$  en el conjunto que cumplen el antecedente de la regla,  $n(Clase_j)$  es el número de instancias de la clase  $j$ , y  $p(Cond_i)$  (es decir, la cobertura de la regla calculada como  $n(Cond_i)/N$ ) es utilizada como factor normalizador. Hay que reseñar que

aunque para cada descripción de subgrupo generada se selecciona solo una clase, el criterio de relevancia mide la novedad en la distribución de forma imparcial de cualquier clase, calculándose por tanto la relevancia tan solo de la condición de la regla.

El cálculo de la relevancia media del conjunto de reglas se calcula como:

$$REL = \frac{1}{n_R} \sum_{i=1}^{n_R} rel(R_i) \quad (1.7)$$

- *Atipicidad*: La atipicidad de una regla se define como la precisión relativa ponderada de una regla (WRAcc) [LFZ99], medida a través de:

$$\begin{aligned} Ati(R_i) &= WRAcc(Cond_i \rightarrow Clase) \\ &= \frac{n(Cond_i)}{N} \cdot \left( \frac{n(Clase \cdot Cond_i)}{n(Cond_i)} - \frac{n(Clase)}{N} \right) \end{aligned} \quad (1.8)$$

La precisión relativa ponderada puede describirse como el equilibrio entre la cobertura de una regla y su ganancia en precisión.

El valor de atipicidad medio de un conjunto de reglas se obtiene:

$$ATI = \frac{1}{n_R} \sum_{i=1}^{n_R} Ati(R_i) \quad (1.9)$$

Cuanto mayor sea la atipicidad de una regla, más relevante será.

Esta definición de la atipicidad está derivada de la definición original [Klo96] en la que se define el “espacio p-g”, que intenta alcanzar un compromiso entre el tamaño de un grupo (denominado el factor “g”) y la atipicidad de su distribución (denominado el factor p). Una medida alternativa,

$$q = \frac{TP}{FP + g} \quad (1.10)$$

se define en [GL02], para minimizar el número de falsos positivos, FP, y maximizar los verdaderos positivos, TP, balanceado mediante el parámetro de generalización “g”.

Tanto la atipicidad como la relevancia miden la novedad distribucional de un subgrupo, siendo dos de las medidas más importantes en descubrimiento de subgrupos. Pero, mientras la relevancia solo tiene en cuenta la novedad en la distribución (calculada en términos de ejemplos cubiertos correctamente clasificados por todas las clases), la atipicidad también tiene en cuenta la cobertura. La atipicidad es apropiada para medir sobre subgrupos separados, debido a que es proporcional a la distancia vertical del subgrupo con la diagonal ascendente en el espacio ROC. La relevancia y la atipicidad también se pueden utilizar como heurísticas de búsqueda en la construcción de reglas.

### 1.2.2.2 Medidas predictivas

Las medidas predictivas evalúan un conjunto de reglas, interpretando un conjunto de descripciones de subgrupos como un modelo predictivo. A pesar de que la optimización predictiva no es uno de los objetivos perseguidos de los algoritmos de descubrimiento de subgrupos, estas medidas pueden utilizarse para mostrar la precisión del conocimiento extraído.

- *Precisión predictiva*: Una de las medidas típicas de calidad predictiva, que mide la calidad del conjunto de reglas, es la “precisión predictiva” de un conjunto de reglas, definida como el porcentaje de instancias correctamente clasificadas. Para un problema de clasificación binaria, la precisión se calcula como:

$$PREC = \frac{TP + TN}{TP + TN + FP + FN} \quad (1.11)$$

Hay que resaltar que PREC mide la precisión del conjunto de reglas tanto sobre los ejemplos positivos como los negativos, mientras que la precisión de una regla (definida como  $Prec(Cond \rightarrow Clase) = p(Clase|Cond)$ ) mide la precisión de una única regla sólo sobre los ejemplos positivos.

- *Área bajo la curva ROC*: Para medirlo se utiliza una medida aplicable a conjuntos de reglas, que interpreta el conjunto de reglas como un modelo probabilístico, dados los diferentes umbrales de probabilidad definidos como en la clasificación probabilística de las pruebas de instancias.

La curva ROC (*Receiver Operating Characteristic*) representa un conjunto de clasificadores en los que el área bajo la curva ROC [PF01] (*AUC, Area Under the ROC Curve*) indica la calidad combinada de todos los subgrupos (es decir, la calidad del conjunto completo de reglas). Si se utiliza el análisis ROC para eliminar las reglas que están dentro del área convexa de la curva ROC por ser redundantes, puede ocurrir el problema de descartar sistemáticamente algunas reglas que cubren subconjuntos disjuntos y que tienen casi el mismo rendimiento [Sch05]. Esto no es deseable en inducción descriptiva, puesto que es fácil descartar así la única regla que cubra un subconjunto específico del espacio de búsqueda, ni en inducción predictiva, puesto que la diversidad de los clasificadores es fundamental para alcanzar una alta precisión predictiva. La limitación principal de este enfoque es que sólo es fácilmente aplicable a problemas de dos clases, por lo que se han estudiado varias aproximaciones para calcular el AUC en problemas multiclase [FHS03, HT01].

### 1.2.3 Revisión de los modelos existentes

A lo largo del tiempo, se han desarrollado diferentes modelos para obtener descripciones de subgrupos representados de diferentes formas y utilizando diferentes medidas de calidad. A continuación se detallan los más importantes:

- **EXPLORA** [Klo96]. Fue el primer sistema desarrollado para descubrimiento de subgrupos. Dispone de distintos patrones predefinidos, útiles para diversos dominios, y permite la incorporación de nuevos patrones apropiados para dominios específicos. Utiliza árboles de decisión para la extracción de las reglas o patrones. La especificación de las reglas se lleva a cabo definiendo el esquema de forma descriptiva e implementando un método de verificación estadística. La búsqueda se lleva a cabo mediante espacios de conceptos, construyendo los conceptos como conjuntos de casos con un lenguaje proposicional. El orden de las descripciones de conceptos se utiliza para buscar en el espacio de conceptos. Para medir el interés de las reglas, se utilizan medidas de evidencia, generalidad, redundancia y simplicidad. EXPLORA puede utilizar un enfoque de búsqueda exhaustiva o heurística (si el número de variables es grande, el tamaño del espacio de conceptos se hace demasiado grande como para poder aplicar una búsqueda exhaustiva).
- **MIDOS** [Wro97]. Amplia el enfoque de EXPLORA a bases de datos multirelacionales. Utiliza estimación optimista y poda por soporte mínimo, un operador de refinamiento optimal y muestreo para asegurar la eficiencia. El objetivo de MIDOS es encontrar subgrupos de la relación objeto (definida mediante conjunciones de primer orden) que tengan características de distribución estadística inusuales con respecto a la población completa. Se utiliza una medida de calidad para evaluar los mejores subgrupos que define el interés en función de la atipicidad y del tamaño. De esta forma, se utiliza una función de evaluación de la calidad que consta de dos componentes: el primero requiere que cada hipótesis cubra al menos una cierta fracción de las tuplas de la relación, y el segundo es una adaptación de las funciones de evaluación definidas en EXPLORA.
- **SubgroupMiner** [KM02]. Es una extensión de los sistemas EXPLORA Y MIDOS. Es un sistema avanzado de descubrimiento de subgrupos que ofrece explotación de grandes bases de datos mediante la integración eficiente de bases de datos, hipótesis multi-relacionales, visualización basada en opciones de interacción, y el descubrimiento de estructuras de subgrupos causales. La idea clave de este enfoque es la representación de subgrupos espaciales utilizando un lenguaje de consulta relacional orientado a objetos incluyendo parte del algoritmo de búsqueda en un sistema de base de datos espacial. SubgroupMiner maneja tanto variables objetivo numéricas como categóricas, discretizando las variables numéricas.

Dispone de un mecanismo para eliminar los subgrupos redundantes. SubgroupMiner descubre subgrupos en forma de reglas de decisión utilizando búsqueda interactiva en el espacio de posibles soluciones. La relevancia estadística de un subgrupo se evalúa mediante una función de calidad que depende del tipo de patrón de subgrupo. Como función estándar de calidad, utiliza el test binomial clásico para verificar si la distribución estadística del objetivo es significativamente diferente en el subgrupo estudiado.

- SD [GL02]. Es un algoritmo iterativo de aprendizaje de reglas mediante búsqueda en haz que induce reglas guiado por conocimiento experto: en lugar de definir una medida óptima para la búsqueda y la selección automática de subgrupos, el objetivo es ayudar al experto a llevar a cabo búsquedas flexibles y efectivas sobre un amplio rango de soluciones óptimas; a este proceso lo denomina “minería activa”. Los subgrupos descubiertos se representan en forma de reglas del tipo Condición  $\rightarrow$  Clase. El algoritmo extrae reglas individuales que maximicen el valor de  $q$  en la expresión:

$$q = \frac{TP}{FP + g} \quad (1.12)$$

donde TP son individuos correctamente clasificados, FP los individuos mal clasificados (falsos positivos) y  $g$  es un parámetro de generalización. Se utiliza un algoritmo heurístico de inducción de reglas pertenecientes sólo a la clase objetivo (denominadas reglas de confirmación) para encontrar reglas que cubran muchos de los ejemplos de la clase objetivo y un número pequeño de ejemplos que no pertenecen a esta clase. El número tolerado de ejemplos que no pertenecen a la clase objetivo se determina mediante el parámetro  $g$ ; la modificación de este parámetro es lo que permite a los expertos guiar el proceso de descubrimiento de subgrupos modificando el ratio TP/FP, para obtener reglas más generales (que cubran más ejemplos de la clase objetivo aunque cubran también algunos ejemplos que no pertenecen a la clase objetivo) o más específicas (cubriendo sólo un pequeño número de ejemplos de la clase objetivo, y casi ninguno que no pertenezca a la misma). Este algoritmo se ha aplicado empleado en aplicaciones médicas, como el análisis de datos de isquemia cerebral [GLKK07].

- CN2-SD [LKFT04]. Induce subgrupos en forma de reglas utilizando como medida de calidad la relación entre el ratio de verdaderos positivos y el ratio de falsos positivos. El algoritmo está construido modificando un algoritmo de extracción de reglas de clasificación, el algoritmo CN2 [CN89], relajando algunas de las consideraciones hechas por los algoritmos de aprendizaje de reglas de clasificación (especialmente las que se hacen cuando se utiliza un algoritmo de cobertura) como que “las reglas inducidas deben ser tan precisas como sea posible”, o “las reglas inducidas deben ser tan diferentes como sea posible,

cubriendo diferentes partes de la población”. La primera consideración, implementada en los algoritmos de aprendizaje de reglas de clasificación mediante heurísticas que intentan optimizar la precisión predictiva, se relaja implementando nuevas heurísticas para descubrimiento de subgrupos que intentan encontrar “mejores” subgrupos en términos de cobertura de las reglas y de atipicidad de la distribución. La relajación de la segunda consideración permite el descubrimiento de subgrupos solapados. Las descripciones de subgrupos inducidas pueden ser redundantes, desde un punto de vista de clasificación, pero muy valiosas en términos de su poder descriptivo, descubriendo propiedades genuinas de subpoblaciones desde diferentes puntos de vista.

- RSD [LZF03]. El enfoque *Relational Subgroup Discovery* desarrolla una tarea de descubrimiento de subgrupos levemente modificada, puesto que su objetivo es obtener subgrupos de la población que sean tan grandes como sea posible, que tengan una distribución estadística lo más inusual con respecto a la propiedad de interés, y que sean suficientemente distintos como para cubrir la mayor parte de la población objetivo. Por tanto, se intenta caracterizar subgrupos de la población que solo pertenecen a una clase de la variable objetivo, lo que hace que el aprendizaje de reglas de clasificación puede ser un enfoque apropiado para resolver la tarea, siempre que se adapten al descubrimiento de subgrupos, explotando la información sobre pertenencia a la clase en los ejemplos de entrenamiento. De esta forma, RSD se desarrolla modificando un algoritmo de aprendizaje de reglas de clasificación en términos similares a lo hecho en CN2-SD: sustituyendo el algoritmo de cobertura por un algoritmo de cobertura ponderado y las heurísticas de búsqueda por heurística de precisión relativa ponderada (definida a través de una expresión que tiene en cuenta la generalidad de la regla y la precisión relativa). Este enfoque tiene la ventaja de obtener un compromiso adecuado entre precisión y cobertura. La salida del algoritmo es un conjunto de subgrupos cuya distribución de clases difiere sustancialmente de la del conjunto de datos completo.
- APRIORI-SD [KL06]. Este modelo está desarrollado adaptando un algoritmo de aprendizaje de reglas de asociación al descubrimiento de subgrupos, área sobre la que actualmente se está mostrando un creciente interés. La mayoría de los algoritmos de descubrimiento de subgrupos actuales se han desarrollado como adaptaciones de modelos de extracción de reglas de clasificación para la tarea de descubrimiento de subgrupos. Sin embargo, APRIORI-SD se ha desarrollado a partir del algoritmo APRIORI [AIS93] de aprendizaje de reglas de asociación. Esto se ha conseguido a partir APRIORI-C [JL01], una modificación del algoritmo original para el aprendizaje de reglas de clasificación, mejorado con un nuevo mecanismo de post-procesamiento, una nueva medida de calidad para las reglas inducidas (precisión relativa ponderada) y utilizando clasificación probabilística

de los ejemplos. Para llevar a cabo la modificación, se han seguido las mismas indicaciones que en [LFKT02] para obtener CN2-SD a partir de CN2, como se ha comentado en el apartado anterior. La evaluación del conjunto de reglas obtenidas se lleva a cabo mediante el área bajo la curva ROC, junto con el criterio estándar de evaluación mediante la cobertura y la relevancia (*significance*) de cada regla individual, y el tamaño y la precisión del conjunto de reglas.

- SD-MAP [AP06, APB04]: Es un algoritmo eficiente y exhaustivo para descubrimiento de subgrupos basado en el algoritmo FP-Growth [HPY00] de reglas de asociación. Maneja valores perdidos, pero necesita que las variables estén discretizadas. Este método está implementado en el sistema VIKAMINE (*Visual, Interactive, and Knowledge-intensive Analysis and Mining Environment*), un sistema integrado para descubrimiento de subgrupos que permite incorporar conocimiento del dominio, y utilizar distintas medidas de calidad para evaluar los subgrupos (como ganancia relativa, test binomial, TP/(FP+g), WRACC, test chi-cuadrado o ganancia de información).

La información obtenida de la revisión de los enfoques más importantes de descubrimiento de subgrupos, permite resaltar ciertos aspectos importantes a tener en cuenta a la hora de desarrollar un algoritmo para la tarea de descubrimiento de subgrupos:

- Aparte de los primeros sistemas, MIDOS y EXPLORA, la tendencia actual es modificar algoritmos ya desarrollados de inducción de reglas para utilizarlos en descubrimiento de subgrupos. Se puede hacer partiendo de enfoques de inducción predictiva, como los algoritmos de clasificación, pero actualmente se está mostrando un interés creciente en desarrollarlos a partir de enfoques de inducción descriptiva, como los de aprendizaje de reglas de asociación.
- Los algoritmos de aprendizaje de reglas de clasificación estándar no se pueden aplicar directamente como enfoques de descubrimiento de subgrupos debido a la utilización del algoritmo de cobertura para la construcción del conjunto de reglas, que va eliminando de la base de ejemplos los ejemplos cubiertos por las reglas ya generadas. De esta forma, cuando se utiliza un algoritmo de cobertura, sólo las primeras pocas reglas inducidas por un algoritmo de cobertura pueden ser interesantes como descripciones de subgrupos con suficiente cobertura, y que representen una población suficientemente grande de ejemplos cubiertos. Las siguientes reglas son inducidas por subconjuntos de ejemplos más pequeños y fuertemente sesgados, es decir, subconjuntos incluyendo sólo los ejemplos positivos no cubiertos por las reglas previamente inducidas. Este sesgo impide que un algoritmo de cobertura pueda inducir descripciones que descubran propiedades significativas de subgrupos de la población completa. Una solución a este problema es la utilización de un algoritmo de cobertura ponderado (con pesos), en el que las reglas inducidas posteriormente con alta cobertura permiten el

descubrimiento de propiedades de subgrupos interesantes de la población completa.

- No hay consenso sobre las medidas de calidad a utilizar para la tarea de descubrimiento de subgrupos. Los autores utilizan distintas medidas de calidad para la evaluación y la selección de las reglas.

## 1.3 Computación flexible

---

La computación flexible (*SC, Soft Computing*) agrupa a un conjunto de técnicas de minería de datos, como los algoritmos evolutivos o la lógica difusa, cuya característica principal es la tolerancia a imprecisión e incertidumbre, ayudando a expresar el conocimiento extraído de forma fácilmente interpretable por el experto. En esta sección estudiaremos el concepto de computación flexible, y dos de sus técnicas más importantes, los algoritmos evolutivos y la lógica difusa, que serán las herramientas que utilizaremos en esta memoria para el desarrollo de nuevos algoritmos de descubrimiento de subgrupos.

### 1.3.1 Introducción

El término computación flexible (*Soft Computing*) fue acuñado a mediados de la década de los 90 y agrupa a un conjunto de metodologías cuya característica principal es la tolerancia a imprecisión e incertidumbre, lo que le confiere una capacidad de adaptación que permite solucionar problemas en entornos cambiantes de forma robusta y con bajo coste. La definición propuesta por Zadeh [Zad94] en 1994 establece que:

"Básicamente, la computación flexible no es un cuerpo homogéneo de conceptos y técnicas. Es más bien una mezcla de distintos métodos que de una forma u otra cooperan desde sus fundamentos. En este sentido, el principal objetivo de la computación flexible es aprovechar la tolerancia que conllevan la imprecisión y la incertidumbre, para conseguir manejabilidad, robustez y soluciones de bajo costo. Los principales ingredientes de la computación flexible son lógica difusa, la neuro-computación y el razonamiento probabilístico, incluyendo este último a los algoritmos genéticos, las redes de creencia, los sistemas caóticos y algunas partes de la teoría de aprendizaje. En esa asociación de lógica difusa, neuro-computación y razonamiento probabilístico, la lógica difusa se ocupa principalmente de la imprecisión y el razonamiento aproximado; la neuro-computación del aprendizaje, y el razonamiento probabilístico de la incertidumbre y la propagación de las creencias".

Según la definición de Zadeh, la computación flexible difiere de la computación tradicional en que, al contrario que ésta, es tolerante a la imprecisión, a la incertidumbre y a verdades parciales. De esta forma, la computación flexible constituye “un enfoque emergente de computación, que se equipara a la destacable capacidad de la mente humana de razonar y aprender en un entorno de imprecisión e incertidumbre” [JSM97].

Hasta que Zadeh dio la primera definición de computación flexible, se hacía referencia a los conceptos que maneja de manera aislada. Por tanto, es importante resaltar que la computación flexible no es una simple mezcla de lógica difusa, redes neuronales, computación evolutiva y razonamiento probabilístico. Más bien es una sociedad en la que cada uno de los socios contribuye con una metodología diferente para tratar problemas en sus dominios de aplicación que, de otra forma, serían irresolubles. Desde esta perspectiva, las principales contribuciones de estas técnicas son complementarias y sinérgicas más que competitivas entre ellas, conduciendo a lo que se denominan “sistemas inteligentes híbridos”. El principio que subyace en la computación flexible es la hibridación de técnicas para el desarrollo de métodos computacionales que obtengan una solución aceptable con un coste bajo mediante la búsqueda de una solución aproximada a un problema formulado de forma precisa o imprecisa [TT01].

A continuación se detallan las técnicas más importantes utilizadas en el ámbito de la computación flexible:

- *Lógica difusa*: la lógica difusa trata con conjuntos difusos [Zad65] y conectores lógicos para modelar los problemas de razonamiento del mundo real de la misma forma que lo hacen los seres humanos, modelando la vaguedad y manejando incertidumbre. Un conjunto difuso, a diferencia de los conjuntos convencionales, incluye a todos los elementos del dominio, pero con valores de pertenencia que varían en el intervalo  $[0,1]$ .
- *Redes Neuronales Artificiales*: las redes neuronales [Gol96] son métodos predecibles no-lineales que aprenden a través del entrenamiento y semejan la estructura de una red neuronal biológica [Zur92]. La aplicación más común de una red neuronal artificial es en aprendizaje automático, en el que se necesita un período de adaptación para actualizar los parámetros de la red hasta que se alcanza un estado de equilibrio
- *Algoritmos Evolutivos*: la computación evolutiva se basa en el empleo de modelos de procesos evolutivos para el diseño e implementación de sistemas de resolución de problemas. Los distintos modelos computacionales que se han propuesto dentro de esta filosofía suelen recibir el nombre genérico de algoritmos evolutivos [BFM97]. Existen cuatro tipos de algoritmos evolutivos bien definidos que han servido como base a la mayor parte del trabajo desarrollado en el área: los algoritmos genéticos, las estrategias de evolución, la programación evolutiva y la

programación genética. Un algoritmo evolutivo se basa en mantener una población de posibles soluciones del problema a resolver, llevar a cabo una serie de alteraciones sobre las mismas y efectuar una selección para determinar qué soluciones permanecen en generaciones futuras y cuáles son eliminadas.

- *Razonamiento probabilístico*: permite trabajar con incertidumbre, uno de los principales problemas para muchas técnicas de las técnicas de minería de datos, debido al uso explícito de la teoría de la probabilidad para cuantificar la incertidumbre. El mayor exponente de estos métodos son las redes bayesianas [Pea88], que consisten en una representación gráfica de dependencias para razonamiento probabilístico.

En el proceso de extracción de conocimiento en bases de datos y, en concreto, en el proceso de minería de datos existen distintas tareas o problemas que se pueden enfocar y resolver como problemas de optimización y búsqueda. Los algoritmos evolutivos imitan los principios de la evolución natural para formar procedimientos de búsqueda y optimización global y son aplicables tanto para el desarrollo de algoritmos de minería de datos propiamente dichos, como para el desarrollo de algoritmos de pre-procesamiento o post-procesamiento o como herramientas para la optimización de los parámetros de otros algoritmos [Fre02].

Por otro lado, uno de los objetivos a considerar en minería de datos, además de la precisión predictiva y el interés, es la comprensibilidad de los resultados para el usuario. En este aspecto, la lógica difusa constituye una herramienta de representación del conocimiento que permite modelar incertidumbre e imprecisión de una forma sencilla y directamente interpretable por el usuario.

Como hemos comentado antes, además del uso de las diferentes técnicas en los dominios en los que son apropiadas, la potencia de la computación flexible está en la hibridación de unas técnicas con otras para abordar la solución a problemas que de otra forma estarían fuera de su ámbito de acción.

Uno de los enfoques más populares es la hibridación entre la lógica difusa y los algoritmos evolutivos, que da lugar a los algoritmos evolutivos de extracción de reglas difusas [CHHM01]. Un algoritmo evolutivo de extracción de reglas difusas es un sistema difuso que incluye un proceso de aprendizaje basado en un algoritmo evolutivo [ES03]. Los sistemas difusos son una de las áreas más importantes para la aplicación de la teoría de los conjuntos difusos. Por lo general se consideran estructuras de modelos en forma de sistemas basados en reglas difusas (*FRBSs*, *Fuzzy rule based systems*). Los FRBSs son una extensión de los sistemas clásicos basados en reglas, puesto que tratan con reglas de tipo "IF - THEN", cuyos antecedentes y consecuentes están formados por sentencias de lógica difusa en lugar de clásicas. Han demostrado su capacidad para resolver problemas de

control [PDH97], modelización [Ped96b], clasificación o minería de datos [IY04, Kun00] en un gran número de aplicaciones.

En los últimos años ha aumentado el interés en sobre los algoritmos evolutivos de extracción de reglas difusas debido a su alta potencialidad. Al contrario que las redes neuronales, el agrupamiento, la inducción de reglas y otros enfoques de aprendizaje automático, los AGs aportan una forma de codificar y evolucionar operadores de agregación de antecedentes de reglas, diferentes semánticas de reglas, operadores de agregación de bases de reglas y métodos de defuzificación.

En las siguientes secciones, se expone detalladamente la utilización tanto de los algoritmos evolutivos como de la lógica difusa en procesos de minería de datos y extracción de conocimiento.

### 1.3.2 Algoritmos evolutivos

El paradigma de la computación evolutiva consta de algoritmos estocásticos de búsqueda basados en abstracciones del proceso de la evolución de Darwin. Estos algoritmos tienen capacidad para solucionar las dificultades mencionadas anteriormente y se utilizan cada vez con mayor frecuencia para reemplazar a los métodos clásicos en la resolución de problemas reales en los que se presentan estos problemas. En este área se han propuesto distintos modelos computacionales denominados algoritmos evolutivos:

- *Algoritmos Genéticos* [Gol89, Hol75], que modelan la evolución genética, por lo que las características de los individuos se expresan mediante genotipos.
- *Estrategias de Evolución* [Sch95], que se orientan hacia la modelación de los parámetros estratégicos que controlan la variación en la evolución, es decir, la evolución de la evolución.
- *Programación Evolutiva* [Fog88], derivada de la simulación de comportamiento adaptativo en evolución.
- *Programación Genética* [Koz92, Koz94], basadas en los algoritmos genéticos, pero en las que los individuos son programas (representados mediante árboles).

Todas estas instancias o tipos de algoritmos evolutivos tratan de modelar la evolución y presentan las siguientes características comunes:

1. Utilizan el proceso de aprendizaje colectivo de una población de individuos. Normalmente cada individuo representa un punto dentro del espacio de búsqueda de todas las soluciones potenciales para un problema dado, es decir, codifica una solución candidata. Los individuos pueden incorporar adicionalmente otra información, como pueden ser los parámetros de la estrategia del algoritmo

evolutivo. En el área de la computación evolutiva a la solución codificada se le denomina genotipo y a la solución decodificada (lo que realmente representa cada individuo en el contexto del problema) se le denomina fenotipo.

2. Los descendientes de los individuos se generan mediante procesos no determinísticos que tratan de modelar los procesos de mutación y cruce. La mutación corresponde a una auto-replicación errónea de los individuos, mientras que el cruce intercambia material genético entre dos o más individuos ya existentes. Ambos operadores son estocásticos, se aplican con probabilidades definidas por el usuario. Normalmente se establece una probabilidad de mutación muy inferior a la probabilidad de cruce, ya que una probabilidad de mutación muy elevada convertiría el proceso de búsqueda evolutivo en un proceso de búsqueda aleatoria. No obstante, la mutación es necesaria para incrementar la diversidad genética de individuos dentro de la población y para alcanzar valores de genes que no estén presentes en la población y que de otra forma serían inalcanzables, puesto que el operador de cruce solo intercambia genes (ya existentes) entre individuos.
3. Se asigna una medida de calidad (denominada habitualmente medida de adaptación o *fitness*) a cada individuo mediante el proceso de evaluación. El operador de selección actúa en base a esta medida y favorece, en el proceso de reproducción, a individuos mejores respecto a aquellos con peor valor de la función de adaptación.

El funcionamiento de cualquier algoritmo evolutivo se puede describir de la siguiente forma: se mantiene una población de posibles soluciones para el problema, se realizan modificaciones sobre las mismas y se seleccionan, en función de una medida de adaptación del individuo al entorno, aquellas que se mantendrán en generaciones futuras y las que serán eliminadas. La población evoluciona a través de las mejores regiones del espacio de búsqueda mediante los procesos de modificación y selección. Las modificaciones sobre la población permiten mezclar información de los padres que debe pasar a los descendientes (operador de cruce) o introducir innovación dentro de la población (operador de mutación).

Una característica importante de los algoritmos evolutivos es que realizan un proceso de búsqueda global. El hecho de que trabajen con una población de soluciones candidatas más que una solución individual, junto con el uso de operadores estocásticos, reduce la probabilidad de caer en un óptimo local e incrementa la probabilidad de encontrar el máximo global.

Además, este carácter de búsqueda global hace a los algoritmos evolutivos especialmente adecuados para resolver problemas presentes en las distintas etapas del proceso de descubrimiento de conocimiento [Fre02]. Por ejemplo, en procesos de extracción de reglas, los algoritmos evolutivos tratan de forma adecuada las interacciones entre atributos porque evalúan una regla como un todo mediante la función de adaptación

en lugar de evaluar el impacto de añadir y/o eliminar una condición de una regla, como ocurre en los procesos de búsqueda local incluidos en la mayoría de los algoritmos de inducción de reglas y árboles de decisión. En [BFM97] se puede encontrar una descripción completa de los distintos tipos de algoritmos evolutivos.

Entre las distintas clases de algoritmos evolutivos, los AGs y la programación genética son los más utilizados en la actualidad en el campo de la minería de datos, y específicamente en el descubrimiento de reglas. Estas dos clases de algoritmos difieren fundamentalmente en la representación de los individuos. En los AGs, los individuos se representan como una cadena lineal de condiciones, y en el caso de reglas cada condición suele ser una pareja atributo-valor, mientras que en programación genética un individuo suele representarse mediante un árbol, y en este caso particular los nodos hoja o terminales son condiciones de reglas y/o valores de atributos, y los nodos internos representan las funciones.

En las siguientes subsecciones se describen los AGs y los AGs multiobjetivo, analizando el problema de la optimización multiobjetivo.

### 1.3.2.1 Algoritmos genéticos

Los AGs son algoritmos estocásticos de optimización y búsqueda inspiradas en los procesos de evolución natural y fueron definidos inicialmente por Holland [Hol75]. Descritos de forma sencilla, funcionan de la siguiente forma: el sistema comienza con una población inicial de individuos que codifican, mediante la representación genética, soluciones candidatas para el problema propuesto. Esta población de individuos (denominados cromosomas) evoluciona en el tiempo a través de un proceso de competición y variación controlada. Cada cromosoma de la población está asociado con una función de adaptación (*fitness*) para determinar qué cromosomas se seleccionaron para formar parte de la nueva población en el proceso de competición. La nueva población se creará utilizando operadores genéticos de cruce y mutación. Bäck, Fogel y Michalewicz en [BFM97] dan una descripción completa de los AGs así como ejemplos de algoritmos evolutivos.

Los AGs, en su propuesta original [Hol75], se distinguen de otros algoritmos evolutivos por tres características: el esquema de codificación binario, el método de selección (proporcional a la función de adaptación) y el método básico para producir variaciones en la población, el cruce. Es fundamentalmente esta tercera característica la que hace a los AGs diferentes del resto de los algoritmos evolutivos. En propuestas posteriores a la de Holland se utilizan métodos alternativos de selección y se adoptan esquemas de codificación adaptados a los problemas a resolver y menos restrictivos que el esquema de codificación binario.

El funcionamiento básico de un AG es el siguiente (ver Figura 1.3) [Mic92]: el sistema parte de una población inicial de individuos que codifican, mediante alguna representación

genética, soluciones candidatas al problema propuesto. Esta población de individuos (a los que se denomina cromosomas) evoluciona en el tiempo a través de un proceso de competición y variación controlada. Cada cromosoma de la población tiene asociada una medida de adaptación para determinar qué cromosomas serán seleccionados para formar parte de la nueva población en el proceso de competición. La nueva población se creará utilizando operadores genéticos de cruce y mutación. Este ciclo evolutivo continúa hasta que se verifique una determinada condición de parada: que se hayan realizado un determinado número máximo de evaluaciones de individuos, que la población haya evolucionado durante un número máximo de generaciones, que se haya alcanzado una solución con un determinado valor de la función de adaptación (o de parte de ella), que se estacione la población por no generarse individuos nuevos durante un determinado número de generaciones, etc.

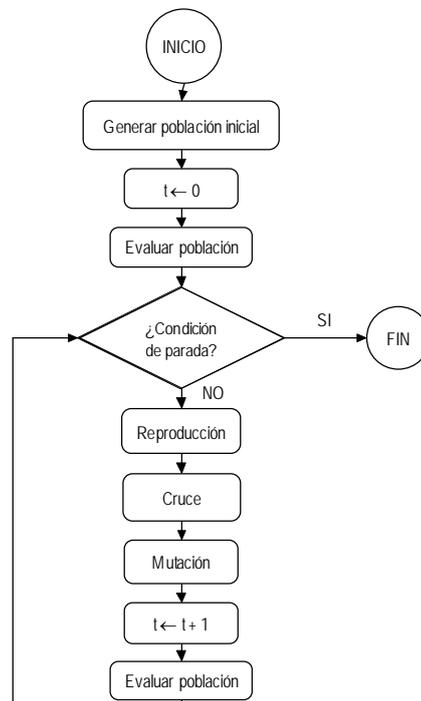


Figura 1.3. Algoritmo de búsqueda en un enfoque evolutivo.

La aplicación de un AG para resolver un problema debe determinar:

- Una representación genética de las soluciones del problema.
- Una forma de crear una población inicial de soluciones.
- Una función de evaluación que proporcione un valor de adaptación de cada cromosoma.

- Operadores que modifiquen la composición genética de la descendencia durante la reproducción.
- Valores para los parámetros que utilizan (tamaño de la población, probabilidades de aplicación de los operadores genéticos, etc.).

### 1.3.2.2 Algoritmos genéticos multiobjetivo

En tareas de minería de datos descriptiva como el descubrimiento de subgrupos, es habitual tener que manejar un problema en el que debemos optimizar distintos objetivos. Los AGs pueden manejar esta situación convirtiendo los distintos objetivos en una función de un único objetivo. Sin embargo, existe un tipo de AGs, los AGs multiobjetivo capaces de manejar distintos objetivos sin necesidad de convertirlos a uno solo. A continuación, se define formalmente el problema de la optimización multiobjetivo, se repasan los métodos clásicos de optimización multiobjetivo y se estudian los algoritmos evolutivos multiobjetivo.

#### 1.3.2.2.1 Optimización multiobjetivo

La optimización consiste en la búsqueda de una o más soluciones óptimas respecto a los valores de uno o más objetivos. Cuando un problema de optimización involucra a un solo objetivo, la tarea de encontrar la solución óptima se denomina optimización “mono-objetivo”. Hoy en día existen algoritmos de optimización mono-objetivo que trabajan utilizando técnicas clásicas deterministas, pero también los hay que utilizan principios de búsqueda estocásticos permitiendo a los algoritmos de optimización encontrar soluciones óptimas globales.

Muchos problemas de búsqueda y optimización del mundo real involucran de forma natural a múltiples objetivos. Cuando un problema de optimización involucra a más de una función objetivo, la tarea de encontrar una o más soluciones óptimas se conoce como “optimización multiobjetivo”.

La optimización multiobjetivo se ha estudiado con profundidad [CVL02, CH83, Deb01, SNT85]. Existen muchos algoritmos y aplicaciones que involucran a múltiples objetivos. Sin embargo, la mayoría de estos métodos evita la complejidad relacionada con un auténtico problema de optimización multiobjetivo y transforma los distintos objetivos en una función de un único objetivo utilizando ciertos patrones definidos por usuario. De esta forma, muchos estudios sobre optimización multiobjetivo clásica no tratan la optimización multiobjetivo de forma diferente a la optimización mono-objetivo (de hecho, la consideran como una aplicación de la optimización mono-objetivo para el manejo de múltiples objetivos). Estos estudios se concentran en las distintas formas de convertir los distintos objetivos en un solo, comparando diferentes modelos, aportando razones a favor de unos modelos sobre otros o sugiriendo mejores modelos para realizar esa conversión.

La diferencia fundamental entre la optimización mono-objetivo y la multiobjetivo es que en la primera tenemos una única solución óptima, mientras que en la optimización multiobjetivo tenemos un conjunto de soluciones óptimas. Esto se debe a que los distintos objetivos suelen estar en conflicto, y por tanto una solución óptima respecto a un objetivo suele provocar que no se alcancen valores óptimos en otros objetivos. Esto impide que se pueda elegir la solución óptima al problema multiobjetivo con respecto a uno solo de los objetivos. Si tomamos por ejemplo un problema con dos objetivos, podemos encontrar una solución óptima a uno de los objetivos, pero esta solución muy probablemente no sea óptima con respecto al segundo objetivo; podemos encontrar soluciones que sean mejores para el segundo objetivo, pero no alcanzarán el óptimo para el primero. Así, encontraremos un conjunto de soluciones en las que la mejora en uno de los objetivos supone un empeoramiento en el otro. ¿Cuál de todas estas soluciones es mejor con respecto a ambos objetivos? En realidad, ninguna de ellas lo es, por lo que en problemas con más de un objetivo (que entren en conflicto) no hay una sola solución óptima, sino un conjunto de soluciones óptimas.

Sin más información, ninguna de las soluciones del conjunto de soluciones óptimas puede decirse que sea mejor que otra. Puesto que hay distintas soluciones óptimas, en un problema de optimización multiobjetivo muchas de estas soluciones son importantes. Así, el algoritmo de búsqueda que utilicemos para resolver el problema multiobjetivo debe aportar ese conjunto de soluciones óptimas. Los algoritmos evolutivos tienen la habilidad de encontrar múltiples soluciones óptimas en una sola ejecución, lo que los hace especialmente útiles en la resolución de problemas multiobjetivo.

Pasemos ahora a definir formalmente el problema de la optimización multiobjetivo. Un problema de optimización multiobjetivo consta de varias funciones objetivo que se deben minimizar o maximizar. Formalmente un problema de optimización multiobjetivo se puede definir de la siguiente forma:

$$\min / \max \vec{y} = f(\vec{x}) = (f_1(\vec{x}), f_2(\vec{x}), \dots, f_n(\vec{x})) \quad (1.13)$$

donde  $\vec{x} = (x_1, x_2, \dots, x_m)$  es el vector de decisión e  $\vec{y} = (y_1, y_2, \dots, y_n)$  es el vector objetivo (una tupla con n objetivos).

Mientras que la optimización mono-objetivo busca un vector de decisión n-dimensional que optimice una función escalar, en optimización multiobjetivo se intenta encontrar uno que optimice una función vectorial cuyos elementos representan las distintas funciones objetivo.

El objetivo de cualquier algoritmo de optimización multiobjetivo es encontrar todos los vectores de decisión para los cuales los correspondientes vectores objetivo no se puedan mejorar en una dimensión sin degradar otra. El conjunto de soluciones es un conjunto de soluciones óptimas en el sentido que cada una es mejor que las otras en algún objetivo, pero

ninguna puede considerarse mejor cuando se tienen en cuenta todos los objetivos de forma simultánea. La existencia de múltiples soluciones óptimas hace necesaria una noción distinta de óptimo.

La noción más aceptada de óptimo para problemas multiobjetivo es la propuesta inicialmente por F. Edgeworth, y generalizada posteriormente por V. Pareto, denominada óptimo de Pareto (*Pareto Optimum*) (como se describe en [Deb01]), y que se basa en el concepto de *dominancia*.

Se dice que una solución  $a$  *domina* a una solución  $b$  si se cumplen a la vez las siguientes dos condiciones:

- La solución  $a$  no es peor que la solución  $b$  en todos los objetivos.
- La solución  $a$  es estrictamente mejor que la solución  $b$  en al menos uno de los objetivos.

Si se viola alguna de las condiciones anteriores, la solución  $a$  no domina a la solución  $b$ . Es intuitivo que si una solución  $a$  domina a otra solución  $b$ , la solución  $a$  es mejor que la solución  $b$ . Puesto que el concepto de dominancia permite comparar soluciones con múltiples objetivos, muchos de los métodos de optimización multiobjetivo utilizan este concepto de dominancia para buscar soluciones no-dominadas.

Para un conjunto finito dado de soluciones, podemos realizar todas las posibles comparaciones dos a dos y encontrar qué soluciones dominan a qué otras y qué soluciones son no-dominadas con respecto a cada una de las otras. Al final, tendremos un conjunto de soluciones en las que cualesquiera dos de ellas no se dominan la una a la otra. Este conjunto tiene otra propiedad. Para cualquiera del resto de soluciones que no pertenecen a este conjunto, siempre podremos encontrar una solución del conjunto que dominará a la anterior. Así, este conjunto particular tiene la propiedad de dominar a todas las demás soluciones que no pertenecen a este conjunto. Expresado de forma sencilla, esto quiere decir que las soluciones de este conjunto son mejores comparadas con el resto de soluciones. A este conjunto se le denomina *Conjunto no-dominado* y se define como:

Entre un conjunto de soluciones  $P$ , el *conjunto no-dominado*  $P'$  está formado por todas las soluciones que no son dominadas por ningún miembro del conjunto  $P$ . Cuando el conjunto origen  $P$  es el espacio de búsqueda completo, el conjunto no-dominado resultante  $P'$  se denomina *Conjunto Pareto Óptimo*.

De esta forma, un vector es Pareto óptimo si no existe ningún otro vector de decisión que lo domine. Los vectores objetivo correspondientes a estos vectores de decisión se denominan *no dominados*, y el conjunto de vectores no dominados en el espacio objetivo se denomina *Frente Pareto Óptimo*.

El objetivo de cualquier algoritmo de optimización multiobjetivo es encontrar todos los vectores de decisión para los cuales los correspondientes vectores objetivo no se puedan

mejorar en una dimensión sin degradar otra; es decir, que el problema se considera resuelto cuando se encuentra el conjunto Pareto óptimo. En problemas reales, se suele requerir la obtención de una única solución. Puesto que desde un punto de vista estrictamente matemático todas las soluciones en el conjunto Pareto son igualmente buenas, para seleccionar cual de las soluciones del conjunto Pareto se toma como solución se necesita información adicional de preferencia. Una persona se encargará de proporcionar la *información de preferencia* necesaria para seleccionar una solución del conjunto Pareto. Así, el proceso de solución de un problema de optimización multiobjetivo puede dividirse en dos procesos conceptualmente distintos [Mie99]:

- *Proceso de búsqueda u optimización*, en el que se explora el conjunto de soluciones en busca de soluciones Pareto Óptimas.
- *Proceso de toma de decisiones*, en el que se selecciona una solución de compromiso adecuada, a partir del Conjunto Pareto Óptimo hallado por el proceso anterior.

La importancia de la toma de decisiones como parte del proceso de solución es una buena razón para clasificar los distintos métodos para solucionar problemas de optimización multiobjetivo de acuerdo con la manera en que se combinan la búsqueda del conjunto de soluciones y la toma de decisiones [Mie99]. Así, los métodos se clasifican en:

- *Métodos sin preferencia*: no asumen ninguna información sobre la importancia de los objetivos, pero se utiliza una heurística para encontrar una única solución óptima. Es importante resaltar que aunque no se utiliza información de preferencia, estos métodos no intentan encontrar múltiples soluciones Pareto-óptimas.
- *Métodos posteriori*: Utilizan información de preferencia de cada objetivo y generan de forma iterativa en conjunto de soluciones Pareto-óptimas. Para la generación de las soluciones es necesario cierto conocimiento sobre los parámetros algorítmicos que asegurarán la obtención de una solución Pareto-óptima. La toma de decisiones la lleva a cabo una persona después de obtener los resultados de la búsqueda.
- *Métodos a priori*: utilizan más información sobre las preferencias de los objetivos y suelen encontrar una solución Pareto-óptima preferida. Así, la toma de decisiones se realiza antes de la búsqueda de soluciones, y se suelen combinar los distintos objetivos en uno solo, que incluye implícitamente la información de preferencia proporcionada. Esto hace que en realidad el problema de optimización multiobjetivo se convierta en uno monobjetivo, antes de la optimización.
- *Métodos interactivos*: utilizan la información de preferencia de forma progresiva durante el proceso de optimización, de forma que la toma de decisiones se realiza durante la búsqueda de soluciones de manera interactiva. Después de cada paso de

optimización, se presentan un conjunto de soluciones, y la información de preferencia guiará el proceso de búsqueda.

Con los métodos a priori, en los que se combinan múltiples objetivos en un único criterio de optimización, cuando son aplicables, se tiene la ventaja de que se pueden utilizar las estrategias clásicas de optimización monoobjetivo sin modificaciones. La desventaja es que requiere un conocimiento profundo del dominio del problema que permita realizar la escalarización de forma correcta. Este conocimiento del dominio del problema requerido por los métodos a priori usualmente no se encuentra disponible. Es más, en algunos casos, lo que se desea es obtener mayor conocimiento sobre el problema y sobre las soluciones alternativas. Realizar la toma de decisiones después del proceso de búsqueda (métodos a posteriori) resuelve el problema, pero excluye la articulación de la preferencia de una persona que tome las decisiones, lo que podría a su vez reducir la complejidad del espacio de búsqueda. Los métodos interactivos superan las desventajas de los métodos a priori y posteriori permitiendo al tomador de decisiones expresar sus preferencias a medida que avanza en el conocimiento del problema considerado.

Como se dijo anteriormente, los métodos tradicionales de búsqueda de óptimos para problemas multiobjetivo se basan en convertir el problema considerado en un problema mono-objetivo (por lo que se les suele denominar métodos de agregación). Estos métodos encuentran una solución a la vez por lo que se han propuesto varios métodos para aproximar un conjunto de soluciones en vez de un único punto.

#### 1.3.2.2.2 Enfoques clásicos para problemas de optimización multiobjetivo

Algunos enfoques tradicionales, representativos para la solución de problemas de optimización multiobjetivo son:

- *Método de suma ponderada* [PS91, YG94]: En los métodos de suma ponderada las funciones objetivo del problema de optimización multiobjetivo original se combinan de forma lineal utilizando diferentes coeficientes de peso para formar una función escalar a ser optimizada.
- *Método de programación de metas* [CC61, Iji65]: En este método, el tomador de decisiones tiene que asignar objetivos o metas que desee alcanzar para cada objetivo. Estos valores se incorporan en el problema como restricciones adicionales. La técnica tratará entonces de minimizar las desviaciones absolutas de cada objetivo con respecto a lo deseado.
- *Método de las restricciones  $\epsilon$*  [RER94]: Este método se basa en la optimización de una sola función objetivo (la principal o preferida) y considera a los demás objetivos como restricciones que están acotadas por ciertos niveles permisibles  $\epsilon_i$ . Por lo tanto, se efectúa una optimización con un sólo objetivo para la función objetivo más relevante  $f_r$  sujeta a restricciones adicionales en las otras funciones

objetivo. Los niveles  $\epsilon_i$  se alteran después para generar otros puntos del conjunto Pareto. El método puede formularse de la siguiente manera:

A continuación describiremos, debido a su importancia y a su utilización en modelos de aprendizaje evolutivo, el método de suma ponderada. En los métodos de suma ponderada las funciones objetivo del problema de optimización multiobjetivo original se combinan de forma lineal utilizando diferentes coeficientes de peso para formar una función escalar a ser optimizada. Esto significa que un problema original de optimización con objetivos múltiples:

$$\text{Optimizar } F(x) = (f_1(x), \dots, f_k(x)) \quad (1.14)$$

se transforma en un problema de optimización de la forma:

$$\text{Optimizar } y = f(x) = w_1 \cdot f_1(x) + \dots + w_k \cdot f_k(x) = \sum_{i=1}^k w_i \cdot f_i(x) \quad (1.15)$$

donde todos los pesos  $w_i \geq 0$ , y la suma de todos los pesos es 1.

Los métodos de suma ponderada pueden ser utilizados tanto a priori, de forma interactiva como a posteriori. Como método a priori, el tomador de decisiones expresa su preferencia por los diferentes objetivos seleccionando un vector de pesos dado y evaluando la función  $f(\mathbf{x})$  correspondiente para obtener *una* solución. El problema es quien debe determinar el valor de los pesos puede no estar seguro de reflejar la importancia de cada objetivo original de forma apropiada. La única solución obtenida por el método de suma ponderada utilizando un vector de pesos seleccionado a priori no brinda información al tomador de decisiones sobre otras alternativas de solución y debe confiar en su decisión inicial. La obtención de un conjunto de soluciones alternativas sería de indudable utilidad.

Para obtener un conjunto de soluciones utilizando el método de suma ponderada, es necesario utilizar diferentes combinaciones de pesos. Así, el proceso de búsqueda de soluciones se inicia con la selección de un vector inicial de pesos  $w^0$  con el que se obtiene una solución. Esta selección puede hacerse de acuerdo a las preferencias del tomador de decisiones o de forma aleatoria. Después, el vector de pesos inicial se modifica para obtener uno nuevo. El proceso se repite hasta que se encuentra un número dado de soluciones.

De esta forma, los pesos no reflejan la importancia proporcional de los objetivos, sino que sólo son factores que, al variarse, localizan puntos diferentes en el conjunto Pareto. Después de obtener un conjunto de soluciones, las soluciones se presentan al tomador de decisiones para que seleccione una. La principal desventaja con este método es que no se pueden generar todas las soluciones Pareto Óptimas cuando el espacio de soluciones no es convexo.

Una vez descrito el método de la suma ponderada, nos centramos en describir algunos de los inconvenientes que presentan los distintos métodos tradicionales de optimización multiobjetivo [Deb01]:

- El algoritmo de optimización se debe aplicar varias veces para encontrar un conjunto de soluciones Pareto-óptimas. Como cada ejecución es independiente de las demás, no se suelen obtener sinergias entre las soluciones de las distintas ejecuciones. Por tanto, trazar el frente de Pareto óptimo resulta computacionalmente costoso.
- La mayoría de los algoritmos requieren conocimiento previo del problema a resolver y son muy sensibles a los parámetros del algoritmo: pesos de los objetivos, orden de evaluación, nivel de objetivos, valor de las restricciones, etc.

Algunos algoritmos son sensibles a la forma del frente de Pareto.

- La variación entre las diferentes soluciones encontradas depende de la eficiencia del optimizador de un sólo objetivo. Puede ocurrir que se encuentre siempre la misma solución o soluciones muy parecidas en distintas ejecuciones.
- Además, en problemas en los que intervenga el azar o exista incertidumbre, los métodos clásicos no son necesariamente confiables.

Distintas investigaciones han demostrado que las dificultades anteriores se pueden superar con la utilización de algoritmos evolutivos [Deb01], que describimos en el siguiente apartado.

#### 1.3.2.2.4 Algoritmos genéticos multiobjetivo

Como hemos indicado previamente, una forma clásica de resolver problemas de optimización multiobjetivo es seguir el enfoque basado en preferencias, utilizando un vector de preferencias relativas para escalarizar múltiples objetivos. Puesto que los métodos clásicos de búsqueda y optimización utilizan un enfoque punto a punto, en el que se modifica una sola solución en cada iteración para obtener una nueva solución (que se espera que sea mejor que la anterior), el resultado que se obtiene al utilizar estos métodos de optimización clásicos es una única solución. El desarrollo de enfoques basados en preferencias estaba motivado por el hecho de que los métodos de optimización disponibles sólo podían encontrar una solución en cada ejecución. Al encontrar una única solución óptima, se hacía necesario convertir la tarea de la optimización multiobjetivo para encontrar múltiples soluciones en otra tarea de optimización convertida a mono-objetivo para encontrar una única solución al problema.

Sin embargo, el campo de la búsqueda y optimización ha cambiado a lo largo de los últimos años con la introducción de varios algoritmos de optimización y búsqueda estocásticos. Uno de estos métodos son los algoritmos evolutivos. La diferencia fundamental entre los métodos clásicos de optimización y búsqueda y los algoritmos

evolutivos es que estos últimos utilizan una población de soluciones en cada generación en lugar de una única solución.

Esta habilidad de los algoritmos evolutivos de encontrar múltiples soluciones óptimas en única sola ejecución da a los algoritmos evolutivos una tremenda ventaja para su uso en la resolución de problemas de optimización multiobjetivo. A esto se le une además el éxito de la aplicación de los algoritmos evolutivos para la resolución de problemas de optimización mono-objetivo.

Recordemos que uno de los objetivos de un procedimiento de optimización multiobjetivo es encontrar tantas soluciones Pareto-óptimas como sea posible. Puesto que un algoritmo evolutivo trabaja con una población de soluciones, en teoría deberíamos ser capaces de hacer algunos cambios a los algoritmos evolutivos básicos de forma que se capture una población de soluciones Pareto-óptimas en una sola ejecución de un algoritmo evolutivo. Si somos capaces de lograr esto, eliminaremos la utilización repetitiva de un método de optimización mono-objetivo para encontrar una solución Pareto-óptima diferente en cada ejecución. Esto eliminará además la necesidad de algunos parámetros, como vectores de pesos,  $\epsilon$ -vectores, vectores objetivo, y varios otros. Estos parámetros son necesarios en los algoritmos clásicos de optimización multiobjetivo para transformar el problema de optimización multiobjetivo en un problema mono-objetivo que obtenga una única solución Pareto-óptima.

Puesto que en cada iteración se procesa una población de soluciones, el resultado de un algoritmo evolutivo es también una población de soluciones. Si un problema de optimización tiene un solo óptimo, se espera que todos los miembros de la población del algoritmo evolutivo converjan a esa solución óptima. Sin embargo, si el problema de optimización tiene múltiples soluciones óptimas, se puede utilizar un algoritmo evolutivo para obtener las múltiples soluciones óptimas en su población final.

Así, podemos utilizar el enfoque poblacional de los algoritmos evolutivos para resaltar todas las soluciones no dominadas en una población de forma equitativa y simultáneamente preservar un conjunto diverso de múltiples soluciones no dominadas utilizando un operador basado en nichos. De esta forma se puede encontrar y mantener en una población múltiples buenas soluciones. Después de algunas generaciones, este proceso puede llevar a la población a converger cerca del frente óptimo de Pareto y con una buena diversidad.

En la actualidad, la optimización evolutiva multiobjetivo (*Evolutionary Multiobjective Optimization*) es un área de investigación muy importante, no sólo por que la mayor parte de los problemas consideren objetivos múltiples por naturaleza, sino también porque aún quedan por resolver un gran número de cuestiones en esta disciplina.

Incidamos ahora con más profundidad en las ventajas de encontrar múltiples soluciones Pareto-óptimas. Supongamos que utilizamos un algoritmo evolutivo

multiobjetivo (*MOEA, Multi Objective Evolutionary Algorithm*) para encontrar varias soluciones Pareto-óptimas en una sola ejecución. Debemos resaltar que cada una de las soluciones podría corresponder con la solución óptima (o muy cercana) a un problema compuesto en el que intervienen distintas funciones objetivo contrapuestas. De esta forma, cada solución es importante con respecto a cierta relación entre los objetivos. Pero, puesto que en la práctica sólo utilizaremos una de las soluciones Pareto-óptimas, debemos plantearnos cuál de estas múltiples soluciones es la que nos interesa. Esto no debería ser una pregunta difícil de contestar si disponemos de muchas soluciones, pero sí lo es cuando no disponemos de esa información. Esta es precisamente la dificultad a la que se enfrenta un usuario cuando utiliza un método clásico. Si el usuario conoce una relación exacta de compromiso entre funciones objetivo (es decir, si el usuario conoce un vector de pesos en el que está interesado), no hay necesidad de encontrar múltiples soluciones. Un método clásico basado en pesos sería suficientemente bueno para encontrar la solución óptima correspondiente. Podemos denominar a este enfoque “enfoco basado en preferencias”, aunque en la literatura clásica se le denomina “enfoco a priori”.

Sin embargo, desafortunadamente, el usuario no suele estar seguro de este tipo de relación entre objetivos. Ante esta situación es mejor, desde un punto de vista práctico, encontrar un conjunto de soluciones Pareto-óptimas primero para después elegir una solución de este conjunto utilizando otra información o consideraciones de alto nivel. A este enfoque se le denomina “enfoco ideal” [Deb01]. Después de encontrar un conjunto de soluciones no dominadas, cada solución se puede asociar con un vector de pesos estimado a partir de la localización de las soluciones en el conjunto no dominado. Después de esto, si disponemos de conocimiento de preferencia sobre el compromiso entre objetivos, aunque no esté muy refinado, se puede utilizar para elegir una de las soluciones no dominadas, que encajará casi perfectamente con la información contenida en el vector artificial de pesos. Este método da al usuario al menos una perspectiva general de otras posibles soluciones óptimas que ofrece el problema de optimización multiobjetivo subyacente antes de elegir una solución, y permite al usuario elegir una solución de acuerdo con el grado de importancia deseado para cada objetivo.

Pero, para obtener una perspectiva de diferentes soluciones Pareto-óptimas que ofrece el problema de optimización multiobjetivo subyacente, podríamos pensar en utilizar el enfoque “a priori” de los métodos clásicos de la siguiente forma: elegimos primero un conjunto de vectores de pesos y después, para cada uno de ellos, construimos un problema de optimización mono-objetivo y encontramos la correspondiente solución óptima; cuando se han realizado todas las optimizaciones de este tipo, obtenemos un conjunto de soluciones Pareto-óptimas. Pero esto no tiene en cuenta las posibles relaciones entre las distintas funciones objetivo.

En el enfoque “ideal” no se asume de inicio ningún conocimiento sobre un vector de pesos y se utiliza un algoritmo de optimización basado en población para encontrar

múltiples soluciones Pareto-óptimas. Puesto que el problema original de optimización multiobjetivo no se ha convertido en un problema mono-objetivo y puesto que normalmente se utiliza el concepto de dominación junto con un mecanismo de preservación de la diversidad para dirigir el proceso de búsqueda, este enfoque puede encontrar un extenso conjunto de soluciones Pareto-óptimas. Utilizando el valor de la función objetivo individual para cada una de estas soluciones, se puede realizar una estimación del compromiso entre diferentes objetivos para cada solución. Podemos relacionar estos valores de preferencia con los pesos asignando a todas las soluciones obtenidas un vector de pseudo-pesos. Ahora el usuario puede comparar diferentes soluciones con sus vectores de pesos asociados y elegir la solución que más le interese.

Este enfoque “ideal” es una mejor estrategia práctica. Muchos de los métodos de algoritmos evolutivos descritos en la literatura trabajan con este tipo de enfoque. Los primeros algoritmos evolutivos que consideraban de forma simultánea objetivos múltiples se desarrollaron a comienzos de los años noventa. Con el transcurso del tiempo, la computación evolutiva multiobjetivo se ha establecido como el método preferido para aproximar el frente Pareto-óptimo en problemas de este tipo. Esto se debe fundamentalmente al paralelismo intrínseco de los algoritmos evolutivos que les permite explorar similitudes entre las soluciones de forma eficiente, y a su capacidad de capturar varias soluciones Pareto-óptimas en una única ejecución [ZDT00].

En las dos últimas décadas se ha desarrollado un interés creciente en el uso de AGs para optimización multiobjetivo. Existen múltiples propuestas de AGs multiobjetivo [CVL02, Deb01], que podemos clasificar como técnicas de primera y segunda generación. A la primera generación pertenecen las propuestas iniciales que no consideran conceptos de Pareto, y aquellas basadas en Pareto que no incluyen mecanismos para la preservación de las buenas soluciones encontradas durante el proceso evolutivo (elitismo). La segunda generación esta caracterizada básicamente por algoritmos basados en Pareto y que incorporan alguna forma de elitismo.

Puesto que los AGs requieren información escalar sobre el valor de adaptabilidad de los individuos, no es extraño que los primeros enfoques evolutivos utilizados para manejar objetivos múltiples se basen en la idea de combinar un AG simple con métodos de escalarización de la función objetivo. Así, estos primeros enfoques se encargaban de optimizar la función agregada en vez de optimizar la verdadera función multiobjetivo [Coe06]. Estos enfoques tienen como inconveniente la posible compensación entre objetivos, el conocimiento profundo sobre el problema que requieren y que, en general, no proporcionan una familia de soluciones. VOW-GA [HL92] y RW-GA [IM98] son ejemplos de algoritmos de este tipo.

La primera implementación real de un algoritmo evolutivo multiobjetivo que no utiliza funciones de agregación para resolver problemas multiobjetivo fue la propuesta por David

Schaffer en 1984 [Sch84, Sch85], denominada *Vector Evaluated Genetic Algorithm* (VEGA). Este algoritmo consiste básicamente en un AG simple con un mecanismo de selección modificado. En cada generación, se genera un conjunto de sub-poblaciones realizando una selección proporcional de acuerdo con cada función objetivo sucesivamente. Estas sub-poblaciones se unen para formar una nueva población sobre la que el AG aplica los operadores de cruce y mutación de la forma habitual. VEGA tenía varios problemas, de los cuales el principal está relacionado con su incapacidad de conservar soluciones aceptables, quizá por encima de la media, pero no destacables para alguna de las funciones objetivo. Estas soluciones eran quizás buenas candidatas a convertirse en soluciones no dominadas, pero no podían sobrevivir bajo el esquema de selección de este enfoque. El resultado final del procedimiento de selección de VEGA corresponde a promediar los valores de cada uno de los objetivos.

No se realizó ningún estudio significativo hasta pasada casi una década de trabajo pionero de Schaffer. La incorporación directa del concepto de optimalidad de Pareto en un algoritmo evolutivo fue propuesta inicialmente por David E. Goldberg en su libro sobre AGs [Gol89]. Criticando el algoritmo VEGA, Goldberg propuso la utilización de la clasificación y selección no dominada para llevar a la población hacia el frente de Pareto en un problema de optimización multiobjetivo. Puesto que un algoritmo evolutivo necesita una función de adaptación para la reproducción, el truco estaba en encontrar una métrica sencilla a partir de distintas funciones objetivo. La aportación de Goldberg era utilizar el concepto de dominación para asignar más copias a los individuos no dominados de una población. Como la diversidad es otra cuestión a tener en cuenta, también sugirió la utilización de una estrategia de nichos para evitar que el AG convergiese a un único punto en el frente. Goldberg no proporcionó una implementación real de su procedimiento, pero prácticamente todos los MOEAs desarrollados después de la publicación de su libro han sido influidos por sus ideas.

Así, se produjo un renacimiento en el campo en la década de los noventa con la aparición de los primeros algoritmos que consideraban de forma simultánea la optimización de objetivos múltiples utilizando el concepto de dominancia Pareto. Al menos tres grupos independientes de investigadores desarrollaron diferentes versiones de algoritmos evolutivos multiobjetivo. El *Multiobjective Genetic Algorithm (MOGA)* de Fonseca y Fleming [FF93], el *Niched Pareto Genetic Algorithm (NPGA)* de Horn y Nafpliotis [HN93], y el *Nondominated Sorting Genetic Algorithm (NSGA)* de Srinivas y Deb [SD95] fueron los primeros MOEAs basados en Pareto. Estos algoritmos, pertenecientes a la primera generación de algoritmos evolutivos multiobjetivo, fueron aplicados a una amplia gama de problemas multiobjetivo con mejores resultados que los de los enfoques no basados en Pareto. Estos algoritmos difieren en la forma en que el fitness es asignado a cada individuo. Se puede encontrar una descripción de todos estos últimos en [Coe06].

A pesar del éxito obtenido por los MOEAs de primera generación basados en Pareto, una vez que estos encontraban una solución no-dominada en una generación, éstas podían perderse cuando se aplicaban los operadores genéticos en las sucesivas generaciones. Para evitar la pérdida de buenas soluciones, se extendió el concepto de *elitismo*, utilizado en algoritmos monobjetivo, al campo de la optimización evolutiva multiobjetivo considerando la existencia de múltiples soluciones posibles. Así, los MOEAs de segunda generación están caracterizados por la utilización de conceptos de Pareto junto con alguna forma de elitismo para la búsqueda de soluciones. Algoritmos correspondientes a la segunda generación son entre otros el *Strength Pareto Evolutionary Algorithm (SPEA)* de Zitzler y Thiele [ZTQ97], el *Strength Pareto Evolutionary Algorithm 2 (SPEA2)* de Zitzler, Laumanns y Thiele [ZLT02], el *Nondominated Sorting Genetic Algorithm II (NSGA-II)* de Deb, Agrawal, Pratab y Meyarivan [DPAM02], y el  $\mu$ - $\lambda$  *Multiobjective Evolutionary Algorithm ( $\mu$ - $\lambda$  MEA)* de Sarker, Liang y Newton [SLN02].

### 1.3.3 Lógica difusa

La lógica difusa (*fuzzy logic*) permite modelar conocimiento impreciso y cuantitativo así como transmitir, manejar incertidumbre y soportar, en una extensión razonable, el razonamiento humano de una forma natural. Desde que Zadeh propuso la teoría de conjuntos difusos [Zad65] y el concepto de variable lingüística [Zad75], se ha aplicado en múltiples áreas de investigación, fundamentalmente por su cercanía al razonamiento humano y por proporcionar una forma efectiva para capturar la naturaleza aproximada e inexacta del mundo real.

La forma de representación del conocimiento ha sido una de las áreas de mayor interés investigadas en la disciplina de las ciencias de la computación y la inteligencia artificial. Uno de los principales aspectos es la representación de conocimiento es lingüísticamente impreciso, para lo que se han demostrado ineficaces las técnicas convencionales. Así, el desarrollo de la lógica difusa se vio motivado por la necesidad de disponer de un marco conceptual que pudiera ser aplicado con éxito al tratamiento de la información en entornos de incertidumbre e imprecisión léxica [Zah92].

Podemos considerar que la lógica difusa es una extensión a la lógica clásica, donde se incorporan nuevos conceptos para trabajar con el problema de representación en un ambiente de incertidumbre e imprecisión. La diferencia fundamental entre las proposiciones de la lógica clásica y las proposiciones difusas está en el rango de valores de verdad. Mientras que en las proposiciones clásicas sólo existen dos posibles valores de verdad (verdadero o falso), el grado de verdad o falsedad de las proposiciones difusas puede tomar distintos valores numéricos. Asumiendo que la verdad y la falsedad se representan con 1 y 0 respectivamente, el grado de verdad de cada proposición difusa se expresa como un valor en el intervalo [0,1]. La lógica difusa es, en realidad, una forma de lógica multivaluada. Su

finalidad última es proveer de una base para el *razonamiento aproximado* con proposiciones imprecisas utilizando la teoría de conjuntos difusos como herramienta principal.

Este paso de la lógica clásica a la lógica difusa tiene como consecuencia la necesidad de definir el concepto de conjunto difuso. Un conjunto difuso puede definirse como una generalización de los conjuntos clásicos. En éstos, la función de pertenencia sólo puede tomar dos valores (0 ó 1, pertenencia o no pertenencia). En cambio, en los conjuntos difusos, la función de pertenencia asigna a cada elemento un grado de pertenencia dentro del intervalo  $[0,1]$ . Esto permite representar conceptos con límites borrosos, mal definidos, pero su significado sí está definido de forma completa y precisa. En [KY95] se puede encontrar una descripción detallada sobre teoría de conjuntos difusos.

Un conjunto difuso es una entidad más compleja que un conjunto clásico pero constituye una representación con mayor precisión para conceptos reales. Esta expresividad permite simplificar reglas y los sistemas basados en ellos.

Una partición difusa de una variable determina una distinción de niveles en los valores de la misma mediante conjuntos difusos y permite solapamiento en las fronteras, al igual que ocurre en el razonamiento humano cuando trabajamos con valores lingüísticos [Zad75]. Así, una variable se describe mediante distintos términos lingüísticos de los que se utilizan habitualmente en el razonamiento humano con variables numéricas (por ejemplo *Bajo*, *Medio*, y *Alto*). Cuando utilizamos estos conceptos, mentalmente pensamos en ellos con un cierto solapamiento entre algunos términos. De ahí que, cuando decidimos trabajar con una variable considerándola una variable *lingüística* que toma como valores términos *lingüísticos*, definimos una partición difusa que considere siempre una división del dominio en términos lingüísticos con cierto nivel de solapamiento. El significado de cada término viene especificado por un conjunto difuso y por tanto por una función de pertenencia. Esta función de pertenencia determinará –de forma precisa– para cualquier valor de la variable, el grado de pertenencia al conjunto difuso correspondiente.

Los sistemas basados en reglas que utilizan conjuntos difusos para describir los valores de sus variables se denominan sistemas basados en reglas difusas. Ante una situación dada, la regla se podrá aplicar si el antecedente de la misma describe la zona del espacio a la que pertenece el ejemplo, es decir, si el grado de compatibilidad del antecedente de la regla y el ejemplo es mayor que cero. Este grado se calcula de la siguiente forma:

- Para cada variable se calcula el grado de pertenencia al conjunto difuso correspondiente. Si en la regla, para una variable se indica una disyunción de términos (por ejemplo, *Nivel = Bajo O Muy Bajo*), esto se interpreta como la unión de los conjuntos difusos correspondientes y el grado de pertenencia se calcula con una t-conorma (operador de unión difusa) que habitualmente es el máximo, aunque existen otras definiciones para el mismo. Según esto el grado de

pertenencia de un valor actual de la variable nivel a “*Bajo O Muy Bajo*” será igual al máximo entre el grado de pertenencia del valor actual del nivel a *Bajo* y el grado de pertenencia a *Muy Bajo*. Las reglas construidas de esta forma se denominan reglas en *forma normal disyuntiva (DNF, Disjunctive Normal Form)*.

- Habitualmente el antecedente de una regla difusa está formado por una conjunción de condiciones para las distintas variables. En este caso, el grado de compatibilidad del ejemplo con la regla se calcula con una t-norma (operador de intersección difusa). Existen múltiples expresiones posibles para las t-normas, pero es frecuente el uso del operador mínimo o producto. Si utilizamos el mínimo, el grado de compatibilidad se calcula como el mínimo entre los grados de pertenencia de las variables implicadas en el antecedente a los conjuntos difusos correspondientes. Como se puede observar, si se elige la t-norma mínimo o producto, cuando una de las variables no pertenece al conjunto difuso implicado, el grado de compatibilidad del ejemplo con la regla es cero. Las reglas construidas de esta forma se denominan reglas *canónicas*.
- Si en el antecedente las condiciones para las variables se combinan con el operador de disyunción (por ejemplo, *Nivel = Bajo O Edad = Joven*), se utilizará el operador de unión difusa (t-conorma) para el cálculo del grado de compatibilidad.

Las reglas difusas se pueden considerar modelos locales simples, lingüísticamente interpretables y con un rango de aplicación muy amplio. Permiten la incorporación de toda la información disponible en el modelado de sistemas, tanto de la que proviene de expertos humanos que expresan su conocimiento sobre el sistema en lenguaje natural, como de la que tiene su origen en medidas empíricas y modelos matemáticos.

Los sistemas difusos se pueden clasificar en dos familias. La primera incluye modelos lingüísticos basados en colecciones de reglas IF-THEN, cuyos antecedentes y consecuentes utilizan valores difusos. Utilizan razonamiento difuso, y el comportamiento del sistema se puede describir en términos *naturales*. El modelo *Mamdani* [MA75] cae dentro de este grupo. El segundo grupo, basado en sistemas de tipo *Sugeno* [TS85] utilizan una estructura de regla con antecedente difuso y consecuente *funcional*. Este enfoque aproxima un sistema no lineal mediante una combinación de varios sistemas lineales, descomponiendo el espacio de entrada en varios espacios parciales difusos y representando cada espacio de salida con una ecuación lineal. Estos modelos son capaces de representar tanto información cualitativa como cuantitativa y permiten una aplicación relativamente sencilla de potentes técnicas de aprendizaje para su identificación a partir de los datos. Pueden aproximar cualquier función continua sobre un conjunto compacto con cualquier grado de precisión [BF99].

En estos sistemas, es necesario establecer un compromiso entre legibilidad y precisión. Si nos interesan soluciones más precisas, no nos preocuparemos tanto sobre la

interpretabilidad lingüística. En estos casos, los sistemas de tipo Sugeno son más adecuados. En otro caso, la opción será un sistema de tipo Mamdani.

Es necesario destacar que no todos los sistemas difusos son sistemas basados en reglas difusas. Los conjuntos difusos se utilizan también, por ejemplo, en algoritmos de agrupamiento con el objetivo de obtener conjuntos difusos que permitan diferenciar los grupos con mayor expresividad, o también en algoritmos de modelado para predicción o regresión. Por ejemplo, se puede obtener un modelo que utilice conjuntos difusos para representar el conocimiento extraído, pero no necesariamente mediante reglas difusas.

En minería de datos, uno de los aspectos que determinan la calidad del conocimiento extraído, y por tanto del algoritmo utilizado, es la interpretabilidad del mismo y en este sentido los sistemas basados en reglas difusas son los más utilizados dentro del campo de la lógica difusa. En la siguiente sección se describen algunos de ellos.

## **1.4 Algoritmos evolutivos y extracción de conocimiento**

---

Aunque los AGs no fueron diseñados específicamente para aprendizaje, sino como algoritmos de búsqueda global, ofrecen algunas ventajas en la extracción de conocimiento y específicamente para procesos de inducción reglas:

- Tienen a tratar bien la interacción entre atributos debido a que suelen evaluar una regla como un todo mediante la función de adaptación, más que evaluar el impacto de añadir/eliminar una condición a/de una regla.
- Tienen la habilidad de rastrear minuciosamente el espacio de búsqueda y la capacidad de permitir funciones de adaptación arbitrarias en la búsqueda. La función de adaptación puede contener diferentes criterios así como la habilidad de penalizar el solapamiento entre reglas o conjuntos de reglas con demasiadas reglas, o una medida de calidad específica del problema, etc.
- Además, la búsqueda genética utiliza implícitamente vuelta atrás en su búsqueda en el espacio de reglas, permitiéndole por tanto encontrar interacciones complejas que otras búsquedas sin vuelta atrás perderían.
- Una ventaja adicional sobre los algoritmos convencionales de aprendizaje de reglas es que la búsqueda se lleva a cabo entre un conjunto de reglas candidatas que compiten entre sí.

Sin embargo esto no quiere decir que los AGs sean inherentemente superiores al resto de algoritmos de inducción de reglas, puesto que no hay ningún algoritmo de descubrimiento de reglas que sea mejor en todos los casos [Dom98, MST94].

En la bibliografía de KDD se han presentado diferentes propuestas que utilizan tanto enfoques predictivos como descriptivos. Los algoritmos de inducción de reglas para descubrimiento de subgrupos (cuyo propósito es fundamentalmente descriptivo) comparten características con algoritmos que guían el proceso de inducción utilizando medidas de calidad predictivas. En esta sección describiremos algunas de las principales propuestas de AGs para inducción de reglas, independientemente de cuál sea su objetivo final.

Como ya hemos comentado, cualquier propuesta de AG cuyo objetivo sea obtener reglas debe determinar el esquema de representación utilizado para codificar cada una de las soluciones, los operadores genéticos y la función de adaptación. En los siguientes apartados explicaremos cada uno de estos aspectos, y la utilización de AGs en tareas de minería de datos.

### 1.4.1 Esquema de representación

El aspecto más determinante de cualquier AG de inducción de reglas es el esquema de codificación utilizado. En este aspecto, las distintas propuestas en la bibliografía especializada se agrupan en torno a dos enfoques [CHHM01]:

- El enfoque “*Cromosoma = Regla*”, donde cada individuo codifica una única regla.
- El enfoque “*Cromosoma = Base de Reglas*”, o enfoque Pittsburgh, en el que cada individuo codifica un conjunto de reglas. GIL [Jan93b] y GA-MINER [FR95] o dAR [AC02] son ejemplos de AGs de este tipo.

A su vez, dentro del enfoque “*Cromosoma = Regla*” existen tres propuestas genéricas:

- El enfoque Michigan en el que cada individuo codifica una única regla. Son sistemas basados en reglas, que utilizan un AG y un componente de refuerzo para aprender reglas que guían su rendimiento en un entorno determinado [Kov04]. El algoritmo XCS [Wil95] es un ejemplo de este enfoque.
- El enfoque IRL (Iterative Rule Learning) en el que cada cromosoma representa una regla, pero la solución del AG es el mejor individuo y la solución global está formada por los mejores individuos de una serie de ejecuciones sucesivas. SLAVE [GP99], MOGUL [CDHL99] y la propuesta de Carvalho y Freitas [CF02] son AGs de este tipo.
- El enfoque “cooperativo-competitivo”, en el que la población completa o un subconjunto de ella codifica la base de reglas. REGAL [GN95], GA-PVMINER [ALF99] o GLOWER [DCP00] son ejemplos de AGs con este tipo de representación.

La elección del esquema de representación depende, entre otros aspectos, de la tarea a realizar por el algoritmo de minería de datos y, por tanto, del tipo de regla a descubrir.

Si el objetivo es determinar un conjunto de reglas de clasificación, se debe evaluar el comportamiento del conjunto de reglas al completo más que la calidad de una regla individual. El esquema de representación que, a primera vista, parece más adecuado es el enfoque “*Cromosoma = Base de Reglas*” que considera la interacción entre las reglas. GABIL [DSG93] y GIL [Jan93b] son ejemplos de AGs para clasificación que utilizan este esquema de representación. No obstante, este enfoque también tiene problemas puesto que implica el uso de individuos con una longitud superior (y a menudo variable) lo que provoca un incremento del costo computacional del algoritmo y la modificación de los operadores genéticos. Esto hace que dentro del campo de la clasificación también se hayan diseñado AGs con el enfoque “*Cromosoma = Regla*”, como COGIN [GD93] y REGAL [GN95], que utilizan individuos con una sintaxis más reducida simplificando el diseño de los operadores genéticos. Este enfoque tiene dos inconvenientes: la dificultad del cálculo del valor de la función de adaptación, ya que cada regla se evalúa individualmente y es difícil determinar la calidad del conjunto de reglas al completo; y por otra parte, puesto que el objetivo es obtener un conjunto de reglas, el AG no debería converger hacia un único individuo. Para evitar esto se necesita alguna técnica de nichos [BBM93] que fomente la existencia de individuos distintos dentro de la población.

Por el contrario, en procesos de descubrimiento de reglas de asociación y de descripción de subgrupos, es más adecuado el enfoque “*Cromosoma = Regla*”, ya que el objetivo suele ser encontrar un conjunto reducido de reglas en las que la calidad de cada regla se evalúa de forma independiente al resto.

Una vez descritos los dos enfoques genéricos de codificación de reglas, explicaremos de forma detallada distintos esquemas de codificación del antecedente y consecuente en función del tipo de regla a obtener. Para ello, en gran parte de la descripción nos centraremos en la codificación de una única regla, de forma que los conceptos introducidos se puedan adaptar a los distintos enfoques de codificación mencionados.

Una regla se puede describir de forma genérica de la siguiente forma:

SI <cond.1> Y <cond.2> Y ... Y <cond.N> ENTONCES <consecuente>

donde:

- Las condiciones expresadas en el antecedente pueden implicar atributos nominales o numéricos. Si los atributos son numéricos, se puede utilizar un proceso de discretización que establezca una correspondencia entre valores e intervalos, o un proceso de agrupamiento, entre otras soluciones.
- El número de condiciones que aparecen en el antecedente es variable.
- Cada una de las condiciones puede estar formada a su vez por una disyunción de condiciones individuales.

- Si la regla es de clasificación, en el consecuente sólo aparecerá una condición que implica a un atributo, el atributo de clase o atributo objetivo, y éste no puede estar contenido en el antecedente. Una regla que determina dependencias funcionales se puede considerar como una generalización de una regla de clasificación, salvo que en el consecuente puede aparecer más de un atributo objetivo. Si la regla es de asociación no tiene porqué existir necesariamente una diferenciación entre atributos predictivos y objetivo, pudiendo aparecer más de una condición en el consecuente.

Dado que el antecedente de una regla está formado por un número de condiciones variable, la representación del mismo en un individuo lleva, de forma inmediata, a un esquema de codificación de longitud variable. Así, si restringimos el antecedente de las reglas a descubrir a una conjunción de atributos, un posible esquema de codificación puede estar formado por un número variable de parejas atributo-valor. Para cada una de estas parejas, si el atributo es nominal el valor se codifica mediante un número entero; si el atributo es numérico se puede codificar en binario el valor numérico correspondiente, o discretizar el dominio y asignar un entero a cada uno de los intervalos. En este último caso, el uso de una representación no binaria permite el tratamiento uniforme de los atributos numéricos frente a los nominales. En cualquier caso, se debe tener en cuenta que el uso de reglas de longitud variable obliga a la modificación del operador de cruce para asegurar que los descendientes resultantes sean individuos válidos.

Para evitar esto, se pueden codificar todos los atributos, pero estableciendo una marca especial que indique que la variable correspondiente no interviene en la regla. De esta forma, una posible estrategia de codificación puede representar el antecedente mediante una cadena de números enteros de longitud N, siendo N el número total de atributos, como se muestra en la Figura 1.4 con una regla para el problema *Winconsin Diagnostic Breast Cancer* cuyas variables son numéricas y se ha realizado una discretización del dominio. En esta codificación, se marcan con un 0 las variables que no intervienen en la regla. Al estar las variables siempre alineadas, el operador de cruce produce descendientes válidos sin necesidad de modificar el operador [NFL99].

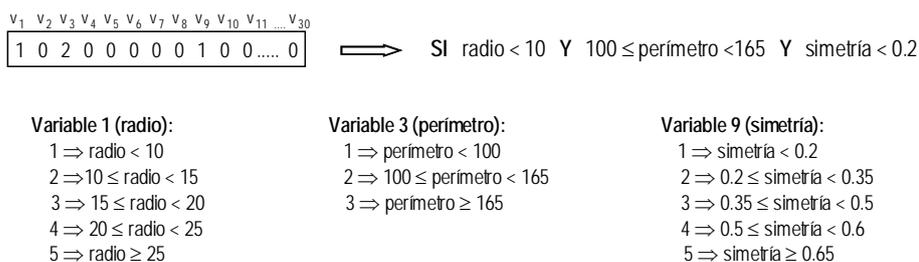


Figura 1.4. Ejemplo de codificación entera de longitud fija para el antecedente de una regla.

Si queremos incluir en el antecedente una condición compuesta por una conjunción entre atributos y varias disyunciones sobre los valores del atributo (es decir, que cada atributo pueda tomar varios valores dentro del antecedente de la regla, construyendo reglas en formato *DNF*), se puede optar por un esquema de codificación binario, en el que por cada atributo se almacene un bit para cada uno de los valores que puede tomar, de forma que si el bit correspondiente tiene valor 0 indica que no pertenece a la condición y si tiene valor 1 que sí pertenece [DSG93]. Si en un individuo todos los bits correspondientes a un atributo tienen valor 1 indican que dicha variable no es relevante para la información aportada en la regla (cualquier valor de la variable verifica la condición de la regla), por lo que esta variable se ignora.

Como vemos, existen bastantes opciones para representar el antecedente y se optará por una u otra en función del problema y de las preferencias de implementación.

Respecto al consecuente, si el objetivo del proceso de minería de datos es extraer reglas de clasificación, la codificación de la clase se puede realizar bajo alguno de estos enfoques:

- Codificarlo en el genoma del individuo [DSG93] de forma que también pueda evolucionar.
- Asociar todos los individuos de la población con la misma clase y ejecutar el algoritmo tantas veces como clases distintas existan [Jan93b].
- Elegir la clase más adecuada para el antecedente de la regla de forma determinística: la clase que tenga más representantes en el conjunto de ejemplos que verifican el antecedente de la regla [GN95] o la clase que maximiza la función de adaptación del individuo [NFL99].

La primera y tercera opciones tienen la ventaja de permitir que los individuos de la población representen reglas de distintas clases y no sea necesario realizar múltiples ejecuciones del algoritmo evolutivo para descubrir reglas de las distintas clases.

Si el objetivo es descubrir reglas para expresar dependencias funcionales, es necesario representar en el consecuente no sólo una variable (el atributo objetivo) sino más de una, por lo que en ocasiones, es conveniente optar por un esquema de codificación del consecuente que represente una conjunción de pares atributo-valor con longitud variable [ALF00].

### 1.4.2 Operadores genéticos

Además de los operadores genéticos clásicos —adaptados al esquema de representación utilizado—, existen distintas propuestas de operadores genéticos diseñados específicamente para AGs cuyo objetivo es el descubrimiento de reglas.

Para AGs con el esquema de representación “*Cromosoma = Regla*”, es necesario evitar la convergencia de la población a un individuo particular, ya que un solo individuo no es una solución válida para el problema. Esto se resuelve en REGAL [GN95] mediante un operador de selección denominado *sufragio universal* que elige los individuos que deben participar en la recombinación mediante una elección por sufragio de los ejemplos de entrenamiento. Para ello, cada ejemplo vota por la regla que determina la zona del espacio de búsqueda en la que está incluido, de forma proporcional a la medida de adaptación de la regla. Es una estrategia de *nichos* que potencia la evolución de diferentes reglas que cubren diferentes zonas del espacio de búsqueda.

Una de las operaciones más adecuadas en el proceso de descubrimiento de reglas es la operación de generalización-especialización que se lleva a cabo, básicamente, eliminando o añadiendo condiciones en el antecedente. En la bibliografía especializada existen propuestas en este sentido integradas en operadores de cruce, de mutación o bien operadores diseñados específicamente para ello.

En un AG en el que evolucionan reglas con distintos consecuentes no es conveniente intercambiar material genético entre individuos (reglas) con consecuentes distintos, pues se considera que es información que no está relacionada. Esto se puede solucionar con un operador de cruce que opere sólo dentro de subpoblaciones, entendiendo que una subpoblación está formada por los individuos que representan reglas con igual consecuente [ALF00].

### 1.4.3 Función de adaptación

En el proceso de descubrimiento de reglas se intenta conseguir reglas con capacidad predictiva alta, comprensibles e interesantes. Esto se puede conseguir en el contexto evolutivo mediante una combinación lineal con pesos de estas tres medidas [NFL99], mediante una matriz de confusión, o bien mediante un AG con enfoque multiobjetivo [Deb01] que orienta el proceso evolutivo hacia la búsqueda de un conjunto de soluciones no dominadas en los distintos objetivos marcados. Las soluciones no dominadas son aquellas para las que no existe ninguna otra solución candidata que las supere en todos los objetivos marcados.

Algunas de las propuestas descritas en esta sección corresponden a algoritmos de descubrimiento de conocimiento con capacidad para trabajar sólo con bases de ejemplos de tamaño moderado, es decir, no son escalables respecto al tamaño del conjunto de ejemplos a explorar. Afortunadamente, surgen, de forma natural, propuestas que aprovechan el procesamiento paralelo en el contexto de los AGs para tareas de minería de datos que trabajen con grandes volúmenes de datos [FL98].

En la minería de datos, la etapa con mayor costo computacional de cualquier algoritmo evolutivo es la correspondiente a la evaluación de los individuos, por lo que es ésta la operación que se paraleliza cuando existe procesamiento paralelo. Los sistemas GA-MINER [FR95] y GA-PVMINER [ALF00] son ejemplos de AGs paralelos en minería de datos.

#### 1.4.4 Aplicaciones de los algoritmos genéticos en Minería de Datos

Los AGs son métodos de búsqueda globales adaptables, robustos y eficientes, adecuados para situaciones en las que el espacio de búsqueda es grande. Optimizan una *función de adaptación*, para llegar a una solución óptima utilizando ciertos operadores genéticos. Los AGs multiobjetivo tratan de encontrar soluciones óptimas a problemas con múltiples funciones objetivo o restricciones. La solución a esto es un conjunto de soluciones *Pareto-óptimo* en el que no existe ninguna solución en el espacio de búsqueda que domine a ningún miembro de este conjunto. Estas soluciones se utilizan para minería de reglas, que a menudo abarca un espacio de búsqueda grande con un enorme número de atributos y registros. Se realiza una búsqueda global con múltiples objetivos, en la que participan una combinación de factores como la precisión predictiva, la comprensibilidad y el interés.

Para evitar la generación de cromosomas no válidos al aplicar el operador de cruce, se deben alinear los valores de los atributos. Los atributos categóricos se pueden representar por su valor, mientras que los atributos continuos se codifican mediante una representación binaria. Se pueden utilizar los mismos operadores de selección y mutación que en los AGs estándares y, aunque se pueden utilizar operadores de cruce convencionales, se puede recurrir a operadores de cruce generalizados o especializados que involucren operaciones lógicas AND/OR sobre el segmento adecuado de los cromosomas de los padres.

La tarea de minería de datos descriptiva a la que más se han aplicado los AGs es la extracción de reglas de asociación [AIS93, FMMT96, HKC99, LHL05]. Lopes y otros [LPVP99] evolucionan reglas de asociación del tipo IF  $c$  THEN  $p$ , que proporcionan un alto grado de precisión y cobertura. Mientras que la precisión de una regla mide su grado de confianza, su cobertura se interpreta como la inclusión comprensiva de todos los registros que satisfagan la regla. Los trabajos de Hong y otros [HKC99, LHL05] inciden en la extracción de reglas de asociación con múltiples niveles de conceptos.

### 1.5 Reglas difusas y extracción de conocimiento

---

Los conjuntos difusos son el componente más utilizado de la computación flexible. La modelización del conocimiento cualitativo e impreciso, así como la transmisión y tratamiento de la incertidumbre en distintas etapas es posible mediante el uso de conjuntos

difusos. Aquí incluimos una visión de la literatura disponible sobre el uso de conjuntos difusos en minería de datos [MPM02].

El KDD está relacionado fundamentalmente con la identificación de patrones interesantes y su descripción de manera concisa y significativa [FPS96]. A pesar de la creciente versatilidad de los sistemas de descubrimiento de conocimiento, tienen un importante componente de interacción humana que es inherente a todo proceso de representación, manipulación y procesamiento del conocimiento. Los conjuntos difusos manejan de forma natural conocimiento de dominio lingüístico y permiten la obtención de soluciones más interpretables.

La teoría de conjuntos difusos está cobrando una importancia creciente en el ámbito de la minería de datos [Yag96]. Se han implementado diversos visualizadores de datos utilizando la teoría de conjuntos difusos [Bal96] para facilitar el manejo simultáneo de diferentes tipos de variables (datos categóricos, simbólicos y numéricos) en el análisis de datos del mundo real en minería de datos. Pedrycz [Ped98b] discute algunos recursos computacionales constructivos y dirigidos por conjuntos difusos y establece la relación entre la minería de datos y modelización difusa.

Así pues, el uso de la lógica difusa en minería de datos viene determinado por los siguientes motivos:

- Cualquier proceso de minería de datos tiene como objetivo principal la identificación de patrones interesantes y la descripción de los mismos de una forma concisa y con significado. Los modelos difusos representan una descripción de los datos orientada al usuario a través de un conjunto de reglas cualitativas que establecen relaciones significativas y útiles entre variables. Los conjuntos difusos permiten establecer límites flexibles entre los distintos niveles de significado, sin ignorar ni enfatizar en exceso los elementos cercanos a las fronteras, de igual forma que ocurre en la percepción humana. En todo proceso de extracción de conocimiento hay un componente de interacción humana y los conjuntos difusos permiten representar el conocimiento de forma lingüística, incorporar conocimiento previo de forma fácil y proporcionar soluciones interpretables.
- En muchos algoritmos de minería de datos y, especialmente, en la evaluación de los patrones extraídos, aparece el concepto de interés [Fre99], que agrupa distintas características como validez, novedad, utilidad y simplicidad, y que puede cuantificarse de manera muy conveniente a través de conjuntos difusos. De forma adicional, algunos algoritmos incorporan, como parámetro adicional de interés, una medida de diferenciación difusa entre un patrón descubierto y un vocabulario definido por el usuario.

A continuación se repasa la utilización de la lógica difusa en minería de datos, y se destaca la de sistemas evolutivos difusos.

### **1.5.1 Aplicaciones de la lógica difusa en minería de de datos**

La lógica difusa se ha aplicado en tareas de agrupamiento, clasificación, reglas de asociación, dependencias funcionales o sumarización. A continuación se indican estas aplicaciones de los conjuntos difusos de acuerdo con las diferentes funciones de la minería de datos que se modelan.

#### ***1.5.1.1 Agrupamiento***

En este campo, los algoritmos de minería de datos intentan diferenciar entre grandes volúmenes de datos mostrando información útil en forma de nuevas relaciones, patrones o grupos (clusters) para la toma de decisiones del usuario [PF91]. Los conjuntos difusos aportan una búsqueda a través de los datos que está orientada y especificada en términos lingüísticos, y que ayuda a descubrir dependencias entre los datos en un formato cualitativo o semi-cualitativo [Tur98]. En minería de datos, el interés suele centrarse en el descubrimiento de la estructura y una posible cuantificación de las dependencias funcionales existentes en el mismo. Esto ayuda a evitar la búsqueda de patrones sin sentido o triviales en una base de datos. Russell y Lodwick [RL99][M65] han explorado los métodos de agrupamiento difusos para extracción de información en bases de datos de clientes de telecomunicaciones para ganar cuota de mercado entre los clientes residenciales y empresariales. Además, el uso de conjuntos difusos permite incluir fácilmente información contextual e incluso orientar el proceso de búsqueda con información lingüística, como en el trabajo de Pedrycz [Ped96a].

#### ***1.5.1.2 Computación granular***

En minería de datos es importante centrar el objetivo, porque hay demasiados atributos y valores a tener en cuenta, y esto puede provocar una explosión combinatoria. La mayoría de los enfoques de minería de datos no supervisados intentan centrarse en atributos reconociendo primero cuales son las características más interesantes. Mazlack [Maz99] sugiere un enfoque para reducir progresivamente el conjunto de datos particionando y eliminando los atributos de menos importantes para reducir la disonancia dentro de las particiones. Se utiliza el mismo enfoque tanto para datos nítidos como imprecisos, y trabaja reduciendo de forma progresiva la disonancia, lo que da lugar a un aumento de la información útil. El objetivo es generar trozos de información coherente y comprensible eliminando los atributos sin interés. Se utiliza una medida de distancia combinada para tener en cuenta los distintos tipos de atributos de forma simultánea, evitando tener que utilizar alguna estructura taxonómica.

La computación granular [Zad97] es útil para encontrar patrones significativos en los datos expresando y procesando trozos de información (gránulos). Estos son considerados esenciales en todas las actividades cognitivas orientadas al establecimiento de patrones significativos en los datos. El aumento de la granularidad reduce la distinción entre atributos, por lo que se pierde información útil, mientras que un grano más fino supone dificultar la partición. El concepto de computación granular nos permite concentrar todos los esfuerzos computacionales en ciertos subconjuntos específicos y orientados al problema de una base de datos completa. También ayuda en la división del esfuerzo de computación en distintas subtarefas, con lo que se obtiene un efecto de modularización.

### **1.5.1.3 Clasificación**

Los conjuntos difusos son muy apropiados para flexibilizar algunos algoritmos de clasificación clásica, utilizando regiones más flexibles para árboles de decisión, redes neuronales, máquinas de vectores soporte, etc. Por ejemplo, [Jan98] presenta árboles de decisión donde las particiones se realizan a través de funciones de pertenencia difusas y no clásicas como ocurre en los árboles de decisión tradicionales. Esto permite que un ejemplo caiga por varias ramas del árbol, ponderándose las predicciones de las hojas de cada rama y dando una estimación de la clase más robusta.

### **1.5.1.4 Reglas de asociación**

Un área importante de la investigación en minería de datos trata con el descubrimiento de reglas de asociación [AIS93], que describe relaciones de asociación interesantes entre los distintos atributos. La afinidad de la lógica difusa con la forma en que se representa el conocimiento humano hace que su uso en las reglas de asociación con variables cuantitativas facilite la legibilidad de las mismas, su diseño, la incorporación de conocimiento cualitativo sobre el problema, el tratamiento de valores perdidos y de clases con límites no muy bien definidos, así como el procesamiento del ruido en las variables que son resultado de medidas reales [AC98].

En [CW02] se propone un algoritmo de extracción de reglas de asociación difusas con modificadores lingüísticos que hacen que el conocimiento extraído sea aún más comprensible y cercano al usuario, enriqueciendo la semántica de las reglas de asociación y haciendo que éstas sean más granulares.

En algunas propuestas, se introduce conocimiento sobre el problema en la definición inicial de los conjuntos difusos [AC99] y otras proponen un algoritmo de agrupamiento para establecer la definición de los mismos [FWS+98]. Hong y otros propusieron un algoritmo difuso de minería de datos para extraer reglas difusas de datos cuantitativos [HKC99], transformando cada elemento cuantitativo en un conjunto difuso y utilizando operaciones difusas para encontrar reglas difusas.

### **1.5.1.5 Dependencias funcionales**

Dentro de este campo se ha utilizado la inferencia difusa para generalizar tanto la inferencia imprecisa como la precisa basada en dependencias funcionales entre variables. De forma similar las bases de datos relacionales difusas generalizan a las clásicas permitiendo el almacenamiento y recuperación de información difusa [HS96]. Las dependencias funcionales son interesantes para la extracción de conocimiento puesto que permiten expresar de forma condensada ciertas propiedades del mundo real que son válidas sobre determinada base de datos. Estas propiedades se pueden utilizar en varias aplicaciones como en ingeniería inversa u optimización de consultas. En la bibliografía especializada existen distintas propuestas para extraer dependencias funcionales extendidas representadas mediante reglas difusas con variables lingüísticas [BPU99].

### **1.5.1.6 Sumarización de datos**

En este área el objetivo es proporcionar al usuario información comprensible para captar la esencia de una gran cantidad de información en una Base de Datos. La lógica difusa en esta tarea constituye una herramienta para representar conceptos difusos, jerarquías difusas [LK97] y además facilita la interacción del usuario en sumarios lingüísticos y conceptos que involucran combinaciones complicadas de atributos.

Se obtienen resúmenes lingüísticos de grandes conjuntos de datos como proposiciones cuantificadas lingüísticamente con un grado de validez [Yag91]. Esto corresponde con el criterio de preferencia que participa en la tarea de minería.

Chiang y otros [CCW00] han utilizado resúmenes lingüísticos difusos para la tarea de minería sobre series temporales. El sistema proporciona interacción con el usuario mediante una pantalla gráfica, para ayudarle a preprocesar una base de datos y determinar qué conocimiento podría descubrirse. El modelo se utiliza para predecir niveles de utilización en línea de diferentes recursos, incluida la CPU y los dispositivos de almacenamiento.

## **1.5.2 Sistemas evolutivos difusos en minería de datos**

Como hemos visto en la Sección 1.3.3, la lógica difusa es una herramienta que permite representar conceptos de forma expresiva y fácilmente entendible para el usuario, es decir, de forma lingüística. Esta herramienta se sitúa, por tanto, en el nivel de representación y se puede utilizar en combinación con otras técnicas y en esta sección estudiaremos la combinación de la lógica difusa con algoritmos evolutivos para la extracción de reglas de asociación.

Los procesos de descubrimiento evolutivo de reglas de asociación difusas se pueden agrupar en torno a tres enfoques:

- Algoritmos evolutivos que sólo evolucionan las reglas difusas, y utilizan funciones de pertenencia definidas por el usuario. Este enfoque permite incorporar el conocimiento del dominio del usuario en la especificación de las funciones de pertenencia.
- Algoritmos evolutivos que evolucionan sólo aspectos relacionados con las funciones de pertenencia, como el número de funciones de pertenencia para cada atributo, la forma de estas funciones de pertenencia, etc.
- Algoritmos evolutivos que evolucionan tanto las reglas difusas como las funciones de pertenencia. Esto se puede realizar de dos formas distintas: utilizando individuos que incluyan los aspectos de las funciones de pertenencia junto con los valores de los atributos, o individuos distintos para los valores de los atributos y para los parámetros de las funciones de pertenencia, lo que implicaría la evolución paralela de ambas poblaciones de individuos.

En [CHHM01] se puede encontrar una revisión exhaustiva de los sistemas evolutivos difusos encuadrados en los distintos enfoques.

Nos centraremos en varios aspectos importantes relacionados con la utilización de AGs para el descubrimiento de reglas de asociación difusas: el esquema de representación de los individuos, los operadores genéticos y la función de adaptación.

#### **1.5.2.1 Esquema de representación**

Para la representación de los individuos, si partimos de una partición difusa predefinida por el usuario se pueden utilizar los mismos esquemas de codificación que para reglas no difusas. Si se aprenden también las funciones de pertenencia, el esquema de codificación debe incluir su representación. En este caso, podemos optar por incluir las características de las funciones de pertenencia en la codificación de los individuos, o codificarlas de forma independiente en otro individuo que evolucione de forma separada.

En [MVFN01] se detalla una forma de codificar las funciones de pertenencia utilizando un individuo separado dividido en  $K$  elementos, donde  $K$  es el número de atributos que se tratarán como variables lingüísticas y de los cuales se va a aprender las funciones de pertenencia. Cada elemento consta de cuatro genes que definen colectivamente tres funciones de pertenencia (bajo, medio y alto) para el atributo correspondiente (ver Figura 1.5). Cada gen se utiliza para especificar las coordenadas de dos vértices del trapecio que pertenecen a un par de funciones de pertenencia adyacentes.

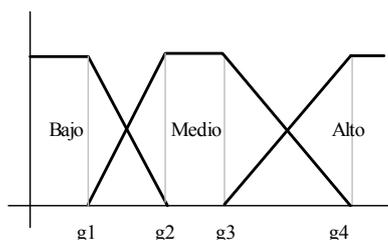


Figura 1.5. Definición de tres funciones trapezoidales de pertenencia mediante cuatro genes.

Esta representación tiene distintas ventajas: reduce el espacio de búsqueda del AG, ahorra tiempo de procesamiento, fuerza a cierto solapamiento entre funciones de pertenencia adyacentes y garantiza que, para cada valor original del atributo continuo, la suma de sus grados de pertenencia a los tres valores lingüísticos sea 1.

### 1.5.2.2 Operadores genéticos

Para la tarea de descubrimiento de reglas de asociación difusas, se pueden utilizar operadores genéticos clásicos además de los descritos en la Sección 1.4.1, adaptándolos a las características de la codificación utilizada para la representación de los individuos.

### 1.5.2.3 Función de adaptación

A la hora de evaluar las reglas difusas obtenidas, se deben tener en cuenta aspectos como la precisión predictiva, la comprensibilidad y el interés. Para medir la precisión predictiva de una regla difusa debemos calcular el grado de pertenencia de cada ejemplo al antecedente de la regla utilizando la t-norma y t-conormas elegidas para representar los operadores de intersección y unión difusas. Una vez calculado el grado de pertenencia del ejemplo, la precisión predictiva del individuo (regla difusa) se puede calcular como [RFP02]:

$$\text{Precisión} = \frac{\text{PredCorr} - \frac{1}{2}}{\text{TotPred}} \quad (1.16)$$

donde *PredCorr* (número de predicciones correctas) es la suma de los grados de pertenencia del antecedente de la regla para todos los ejemplos que tienen el valor predicho por la regla, y *TotPred* (numero total de predicciones) es la suma de los grados de pertenencia al antecedente para todos los ejemplos.

Esta fórmula es una versión difusa de la medida de precisión utilizada por algunos algoritmos de minería de datos [NFL99]. El objetivo al restar  $\frac{1}{2}$  a *CorrPred* en el numerador es penalizar las reglas que son demasiado específicas sin tener una influencia significativa en reglas más generales.

La precisión predictiva de una regla difusa también se puede medir calculando el factor de confianza, *FC*, a partir de las medidas *PV* (Positivos Verdaderos, suma del grado de

pertenencia al antecedente de los ejemplos pertenecientes a la clase indicada en el consecuente),  $PF$  (Positivos Falsos, suma del grado de pertenencia al antecedente de los ejemplos pertenecientes a otra clase distinta a la indicada en el consecuente),  $NF$  (Negativos Falsos, suma del grado de pertenencia de los ejemplos a la zona del espacio no delimitada por el antecedente, pero que satisfacen el consecuente) y  $NV$  (Negativos Verdaderos, suma del grado de pertenencia a la zona no delimitada por el antecedente de los ejemplos no pertenecientes a la clase indicada en el consecuente). El factor de confianza se calcula con la siguiente expresión:

$$FC = \frac{PV}{PV + PF} \quad (1.17)$$

También se puede extender la función de adaptación con una medida de comprensibilidad, que mida la simplicidad de la regla. Algunas funciones de adaptación que tienen en cuenta tanto la precisión predictiva como la comprensibilidad de una regla se describen en [FR95, GN95, Jan93b].

Otro criterio a considerar es el interés. En [NFL99] se propone una función de adaptación que tiene en cuenta de forma objetiva el grado de interés de una regla mediante una suma ponderada cuyos pesos son especificados por el usuario. Una forma de considerar las medidas de interés subjetivas en la función de adaptación se puede encontrar en [RFP02], donde se considera interesante una regla cuando es sorprendente para el usuario, en el sentido de representar conocimiento que no sólo es desconocido para el usuario, sino que también contradice las creencias originales del usuario.

En la Sección 1.2.2 se analizan con detalle las medidas de calidad más adecuadas para nuestro objetivo en esta memoria, el desarrollo de algoritmos de descubrimiento de subgrupos.



## Capítulo 2

# Un modelo evolutivo de extracción de reglas de descubrimiento de subgrupos

---

En este capítulo describimos en primer lugar nuestra propuesta de un modelo evolutivo de extracción de reglas para descubrimiento de subgrupos, analizando a continuación los componentes del modelo para seleccionar los que permitan obtener mejores resultados. Se presenta después la comparación de los resultados de la propuesta con los obtenidos por otros algoritmos clásicos de descubrimiento de subgrupos. Por último, se detalla la aplicación del modelo a dos problemas reales y se comentan sus resultados.

## 2.1 Descripción del modelo

---

Se presenta aquí el modelo evolutivo para la extracción de reglas difusas para la tarea de descubrimiento de subgrupos, denominado SDIGA (Subgroup Discovery Iterative Genetic Algorithm) [DGHM07]. En la tarea de descubrimiento de subgrupos hay un conjunto de variables descriptivas y una única variable objetivo que describe los subgrupos. Como el objetivo es obtener un conjunto de reglas que describan subgrupos para todos los valores de la variable objetivo, el AG presentado en esta propuesta descubre reglas difusas con el consecuente prefijado a uno de los valores posibles de la variable objetivo. De esta forma, cada ejecución de SDIGA obtiene un conjunto de reglas correspondiente al valor especificado para la variable objetivo, y el algoritmo debe ser ejecutado para cada uno de los valores posibles de la variable objetivo. Por tanto, cada ejecución de SDIGA obtiene un conjunto de reglas para un valor específico de la variable objetivo.

Se trata de un modelo evolutivo que sigue el enfoque IRL, anteriormente descrito. Por lo tanto, el AG incluido en la propuesta devuelve como solución una sola regla, pero el modelo devuelve el conjunto de soluciones obtenidas en sucesivas ejecuciones del AG. El modelo consta de dos componentes fundamentales, que se describirán en las siguientes secciones:

- El núcleo de SDIGA es un AG que utiliza una etapa de post-procesamiento basada en una búsqueda local. El AG híbrido extrae una sola regla sencilla e interpretable con unos niveles de completitud (grado de cobertura de la regla sobre los ejemplos de la clase) y confianza (precisión de la regla) adecuados. El consecuente de la

regla está compuesto por una sola variable (la propiedad de interés para el usuario, o variable objetivo) La etapa de post-procesamiento consiste en un proceso de búsqueda local (un proceso de ascensión de colinas) que incrementa la generalidad de la regla obtenida.

- Este AG híbrido se incluye en un proceso iterativo para la extracción de un conjunto de reglas difusas de descripción de subgrupos soportado por zonas distintas (no necesariamente disjuntas) del espacio de búsqueda. Obtenemos un conjunto de soluciones generadas en ejecuciones sucesivas del AG para el mismo valor de la variable objetivo.

El funcionamiento del modelo se esquematiza en la Figura 2.1. Se parte de un conjunto de reglas vacío. Se ejecuta el AG para el atributo seleccionado, y a continuación se aplica la búsqueda local. Si la regla cumple las condiciones (cubrir ejemplos no cubiertos por otras reglas y alcanzar un umbral establecido de confianza) se añade al conjunto y se marcan los ejemplos que cubre. Por último, lo anterior se incluye en un proceso iterativo para extraer reglas mientras se cubran nuevos ejemplos y las reglas generadas superen el umbral de confianza.

```

INICIO
  REPETIR
    Regla R ← AG (AtOBJ)
    R ← Optimización_local (R)
    Si R cumple las condiciones
      Añadir la regla R al conjunto
      Anotar ejemplos cubiertos por R
  MIENTRAS condición_parada = Falso
FIN

```

Figura 2.1. Esquema de funcionamiento del modelo.

El AG tiene como objetivo descubrir reglas de descripción de subgrupos para un único atributo objetivo cuyo valor está prefijado; es decir, el consecuente de la regla estará formado por un único atributo, cuyo valor será fijo en cada ejecución del AG. Por lo tanto, como el objetivo es obtener un conjunto de reglas para cada valor del atributo objetivo, el AG deberá ejecutarse tantas veces como valores distintos tenga el atributo objetivo.

Como se describió al introducir la tarea de descubrimiento de subgrupos, el objetivo no es obtener un conjunto de reglas que cubran toda la población (instancias del conjunto de datos), sino reglas individuales que, dada una propiedad de los datos, describan subgrupos de mayor interés para el usuario.

Cada solución candidata se codifica según el esquema "Cromosoma = Regla" que representa sólo el antecedente de la regla en el cromosoma (ya que todos los individuos de la población son asociados con el mismo valor de la variable objetivo). El algoritmo se puede utilizar para extraer dos tipos de reglas: canónicas o en forma normal disyuntiva (DNF). Para las reglas canónicas, el antecedente de una regla está compuesto por una

conjunción de pares valor-variable. Por otra parte, una regla DNF ofrece una estructura más flexible a las reglas, permitiendo a cada variable para tomar más de un valor, y facilitando la extracción de reglas más generales.

En esta clase de regla difusa, la lógica difusa mejora la interpretabilidad de las reglas extraídas debido a la utilización de una representación del conocimiento más cercana al experto, permitiendo además la utilización de variables numéricas sin necesidad de realizar una discretización previa. Los conjuntos difusos que corresponden con las etiquetas lingüísticas ( $LL_m^1, \dots, LL_m^l$ ) se definen mediante las correspondientes funciones de pertenencia que pueden ser especificadas por el usuario o definidas mediante una partición uniforme si no está disponible el conocimiento del experto. En este algoritmo, utilizamos particiones uniformes con funciones de pertenencia triangulares, como se muestra en la Figura 2.2 para una variable con 5 etiquetas lingüísticas. La propuesta se puede utilizar, como se ha mencionado antes, con un conjunto predefinido de etiquetas lingüísticas (y los correspondientes conjuntos difusos). Esta partición difusa se puede definir mediante un enfoque heurístico que defina los conjuntos difusos de forma que cada uno de ellos cubra aproximadamente la misma cantidad de datos, si el experto lo desea. Pero debe considerarse que, dependiendo del problema, se podría reducir la interpretabilidad de las reglas difusas resultantes. Es más, si es necesario, se podría llevar a cabo un análisis preliminar de los datos para detectar valores anómalos en los datos antes de determinar las particiones difusas. De esta forma, se puede realizar un análisis específico de estos valores anómalos de forma que las particiones difusas (eliminando estos valores) no queden sesgados por los mismos.

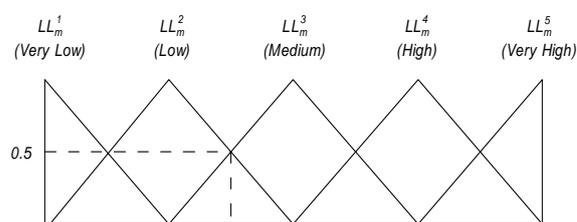


Figura 2.2. Ejemplo de partición difusa para una variable continua.

Debe resaltarse que el AG híbrido está incluido en un proceso iterativo para la extracción de reglas diferentes en sucesivas ejecuciones del algoritmo. Por esta razón, cuando termina una ejecución del AG híbrido y se obtiene la regla difusa, los ejemplos positivos de la regla (ejemplos cubiertos) son marcados para evitar la obtención de una nueva regla que cubra exactamente los mismos ejemplos en las siguientes ejecuciones del AG. En la primera iteración, ninguno de los ejemplos está cubierto, porque aún no se ha extraído ninguna regla.

Esta forma de dirigir la evolución del AG para la obtención de reglas difusas distintas –aunque puede que solapadas– se explica detalladamente en la siguiente

subsección. A continuación se describe detalladamente el AG y el modelo iterativo de extracción de reglas.

### 2.1.1 Descripción del AG Híbrido

Se trata de un AG de extracción de reglas de difusas que intenta optimizar la precisión, generalidad e interés de las reglas difusas. El algoritmo incluye una medida de interés objetiva e incorpora conocimiento del usuario y del dominio en la definición previa del conjunto de términos lingüísticos para las variables continuas. La utilización de la lógica difusa permite el tratamiento de las variables continuas sin tener que discretizarlas previamente, además de conseguir reglas con una mayor interpretabilidad.

Se incorpora una etapa de post-procesamiento, un proceso de ascensión de colinas, que optimiza cada regla obtenida con el objetivo de incrementar la completitud manteniendo el grado de confianza de la misma. Para ello, en cada iteración se determina la variable tal que, al eliminarla aumenta en mayor grado la completitud de la regla resultante, obteniendo así una regla más general. Finalmente, la regla optimizada sustituirá a la original sólo si supera la confianza mínima.

A continuación se describen con más detalle los elementos del AG.

#### 2.1.1.1 Esquema de representación

La interpretabilidad es crucial el campo de minería de datos donde el conocimiento debe registrarse de la base de datos y ser representado de forma comprensible, o para sistemas soporte a la decisión donde el proceso de razonamiento debería ser transparente para el usuario. De hecho, la utilización de variables lingüísticas y términos lingüísticos en un proceso descubrimiento se ha explorado por distintos autores [INN04].

Los conjuntos difusos correspondientes a las etiquetas lingüísticas se define mediante las correspondientes funciones de pertenencia que pueden ser especificadas por el usuario o definidas mediante una partición uniforme si está disponible el conocimiento del experto (utilizando particiones uniformes con funciones de pertenencia triangulares) [Zad75].

Para describir una regla difusa, consideramos un problema de descubrimiento de subgrupos con:

- $\{X_m / m = 1, \dots, n_v\}$ , un conjunto de variables utilizadas para describir los subgrupos, donde  $n_v$  es el número de variables. Estas variables pueden ser categóricas (discretas) o numéricas (continuas);
- $\{Class_j / j = 1, \dots, n_c\}$ , un conjunto de valores de la variable objetivo, donde  $n_c$  es el número de valores;

- $\{E^k = (e_1^k, e_2^k, \dots, e_{n_s}^k, class_j) / k = 1, \dots, n_s\}$ , un conjunto de ejemplos, donde  $class_j$  es el valor de la variable objetivo para el ejemplo  $E^k$  (es decir, la clase para este ejemplo) y  $n_s$  es el número de ejemplos para el proceso de inducción descriptiva;
- $X_m : \{LL_m^1, LL_m^2, \dots, LL_m^{l_m}\}$ , un conjunto de etiquetas lingüísticas para las variables continuas. El número de etiquetas lingüísticas y la definición de los correspondientes conjuntos difusos depende de cada variable: la variable  $X_m$  tiene  $l_m$  etiquetas lingüísticas distintas para describir su dominio de forma comprensible.

Así, una regla difusa,  $R^i : Cond^i \rightarrow Class_j$ , se puede expresar como:

$$R^1 : \text{If } X_1 \text{ is } LL_1^3 \text{ and } X_7 \text{ is } LL_7^1 \text{ then } Class_j \quad (2.1)$$

donde  $LL_7^1$  es la etiqueta lingüística número 1 de la variable número 7.

También podemos utilizar reglas difusas en forma normal disyuntiva (DNF) como lenguaje de descripción para especificar los subgrupos. Las reglas DNF permiten una disyunción para los valores de cualquier variable presente en el antecedente de la regla. En este caso, una regla DNF difusa se puede expresar como:

$$R^1 : \text{If } X_1 \text{ is } LL_1^1 \text{ or } LL_1^3 \text{ and } X_7 \text{ is } LL_7^1 \text{ then } Class_j \quad (2.2)$$

Hay que resaltar que cualquier subconjunto del conjunto completo de variables (por cualquier combinación de etiquetas lingüísticas relacionadas con el operador OR) pueden tomar parte en el antecedente de la regla. De esta forma, un subgrupo es una descripción un subgrupo es una descripción compacta e interpretable de patrones de interés en los datos.

Para este tipo de regla difusa, consideramos que:

- un ejemplo  $E^k$  verifica el antecedente de una regla  $R^i$  si:

$$APC(E^k, R^i) = T(TC(\mu_{LL_1^1}(e_1^k), \dots, \mu_{LL_1^{l_1}}(e_1^k)), \dots, TC(\mu_{LL_{n_v}^1}(e_{n_v}^k), \dots, \mu_{LL_{n_v}^{l_{n_v}}}(e_{n_v}^k))) > 0 \quad (2.3)$$

donde:

- $APC$  (Antecedent Part Compatibility) es el grado de compatibilidad entre un ejemplo y el antecedente de una regla difusa, es decir, el grado de pertenencia del ejemplo al subespacio difuso delimitado por el antecedente de la regla,
- $LL_{n_v}^{l_{n_v}}$  es la etiqueta lingüística número  $l_{n_v}$  de la variable  $n_v$ ,
- $\mu_{LL_{n_v}^{l_{n_v}}}(e_{n_v}^k)$  es el grado de pertenencia del valor de la variable  $n_v$  para el ejemplo  $E^k$  al conjunto difuso correspondiente a la etiqueta lingüística  $l_{n_v}$  para esta variable ( $n_v$ ),

- $T$  es la t-norma seleccionada para representar el significado el operador AND –la intersección difusa–, en nuestro caso la t-norma mínimo, y
  - $TC$  es la t-conorma seleccionada para representar el significado del operador OR –la unión difusa– que en nuestro caso es la t-conorma máximo.
- Un ejemplo  $E^k$  está cubierto por una regla  $R^i$  si:
- $$APC(E^k, R^i) > 0 \text{ AND } E^k \in Class_j \quad (2.4)$$

Lo anterior significa que un ejemplo está cubierto por una regla si el ejemplo tiene un grado de pertenencia mayor que 0 al subespacio de entrada difuso por el antecedente de la regla difusa, y el valor indicado en el consecuente de la regla coincide con el valor de la variable objetivo para el ejemplo. Para variables categóricas, los grados de pertenencia son 0 o 1.

Uno de los aspectos fundamentales cuando se trabaja con reglas difusas es la definición de las funciones de pertenencia asociadas con los conjuntos difusos usados. Los conjuntos difusos correspondientes a las etiquetas lingüísticas para una variable lingüística  $m$ ,  $(LL_m^1 \dots LL_m^l)$ , se especifican mediante las correspondientes funciones de pertenencia que se pueden definir por el usuario o mediante una partición uniforme si no está disponible el conocimiento experto. La Figura 2.2 muestra una variable  $m$  con 5 etiquetas lingüísticas, definida mediante particiones uniformes con funciones de pertenencia triangulares.

Como ya hemos mencionado, solo el antecedente de la regla se representa en el cromosoma y todos los individuos se asocian con el mismo valor de la variable objetivo. Esta forma de codificar la variable objetivo, utilizada en algoritmos de extracción de reglas de clasificación [Jan93b], obliga a realizar múltiples ejecuciones del algoritmo evolutivo para descubrir reglas de las distintas clases. En la bibliografía especializada se han considerado otras propuestas como la codificación dentro del genoma del individuo [DSG93] o la elección determinista para cada regla del valor de la variable objetivo [GN95, NFL99]. En tareas como la que describimos, el enfoque adoptado es adecuado porque se necesita describir todos y cada uno de los valores de la variable objetivo, y las dos alternativas anteriores no aseguran la extracción de información sobre todas las clases.

Para las reglas canónicas, en las que el antecedente está compuesto por una conjunción de pares variable-valor, toda la información relacionada con una regla está contenida en un cromosoma de longitud fija con representación entera (en el que la posición  $i$ -ésima indica el valor ajustado por la variable  $i$ -ésima). El conjunto de valores posibles para las variables categóricas (o discretas) continuas se incrementa con un valor adicional que, cuando se utiliza en un cromosoma, indica que la variable correspondiente no interviene en la regla. Para las variables continuas el conjunto de valores es el conjunto de etiquetas lingüísticas determinadas de forma heurística o mediante información experta, más el valor que indica

la ausencia de la variable. La Figura 2.3 muestra un cromosoma de acuerdo con esta representación para el antecedente de la regla:

$$\text{If } X_1 \text{ is Value3 and } X_3 \text{ is } LL_3^1 \text{ then } Class_j \quad (2.5)$$

en el que  $X_1$  es una variable categórica que puede tomar tres valores y  $X_3$  es una variable continua que toma la etiqueta lingüística número 1 para esta variable. En esta regla, la variable  $X_2$  es una variable categórica con tres valores posibles, por lo que el valor 4 para esta variable indica que la variable no interviene en la regla. Tampoco la variable  $X_4$  interviene en la regla:  $X_4$  es una variable continua con cuatro etiquetas lingüísticas, y toma el valor 5 indicando a ausencia de la variable en la regla.

$X_1$	$X_2$	$X_3$	$X_4$
3	4	1	5

Figura 2.3. Esquema de codificación de una regla canónica.

Para las reglas DNF, en las que se puede indicar más de un valor para cada variable, el antecedente de una regla se representa mediante un cromosoma de longitud fija de representación binaria en el que, para cada variable se almacena un bit para cada uno de los posibles valores de la variable; de esta forma, si el bit correspondiente contiene el valor 0 indica que el valor no se utiliza en la regla, y si el bit contiene el valor 1 indica que se incluye. La Figura 2.4 muestra un cromosoma que utiliza esta representación para el antecedente de la regla:

$$\text{If } X_1 \text{ is Value1 or Value3 and } X_3 \text{ is } LL_3^1 \text{ then } Class_j \quad (2.6)$$

en la que  $X_1, X_2, X_3$  y  $X_4$  están definidas como en el ejemplo anterior.

$X_1$				$X_2$				$X_3$				$X_4$			
1	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0

Figura 2.4. Esquema de codificación de una regla DNF.

### 2.1.1.2 Función de adaptación

En este proceso de descubrimiento de reglas el objetivo es obtener reglas con una alta capacidad predictiva, y comprensibles e interesantes. Esto significa que el problema tiene varios objetivos que debemos maximizar. Para alcanzar este objetivo, el enfoque más sencillo es utilizar como único objetivo la media ponderada del conjunto de objetivos [NFL99], lo que además nos permite introducir en el proceso de generación de reglas el criterio de los expertos respecto a la importancia de los objetivos para un problema específico. Este método presenta la dificultad de determinar los valores adecuados para los pesos, lo que depende de la importancia de cada objetivo en el contexto de un problema. El

peso de un objetivo se elige en proporción a la importancia relativa del objetivo en el problema. Así, en esta propuesta se utiliza una combinación lineal ponderada. Sin embargo, debido a las diferentes características de las reglas canónicas y las reglas DNF, se utilizan diferentes expresiones.

Para las reglas canónicas, la función de adaptación se calcula de acuerdo con la expresión:

$$fitness(c) = \frac{\omega_1 \times Complejidad(c) + \omega_2 \times Confianza(c) + \omega_3 \times Interés(c)}{\omega_1 + \omega_2 + \omega_3} \quad (2.7)$$

donde la complejidad, la confianza, y el grado de interés de la regla, se definen:

- *Complejidad*. Es una medida del grado de cobertura que la regla ofrece a los ejemplos de la clase. Para promover la obtención de diferentes reglas difusas en diferentes ejecuciones del AG híbrido, en su cálculo sólo se consideran los ejemplos no marcados (es decir, los ejemplos no cubiertos por otras reglas difusas obtenidas en ejecuciones anteriores del AG). Así, la complejidad se define como el cociente entre el número de nuevos ejemplos de la clase que cubre la regla y el número de ejemplos de la clase que quedaban por cubrir:

$$Comp(R^i) = \frac{Ne^+(R^i)}{Ne_{NC}} \quad (2.8)$$

donde:

- $Ne_{NC}$  es el número de ejemplos no cubiertos por las reglas anteriores.
- $Ne^+(R^i)$  es el número de ejemplos cubiertos por la regla que no habían sido cubiertos por las reglas anteriores.

Utilizamos la expresión (2.4) para determinar cuando un ejemplo está cubierto por una regla.

Esta forma de medir la complejidad toma sentido al utilizarse el AG dentro de un proceso iterativo, con el objetivo de potenciar la obtención de reglas distintas en cada ejecución del AG. A partir de la segunda iteración se penalizan aquellas reglas que cubren ejemplos pertenecientes a las zonas delimitadas por reglas obtenidas previamente. Esta penalización no utiliza ninguna función de distancia ya que penaliza diferencias a nivel fenotípico.

- *Confianza*. La confianza de una regla es una medida estándar que determina la frecuencia relativa de los ejemplos que satisfacen tanto el antecedente como el consecuente de una regla entre aquellos que satisfacen sólo el antecedente. Se puede calcular con diferentes expresiones propuestas en la bibliografía. La expresión utilizada aquí refleja el grado con el que los ejemplos pertenecientes a la zona del espacio delimitado por el antecedente verifican la información indicada en el consecuente de la regla. Para el cálculo de este factor utilizamos una

expresión modificada de la definición de precisión aportada por Quinlan en [Qui87] que se utiliza frecuentemente en la generación de reglas difusas de clasificación [CDH98]: la suma del grado de pertenencia de los ejemplos de la clase a la zona determinada por el antecedente dividido entre la suma del grado de pertenencia de todos los ejemplos (independientemente de la clase a la que pertenezcan) a la misma zona:

$$Conf(R^i) = \frac{\sum_{E^k \in E / E^k \in Class_j} APC(E^k, R^i)}{\sum_{E^k \in E} APC(E^k, R^i)} \quad (2.9)$$

donde  $APC$  se calcula según la expresión (2.4). En el caso de reglas no difusas, los grados de pertenencia son los correspondientes a conjuntos clásicos, 0 ó 1.

- *Interés.* Para el cálculo del interés, en la práctica es adecuado utilizar los criterios objetivos como medidas que permitan seleccionar reglas potencialmente interesantes y los criterios subjetivos para que el usuario final determine reglas realmente interesantes [Fre02]. En nuestra propuesta se sigue este enfoque y en el AG el grado de interés se evalúa de forma objetiva. Para ello utilizamos el criterio de interés proporcionado en [NFL99], que considera (en un proceso de modelado de dependencias) que el nivel de interés de una regla viene determinado por dos términos, uno referido al antecedente y otro al consecuente). Como el consecuente está prefijado, para el cálculo de interés sólo se utiliza el componente del antecedente, basado en una medida de información dada por la expresión:

$$Interes = 1 - \left( \frac{\sum_{i=1}^n Ganancia(A_i)}{n \cdot \log_2(|dom(G_k)|)} \right) \quad (2.10)$$

donde *Ganancia* es la ganancia de información,  $n$  es el número de variables que aparecen en el antecedente de la regla y  $|dom(G_k)|$  es la cardinalidad de la variable objetivo (el número de valores posibles para la variable considerada como clase). Las variables con un valor alto de ganancia de información son adecuadas para predecir una clase, cuando estas variables se consideran de forma individual. Pero, desde el punto de vista del interés de una regla, se entiende que el usuario ya conoce o ha averiguado cuáles son las variables más predictivas para un dominio de aplicación concreto y por tanto las reglas que contienen dichas variables son menos interesantes (por ser menos sorprendidas y aportar menos información). Por eso se entiende que el antecedente de una regla es más interesante si contiene atributos con poca cantidad de información.

El objetivo global de la función de evaluación es orientar la búsqueda hacia reglas que maximicen la precisión y la medida de interés, minimizando el número de ejemplos negativos y no cubiertos.

Para las reglas DNF, la función de adaptación se calcula de acuerdo con la expresión:

$$fitness(c) = \frac{\omega_1 \times Complejidad(c) + \omega_2 \times Confianza(c)}{\omega_1 + \omega_2} \quad (2.11)$$

donde la complejidad y la confianza se definen como en el caso de las reglas canónicas.

Se discutirá sobre la elección de estas medidas en la Sección 2.2.

### 2.1.1.3 Esquema de reproducción y operadores genéticos

El AG utiliza un modelo de reproducción de estado estacionario modificado [BFM97], que intenta incrementar la diversidad de la población. En este modelo, la población original se modifica mediante la sustitución de los peores individuos por individuos resultantes del cruce, y la mutación no sólo se aplica a los individuos obtenidos mediante el cruce sino a toda la población.

La recombinación se lleva a cabo mediante un operador de cruce en dos puntos y un operador de mutación aleatoria sesgado. El cruce se aplica sobre los dos mejores individuos de la población, obteniendo dos nuevos individuos, que sustituirán a los dos peores individuos de la población. Esta estrategia provoca una alta presión selectiva con el objetivo de obtener una rápida convergencia del algoritmo, debido a que aplicamos iterativamente el AG para obtener diferentes reglas y a que también aplicamos una búsqueda local para mejorar cada regla de forma local. Así, no necesitamos introducir una alta diversidad en la búsqueda del AG mediante el mecanismo de selección de padres; preferimos tener una rápida convergencia.

A diferencia del modelo de estado estacionario clásico, la mutación se aplica según la probabilidad de mutación, mediante un operador de mutación aleatoria sesgada que se aplica al gen seleccionado de acuerdo con la probabilidad de mutación. Este operador se puede aplicar dos formas distintas: en la primera forma, la mutación provoca la eliminación de la variable a que corresponde el gen (poniendo el valor que indica la no participación de la variable, como se ve en la Figura 2.5 para una regla de tipo canónico, o poniendo a 0 todos los valores de esta variable como se muestra en la Figura 2.7 para una regla DNF); y en la segunda, el valor para la variable a mutar se asigna de forma aleatoria (para las reglas canónicas, se asigna un solo valor por variable como se observa en la Figura 2.6, mientras que para las reglas DNF se asigna de forma aleatoria 0 ó 1 para cada uno de los valores posibles de la variable como se muestra en la Figura 2.8). La selección de una de las dos opciones se realiza de forma aleatoria, con la misma probabilidad. La utilización de este operador permite promover la diversidad de la población.

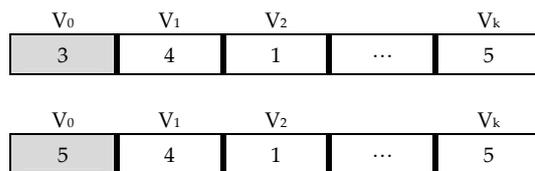


Figura 2.5. Mutación tipo 1: eliminación de la variable  $V_0$  en una regla canónica.

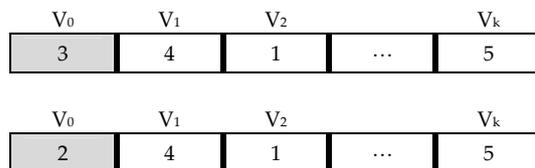


Figura 2.6. Mutación tipo 2: valores aleatorios para la variable  $V_0$  en una regla canónica.

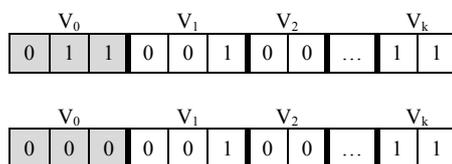


Figura 2.7. Mutación tipo 1: eliminación de la variable  $V_0$  en una regla DNF.

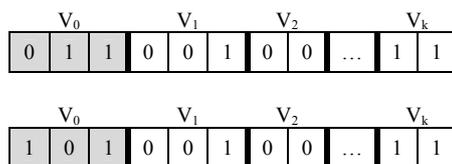


Figura 2.8. Mutación tipo 2: valores aleatorios para la variable  $V_0$  en una regla DNF.

### 2.1.1.4 Etapa de post-procesamiento

La etapa de post-procesamiento, que mejora la regla obtenida mediante un proceso de ascensión de colinas (*hill-climbing*), generaliza la regla mientras se incremente el grado de completitud.

Para ello, en cada iteración se determina la variable tal que, al eliminarla, aumenta en mayor grado la completitud de la regla resultante, obteniendo así reglas más generales.

Finalmente, la regla optimizada sustituirá a la original sólo si supera la confianza mínima. En la Figura 2.9. se muestra el esquema de la etapa de post-procesamiento.

```

INICIO
  Mejor_regla ← R
  Mejor_support ← support(R)
  Mejor ← True
  REPETIR MIENTRAS Mejor
    Mejor ← False
    PARA (m=1 hasta num_genes)
      R'm ← R eliminando la variable m
      SI (support (R'm) >= support (R))
        Mejor ← True
        SI (support (R'm) > Mejor_support)
          Y
            confidence (R'm) >= confidence (R)
            Mejor_support ← support
            (R'm)
            Mejor_regla ← R'm
    FIN PARA
  FIN MIENTRAS
  SI (Mejor Y support (Mejor_regla) >= supp_min)
    Devolver Mejor_regla
  SI NO
    Devolver R
FIN

```

Figura 2.9. Fase de post-procesamiento del AG híbrido.

### 2.1.2 Modelo iterativo

El modelo de extracción de reglas difusas descriptivas sigue el enfoque IRL y su objetivo general es obtener, para cada valor de la variable objetivo, un número variable de reglas que expresen información sobre la mayoría de los ejemplos del conjunto de partida.

El proceso de minería de datos se realiza con un algoritmo iterativo que permite la obtención de varias reglas (una regla por cada llamada al AG). Todas las reglas obtenidas dentro de este algoritmo iterativo corresponden al mismo valor de la variable objetivo. El algoritmo interactivo continúa obteniendo reglas mientras las reglas generadas:

- alcancen un nivel mínimo de confianza (previamente especificado), y
- y describan información sobre zonas del espacio de búsqueda en las que aún queden ejemplos no descritos por las reglas generadas en las iteraciones anteriores.

Este mecanismo de repetición potencia la generación de reglas distintas (en el sentido de que expresen información sobre grupos distintos de ejemplos). Esto se consigue penalizando –una vez obtenida una regla– el conjunto de ejemplos representados por la misma para la generación de futuras reglas.

Es importante señalar que esta penalización no impide la extracción de reglas solapadas que pueden ser de interés para el descubrimiento de subgrupos ya que descripciones redundantes de subgrupos pueden ser interesantes por describir propiedades de grupos de ejemplos desde diferente perspectiva. El esquema completo del algoritmo se muestra en la Figura 2.10.

```
INICIO
  Elegir un atributo objetivo  $At_{OBJ}$ 
   $Cto\_Reglas \leftarrow \emptyset$ 
  REPETIR
    Ejecutar el AG ( $At_{OBJ}$ ) obteniendo la regla R
    Optimización local (R)
    SI  $confianza(R) \geq conf\_min$  y R cubre ejemplos nuevos
       $CtoReglas \leftarrow CtoReglas \cup R$ 
      Modificar conjunto ejemplos (penaliza ejemplos
        cubiertos por R)
    MIENTRAS  $confianza(R) \geq conf\_min$  y R cubra ejemplos nuevos
  FIN
```

Figura 2.10. Modelo iterativo de extracción de reglas.

Como se puede observar en el esquema del modelo de extracción, se exige en cada iteración que la confianza de la regla obtenida supere un valor mínimo especificado previamente.

En los algoritmos de inducción descriptiva, uno de los problemas fundamentales y determinantes en parte de la calidad de los resultados obtenidos es la especificación del soporte mínimo (confianza mínima) exigido a las reglas a extraer. Este valor depende en gran medida del problema al resolver y su determinación es un problema aún no resuelto de forma completa para el que en [ZLZ04] se describe un método basado en lógica difusa para la determinación del nivel mínimo de confianza.

## 2.2 Análisis de componentes

---

En la Sección anterior, hemos descrito un nuevo modelo evolutivo para extracción de reglas difusas de descubrimiento de subgrupos. En esta Sección, describiremos las distintas medidas de calidad consideradas para la construcción del modelo, los detalles de la experimentación realizada y los resultados de la misma, así como las conclusiones obtenidas de este estudio experimental.

### 2.2.1 Medidas de calidad

Uno de los principales problemas a resolver es la determinación de las medidas de calidad a utilizar para la selección de las reglas a lo largo del proceso. Existen distintos enfoques clásicos de descubrimiento de subgrupos pero, hasta donde conocemos, no existe ningún algoritmo de descubrimiento de subgrupos que utilice reglas difusas.

Como se comentó en la Sección 1.2.2, existen medidas objetivas de calidad y medidas subjetivas de interés [ST95], pero a la hora de llevar a cabo la inducción automática de reglas sólo son aplicables los criterios de calidad objetivos (aunque las medidas subjetivas son importantes en la toma de decisiones por parte de los expertos). Por tanto, en el proceso de selección de reglas utilizaremos medidas objetivas.

Existen distintas medidas objetivas de interés aplicables en los procesos de inducción de reglas, y no existe una mejor medida a utilizar, porque en la mayoría de los casos ésta depende del problema a resolver. Nuestro objetivo es definir qué medidas utilizar para la selección de las reglas difusas de descripción de subgrupos.

Así, en esta sección vamos a estudiar la aplicación de distintas medidas de calidad en nuestra propuesta de algoritmo evolutivo de descubrimiento de subgrupos, para seleccionar las más adecuadas para esta tarea.

En procesos de inducción de reglas de asociación, se utilizan los conceptos de completitud (o soporte) y confianza. La definición de estas medidas de calidad para reglas nítidas es la siguiente:

- *Soporte (o completitud)*: tal como se define en (1.3), el soporte de una regla se define como la frecuencia de ejemplos positivos cubiertos, de la forma:

$$Sop(R_i) = Sop(Cond_i \rightarrow Clase) = \frac{n(Clase.Cond_i)}{N}$$

donde  $n(Clase.Cond_i)$  es el número de ejemplos cubiertos por  $Cond_i$  pertenecientes a  $Clase$ , y  $N$  es el número total de ejemplos.

- *Confianza*: definida como el porcentaje de ejemplos positivos cubiertos; es decir, el número de ejemplos que cumplen el antecedente y el consecuente de la regla dividido entre el número de ejemplos que cumplen el antecedente [AMS+96]:

$$Conf_{Nítida}(R_i) = \frac{n(Clase.Cond_i)}{n(Cond_i)} \quad (2.12)$$

También existen definiciones de estas medidas para su utilización en reglas de asociación difusas aplicadas en clasificación, como las definidas por Ishibuchi [INY01]:

- *Soporte (o completitud)*: el soporte de una regla difusa se define como la frecuencia de ejemplos positivos cubiertos, de la forma:

$$Sop_{Difuso}(R_i) = Sop(Cond_i \rightarrow Clase) = \frac{\sum_{E^k \in E / E^k \in Class_j} APC(E^k, R^i)}{N} \quad (2.13)$$

donde  $APC$  es el grado de compatibilidad entre un ejemplo y el antecedente de una regla difusa, se calcula según la expresión (2.4), y  $N$  es el número total de ejemplos.

- *Confianza*: Tal como se define en (2.9), la confianza de una regla difusa determina la frecuencia relativa de los ejemplos que satisfacen tanto el antecedente como el consecuente de una regla entre aquellos que satisfacen sólo el antecedente, medida como la suma del grado de pertenencia de los ejemplos de la clase a la zona determinada por el antecedente dividido entre la suma del grado de pertenencia de todos los ejemplos (independientemente de la clase a la que pertenezcan) a la misma zona:

$$Conf(R^i) = \frac{\sum_{E^k \in E / E^k \in Class_j} APC(E^k, R^i)}{\sum_{E^k \in E} APC(E^k, R^i)}$$

donde  $APC$  se calcula según la expresión (2.4). En el caso de reglas no difusas, los grados de pertenencia son los correspondientes a conjuntos clásicos, 0 ó 1.

Además, teniendo en cuenta las características de la tarea de descubrimiento de subgrupos y de nuestra propuesta, consideramos también otra definición de completitud nítida distinta:

- *Completitud<sub>Clase</sub>*: se define como el número de ejemplos de la clase cubiertos por la regla entre el número de ejemplos de la clase:

$$Comp_{Clase}(R_i) = p(Clase.Cond_i) = \frac{n(Clase.Cond_i)}{n(Clase)} \quad (2.14)$$

Sin embargo, durante el proceso de selección, para potenciar la extracción de reglas distintas en cada ejecución del AG, esta medida se calcula se acuerdo con la expresión definida en (2.8), en la que solo se consideran los ejemplos no marcados (es decir, los ejemplos no cubiertos por otras reglas difusas obtenidas en ejecuciones anteriores del AG). Así, la completitud se define como el cociente entre el número de nuevos ejemplos de la clase que cubre la regla y el número de ejemplos de la clase que quedaban por cubrir:

$$Comp(R^i) = \frac{Ne^+(R^i)}{Ne_{NC}}$$

donde:  $Ne_{NC}$  es el número de ejemplos no cubiertos por las reglas anteriores, y  $Ne^+(R^i)$  es el número de ejemplos cubiertos por la regla que no habían sido cubiertos por las reglas anteriores. Utilizamos la expresión (2.4) para determinar cuando un ejemplo está cubierto por una regla.

Por último, consideramos también una medida de interés, definida como en (2.10):

- *Interés*. El criterio de interés proporcionado en [NFL99], considera que el nivel de interés de una regla viene determinado por dos términos, uno referido al antecedente y otro al consecuente). Como el consecuente está prefijado, para el cálculo de interés sólo se utiliza el componente del antecedente, basado en una medida de información dada por la expresión:

$$Interes = 1 - \left( \frac{\sum_{i=1}^n Ganancia(A_i)}{n \cdot \log_2(|dom(G_k)|)} \right)$$

donde *Ganancia* es la ganancia de información,  $n$  es el número de variables que aparecen en el antecedente de la regla y  $|dom(G_k)|$  es la cardinalidad de la variable objetivo (el número de valores posibles para la variable considerada como clase). Esta medida de interés no está definida para reglas en formato DNF, por lo que no es aplicable.

### 2.2.1 Características de la experimentación

De esta forma, para realizar el análisis de componentes, se van a realizar experimentaciones utilizando tres conjuntos de medidas de calidad que intervendrán en la función fitness de nuestra propuesta evolutiva:

- Un esquema híbrido, que utiliza confianza difusa, completitud nítida sobre los ejemplos de la clase e interés, cuyas experimentaciones identificaremos como *SDIGA-H*.
- Un esquema difuso, que utiliza confianza difusa, completitud difusa e interés, cuyas experimentaciones identificaremos como *SDIGA-D*.
- Un esquema nítido, que utiliza confianza nítida, completitud nítida e interés, cuyas experimentaciones identificaremos como *SDIGA-N*.

Debemos tener en cuenta que la medida de interés no se contempla cuando se aplica el modelo para la extracción de reglas DNF.

Para estas experimentaciones, se han utilizado los siguientes parámetros generales:

- Tamaño de la población: 100.
- Máximo número de evaluaciones de individuos en cada ejecución del AG: 10000.

- Probabilidad de mutación: 0.01.
- Pesos de las medidas de calidad para la function fitness:
  - Completitud: 0.4
  - Confianza: 0.3
  - Interés: 0.1 (para reglas no DNF)

Para analizar el comportamiento de los distintos elementos de nuestra propuesta se ha ejecutado el algoritmo SDIGA para:

- 2 tipos de modelo de representación del conocimiento, es decir, 2 tipos de reglas: DNF y no DNF (o canónicas)
- 3 variantes de la función fitness:
  - Para reglas DNF:
    - Con Completitud y Confianza difusas, e interés.
    - Con completitud y confianza nítidas, e interés.
    - Con completitud nítida medida sobre el total de ejemplos de la clase, y confianza difusa e interés.
  - Para reglas DNF: igual que lo anterior, pero sin la medida de interés.
- Distinto número de etiquetas: 3, 5 y 7
- Distintos valores de Confianza Mínima: 0.6, 0.7, 0.8 y 0.9

Para cada base de ejemplos, y para cada algoritmo, por ser no determinista, se han ejecutado 5 veces y se muestran las medias de los resultados de las 5 ejecuciones.

Todo ello hace que el número de experimentos realizados con el algoritmo SDIGA sea: 8 bases de ejemplos x 2 tipos de reglas x 3 combinaciones de fitness x 4 valores de confianza mínima x 3 valores del número de etiquetas x 5 ejecuciones = 2880 *experimentos*.

Las tablas con las medias para las 5 ejecuciones correspondientes a las distintas bases de ejemplos y para cada tipo de regla se muestran en el Apéndice B. En esta sección se muestra una tabla resumen y el análisis de los componentes.

Tanto en las tablas extendidas del Apéndice B como en las que se incluyen en esta sección se muestran resultados para las medidas de calidad incluidas en la función fitness y para el resto de medidas de calidad consideradas en la bibliografía especializada. Esto se hace con el objetivo de analizar si es posible que algoritmos de extracción de reglas de descripción de subgrupos que consideran en su función de calidad sólo algunas de las medidas, obtengan reglas de descripción de subgrupos con valores adecuados en las medidas de calidad consideradas por otros autores.

### 2.2.3 Análisis de resultados

A continuación se incluye el análisis de resultados para las bases de ejemplos utilizadas, y las conclusiones obtenidas.

#### Conjunto de datos Australian

Los datos de la experimentación realizada para la base de ejemplos *Australian*, con 600 ejemplos distribuidos en 2 clases y descritos mediante 14 variables de las cuales 6 son continuas, se muestran en la Tabla 2.1.

Tabla 2.1. Resumen del análisis de componentes para el dataset Australian

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Cmp	CCmp	FCmp	FCnf	CCnf	Int	
No DNF	SDIGA-H	5 / 0.9	<b>2,64</b>	3,28	0,310	<b>16,348</b>	0,120	<b>0,803</b>	0,591	0,670	0,274	<b>0,793</b>	<b>0,771</b>	0,847
	SDIGA-D	3 / 0.6	3,36	<b>3,34</b>	<b>0,346</b>	15,354	<b>0,126</b>	0,761	<b>0,610</b>	<b>0,833</b>	<b>0,297</b>	0,719	0,705	0,876 *
	SDIGA-N	3 / 0.9	4,52	<b>3,24</b>	0,027	1,666	0,009	0,481	0,124	0,422	0,025	0,525	0,464	0,686
DNF	SDIGA-H	7 / 0.9	<b>2,40</b>	4,82	0,217	9,409	0,076	<b>0,790</b>	<b>0,715</b>	0,417	0,184	<b>0,797</b>	<b>0,794</b>	
	SDIGA-D	3 / 0.8	3,36	<b>3,64</b>	<b>0,345</b>	<b>15,138</b>	<b>0,124</b>	0,749	0,597	<b>0,826</b>	<b>0,297</b>	0,692	0,675	*
	SDIGA-N	5 / 0.7	35,20	5,49	0,048	2,881	0,016	0,664	0,180	0,672	0,042	0,751	0,674	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA con función fitness que utiliza las medidas confianza difusa, completitud nítida sobre los ejemplos de la clase e interés (SDIGA-H), al aumentar el número de etiquetas, mejoran los resultados, salvo para la confianza (tanto difusa como nítida), y el aumento del valor de confianza mínima mejora los resultados ligeramente.
  - b) Para SDIGA con función fitness que utiliza las medidas confianza difusa, completitud difusa e interés (SDIGA-D), no se observan diferencias significativas al variar el número de etiquetas, y se obtienen mejores resultados con valores de confianza mínima 0.6 y 0.9.
  - c) Para SDIGA con función fitness que utiliza las medidas confianza y completitud nítidas e interés (SDIGA-N), los resultados empeoran al aumentar el número de etiquetas, y no hay variaciones significativas al variar los valores de de confianza mínima.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, al aumentar el número de etiquetas, los resultados varían poco, aunque empeora la confianza y mejora la completitud nítida. El aumento del valor de confianza mínima mejora los resultados, aunque la completitud nítida empeora.
  - b) Para SDIGA-D, se obtienen peores resultados para 5 etiquetas, y al aumentar el valor de confianza mínima, los resultados mejoran algo

- c) Para SDIGA-N, no hay variaciones significativas variando el número de etiquetas o el valor de confianza mínima. El algoritmo con estas medidas de calidas obtiene para este dataset conjuntos de reglas más grandes.

En general, para este conjunto de datos, los mejores resultados se obtienen en las ejecuciones que utilizan las medidas de calidad completitud y confianza difusas, y hay muy poca variación al obtener reglas canónicas o DNF. Los resultados cuando se utilizan la completitud y la confianza nítidas son peores en esta base de ejemplos.

**Conjunto de datos Breast-w**

Los datos de la experimentación realizada para la base de ejemplos *Breast-w*, con 699 ejemplos distribuidos en 2 clases y descritos mediante 9 variables (todas discretas), se muestran en la Tabla 2.2.

Tabla 2.2. Resumen del análisis de componentes para el dataset *Breast-w*

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Cmp	CCmp	FCmp	FCnf	CCnf	Int
No DNF	SDIGA-H 7 / 0.8	2,42	<b>2,36</b>	<b>0,447</b>	18,046	<b>0,124</b>	<b>0,855</b>	<b>0,715</b>	<b>0,783</b>	<b>0,397</b>	<b>0,890</b>	<b>0,890</b>	<b>0,649</b> *
	SDIGA-D 3 / 0.9	<b>2,34</b>	2,38	0,442	<b>18,576</b>	<b>0,124</b>	0,852	0,712	0,771	0,394	0,875	0,875	0,648
	SDIGA-N 3 / 0.7	11,78	2,50	0,080	7,325	0,035	0,744	0,173	0,629	0,080	0,749	0,749	0,621
DNF	SDIGA-H 5 / 0.9	4,28	5,54	0,375	19,891	0,129	0,823	0,667	<b>0,944</b>	0,353	0,804	0,804	
	SDIGA-D 3 / 0.9	<b>3,92</b>	<b>5,29</b>	<b>0,421</b>	<b>20,833</b>	<b>0,141</b>	<b>0,829</b>	<b>0,742</b>	0,940	<b>0,387</b>	<b>0,819</b>	<b>0,819</b>	*
	SDIGA-N 7 / 0.6	21,62	5,36	0,128	8,872	0,048	0,742	0,242	0,940	0,123	0,745	0,745	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los mejores resultados se obtienen con 7 etiquetas y confianza mínima 0.8. Al aumentar el número de etiquetas, los resultados mejoran un poco. El aumento del valor de confianza mínima mejora los resultados en general, salvo para el soporte nítido.
  - b) Para SDIGA-D, los mejores resultados se obtienen con 3 etiquetas y confianza mínima 0.9. No se observan diferencias significativas al variar el número de etiquetas y, salvo para el soporte nítido, se obtienen mejores resultados al aumentar el valor de confianza mínima.
  - c) Para SDIGA-N, los mejores resultados se obtienen con 5 etiquetas y confianza mínima 0.7. No hay diferencias significativas al variar el número de etiquetas ni el valor de la confianza mínima, pero los conjuntos de reglas tienen mayor cardinalidad.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, los mejores resultados se obtienen con 5 etiquetas y confianza mínima 0.9. Sólo algunas medidas mejoran al aumentar el número de etiquetas,

pero el aumento del valor de confianza mínima sí mejora los resultados, aunque la completitud nítida empeora.

- b) Para SDIGA-D, los mejores resultados se obtienen con 3 etiquetas y confianza mínima 0.9. Al aumentar el valor de confianza mínima, los resultados mejoran, aunque en poca medida.
- c) Para SDIGA-N, los mejores resultados se obtienen con 7 etiquetas y confianza mínima 0.6. No hay variaciones significativas variando el número de etiquetas o el valor de confianza mínima. Sin embargo, se obtienen conjuntos de reglas bastante más grandes.

En general, para este conjunto de datos, los mejores resultados se obtienen en las ejecuciones que utilizan como medidas de calidad la completitud nítida sobre ejemplos de la clase y la confianza difusa, pero con valores muy cercanos a los obtenidos por las ejecuciones que utilizan completitud y confianza difusa. Los resultados son mejores cuando se obtienen reglas canónicas.

### Conjunto de datos Bridges

La Tabla 2.3 muestra los datos de la experimentación realizada para la base de ejemplos *Bridges*, que contiene 102 ejemplos distribuidos en 2 clases y descritos mediante 7 variables de las cuales 4 son continuas.

Tabla 2.3. Resumen del análisis de componentes para el dataset Bridges

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Cmp	CCmp	FCmp	FCnf	CCnf	Int
No DNF	SDIGA-H 3 / 0.6	<b>3,04</b>	2,76	0,299	<b>0,805</b>	<b>0,024</b>	<b>0,650</b>	<b>0,505</b>	0,662	0,251	0,637	<b>0,632</b>	1,043 *
	SDIGA-D 3 / 0.8	3,98	<b>2,51</b>	<b>0,397</b>	0,622	0,020	0,606	0,446	<b>0,845</b>	<b>0,317</b>	0,537	0,526	0,986
	SDIGA-N 3 / 0.8	10,44	3,39	0,144	0,620	0,014	0,621	0,279	0,749	0,128	<b>0,680</b>	0,594	<b>1,049</b>
	SDIGA-H 5 / 0.9	<b>2,08</b>	5,27	<b>0,299</b>	<b>1,204</b>	<b>0,038</b>	<b>0,648</b>	<b>0,813</b>	0,506	<b>0,231</b>	0,608	0,616	*
DNF	SDIGA-D 7 / 0.8	3,22	<b>3,41</b>	0,144	0,380	0,010	0,272	0,250	<b>0,934</b>	0,031	0,142	0,101	
	SDIGA-N 5 / 0.9	9,30	3,85	0,214	0,678	0,021	0,641	0,375	0,833	0,178	<b>0,639</b>	<b>0,629</b>	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores en general con un menor número de etiquetas, salvo para la confianza nítida. El aumento del valor de confianza mínima empeora los resultados pero en poca medida.
  - b) Para SDIGA-D, al reducir el número de etiquetas se obtienen mejores resultados en todas las medidas de calidad. Sin embargo, al aumentar el valor de confianza mínima los resultados mejoran para algunas medidas y empeoran en otras, pero en poca proporción.
  - c) Para SDIGA-N, no hay diferencias significativas al variar el número de etiquetas ni el valor de confianza mínima.

- 2) Con reglas DNF:
  - a) Para SDIGA-H, los mejores resultados se obtienen con 5 etiquetas y no hay diferencias significativas al variar la confianza mínima.
  - b) Para SDIGA-D, al aumentar el número de etiquetas mejora la confianza y la precisión y disminuye la completitud. Los resultados mejoran ligeramente al aumentar el valor de confianza mínima.
  - c) Para SDIGA-N, no hay variaciones significativas variando el número de etiquetas o el valor de confianza mínima, pero los conjuntos de reglas obtenidos son mayores.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen resultados mucho mejores. Las experimentaciones con confianza y completitud nítidas obtienen conjuntos de reglas de mayor cardinalidad.

### Conjunto de datos Diabetes

Los datos de la experimentación realizada para la base de ejemplos *Diabetes* que tiene 768 ejemplos distribuidos en 2 clases y descritos mediante 8 variables continuas, se muestran en la Tabla 2.4.

Tabla 2.4. Resumen del análisis de componentes para el dataset Diabetes

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int	
No DNF	Orig	3 / 0.8	<b>2,00</b>	<b>2,25</b>	<b>0,378</b>	<b>5,236</b>	<b>0,035</b>	<b>0,686</b>	<b>0,812</b>	0,527	<b>0,247</b>	<b>0,671</b>	<b>0,708</b>	<b>0,904</b> *
	Difuso	3 / 0.6	4,26	2,72	0,294	1,226	0,016	0,532	0,446	<b>0,688</b>	0,176	0,490	0,338	0,854
	Nitido	5 / 0.6	12,54	3,82	0,038	1,195	0,007	0,550	0,155	0,328	0,035	0,615	0,344	0,821
DNF	Orig	3 / 0.8	<b>2,00</b>	3,92	<b>0,265</b>	<b>4,652</b>	<b>0,039</b>	<b>0,649</b>	<b>0,961</b>	0,346	<b>0,183</b>	<b>0,584</b>	<b>0,669</b>	*
	Difuso	7 / 0.7	8,22	<b>3,52</b>	0,007	0,611	0,002	0,361	0,048	<b>0,734</b>	0,005	0,373	0,213	
	Nitido	5 / 0.7	26,50	5,28	0,031	1,451	0,004	0,533	0,285	0,367	0,035	0,550	0,421	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas, y el aumento del valor de confianza mínima mejora ligeramente los resultados.
  - b) Para SDIGA-D, los resultados son mejores con un número menor de etiquetas.
  - c) Para SDIGA-N, los resultados son mejores para el número intermedio de etiquetas.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, se obtienen mejores resultados al aumentar el número de etiquetas.

- c) Para SDIGA-N, al aumentar el número de etiquetas, mejoran algunas medidas, pero se incrementa enormemente el número de reglas obtenidas. Se obtienen conjuntos de reglas mucho más grandes.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen mucho mejores resultados. Se obtienen mejores resultados con reglas canónicas que con reglas DNF. Los resultados de las experimentaciones con confianza y completitud nítidas obtienen mejores resultados que con la confianza y completitud difusas.

### Conjunto de datos Echo

Los datos de la experimentación realizada para la base de ejemplos *Echo*, con 131 ejemplos distribuidos en 2 clases y descritos mediante 6 variables de las cuales 5 son continuas, se muestran en la Tabla 2.5.

Tabla 2.5. Resumen del análisis de componentes para el dataset Echo

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Cmp	CCmp	FCmp	FCnf	CCnf	Int	
No DNF	SDIGA-H 3 / 0.6	3,02	2,87	0,325	0,943	<b>0,026</b>	<b>0,606</b>	<b>0,668</b>	0,576	0,212	<b>0,637</b>	<b>0,627</b>	<b>0,877</b>	*
	SDIGA-D 5 / 0.7	<b>2,36</b>	<b>2,29</b>	<b>0,381</b>	0,346	0,020	0,477	0,447	<b>0,762</b>	<b>0,274</b>	0,459	0,428	0,679	
	SDIGA-N 3 / 0.8	4,72	3,02	0,087	<b>0,991</b>	0,023	0,460	0,289	0,663	0,062	0,463	0,395	0,725	
DNF	SDIGA-H 5 / 0.8	<b>2,02</b>	4,97	0,267	<b>1,456</b>	<b>0,043</b>	<b>0,607</b>	<b>0,744</b>	0,385	<b>0,166</b>	<b>0,608</b>	<b>0,599</b>	*	
	SDIGA-D 7 / 0.7	3,60	<b>2,55</b>	<b>0,030</b>	0,352	0,008	0,233	0,085	<b>0,840</b>	0,016	0,183	0,129		
	SDIGA-N 7 / 0.8	16,90	4,79	0,088	0,720	0,010	0,536	0,293	0,592	0,059	0,508	0,375		

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores en general con un menor número de etiquetas, salvo para la completitud y la cobertura. El aumento del valor de confianza mínima mejora los resultados, salvo para la completitud nítida.
  - b) Para SDIGA-D, al reducir el número de etiquetas se obtienen mejores resultados en todas las medidas de calidad. Sin embargo, al aumentar el valor de confianza mínima los resultados mejoran en poca proporción, salvo para la completitud nítida.
  - c) Para SDIGA-N, no hay diferencias significativas al variar el valor de confianza mínima, pero los resultados son mejores con un número menor de etiquetas.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, no hay diferencias significativas al variar el número de etiquetas o la confianza mínima, salvo para la confianza difusa.
  - b) Para SDIGA-D, al aumentar el número de etiquetas mejoran todas las medidas salvo la completitud nítida. Los resultados mejoran ligeramente al aumentar el valor de confianza mínima.

- c) Para SDIGA-N, no hay variaciones significativas variando el valor de confianza mínima, y sin embargo los resultados mejoran al aumentar el número de etiquetas para las variables lingüísticas, salvo para la completitud nítida. Se obtienen los conjuntos de reglas mayores.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen resultados mucho mejores. Los resultados son mejores para reglas canónicas que para reglas DNF, salvo para la relevancia.

### Conjunto de datos German

Los datos de la experimentación realizada para la base de ejemplos *German* que tiene 1000 ejemplos distribuidos en 2 clases y descritos mediante 20 variables de las cuales 7 son continuas, se muestran en la Tabla 2.6.

Tabla 2.6. Resumen del análisis de componentes para el dataset German

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int	
No DNF	Orig	3 / 0.6	8,56	4,40	0,082	0,615	<b>0,006</b>	<b>0,555</b>	0,177	0,363	0,060	0,313	0,270	<b>0,982</b> *
	Difuso	7 / 0.6	<b>3,50</b>	<b>2,48</b>	<b>0,282</b>	0,233	0,003	0,341	<b>0,287</b>	<b>0,834</b>	<b>0,126</b>	0,230	0,226	0,667
	Nitido	3 / 0.6	14,74	4,41	0,010	<b>0,677</b>	0,001	0,534	0,042	0,146	0,009	<b>0,501</b>	<b>0,374</b>	0,969
DNF	Orig	3 / 0.8	<b>25,98</b>	<b>7,04</b>	<b>0,027</b>	0,875	<b>0,004</b>	0,521	<b>0,085</b>	0,200	<b>0,020</b>	0,309	0,280	
	Difuso	5 / 0.7	35,06	7,17	0,007	0,715	0,001	0,483	0,013	<b>0,786</b>	0,003	0,243	0,219	
	Nitido	3 / 0.6	79,70	7,38	0,019	<b>1,072</b>	0,002	<b>0,586</b>	0,050	0,599	0,016	<b>0,588</b>	<b>0,521</b>	*

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas. El aumento del valor de confianza mínima empeora en cierta medida los resultados.
  - b) Para SDIGA-D, los resultados son mejores con un número menor de etiquetas.
  - c) Para SDIGA-D, los resultados son mejores al disminuir el número de etiquetas.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, con 5 etiquetas se obtienen mejores resultados.
  - c) Para SDIGA-N, al disminuir el número de etiquetas, mejoran algunas medidas, pero se incrementa el número de reglas obtenidas. Se obtienen conjuntos de reglas más grandes.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen mejores resultados de atipicidad y precisión, con confianza y completitud difusa

obtienen mejores resultados en completitud, y con confianza y completitud nítidas obtienen mejores resultados para la confianza. En cualquier caso, los mejores resultados se obtienen cuando se utiliza completitud nítida sobre ejemplos de la clase y confianza difusa.

### Conjunto de datos Heart

Los datos de la experimentación realizada para la base de ejemplos *Heart*, con 270 ejemplos distribuidos en 2 clases y descritos mediante 13 variables de las cuales 7 son continuas, se muestran en la Tabla 2.7.

Tabla 2.7. Resumen del análisis de componentes para el dataset Heart

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	SDIGA-H 7 / 0.9	<b>2,00</b>	2,08	0,501	2,426	<b>0,078</b>	<b>0,621</b>	0,678	0,690	0,330	0,628	<b>0,616</b>	0,812 *
	SDIGA-D 7 / 0.9	<b>2,00</b>	<b>2,07</b>	<b>0,523</b>	<b>2,507</b>	<b>0,078</b>	0,599	<b>0,679</b>	<b>0,743</b>	0,339	0,586	0,586	0,820
	SDIGA-N 3 / 0.7	18,60	4,35	0,053	1,318	0,016	0,590	0,207	0,504	<b>0,049</b>	<b>0,634</b>	0,509	<b>0,891</b>
DNF	SDIGA-H 5 / 0.9	<b>2,00</b>	3,93	0,344	<b>3,056</b>	<b>0,079</b>	<b>0,689</b>	<b>0,932</b>	0,506	<b>0,245</b>	0,617	<b>0,744</b>	*
	SDIGA-D 7 / 0.6	2,48	<b>2,09</b>	<b>0,339</b>	0,390	0,020	0,311	0,377	<b>0,930</b>	0,205	0,323	0,299	
	SDIGA-N 3 / 0.7	29,48	5,03	0,068	1,704	0,023	0,620	0,263	0,723	0,062	<b>0,691</b>	0,586	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son peores en general para 5 etiquetas,. El aumento del valor de confianza mínima mejora los algunas medidas de calidad, y otras se mantienen.
  - b) Para SDIGA-D, al variar el número de etiquetas, se obtienen mejores resultados en unas medidas y peores en otras. Salvo para la completitud nítida, los resultados mejoran al aumentar el valor de confianza mínima.
  - c) Para SDIGA-N, los resultados son peores al aumentar el número de etiquetas, y se mantienen o mejoran ligeramente al aumentar el valor de confianza mínima.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, los resultados son mucho peores al aumentar el número de etiquetas, y mejoran al aumentar el valor de confianza mínima, salvo para la completitud nítida.
  - b) Para SDIGA-D, al aumentar el número de etiquetas mejoran prácticamente todas las medidas (salvo la completitud nítida).
  - c) Para SDIGA-N, lno hay cambios significativos variando el valor de confianza mínima ni el número de etiquetas (salvo para la relevancia).

En general, para este conjunto de datos, los mejores resultados se obtienen para reglas DNF. El mejor comportamiento general es al utilizar las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, aunque para reglas canónicas se obtienen resultados más igualados con la completitud y confianza difusas.

### Conjunto de datos Hepatitis

Los datos de la experimentación realizada para la base de ejemplos *Hepatitis* que tiene 155 ejemplos distribuidos en 2 clases y descritos mediante 19 variables de las cuales 6 son continuas, se muestran en la Tabla 2.8.

Tabla 2.8. Resumen del análisis de componentes para el dataset *Hepatitis*

		Etiqu/	CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	Orig	3 / 0.8	5,16	4,63	0,187	<b>0,813</b>	0,017	<b>0,623</b>	<b>0,415</b>	0,536	0,153	<b>0,582</b>	0,481	<b>0,997</b>	*
	Difuso	5 / 0.8	<b>4,34</b>	<b>3,92</b>	<b>0,330</b>	0,764	<b>0,024</b>	0,573	0,407	<b>0,788</b>	<b>0,249</b>	0,437	0,420	0,959	
	Nitido	5 / 0.9	10,18	4,21	0,105	0,892	0,013	0,595	0,186	0,583	0,091	0,560	<b>0,525</b>	0,988	
DNF	Orig	3 / 0.9	<b>2,34</b>	5,75	0,286	0,864	<b>0,027</b>	<b>0,614</b>	<b>0,737</b>	0,518	0,208	<b>0,663</b>	0,486		*
	Difuso	3 / 0.9	3,82	<b>3,67</b>	<b>0,352</b>	0,753	<b>0,027</b>	0,533	0,454	<b>0,802</b>	<b>0,242</b>	0,405	0,380		
	Nitido	7 / 0.9	15,92	5,25	0,122	<b>0,975</b>	0,012	0,593	0,275	0,751	0,091	0,592	<b>0,506</b>		

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas, y el aumento del valor de confianza mínima mejora ligeramente los resultados.
  - b) Para SDIGA-D, los resultados son mejores con un número mayor de etiquetas.
  - c) Para SDIGA-N, no hay variaciones significativas al variar el número de etiquetas o de la confianza mínima.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, se obtienen mejores resultados al disminuir el número de etiquetas.
  - c) Para SDIGA-N, al aumentar el número de etiquetas, mejoran ligeramente los resultados. Se obtienen conjuntos de reglas más grandes.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen mejores resultados. Los resultados de las experimentaciones con confianza y completitud nítidas obtienen resultados similares a los de la confianza y completitud difusas. No hay diferencias significativas entre los resultados para reglas canónicas y DNF.

### Conjunto de datos *Hypothyroid*

Los datos de la experimentación realizada para la base de ejemplos *Hypothyroid*, con 3163 ejemplos distribuidos en 2 clases y descritos mediante 25 variables de las cuales 7 son continuas, se muestran en la Tabla 2.9.

Tabla 2.9. Resumen del análisis de componentes para el dataset Hypothyroid

	Etiqu/	CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	SDIGA-H	5 / 0.6	3,48	3,26	0,328	<b>10,657</b>	<b>0,013</b>	<b>0,859</b>	<b>0,699</b>	0,805	<b>0,299</b>	<b>0,788</b>	<b>0,846</b>	<b>1,205</b> *
	SDIGA-D	7 / 0.6	<b>3,12</b>	<b>2,68</b>	<b>0,389</b>	5,200	0,010	0,416	0,474	<b>0,972</b>	0,234	0,320	0,316	0,820
	SDIGA-N	3 / 0.6	4,44	2,73	0,176	5,206	0,008	0,735	0,387	0,551	0,186	0,748	0,754	0,983
DNF	SDIGA-H	5 / 0.9	2,76	6,12	<b>0,416</b>	<b>18,643</b>	<b>0,022</b>	<b>0,893</b>	<b>0,817</b>	0,824	<b>0,352</b>	<b>0,823</b>	<b>0,889</b>	*
	SDIGA-D	7 / 0.8	<b>2,74</b>	4,15	0,092	6,809	0,004	0,305	0,247	<b>0,971</b>	0,008	0,178	0,198	
	SDIGA-N	7 / 0.7	6,34	<b>3,49</b>	0,221	6,441	0,010	0,745	0,434	0,740	0,204	0,705	0,718	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores en general con 5 etiquetas.
  - b) Para SDIGA-D, al aumentar el número de etiquetas se obtienen mejores resultados para la relevancia y confianza.
  - c) Para SDIGA-N, no hay diferencias significativas al variar el valor de confianza mínima, pero los resultados son dispares al aumentar el número de etiquetas (mejora la cobertura y a confianza, y empeora la relevancia y la completitud).
- 2) Con reglas DNF:
  - a) Para SDIGA-H, no hay diferencias significativas al variar la confianza mínima, y se obtienen resultados dispares al aumentar el número de etiquetas para las variables lingüísticas.
  - b) Para SDIGA-D, no hay diferencias significativas al variar la confianza mínima, y se obtienen resultados dispares al aumentar el número de etiquetas.
  - c) Para SDIGA-N, se obtienen mejores resultados al aumentar el número de etiquetas y disminuir la confianza mínima.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad completitud nítida sobre ejemplos de la clase y confianza difusa, obtienen mejores resultados. Los resultados son mejores en general para las reglas DNF.

### Conjunto de datos Ionosphere

Los datos de la experimentación realizada para la base de ejemplos *Ionosphere*, con 351 ejemplos distribuidos en 2 clases y descritos mediante 34 variables continuas, se muestran en la Tabla 2.10.

Tabla 2.10. Resumen del análisis de componentes para el dataset *Ionosphere*

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	SDIGA-H 3 / 0.7	<b>3,60</b>	4,84	0,120	<b>2,769</b>	0,036	0,581	0,367	0,511	0,113	<b>0,662</b>	0,449	0,771
	SDIGA-D 3 / 0.7	4,02	<b>3,05</b>	0,276	0,888	0,027	0,523	0,360	0,791	0,202	0,510	0,414	0,761
	SDIGA-N 3 / 0.6	4,14	3,23	<b>0,496</b>	2,002	<b>0,049</b>	<b>0,640</b>	<b>0,687</b>	<b>0,848</b>	<b>0,304</b>	0,648	<b>0,617</b>	<b>0,918</b> *
	SDIGA-H 3 / 0.6	8,34	5,08	0,071	<b>2,553</b>	<b>0,029</b>	<b>0,643</b>	0,266	0,386	0,070	<b>0,649</b>	0,521	*
DNF	SDIGA-D 3 / 0.6	4,28	3,16	0,294	1,108	<b>0,029</b>	0,529	0,401	0,779	0,216	0,535	0,412	
	SDIGA-N 5 / 0.6	<b>2,56</b>	<b>2,00</b>	<b>0,833</b>	0,634	0,027	0,555	<b>0,939</b>	<b>0,918</b>	<b>0,422</b>	0,554	<b>0,559</b>	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, al aumentar el número de etiquetas, mejoran los resultados en Completitud, pero empeoran en confianza y relevancia.
  - b) Para SDIGA-D, los resultados son peores con un número mayor de etiquetas, salvo para completitud sobre ejemplos de la clase.
  - c) Para SDIGA-N, al aumentar el número de etiquetas, mejora la completitud, pero empeora la relevancia, precisión y confianza. Los resultados son mejores con valores de confianza mínima menores.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, se obtienen mejores resultados generales al disminuir el número de etiquetas y el valor de confianza mínima.
  - c) Para SDIGA-N, se obtienen mejores resultados con un valor inferior de confianza mínima.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad nítidas de completitud y confianza obtienen mejores resultados. Se obtienen mejores resultados con reglas canónicas (salvo para la completitud). Resalta el hecho de que, a pesar de ser un dataset con todas las variables continuas, se obtienen mejores resultados al utilizar medidas nítidas de calidad, al obtener en este caso reglas más generales (mayor cobertura y completitud).

### *Conjunto de datos Iris*

Los datos de la experimentación realizada para la base de ejemplos *Iris* que tiene 150 ejemplos distribuidos en 3 clases y descritos mediante 4 variables continuas, se muestran en la Tabla 2.11.

Tabla 2.11. Resumen del análisis de componentes para el dataset Iris

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
Orig	3 / -	3,10	2,38	0,304	<b>8,178</b>	<b>0,176</b>	0,677	0,985	0,853	0,243	0,844	<b>0,915</b>	<b>0,086</b>
No DNF	Difuso	3 / 0.7	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	8,146	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	<b>0,261</b>	0,824	0,903
	Nítido	5 / 0.8	5,68	2,43	0,179	5,719	0,116	0,588	0,811	0,724	0,157	<b>0,924</b>	0,846
	Orig	5 / 0.7	<b>3,00</b>	2,49	0,280	8,896	0,183	0,705	<b>1,000</b>	0,828	0,225	<b>0,926</b>	<b>0,981</b>
DNF	Difuso	5 / 0.7	<b>3,00</b>	<b>2,06</b>	<b>0,316</b>	<b>9,143</b>	<b>0,193</b>	<b>0,708</b>	<b>1,000</b>	<b>0,896</b>	<b>0,243</b>	0,897	0,954
	Nítido	5 / 0.9	4,38	2,99	0,208	6,336	0,131	0,621	0,877	0,792	0,163	0,818	0,919

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas. El aumento del valor de confianza mínima mejora ligeramente los resultados.
  - b) Para SDIGA-D, los resultados son mejores con un número menor de etiquetas.
  - c) Para SDIGA-N, al aumentar el número de etiquetas, mejora la confianza pero empeora la completitud.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, len general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, se obtienen mejores resultados al aumentar el número de etiquetas.
  - c) Para SDIGA-N, al aumentar el número de etiquetas, en general mejoran los resultados.

Para este conjunto de ejemplos se muestra mejor comportamiento al utilizar las medidas de calidad de confianza y completitud difusas para las reglas de tipo DNF, pero con las medidas de completitud nítida sobre ejemplos de la clase y confianza difusa para reglas no DNF.

### Conjunto de datos Tic-Tac-Toe

Los datos de la experimentación realizada para la base de ejemplos *Tic-Tac-Toe*, con 958 ejemplos distribuidos en 2 clases y descritos mediante 9 discretas, se muestran en la Tabla 2.12.

Tabla 2.12. Resumen del análisis de componentes para el dataset Tic-Tac-Toe

	Etiqu/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
SDIGA-H	7 / 0.8	7,42	3,86	0,125	<b>6,084</b>	<b>0,030</b>	0,753	0,194	0,535	0,100	0,817	0,817	0,901
No DNF	SDIGA-D	3 / 0.6	11,24	<b>3,68</b>	<b>0,150</b>	5,642	0,027	<b>0,759</b>	<b>0,208</b>	<b>0,886</b>	<b>0,117</b>	0,818	0,818
	SDIGA-N	5 / 0.9	<b>6,56</b>	3,92	0,112	6,286	0,028	0,753	0,183	0,436	0,088	<b>0,831</b>	<b>0,831</b>
	SDIGA-H	3 / 0.8	<b>6,72</b>	3,64	0,337	<b>6,133</b>	<b>0,030</b>	<b>0,698</b>	0,408	0,678	0,205	<b>0,780</b>	<b>0,780</b>
DNF	SDIGA-D	5 / 0.9	6,90	<b>3,50</b>	<b>0,368</b>	5,492	0,029	0,679	<b>0,431</b>	0,732	<b>0,219</b>	0,741	0,741
	SDIGA-N	5 / 0.7	8,30	3,73	0,316	5,786	0,028	0,695	0,382	<b>0,753</b>	0,197	0,765	0,765

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, se obtienen resultados algo mejores con un umbral inferior de confianza mínima.
  - b) Para SDIGA-D, los resultados son algo peores con un valor superior de confianza mínima.
  - c) Para SDIGA-N, casi no hay variaciones al variar la confianza mínima, aunque se obtienen peores resultados con un valor más alto.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, se obtienen casi los mismos resultados con distintos valores de confianza mínima y de número de etiquetas.
  - b) Para SDIGA-D, no hay prácticamente variación con distintos valores de confianza mínima o de número de etiquetas.
  - c) Para SDIGA-N, casi no varían los resultados con distintos valores de confianza mínima o de número de etiquetas.

En general, para este conjunto de datos, no hay prácticamente variaciones en los resultados al variar el número de etiquetas o el valor de la confianza mínima. Se obtienen mejores resultados al utilizar medidas de calidad nítidas, y los resultados son algo mejores para las reglas DNF en cobertura y completitud, y mejores para las reglas canónicas en precisión y confianza. Lógicamente, al tratarse de un conjunto de datos con todas las variables discretas, se obtienen los mismos resultados para la confianza difusa que para la nítida.

### Conjunto de datos *Vote*

Los datos de la experimentación realizada para la base de ejemplos *Vote*, con 435 ejemplos distribuidos en 2 clases y descritos mediante 16 variables discretas, se muestran en la Tabla 2.13.

Tabla 2.13. Resumen del análisis de componentes para el dataset *Vote*

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	SDIGA-H	3 / 0.9	3,06	3,19	0,422	18,243	0,180	<b>0,871</b>	0,802	0,943	0,400	0,891	<b>0,704</b>
	SDIGA-D	7 / 0.9	<b>2,86</b>	<b>3,12</b>	<b>0,430</b>	<b>18,478</b>	<b>0,183</b>	0,867	<b>0,813</b>	<b>0,957</b>	<b>0,407</b>	<b>0,893</b>	<b>0,893</b> 0,698 *
	SDIGA-N	7 / 0.7	7,74	5,11	0,085	5,076	0,042	0,598	0,191	0,882	0,079	0,598	0,598 0,691
DNF	SDIGA-H	3 / 0.9	2,28	<b>2,17</b>	<b>0,492</b>	<b>20,335</b>	<b>0,208</b>	<b>0,886</b>	<b>0,931</b>	<b>0,962</b>	<b>0,462</b>	<b>0,923</b>	<b>0,923</b> *
	SDIGA-D	3 / 0.9	<b>2,26</b>	2,19	0,489	20,220	0,207	0,885	0,925	0,961	0,459	0,923	0,923
	SDIGA-N	3 / 0.8	7,68	4,40	0,088	4,989	0,042	0,577	0,192	0,870	0,082	0,619	0,619

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, se obtienen resultados algo mejores con un umbral superior de confianza mínima (salvo para la completitud nítida).
  - b) Para SDIGA-D, los resultados son algo mejores con un valor superior de confianza mínima (salvo para la completitud nítida).
  - c) Para SDIGA-N, no hay prácticamente variaciones al variar la confianza mínima, o el número de etiquetas.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, no hay cambios al variar el número de etiquetas, y pero mejoran los resultados al elevar el umbral de confianza mínima.
  - b) Para SDIGA-D, los resultados mejoran al aumentar el umbral de confianza mínima.
  - c) Para SDIGA-N, no hay diferencias en los resultados con distintos valores de confianza mínima o número de etiquetas.

En general, se obtienen mejores resultados con reglas DNF, y utilizando la completitud sobre los ejemplos de la clase y la confianza difusa. Para reglas canónicas, se obtienen mejores resultados con la completitud y confianza difusas (aunque peores que con reglas DNF).

### Conjunto de datos Balance

Los datos de la experimentación realizada para la base de ejemplos *Balance*, con 625 ejemplos distribuidos en 3 clases y descritos mediante 4 variables continuas, se muestran en la Tabla 2.14.

Tabla 2.14. Resumen del análisis de componentes para el dataset Balance

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int	
	SDIGA-H	3 / 0.6	7,40	2,39	0,291	5,331	0,049	0,535	0,487	0,856	0,150	<b>0,664</b>	0,618	0,391
No DNF	SDIGA-D	3 / 0.6	8,90	<b>2,04</b>	0,311	5,810	0,058	<b>0,571</b>	<b>0,561</b>	<b>0,909</b>	<b>0,185</b>	0,622	<b>0,622</b>	0,391 *
	SDIGA-N	3 / 0.6	<b>5,00</b>	2,29	<b>0,360</b>	<b>6,173</b>	<b>0,066</b>	0,544	0,509	0,810	0,171	0,589	0,542	<b>0,392</b>
	SDIGA-H	3 / 0.6	5,00	2,80	0,535	<b>6,978</b>	<b>0,073</b>	<b>0,531</b>	<b>0,786</b>	<b>0,918</b>	0,209	<b>0,522</b>	<b>0,555</b>	*
DNF	SDIGA-D	5 / 0.9	<b>3,00</b>	<b>2,69</b>	<b>0,689</b>	4,788	0,069	0,435	0,779	0,858	<b>0,284</b>	0,444	0,443	
	SDIGA-N	5 / 0.9	<b>3,00</b>	2,71	0,684	4,826	0,069	0,437	0,770	0,856	0,283	0,443	0,442	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas y un menor umbral de confianza mínima.
  - b) Para SDIGA-D, los resultados son mejores con un número menor de etiquetas y un umbral de confianza mínima menor.

- c) Para SDIGA-N, se obtienen mejores resultados con 5 etiquetas, y al aumentar la confianza mínima los resultados son algo peores en algunas medidas.
- 2) Con reglas DNF:
- a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran, al igual que al aumentar el umbral de confianza mínima.
  - b) Para SDIGA-D, se obtienen mejores resultados con 5 etiquetas.
  - c) Para SDIGA-N, se obtienen mejores resultados con 5 etiquetas, y los resultados se mantienen al aumentar la confianza mínima salvo para la cobertura y el soporte, que aumentan, y la confianza, que disminuye.

Para este conjunto de ejemplos se muestra mejor comportamiento al utilizar las medidas de calidad de confianza difusa y completitud sobre los ejemplos de la clase con reglas DNF. Para reglas canónicas, la completitud y confianza difusas obtienen resultados algo mejores.

### Conjunto de datos Car

Los datos de la experimentación realizada para la base de ejemplos *Car*, con 1728 ejemplos distribuidos en 4 clases y descritos mediante 6 variables discretas, se muestran en la Tabla 2.15.

Tabla 2.15. Resumen del análisis de componentes para el dataset *Car*

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int	
	SDIGA-H	5 / 0.8	<b>16,76</b>	5,03	0,014	1,935	0,002	0,257	0,048	0,768	0,003	0,238	0,238	0,278
No DNF	SDIGA-D	7 / 0.9	18,66	5,08	0,011	1,844	0,002	0,264	0,037	<b>0,774</b>	0,003	0,249	0,249	0,280
	SDIGA-N	5 / 0.9	24,40	<b>4,38</b>	<b>0,049</b>	<b>6,515</b>	<b>0,015</b>	<b>0,466</b>	<b>0,073</b>	0,748	<b>0,048</b>	<b>0,545</b>	<b>0,545</b>	<b>0,294</b>
	SDIGA-H	5 / 0.6	4,04	<b>3,88</b>	<b>0,137</b>	33,018	<b>0,045</b>	0,353	0,703	<b>0,972</b>	0,068	0,413	0,413	
DNF	SDIGA-D	7 / 0.7	<b>4,02</b>	3,87	0,136	<b>33,690</b>	<b>0,045</b>	0,351	<b>0,714</b>	0,970	0,067	0,400	0,400	
	SDIGA-N	7 / 0.7	8,50	2,64	0,115	15,014	0,035	<b>0,559</b>	0,171	0,857	<b>0,115</b>	<b>0,670</b>	<b>0,670</b>	*

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, no hay cambios al modificar el número de etiquetas o el umbral de confianza mínima.
  - b) Para SDIGA-D, no hay cambios al modificar el número de etiquetas o el umbral de confianza mínima.
  - c) Para SDIGA-N, no hay cambios al modificar el número de etiquetas o el umbral de confianza mínima.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, no hay cambios al modificar el número de etiquetas o el umbral de confianza mínima.

- b) Para SDIGA-D, no hay cambios al modificar el número de etiquetas o el umbral de confianza mínima.
- c) Para SDIGA-N, no hay cambios significativos al modificar el número de etiquetas o el umbral de confianza mínima.

En general, se obtienen mejores resultados con reglas DNF, y utilizando medidas de calidad nítidas. Es de reseñar que en ningún caso se produzcan cambios en los resultados al modificar el umbral de confianza nítida ni el número de etiquetas. Al ser un conjunto de datos con todas sus variables discretas, los resultados de las medidas de calidad de confianza difusa y nítida son idénticos.

### Conjunto de datos Glass

Los datos de la experimentación realizada para la base de ejemplos *Glass* que tiene 214 ejemplos distribuidos en 6 clases y descritos mediante 9 variables continuas, se muestran en la Tabla 2.16.

Tabla 2.16. Resumen del análisis de componentes para el dataset *Glass*

	Etq/ CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Orig	7 / 0.9	8,84	3,27	0,116	2,241	0,010	0,191	0,308	0,349	0,039	0,268	0,182	0,018	
No DNF	Difuso	7 / 0.8	7,34	2,73	<b>0,293</b>	<b>2,798</b>	<b>0,017</b>	<b>0,195</b>	<b>0,487</b>	0,607	<b>0,083</b>	<b>0,298</b>	<b>0,241</b>	<b>0,061</b> *
	Nitido	3 / 0.6	<b>7,28</b>	<b>1,97</b>	0,034	1,375	0,006	0,099	0,201	<b>0,736</b>	0,012	0,189	0,137	0,055
Orig	3 / 0.9	<b>6,72</b>	6,44	0,054	2,109	0,015	<b>0,209</b>	<b>0,592</b>	0,182	0,037	<b>0,381</b>	0,268		
DNF	Difuso	3 / 0.9	6,74	<b>2,70</b>	<b>0,321</b>	<b>2,667</b>	<b>0,022</b>	0,206	0,560	<b>0,764</b>	<b>0,105</b>	0,307	<b>0,285</b>	*
	Nitido	5 / 0.8	12,48	3,77	0,063	2,594	0,011	0,161	0,319	0,581	0,018	0,223	0,189	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número intermedio de etiquetas. El aumento del valor de confianza mínima mejora ligeramente los resultados.
  - b) Para SDIGA-D, los resultados son mejores con un número menor de etiquetas.
  - c) Para SDIGA-N, los resultados son mejores para el número menor de etiquetas.
- 2) Con reglas DNF:
  - d) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - e) Para SDIGA-D, se obtienen mejores resultados al disminuir el número de etiquetas.
  - f) Para SDIGA-N, al aumentar el número de etiquetas, mejoran algo los resultados.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad de completitud y confianza difusas obtienen mejores resultados. Se obtienen mejores resultados con reglas DNF.

### Conjunto de datos Wine

Los datos de la experimentación realizada para la base de ejemplos *Wine* que tiene 178 ejemplos distribuidos en 3 clases y descritos mediante 13 variables continuas, se muestran en la Tabla 2.17.

Tabla 2.17. Resumen del análisis de componentes para el dataset Wine

	Etiqu/	CnfMin	NR	NV	Cob	Rel	Ati	Prec	Comp	CComp	FComp	FConf	CConf	Int
No DNF	Orig	3 / 0.9	5,12	4,24	0,088	3,486	0,058	<b>0,502</b>	<b>0,677</b>	0,395	0,097	<b>0,803</b>	0,607	<b>0,232</b>
	Difuso	3 / 0.7	<b>3,44</b>	<b>2,37</b>	<b>0,174</b>	<b>4,343</b>	0,041	0,365	0,630	0,621	0,099	0,516	0,451	0,160 *
	Nitido	3 / 0.7	8,74	3,01	0,115	3,599	<b>0,059</b>	0,475	0,661	<b>0,688</b>	<b>0,108</b>	0,673	<b>0,635</b>	0,227
DNF	Orig	3 / 0.9	5,08	5,29	0,084	3,299	0,056	<b>0,495</b>	0,697	0,393	0,090	<b>0,814</b>	0,560	
	Difuso	5 / 0.9	<b>3,34</b>	<b>2,40</b>	<b>0,183</b>	<b>6,109</b>	<b>0,110</b>	0,494	0,662	<b>0,862</b>	<b>0,131</b>	0,661	0,672	*
	Nitido	3 / 0.9	12,78	3,87	0,147	4,265	0,068	0,515	<b>0,814</b>	0,825	0,123	0,656	<b>0,675</b>	

El análisis de estos datos muestra que:

- 1) Con reglas canónicas (no DNF):
  - a) Para SDIGA-H, los resultados son mejores con un número menor de etiquetas. El aumento de confianza mínima mejora ligeramente los resultados.
  - b) Para SDIGA-D, se obtienen mejores resultados con un número menor de etiquetas.
  - c) Para SDIGA-N, los resultados son mejores para el número pequeño de etiquetas.
- 2) Con reglas DNF:
  - a) Para SDIGA-H, en general, al aumentar el número de etiquetas, los resultados empeoran.
  - b) Para SDIGA-D, se obtienen mejores resultados al aumentar el número de etiquetas.
  - c) Para SDIGA-N, al aumentar el número de etiquetas, mejoran algunas medidas, pero se incrementa enormemente el número de reglas obtenidas. Se obtienen conjuntos de reglas más grandes.

En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad de completitud y confianza difusas obtienen mejores resultados. Las reglas DNF obtienen mejores resultados.

### 2.2.4 Conclusiones

A la vista de los resultados, no se puede concluir que en general un conjunto de medidas sea superior a los otros. En general, para este conjunto de datos, las ejecuciones de nuestra propuesta que utilizan las medidas de calidad de completitud y confianza difusas obtienen mejores resultados. La Tabla 2.18 muestra las características de los distintos conjuntos de ejemplos y la combinación de medidas de calidad que obtiene en general mejores resultados sobre el mismo.

Tabla 2.18. Resumen de características de los conjuntos de ejemplos y sus resultados.

Nombre	Variables	Discretas	Continuas	Nº Clases	Ejemplos	Mejores resultados	
						Medidas	Tipo de regla
Australian	14	8	6	2	690	SDIGA-D	No DNF
Breast-w	9	9	0	2	699	SDIGA-H	No DNF
Bridges	7	4	3	2	102	SDIGA-H	No DNF / DNF
Diabetes	8	0	8	2	768	SDIGA-H	No DNF
Echo	6	1	5	2	131	SDIGA-H	No DNF
German	20	13	7	2	1000	SDIGA-H	No DNF / DNF
Heart	13	6	7	2	270	SDIGA-H	DNF
Hepatitis	19	13	6	2	155	SDIGA-H	No DNF / DNF
Hypothyroid	25	18	7	2	3163	SDIGA-H	DNF
Ionosphere	34	0	34	2	351	SDIGA-N	No DNF
Iris	4	0	4	3	150	SDIGA-D	DNF
Tic-tac-toe	9	9	0	2	958	SDIGA-N	No DNF / DNF
Vote	16	16	0	2	435	SDIGA-H	DNF
Balance	4	0	4	3	625	SDIGA-H	DNF
Car	6	6	0	4	1728	SDIGA-N	DNF
Glass	9	0	9	6	214	SDIGA-D	DNF
Wine	13	0	13	3	178	SDIGA-D	DNF

En general, para el conjunto de bases de ejemplos, el modelo tiene mejores resultados cuando se utilizan como medidas de calidad la completitud nítida sobre ejemplos de la clase y la confianza difusa (SDIGA-H). Y cuando SDIGA-H no es el mejor en alguna base de ejemplos, sus resultados están próximos a la mejor alternativa. La utilización de las medidas de calidad de completitud y confianza difusa aporta mejores resultados sólo en algunas bases de ejemplos con todas sus variables continuas y con variables objetivo con más de dos clases. La utilización de medidas de calidad nítidas sólo aporta mejores resultados con parte de los conjuntos de ejemplos cuyas variables son discretas.

En definitiva, analizando los resultados, la mejor alternativa para el conjunto de bases de ejemplos es la utilización de las medidas de calidad de completitud nítida sobre ejemplos de la clase y la confianza difusa, que utilizaremos en adelante.

## 2.3 Comparación entre el algoritmo SDIGA y otros algoritmos de descubrimiento de subgrupos

Para verificar la aplicabilidad de la propuesta, hemos comparado sus resultados con los de otros algoritmos de descubrimiento de subgrupos.

La comparación se ha realizado utilizando como referencia el trabajo de Lavrac et al. con CN2-SD [LKFT04] y de Kavsec et al. con Apriori-SD [KL06]. El algoritmo CN2-SD, como se ha mencionado previamente, es un algoritmo para la extracción de reglas descripción de subgrupos, obtenido modificando el algoritmo CN2 de extracción de reglas de clasificación, y el algoritmo Apriori-SD es otro algoritmo de extracción de reglas de

descripción de subgrupos obtenido mediante la modificación del algoritmo de extracción de reglas de clasificación Apriori-C. Se puede encontrar una breve descripción de ambos algoritmos en el Apéndice C.

### 2.3.1 Características de la experimentación

Para la evaluación experimental y la comparación del enfoque propuesto, se han utilizado distintos conjuntos de datos que están disponibles en el repositorio UCI<sup>1</sup> (se puede encontrar la descripción de estos conjuntos de datos sintéticos del repositorio UCI en el Apéndice A).

Algunas bases de ejemplos contienen variables numéricas, y se utilizan para mostrar los resultados de las reglas difusas extraídas por la propuesta en comparación con otros algoritmos de descubrimiento de subgrupos. Además, la propuesta puede también manejar variables categóricas, y se han incluido en la experimentación varias bases de ejemplos con variables categóricas para mostrar el comportamiento de la propuesta con esta clase de problemas.

Los experimentos se han llevado a cabo de la misma forma que en [LKFT04] para permitir la comparación de los algoritmos de descubrimiento de subgrupos: validación cruzada con 10 particiones para la estimación de error (se divide el dataset en 10 particiones y se obtienen 10 combinaciones distintas formadas por un 90% de los datos para entrenamiento y un 10% para prueba).

Como ya hemos mencionado, cada ejecución del proceso iterativo obtiene un número variable de reglas, todas correspondientes al mismo valor de la variable objetivo. Así, el proceso se debe repetir para cada uno de los valores de la variable objetivo. Por último, como la propuesta es no-determinista, se han llevado a cabo 5 ejecuciones sobre cada conjunto de particiones de entrenamiento/prueba. Después de obtener las reglas con el algoritmo SDIGA, se han calculado las medidas de Cobertura (*Cob*), Soporte (*Sop*), Relevancia (*Rel*) y Atipicidad (*WRAcc*) de las reglas obtenidas, con las expresiones definidas en el Capítulo 1 de esta memoria, y los correspondientes valores para los conjuntos de reglas (*COB*, *SOP*, *REL* y *WRACC* respectivamente) y la complejidad (*TAM*). La experimentación se ha realizado para obtener reglas tanto de tipo canónico como DNF. Los parámetros utilizados en esta experimentación son los siguientes:

- Tamaño de la población: 100.
- Máximo número de evaluaciones de individuos en cada ejecución del AG: 10000.

---

<sup>1</sup> [www.ics.uci.edu/~mllearn/MLRepository.html](http://www.ics.uci.edu/~mllearn/MLRepository.html)

- Probabilidad de mutación: 0.01.
- Número de etiquetas lingüísticas para las variables continuas: 3 y 5.
- Pesos de las medidas de calidad para la función de adaptación:
  - $w_1$ : 0.4
  - $w_2$ : 0.3

Como se ha mencionado en la Subsección 2.1.1, la especificación de los pesos para la función de adaptación depende del conocimiento de los expertos sobre las características y/o complejidad del problema a resolver. Aquí, ante la no disponibilidad de conocimiento experto, se han utilizado valores para estos pesos considerando únicamente promover ligeramente la extracción de reglas generales.

### 2.3.2 Análisis de resultados

Las Tablas 2.19 a 2.35 muestran los resultados obtenidos por la propuesta y los reflejados en el trabajo de Lavrač y otros [LKFT04] para los distintos conjuntos de datos. Los resultados muestran para nuestra propuesta las medias de los valores obtenidos en las particiones de prueba para todas las ejecuciones.

En estas tablas, se marca con un punto (“•”) la experimentación con mejores resultados de todos los algoritmos, con asterisco (“\*”) la experimentación con mejores resultados para el algoritmo SDIGA en cualquiera de sus versiones, y con un signo mas (“+”) la experimentación con mejores resultados para cada uno de los grupos (SDIGA con reglas canónicas, SDIGA con reglas DNF, y el resto de los algoritmos de SD).

Las tablas incluyen los resultados obtenidos con:

- El algoritmo SDIGA (para 4 valores de confianza mínima, desde 0.6 a 0.9, y para 3 y 5 etiquetas para las variables lingüísticas).
- El algoritmo SDIGA obteniendo reglas DNF (SDIGA-DNF).
- El algoritmo CN2.
- El algoritmo CN2 modificando la medida de atipicidad (CN2-WRAcc).
- El algoritmo CN2-SD utilizando diferentes parámetros para los pesos (CN2-SD ( $\gamma=x$ ) es el algoritmo CN2-SD utilizando pesos multiplicativos con  $\gamma=x$ , y CN2-SD (add.) es el algoritmo CN2-SD utilizando pesos aditivos).
- El algoritmo Apriori-SD.

En el Apéndice C, se describe el significado de los parámetros del algoritmo CN2-SD.

Para cada medida, se muestra el valor de la media de los resultados obtenidos por los conjuntos de reglas. “COB” es la cobertura media del conjunto de reglas calculada como en (1.2), “SOP” es el soporte total de un conjunto de reglas calculada como en (1.3), “TAM”

es el número de reglas del conjunto inducido, “REL” es el promedio de la relevancia del conjunto de reglas calculada como en (1.7), y “WRACC” es la media de la atipicidad del conjunto de reglas calculado como en (1.9).

Tabla 2.19. Comparación de algoritmos de descubrimiento de subgrupos para Australian

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,196	<b>0,619</b>	3,58	5,844	0,052	
		0.7	0,113	0,548	3,12	6,093	0,043	
		0.8	0,110	0,544	3,12	5,706	0,041	
		0.9	0,120	0,569	3,06	6,098	0,044	
	5	0.6	0,303	0,537	4,66	10,996	0,092	
		0.7	0,290	0,558	3,18	14,847	0,111	
		0.8	0,276	0,545	3,00	14,647	0,108	
		0.9	<b>0,310</b>	0,591	<b>2,64</b>	<b>16,348</b>	<b>0,120</b> *	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,197	0,665	4,30	5,522	0,052
			0.7	0,114	0,606	3,12	5,616	0,043
			0.8	0,134	0,655	2,70	6,848	0,051
			0.9	0,143	<b>0,733</b>	<b>2,30</b>	<b>7,344</b>	0,055
5		0.6	<b>0,230</b>	0,619	4,64	5,543	0,057	
		0.7	0,148	0,599	3,14	6,394	0,052	
		0.8	0,135	0,533	3,60	5,737	0,046	
		0.9	0,160	0,707	2,50	7,169	<b>0,058</b> <sup>+</sup>	
CN2 Standard		0,071	0,810	12,40	2,000	0,022		
CN2 WRAcc		0,416	0,890	<b>2,00</b>	7,800	0,148		
CN2-SD		Esq. pesos						
		$\gamma=0.5$	0,473	0,870	2,70	14,600	<b>0,186</b>	
		$\gamma=0.7$	0,492	<b>0,970</b>	2,60	<b>24,000</b>	0,185 <sup>•</sup>	
	$\gamma=0.9$	0,480	0,840	2,20	15,600	0,181		
	add.	0,424	0,890	3,50	4,600	0,162		
Apriori-SD		<b>0,550</b>	0,790	3,50	8,400	0,045		

Para el conjunto de datos *Australian*, el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.9$  obtiene los mejores resultados. En nuestra propuesta se obtienen mejores resultados con reglas canónicas, 5 etiquetas para las variables lingüísticas y umbral de confianza mínima de 0.9, y en el que los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,591
- Confianza: 0,793
- Interés: 0,847

Tabla 2.20. Comparación de algoritmos de descubrimiento de subgrupos para *Breast-w*

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,419	0,608	4,50	12,212	0,094	
		0.7	0,474	0,686	4,20	13,835	0,106	
		0.8	0,429	0,681	2,70	17,013	0,117	
		0.9	0,422	0,674	2,52	17,325	0,118	
	5	0.6	0,428	0,615	4,72	12,167	0,095	
		0.7	<b>0,497</b>	<b>0,709</b>	4,10	13,537	0,107	
		0.8	0,425	0,679	2,58	17,245	0,118	
		0.9	0,430	0,692	<b>2,42</b>	<b>17,869</b>	<b>0,121</b> •	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,290	0,526	6,60	15,122	0,099
			0.7	0,269	0,495	7,40	14,697	0,093
0.8			0,308	0,542	6,46	15,217	0,100	
0.9			<b>0,398</b>	<b>0,693</b>	<b>4,08</b>	19,455	<b>0,131</b> +	
5		0.6	0,288	0,513	6,92	14,222	0,095	
		0.7	0,307	0,558	6,52	15,972	0,105	
		0.8	0,305	0,548	6,54	15,593	0,103	
		0.9	0,375	0,667	4,28	<b>19,891</b>	0,129	
CN2 Standard		0,079	0,880	12,60	2,700	0,034		
CN2 WRAcc		0,150	0,900	8,80	13,300	0,063		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,208	0,890	7,90	<b>27,100</b>	0,095		
	$\gamma=0.7$	0,174	0,840	8,50	2,100	0,079		
	$\gamma=0.9$	0,218	<b>0,930</b>	9,00	20,500	0,093		
	add.	0,260	0,860	9,20	26,600	<b>0,111</b> +		
Apriori-SD		<b>0,300</b>	0,640	<b>4,20</b>	14,200	0,038		

Para el conjunto de datos *Breast-w*, nuestra propuesta, con reglas canónicas, 5 etiquetas para las variables lingüísticas y umbral de confianza mínima de 0.9 es la que obtiene mejores resultados, a continuación nuestra propuesta con reglas DNF, y por último CN2-SD. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,692
- Confianza: 0,858
- Interés: 0,649

Tabla 2.21. Comparación de algoritmos de descubrimiento de subgrupos para Bridges

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	<b>0,299</b>	0,505	3,04	<b>0,805</b>	<b>0,024</b> <sup>+</sup>	
		0.7	0,288	0,469	3,06	0,652	0,014	
		0.8	0,284	0,472	3,02	0,723	0,020	
		0.9	0,281	<b>0,507</b>	<b>2,54</b>	0,704	0,013	
	5	0.6	0,266	0,361	4,70	0,589	0,016	
		0.7	0,281	0,382	4,08	0,705	0,015	
		0.8	0,266	0,378	4,28	0,646	0,015	
		0.9	0,208	0,331	3,04	0,697	0,012	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,433	0,808	2,04	0,513	0,016
			0.7	0,439	<b>0,830</b>	<b>2,00</b>	0,565	0,015
			0.8	0,437	0,820	<b>2,00</b>	0,507	0,015
			0.9	<b>0,443</b>	0,820	<b>2,00</b>	0,398	0,015
5		0.6	0,298	0,805	2,06	1,057	0,035	
		0.7	0,292	0,775	2,10	1,035	0,033	
		0.8	0,299	0,822	2,04	1,160	0,037	
		0.9	0,299	0,813	2,08	<b>1,204</b>	<b>0,038</b> <sup>*</sup>	
CN2 Standard			0,625	0,870	<b>1,80</b>	2,100	-0,016	
CN2 WRAcc		0,322	0,870	2,00	7,800	-0,012		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,612	0,840	2,00	13,300	-0,005		
	$\gamma=0.7$	0,617	0,930	2,70	2,500	-0,006		
	$\gamma=0.9$	<b>0,721</b>	0,840	1,90	21,200	-0,001		
	add.	0,330	<b>0,950</b>	<b>1,80</b>	<b>22,900</b>	-0,012 <sup>•</sup>		
Apriori-SD		0,540	0,820	2,40	8,200	<b>0,023</b>		

Para el conjunto de datos *Bridges*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos, pero la propuesta SDIGA con reglas DNF, 5 etiquetas para las variables lingüísticas y umbral de confianza mínima de 0.9 está muy cercana. El hecho de que el algoritmo CN2-SD obtenga una media de número de reglas inferior a 2 (en un conjunto de datos en el que la variable de clase tiene 2 valores) indica que no obtiene reglas para todas las clases. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,813
- Confianza: 0,608

Tabla 2.22. Comparación de algoritmos de descubrimiento de subgrupos para Diabetes

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,274	0,657	2,90	4,107	0,029	
		0.7	0,272	0,651	2,92	4,043	0,028	
		0.8	<b>0,378</b>	<b>0,812</b>	<b>2,00</b>	<b>5,236</b>	<b>0,035</b>	
		0.9	<b>0,378</b>	<b>0,812</b>	<b>2,00</b>	<b>5,236</b>	<b>0,035</b> *	
	5	0.6	0,196	0,423	3,68	1,935	0,016	
		0.7	0,267	0,548	2,36	2,671	0,021	
		0.8	0,253	0,554	2,22	2,752	0,021	
		0.9	0,279	0,588	2,14	2,971	0,024	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,212	0,891	2,88	3,824	0,032
			0.7	0,209	0,892	2,86	3,725	0,031
0.8			<b>0,265</b>	<b>0,961</b>	<b>2,00</b>	<b>4,652</b>	<b>0,039</b> <sup>+</sup>	
0.9			0,263	<b>0,961</b>	<b>2,00</b>	4,633	0,038	
5		0.6	0,097	0,828	2,10	3,463	0,023	
		0.7	0,098	0,827	2,14	3,492	0,024	
		0.8	0,103	0,849	<b>2,00</b>	3,649	0,025	
		0.9	0,100	0,845	<b>2,00</b>	3,503	0,024	
CN2 Standard		0,057	0,800	12,80	2,000	0,013		
CN2 WRAcc		0,275	0,820	5,20	15,800	0,065		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,296	0,920	6,00	14,900	0,085		
	$\gamma=0.7$	0,344	0,850	5,60	11,000	<b>0,099</b>		
	$\gamma=0.9$	0,299	<b>0,950</b>	5,40	15,200	0,086		
	add.	<b>0,381</b>	0,870	4,60	2,100	0,092		
Apriori-SD		0,300	0,690	<b>4,40</b>	<b>16,400</b>	0,043		

Para el conjunto de datos *Diabetes*, obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.9$ . Sin embargo, los mejores resultados de nuestra propuesta (SDIGA para reglas canónicas, con 3 etiquetas y confianza mínima 0,9) superan a los de CN2-SD en cobertura y número de reglas. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,812
- Confianza: 0,671

Tabla 2.23. Comparación de algoritmos de descubrimiento de subgrupos para Echo

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,325	0,668	3,02	0,943	0,026	
		0.7	0,309	0,654	2,62	1,058	<b>0,033</b>	
		0.8	0,329	<b>0,704</b>	<b>2,00</b>	1,003	0,030 +	
		0.9	0,329	0,702	<b>2,00</b>	0,997	0,029	
	5	0.6	0,321	0,538	3,30	1,120	0,022	
		0.7	0,394	0,566	2,32	<b>1,165</b>	0,013	
		0.8	0,374	0,587	<b>2,00</b>	0,855	0,014	
		0.9	<b>0,395</b>	0,584	<b>2,00</b>	1,096	0,018	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	<b>0,315</b>	0,832	<b>2,00</b>	1,219	0,036
			0.7	<b>0,315</b>	0,832	<b>2,00</b>	1,219	0,036
			0.8	0,314	0,830	<b>2,00</b>	1,226	0,035
			0.9	<b>0,315</b>	<b>0,834</b>	<b>2,00</b>	1,212	0,036
5		0.6	0,272	0,750	<b>2,00</b>	1,394	0,038	
		0.7	0,268	0,744	2,02	1,419	0,038	
		0.8	0,267	0,744	2,02	<b>1,456</b>	<b>0,043</b> *	
		0.9	0,263	0,738	<b>2,00</b>	1,344	0,036	
CN2 Standard			0,312	0,900	3,70	1,900	0,058	
CN2 WRAcc		0,576	0,810	2,50	10,000	0,099		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,936	0,950	3,10	11,000	0,174		
	$\gamma=0.7$	1,039	0,850	3,80	<b>30,500</b>	0,208		
	$\gamma=0.9$	1,006	<b>0,980</b>	4,70	30,100	0,213		
	add.	<b>1,295</b>	0,820	3,40	23,100	<b>0,243</b> •		
Apriori-SD		1,000	<b>0,980</b>	<b>1,00</b>	10,400	0,040		

Para el conjunto de datos *Echo*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos. Los mejores resultados de nuestra propuesta se obtienen con reglas DNF, 5 etiquetas y confianza mínima 0,8. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,744
- Confianza: 0,608

Tabla 2.24. Comparación de algoritmos de descubrimiento de subgrupos para German

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,082	0,177	8,56	<b>0,615</b>	<b>0,006</b> *	
		0.7	0,078	0,170	9,48	0,487	0,005	
		0.8	0,057	0,128	8,68	0,386	0,003	
		0.9	0,050	0,111	8,18	0,363	0,003	
	5	0.6	<b>0,138</b>	<b>0,193</b>	4,82	0,353	0,002	
		0.7	0,103	0,146	5,68	0,258	0,001	
		0.8	0,076	0,116	5,44	0,398	0,002	
		0.9	0,103	0,118	<b>4,38</b>	0,317	0,001	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,018	0,058	32,40	0,862	0,002
			0.7	0,020	0,066	29,20	0,836	0,003
0.8			<b>0,027</b>	<b>0,085</b>	<b>25,98</b>	<b>0,875</b>	<b>0,004</b> +	
0.9			0,016	0,049	29,30	0,796	0,002	
5		0.6	0,024	0,069	28,24	0,586	0,002	
		0.7	0,016	0,047	33,62	0,638	0,001	
		0.8	0,015	0,036	30,78	0,565	0,001	
		0.9	0,011	0,031	32,76	0,607	0,001	
CN2 Standard		0,053	0,890	15,10	2,000	0,012		
CN2 WRAcc		0,092	0,880	7,80	2,700	0,020		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,141	0,900	8,40	<b>19,800</b>	0,034 •		
	$\gamma=0.7$	0,153	0,810	8,70	17,700	<b>0,040</b>		
	$\gamma=0.9$	0,138	<b>0,970</b>	9,10	11,100	0,034		
	add.	0,151	0,960	8,80	16,300	0,034		
Apriori-SD		<b>0,300</b>	0,770	<b>6,20</b>	11,000	0,036		

Para el conjunto de datos *German*, obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.5$ . Nuestros mejores resultados son para reglas canónicas con 3 etiquetas y confianza mínima 0,6. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,177
- Confianza: 0,313

Tabla 2.25. Comparación de algoritmos de descubrimiento de subgrupos para Heart

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,367	0,665	3,30	1,468	0,045	
		0.7	0,438	0,747	2,76	1,516	0,047	
		0.8	<b>0,504</b>	<b>0,852</b>	<b>2,00</b>	<b>1,790</b>	<b>0,059</b> +	
		0.9	0,486	0,833	<b>2,00</b>	1,731	0,058	
	5	0.6	0,371	0,538	2,72	1,321	0,048	
		0.7	0,391	0,591	2,60	1,556	0,054	
		0.8	0,402	0,559	2,02	1,277	0,048	
		0.9	0,368	0,520	2,04	1,047	0,041	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,423	0,887	2,28	2,220	0,079
			0.7	0,436	0,963	2,02	2,389	0,082
			0.8	0,457	0,968	<b>2,00</b>	2,426	<b>0,083</b>
			0.9	<b>0,464</b>	<b>0,971</b>	<b>2,00</b>	2,359	<b>0,083</b> *
5		0.6	0,266	0,722	3,00	2,758	0,064	
		0.7	0,284	0,742	2,82	2,437	0,064	
		0.8	0,322	0,898	<b>2,00</b>	2,820	0,071	
		0.9	0,344	0,932	<b>2,00</b>	<b>3,056</b>	0,079	
CN2 Standard		0,107	0,840	6,40	1,900	0,026		
CN2 WRAcc		0,240	0,870	3,00	4,600	0,065		
CN2-SD		Esq. pesos						
		$\gamma=0.5$	0,419	0,940	2,90	23,200	<b>0,124</b>	
		$\gamma=0.7$	0,376	0,830	2,70	5,300	0,104	
	$\gamma=0.9$	0,366	0,890	2,70	4,000	0,104		
	add.	0,435	<b>0,980</b>	1,80	<b>30,600</b>	0,122 •		
Apriori-SD		<b>0,670</b>	0,670	<b>1,40</b>	5,200	0,048		

Para el conjunto de datos *Heart*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos. Sin embargo, nuestra propuesta con reglas DNF, 3 etiquetas y umbral de confianza mínima 0,9 obtiene resultados casi iguales (salvo para la relevancia). En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,971
- Confianza: 0,602

Tabla 2.26. Comparación de algoritmos de descubrimiento de subgrupos para Hepatitis

Algoritmo		COB	SOP	TAM	REL	WRACC	
SDIGA	Etiqu CnfMin						
	3	0.6	0,162	0,365	5,64	0,744	0,014
		0.7	0,154	0,372	5,56	0,746	0,014
		0.8	0,187	0,415	5,16	0,813	0,017
		0.9	0,235	<b>0,550</b>	<b>2,68</b>	<b>0,875</b>	<b>0,019</b> +
	5	0.6	0,201	0,332	5,14	0,782	0,016
		0.7	0,165	0,285	5,02	0,661	0,014
		0.8	<b>0,255</b>	0,383	4,34	0,722	<b>0,019</b>
		0.9	0,223	0,365	3,74	0,526	0,016
	SDIGA DNF	Etiqu CnfMin					
3		0.6	0,234	0,598	3,60	0,876	0,023
		0.7	0,250	0,606	2,94	0,670	0,022
		0.8	0,273	0,703	2,62	<b>0,962</b>	0,025
		0.9	<b>0,286</b>	<b>0,737</b>	<b>2,34</b>	0,864	<b>0,027</b> *
5		0.6	0,113	0,443	4,58	0,816	0,012
		0.7	0,129	0,470	4,26	0,738	0,012
		0.8	0,123	0,491	4,18	0,856	0,012
		0.9	0,156	0,542	3,22	0,730	0,014
CN2 Standard		0,207	0,870	3,00	2,700	0,004	
CN2 WRAcc		0,430	0,810	2,10	9,700	0,018	
CN2-SD	Esq. pesos						
	$\gamma=0.5$	0,637	0,850	<b>1,70</b>	12,300	0,057	
	$\gamma=0.7$	0,829	0,940	2,70	9,300	<b>0,073</b>	
	$\gamma=0.9$	0,826	0,900	3,60	8,500	0,066	
	add.	0,686	<b>0,990</b>	2,70	<b>25,000</b>	0,049 •	
Apriori-SD		<b>0,850</b>	0,850	2,80	10,500	0,030	

Para el conjunto de datos *Hepatitis*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos. La experimentación de nuestra propuesta que mejores resultados obtiene es con reglas DNF, 3 etiquetas y umbral de confianza mínima 0,9. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,737
- Confianza: 0,663

Tabla 2.27. Comparación de algoritmos de descubrimiento de subgrupos para Hypothyroid

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,288	0,665	<b>2,74</b>	<b>11,776</b>	<b>0,016</b> <sup>+</sup>	
		0.7	0,309	0,678	2,80	10,797	<b>0,016</b>	
		0.8	0,269	0,579	2,92	10,363	0,014	
		0.9	0,285	0,607	2,90	10,301	0,015	
	5	0.6	0,328	<b>0,699</b>	3,48	10,657	0,013	
		0.7	0,345	0,674	3,22	10,470	0,013	
		0.8	0,333	0,631	3,40	9,225	0,012	
		0.9	<b>0,346</b>	0,665	3,26	9,419	0,012	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,223	0,830	2,88	14,208	0,014
			0.7	0,231	0,833	2,82	13,935	0,014
			0.8	0,232	<b>0,881</b>	2,78	14,364	0,015
			0.9	0,208	0,794	2,78	12,163	0,013
5		0.6	0,359	0,751	3,32	<b>18,738</b>	0,020	
		0.7	0,406	0,798	2,88	18,491	0,021	
		0.8	0,365	0,725	3,10	16,673	0,019	
		0.9	<b>0,416</b>	0,817	<b>2,76</b>	18,643	<b>0,022</b> <sup>*</sup>	
CN2 Standard		0,093	0,840	10,10	1,400	0,013		
CN2 WRAcc		0,495	0,830	3,90	3,600	0,067		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,509	0,820	3,90	5,800	<b>0,076</b>		
	$\gamma=0.7$	0,509	<b>1,000</b>	3,40	<b>28,300</b>	0,073 <sup>•</sup>		
	$\gamma=0.9$	0,516	0,900	3,30	24,900	<b>0,076</b>		
	add.	0,513	0,950	2,50	13,500	0,072		
Apriori-SD		<b>0,520</b>	0,520	<b>1,40</b>	4,200	0,008		

Para el conjunto de datos *German*, obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.7$ . Nuestros mejores resultados son para reglas DNF con 5 etiquetas y confianza mínima 0,9. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,817
- Confianza: 0,823

Tabla 2.28. Comparación de algoritmos de descubrimiento de subgrupos para *Ionosphere*

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,113	0,352	3,52	2,581	0,035	
		0.7	0,120	0,367	3,60	<b>2,769</b>	0,036	
		0.8	0,117	0,373	3,40	2,623	0,036	
		0.9	0,105	0,358	3,46	2,448	0,032	
	5	0.6	0,414	0,502	2,22	0,766	0,035	
		0.7	<b>0,430</b>	<b>0,512</b>	2,14	0,857	<b>0,038</b>	
		0.8	0,418	0,495	2,14	1,011	<b>0,038</b>	
		0.9	0,416	0,500	<b>2,08</b>	1,017	<b>0,038</b> *	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,071	0,266	8,34	<b>2,553</b>	<b>0,029</b>
			0.7	0,058	0,237	8,72	2,101	0,024
0.8			<b>0,081</b>	0,297	7,52	2,518	<b>0,029</b>	
0.9			0,058	0,244	8,56	2,208	0,024	
5		0.6	0,048	0,312	3,30	1,229	0,015	
		0.7	0,066	0,380	2,90	1,816	0,022	
		0.8	0,078	<b>0,385</b>	2,92	1,845	0,023 <sup>+</sup>	
		0.9	0,069	0,376	<b>2,64</b>	1,681	0,021	
CN2 Standard		0,099	0,830	7,60	2,000	0,041		
CN2 WRAcc		0,168	0,850	<b>3,00</b>	1,800	0,065		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,229	0,960	3,90	16,700	0,099		
	$\gamma=0.7$	0,234	0,950	4,00	23,900	0,095		
	$\gamma=0.9$	0,246	0,890	3,60	<b>30,900</b>	0,104		
	add.	<b>0,354</b>	<b>0,980</b>	4,20	14,900	<b>0,145</b> <sup>•</sup>		
Apriori-SD		0,240	0,680	3,50	1,900	0,043		

Para el conjunto de datos *Ionosphere*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos. La experimentación de nuestra propuesta que mejores resultados obtiene es con reglas canónicas, 5 etiquetas y umbral de confianza mínima 0,9, que supera a CN2-SD en cobertura. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,500
- Confianza: 0,418
- Interés: 0,536

Tabla 2.29. Comparación de algoritmos de descubrimiento de subgrupos para Iris

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	<b>0,304</b>	<b>0,985</b>	3,10	<b>8,178</b>	<b>0,176</b>	
		0.7	<b>0,304</b>	<b>0,985</b>	3,10	<b>8,178</b>	<b>0,176</b>	
		0.8	<b>0,304</b>	<b>0,985</b>	3,10	<b>8,178</b>	<b>0,176</b>	
		0.9	<b>0,304</b>	<b>0,985</b>	3,10	<b>8,178</b>	<b>0,176</b> +	
	5	0.6	0,220	0,865	3,90	6,578	0,137	
		0.7	0,223	0,859	3,90	6,563	0,137	
		0.8	0,253	0,947	3,30	7,502	0,157	
		0.9	0,264	0,979	<b>3,00</b>	7,976	0,165	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	<b>0,311</b>	<b>1,000</b>	<b>3,00</b>	8,416	0,181
			0.7	<b>0,311</b>	<b>1,000</b>	<b>3,00</b>	8,416	0,181
			0.8	<b>0,311</b>	<b>1,000</b>	<b>3,00</b>	8,416	0,181
0.9			<b>0,311</b>	<b>1,000</b>	<b>3,00</b>	8,416	0,181 *	
5		0.6	0,280	<b>1,000</b>	<b>3,00</b>	8,881	0,182	
		0.7	0,280	<b>1,000</b>	<b>3,00</b>	<b>8,896</b>	<b>0,183</b>	
		0.8	0,280	0,999	<b>3,00</b>	8,867	0,182	
		0.9	0,276	0,999	<b>3,00</b>	8,768	0,180	
CN2 Standard		0,378	0,820	3,80	1,900	0,024		
CN2 WRAcc		0,386	0,890	3,00	7,100	0,024		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,619	0,830	3,20	17,000	<b>0,062</b>		
	$\gamma=0.7$	0,444	0,910	3,40	1,300	0,042		
	$\gamma=0.9$	0,768	0,880	2,90	<b>17,600</b>	0,052 •		
	add.	0,668	<b>0,950</b>	3,60	4,000	0,045		
Apriori-SD		<b>0,840</b>	0,840	<b>2,10</b>	7,500	0,039		

Para el conjunto de datos *Iris*, obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.9$ . Nuestros mejores resultados son para reglas DNF con 3 etiquetas y confianza mínima 0,9. En este caso, nuestra propuesta consigue mejorar la completitud y atipicidad de CN2-SD. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 1,000
- Confianza: 0,842

Tabla 2.30. Comparación de algoritmos de descubrimiento de subgrupos para Tic-Tac-Toe

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,156	0,216	10,64	5,659	<b>0,029</b>	
		0.7	0,162	0,221	9,20	5,135	0,027 <sup>+</sup>	
		0.8	0,108	0,175	<b>7,50</b>	5,948	<b>0,029</b>	
		0.9	0,088	0,152	7,90	6,148	0,026	
	5	0.6	<b>0,169</b>	<b>0,224</b>	10,26	5,084	0,026	
		0.7	0,160	0,220	9,94	5,432	0,028	
		0.8	0,107	0,171	7,64	5,979	0,027	
		0.9	0,108	0,177	7,82	<b>6,277</b>	<b>0,029</b>	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	<b>0,405</b>	<b>0,455</b>	8,40	4,619	0,022
			0.7	0,362	0,420	7,10	4,821	0,027
0.8			0,337	0,408	6,72	<b>6,133</b>	<b>0,030</b>	
0.9			0,366	0,431	7,02	5,316	0,028	
5		0.6	0,371	0,426	8,66	4,935	0,024	
		0.7	0,350	0,412	7,84	4,946	0,028	
		0.8	0,361	0,425	7,12	5,185	0,028	
		0.9	0,351	0,422	<b>6,48</b>	5,866	<b>0,030</b> <sup>*</sup>	
CN2 Standard		0,030	0,830	21,20	2,500	0,015		
CN2 WRAcc		0,113	0,800	10,50	4,200	0,030		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,129	<b>0,960</b>	11,20	17,500	0,036		
	$\gamma=0.7$	0,146	0,860	10,30	5,700	0,041		
	$\gamma=0.9$	0,182	0,800	9,60	21,900	<b>0,055</b> <sup>•</sup>		
	add.	0,117	0,810	10,20	<b>26,500</b>	0,032		
Apriori-SD		<b>0,290</b>	0,840	<b>7,10</b>	15,200	0,045		

Para el conjunto de datos *Tic-Tac-Toe*, de nuevo obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.9$ , aunque nuestra propuesta con reglas DNF, 5 etiquetas y confianza mínima 0,9 lo supera en cobertura, y número de reglas. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,422
- Confianza: 0,759

Tabla 2.31. Comparación de algoritmos de descubrimiento de subgrupos para Vote

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,373	0,655	4,92	13,327	0,137	
		0.7	0,380	0,704	4,44	14,949	0,153	
		0.8	0,371	0,679	4,28	14,461	0,148	
		0.9	<b>0,422</b>	<b>0,802</b>	<b>3,06</b>	<b>18,243</b>	<b>0,180</b> +	
	5	0.6	0,359	0,633	5,22	12,921	0,132	
		0.7	0,395	0,728	4,24	15,644	0,159	
		0.8	0,361	0,676	4,58	14,933	0,148	
		0.9	0,414	0,785	3,16	17,733	0,176	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,299	0,564	4,86	12,120	0,123
			0.7	0,368	0,703	4,02	15,167	0,154
			0.8	0,364	0,688	3,80	14,804	0,150
			0.9	<b>0,492</b>	<b>0,931</b>	<b>2,28</b>	<b>20,335</b>	<b>0,208</b> •
5		0.6	0,310	0,588	4,68	12,725	0,129	
		0.7	0,356	0,677	4,12	14,621	0,148	
		0.8	0,380	0,722	3,82	15,524	0,158	
		0.9	0,487	0,920	<b>2,28</b>	20,131	0,206	
CN2 Standard		0,129	0,850	7,10	2,600	0,017		
CN2 WRAcc		0,650	0,820	2,00	11,700	0,095		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,703	<b>1,000</b>	2,40	9,600	0,117		
	$\gamma=0.7$	0,711	0,840	2,40	<b>22,700</b>	0,129 +		
	$\gamma=0.9$	0,674	0,960	2,90	2,300	0,127		
	add.	<b>0,831</b>	0,850	<b>1,80</b>	6,000	<b>0,138</b>		
Apriori-SD		0,710	0,710	2,00	12,000	0,046		

Para el conjunto de datos *Vote*, nuestra propuesta con reglas DNF, 3 etiquetas y confianza mínima 0,9 es la que mejores resultados obtiene, seguida por la propuesta con reglas canónicas y por último CN2-SD. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,931
- Confianza: 0,923

Tabla 2.32. Comparación de algoritmos de descubrimiento de subgrupos para Balance

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,291	0,487	7,40	5,331	0,049	
		0.7	0,315	0,501	6,46	<b>5,368</b>	<b>0,050</b>	
		0.8	<b>0,388</b>	<b>0,507</b>	<b>3,00</b>	4,738	0,042 <sup>+</sup>	
		0.9	0,386	0,503	<b>3,00</b>	4,613	0,042	
	5	0.6	0,061	0,094	33,50	1,791	0,015	
		0.7	0,055	0,086	27,38	1,781	0,015	
		0.8	0,023	0,036	24,36	0,743	0,006	
		0.9	0,021	0,035	24,58	0,795	0,007	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,535	<b>0,786</b>	5,00	6,978	<b>0,073</b>
			0.7	0,471	0,776	<b>3,00</b>	<b>9,374</b>	0,070 <sup>•</sup>
0.8			0,475	0,772	<b>3,00</b>	9,287	0,070	
0.9			0,479	0,769	<b>3,00</b>	9,336	0,069	
5		0.6	0,572	0,671	4,50	4,461	0,062	
		0.7	0,690	0,779	<b>3,00</b>	4,782	0,069	
		0.8	<b>0,696</b>	0,778	<b>3,00</b>	4,812	0,068	
		0.9	0,690	0,776	<b>3,00</b>	4,814	0,069	
CN2 Standard		0,021	0,860	28,70	2,700	0,005		
CN2 WRAcc		0,216	0,900	9,90	4,800	0,048		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,225	0,860	9,40	11,700	0,051		
	$\gamma=0.7$	0,270	0,820	8,90	21,800	0,073		
	$\gamma=0.9$	0,307	<b>1,000</b>	9,50	15,000	0,083		
	add.	0,324	0,850	8,30	<b>24,300</b>	0,073 <sup>+</sup>		
Apriori-SD		<b>0,380</b>	<b>1,000</b>	<b>4,20</b>	5,600	<b>0,085</b>		

Para el conjunto de datos *Balance*, nuestra propuesta con reglas DNF, 3 etiquetas y confianza mínima 0,7 es la que mejores resultados obtiene, seguida por CN2-SD y la propuesta con reglas canónicas. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,776
- Confianza: 0,458

Tabla 2.33. Comparación de algoritmos de descubrimiento de subgrupos para Car

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,011	0,037	18,34	1,675	<b>0,002</b>	
		0.7	0,007	0,026	17,62	1,532	<b>0,002</b>	
		0.8	0,010	0,035	16,32	1,689	<b>0,002</b>	
		0.9	0,012	0,041	19,14	1,774	<b>0,002</b>	
	5	0.6	0,009	0,032	<b>15,38</b>	1,529	<b>0,002</b>	
		0.7	0,012	0,040	16,92	1,666	<b>0,002</b>	
		0.8	<b>0,014</b>	<b>0,048</b>	16,76	<b>1,935</b>	<b>0,002</b> +	
		0.9	0,010	0,035	17,68	1,608	<b>0,002</b>	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,136	<b>0,706</b>	4,04	<b>33,046</b>	<b>0,045</b> •
			0.7	0,127	0,680	4,06	31,907	0,042
			0.8	0,134	0,698	<b>4,02</b>	32,861	0,044
			0.9	<b>0,139</b>	0,697	<b>4,02</b>	32,325	<b>0,045</b>
5		0.6	0,137	0,703	4,04	33,018	<b>0,045</b>	
		0.7	0,125	0,666	4,06	31,434	0,042	
		0.8	0,121	0,675	4,06	31,765	0,040	
		0.9	0,136	0,698	4,04	32,694	<b>0,045</b>	
CN2 Standard		0,022	0,810	83,80	1,500	0,009		
CN2 WRAcc		0,146	0,850	10,90	14,100	0,030		
CN2-SD	Esq. pesos							
	$\gamma=0.5$	0,155	0,960	11,30	6,000	0,037		
	$\gamma=0.7$	0,157	0,890	11,80	<b>26,800</b>	0,032		
	$\gamma=0.9$	0,166	0,950	11,70	12,600	0,034		
	add.	0,200	<b>0,970</b>	12,80	19,300	<b>0,045</b>		
Apriori-SD		<b>0,260</b>	0,940	<b>5,80</b>	25,000	0,043 +		

Para el conjunto de datos *Car*, nuestra propuesta con reglas DNF, 3 etiquetas y confianza mínima 0,6 es la que mejores resultados obtiene, seguida por CN2-SD y la propuesta con reglas canónicas. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,706
- Confianza: 0,405

Tabla 2.34. Comparación de algoritmos de descubrimiento de subgrupos para Glass

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,066	0,444	9,18	1,475	0,011	
		0.7	0,068	0,461	8,86	1,569	0,011	
		0.8	0,060	0,473	8,36	1,638	0,012	
		0.9	0,078	<b>0,532</b>	<b>7,28</b>	<b>1,796</b>	<b>0,013</b> +	
	5	0.6	0,083	0,229	10,82	1,584	0,005	
		0.7	0,081	0,255	10,84	1,654	0,005	
		0.8	<b>0,088</b>	0,225	10,82	1,492	0,004	
		0.9	0,082	0,282	9,90	1,740	0,007	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,048	0,517	7,90	2,014	0,013
			0.7	0,050	0,533	7,70	1,987	0,013
0.8			0,052	0,549	7,50	<b>2,110</b>	0,014	
0.9			<b>0,054</b>	<b>0,592</b>	<b>6,72</b>	2,109	<b>0,015</b> *	
5		0.6	0,028	0,346	9,22	1,415	0,008	
		0.7	0,027	0,357	8,72	1,436	0,008	
		0.8	0,024	0,339	8,52	1,413	0,007	
		0.9	0,028	0,354	8,06	1,497	0,008	
CN2 Standard		0,066	0,830	12,90	1,000	0,007		
CN2 WRAcc		0,331	0,850	7,70	2,400	0,060		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,357	0,920	8,60	<b>22,000</b>	0,081		
	$\gamma=0.7$	0,628	<b>0,950</b>	9,10	17,000	0,133 •		
	$\gamma=0.9$	0,616	0,900	8,40	16,400	0,132		
	add.	0,759	0,840	10,10	9,100	<b>0,147</b>		
Apriori-SD		<b>0,840</b>	0,910	<b>2,80</b>	2,500	0,122		

Para el conjunto de datos *Glass*, obtiene mejores resultados el algoritmo CN2-SD con pesos multiplicativos y valor  $\gamma = 0.7$ , aunque nuestra propuesta con reglas DNF obtiene menos reglas y más sencillas. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,592
- Confianza: 0,381

Tabla 2.35. Comparación de algoritmos de descubrimiento de subgrupos para Wine

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA	Etiqu CnfMin							
	3	0.6	0,077	0,608	6,00	3,036	0,051	
		0.7	0,081	0,633	6,02	3210	0,054	
		0.8	0,071	0,597	6,20	2,831	0,047	
		0.9	<b>0,088</b>	<b>0,677</b>	<b>5,12</b>	<b>3,486</b>	<b>0,058</b> +	
	5	0.6	0,057	0,386	7,14	1,948	0,032	
		0.7	0,059	0,396	7,18	2,052	0,032	
		0.8	0,059	0,379	6,84	2,050	0,034	
		0.9	0,058	0,397	6,16	2,111	0,035	
	SDIGA DNF	Etiqu CnfMin						
		3	0.6	0,075	0,645	5,58	2,964	0,050
			0.7	0,077	0,652	5,54	3,016	0,051
0.8			0,081	0,663	5,32	3,175	0,053	
0.9			<b>0,084</b>	<b>0,697</b>	<b>5,08</b>	<b>3,299</b>	<b>0,056</b> *	
5		0.6	0,056	0,578	5,44	2,156	0,035	
		0.7	0,052	0,556	5,50	1,991	0,032	
		0.8	0,053	0,579	5,30	2,025	0,033	
		0.9	0,059	0,607	5,30	2,252	0,037	
CN2 Standard		0,231	0,820	5,50	2,000	0,033		
CN2 WRAcc		0,477	0,820	3,00	13,500	0,076		
CN2-SD		Esq. pesos						
	$\gamma=0.5$	0,552	0,940	2,10	20,700	0,089		
	$\gamma=0.7$	0,715	0,870	2,10	2,700	0,144		
	$\gamma=0.9$	0,818	<b>0,990</b>	<b>1,20</b>	<b>29,400</b>	0,149		
	add.	<b>1,022</b>	<b>0,990</b>	1,40	25,700	<b>0,167</b> •		
Apriori-SD		0,620	0,970	2,40	13,500	0,139		

Para el conjunto de datos *Wine*, obtiene mejores resultados el algoritmo CN2-SD con pesos aditivos. La experimentación de nuestra propuesta que mejores resultados obtiene es con reglas DNF, 3 etiquetas y umbral de confianza mínima 0,9. El hecho de que CN2-SD obtenga conjuntos de reglas con menos de 2 reglas indica que no está obteniendo reglas para todas las clases de la variable objetivo del problema. En nuestra propuesta los resultados obtenidos para las medidas de calidad utilizadas en SDIGA son:

- Completitud: 0,697
- Confianza: 0,814

### 2.3.3 Conclusiones

Los resultados de la comparativa varían dependiendo del conjunto de datos utilizado. En general, el algoritmo que obtiene mejores resultados en más conjuntos de datos es CN2-SD en sus distintas variantes, seguido de SDIGA con reglas DNF, SDIGA con reglas canónicas y por último A priori-SD.

Y al evaluar los resultados, hay que tener en cuenta que nuestra propuesta no utiliza las medidas de calidad utilizadas por los otros algoritmos de descubrimiento de subgrupos. También hay que resaltar que nuestra propuesta maneja directamente variables continuas sin realizar una discretización previa, y que obtiene reglas difusas, lo que mejora la interpretabilidad de las reglas extraídas.

La inclusión de medidas estándar de calidad para descubrimiento de subgrupos adaptadas a reglas difusas puede mejorar los resultados de nuestra propuesta. Este aspecto constituye uno de los trabajos futuros.

Otra decisión importante es el número de etiquetas por variable, porque esto puede modificar el comportamiento de la regla con respecto a las medidas de soporte e interés. Hemos utilizado tres o cinco etiquetas por regla para incrementar la interpretabilidad lingüística del modelo.

Como conclusiones fundamentales de esta comparativa podemos concluir que la propuesta nos permite obtener reglas de descubrimiento de subgrupos:

- altamente compactas, porque tanto los tamaños de los conjuntos de reglas como el número de variables que intervienen en cada regla es pequeño;
- altamente descriptivas, debido a la utilización de las reglas DNF difusas, permitiendo una representación del conocimiento cercana al razonamiento humano, y haciendo que el conocimiento extraído se pueda utilizar para actuar sobre el dominio, un objetivo fundamental de cualquier algoritmo de descubrimiento de subgrupos;
- con un comportamiento variable en las medidas de interés.

## 2.4 Aplicaciones de SDIGA a problemas reales

---

A continuación se detalla la experimentación y resultados obtenidos de la aplicación de esta propuesta sobre dos problemas reales, uno de extracción de conocimiento sobre datos de marketing, y otro sobre datos de e-learning. En el primero, el objetivo es extraer información que permita mejorar la eficiencia de los expositores en futuras muestras; en el

segundo, se trata de extraer conocimiento para mejorar los resultados académicos de los usuarios del sistema de e-learning Moodle.

### **2.4.1 Problema de marketing: extracción de conocimiento en certámenes feriales**

En el área de marketing, y en concreto en la planificación de ferias de muestras, es importante extraer conclusiones de información de ferias anteriores para determinar la relación entre las variables de planificación ferial y el éxito del stand. Para este problema es adecuado un algoritmo de inducción de reglas de descripción de subgrupos. El problema planteado ha sido estudiado en el Departamento de Organización y Marketing de la Universidad de Mondragón: la extracción de información útil sobre certámenes feriales [Mes04].

Las empresas consideran los certámenes feriales un instrumento que facilita la consecución de objetivos comerciales tales como el contacto con los clientes actuales, la captación de nuevos clientes potenciales, la realización de pedidos o la mejora de la imagen corporativa entre otros [GLWS95]. Uno de los principales inconvenientes de este tipo de certámenes es la elevada inversión que suponen en términos tanto económicos como de tiempo. A esta inversión a veces se une una falta de planificación que enfatiza la sensación de que las ferias no son más que un “gasto” que las compañías han de afrontar por motivos varios (tradicción, exigencia clientes, no dar la sensación de que las cosas van mal, etc.) [Mil03a]. Es conveniente, por tanto, la extracción automática de información sobre las variables implicadas que permita obtener datos desconocidos determinantes en parte de la eficacia de los stands de un certamen.

Anderson [And02] propone utilizar la consecución de los objetivos establecidos para los certámenes feriales como un índice para medir la eficiencia de las ferias. Sin embargo, el porcentaje de expositores que tienen los objetivos por escrito o que pueden expresarlos en términos cuantificables es pequeño. La ausencia de documentación formal que contenga los objetivos de las compañías hace muy difícil cuantificar el grado de éxito de la feria. Por lo tanto, se hace necesario utilizar la valoración del grado de cumplimiento de los objetivos realizada por la propia compañía.

A partir de una revisión de la bibliografía y preguntando a los expositores, se diseñó un cuestionario para reflejar las variables que permiten una mejor explicación del éxito de los certámenes feriales, que después fue contrastado por los expertos. Este cuestionario contiene 104 variables, de las cuales 7 son continuas y el resto categóricas (obtenidas mediante una discretización realizada por los expertos). El cuestionario contiene preguntas relacionadas con la planificación previa a la feria (que deben ser contestadas antes de la celebración del certamen), con la valoración de la participación en la feria y con las

acciones a desarrollar por la compañía después de la feria (preguntas que deben contestarse una vez que la feria ha terminado), y otras cuestiones a responder durante la feria.

De esta forma, una vez que se han recogido los datos de cada expositor, se establece la eficiencia global del stand como *alta*, *media* o *baja*, en función del nivel de consecución de los objetivos establecidos para el certamen ferial, basado en distintos criterios de marketing.

La Tabla A.53 recogida en el Apéndice D muestra las características de las variables recogidas.

Los datos contenidos en este dataset se recogieron en la Bienal de Máquina-Herramienta celebrada en Bilbao en marzo de 2002 y contiene información sobre 228 expositores. Con los datos recogidos para cada expositor, se caracterizaron los distintos stands de acuerdo con su nivel de consecución de objetivos, obteniendo la distribución de clases (*eficiencia baja*, *media* o *alta*) mostrada en la Tabla 2.36.

Tabla 2.36. Distribución de clases en el dataset

Clase	# Ejemplos	%
Baja eficiencia	38	16.5
Media eficiencia	148	65.0
Alta eficiencia	42	18.5

Para este problema real, el algoritmo de minería de datos debe extraer información de interés sobre cada uno de los tres grupos de eficacia de los stands. Las reglas generadas deben determinar la aportación que las distintas variables de planificación ferial ejercen sobre los resultados obtenidos por el expositor, permitiendo de esta forma mejorar las políticas de planificación ferial.

La utilización de un algoritmo de descubrimiento de subgrupos para resolver este problema es adecuada porque en una tarea de descubrimiento de subgrupos el objetivo no es generar un conjunto de reglas que cubran todos los ejemplos del dataset, sino reglas individuales que, dada una propiedad de interés de los datos, describan los subgrupos más interesantes para el usuario. Este es el tipo de conocimiento que queremos extraer.

#### 2.4.1.1 Experimentación sobre conjunto de datos de Marketing

La experimentación se ha llevado a cabo mediante 5 ejecuciones (5 ejecuciones para cada una de las clases de la variable objetivo: baja, media y alta eficiencia), y utilizando los siguientes parámetros:

- Tamaño de la población: 100.
- Número máximo de evaluaciones de individuos en cada ejecución del AG: 10000.
- Probabilidad de mutación: 0.01.
- Número de etiquetas lingüísticas par alas variables continuas: 3.

- Pesos de las medidas de calidad para la función de adaptación:
  - $w_1$ : 0.4
  - $w_2$ : 0.3
- Valor de confianza mínima: 0.6.

La Tabla 2.37 muestra los mejores resultados obtenidos para todas las clases de la variable objetivo (eficacia baja, media y alta). En esta tabla se muestra el número de variables que intervienen en cada regla (*Nº Var.*), y la completitud (*Completitud*) y confianza (*Confianza*) de cada regla. La completitud se calcula como se describe en la expresión (2.14) (aunque durante el proceso de evaluación se hace utilizando la expresión definida en (2.8)), y la confianza como se describe en la expresión (2.9).

Tabla 2.37 Resultados para eficiencia Baja, Media y Alta

<i>Eficiencia</i>	<i>Nº Var.</i>	<i>Completitud</i>	<i>Confianza</i>
<i>Baja</i>	5	0.029	1.000
	5	0.029	1.000
	4	0.114	1.000
	7	0.029	1.000
<i>Media</i>	5	0.086	1.000
	5	0.023	1.000
	3	0.016	1.000
	2	0.008	1.000
	2	0.578	0.667
	3	0.047	1.000
<i>Alta</i>	3	0.054	1.000
	4	0.027	1.000
	2	0.027	1.000
	4	0.027	1.000
	2	0.081	1.000
	4	0.027	1.000

La completitud y confianza tienen valores comprendidos entre 0 y 1. Un valor alto de la completitud indica que la regla cubre muchos de los ejemplos de la clase, y un valor alto de confianza indica que la regla tiene pocos ejemplos negativos. Las reglas generadas tienen valores adecuados de confianza y completitud. El algoritmo induce un conjunto de reglas con una alta confianza (mayor que el valor de confianza mínima).

La completitud, excepto para algunas reglas, es bajo. El problema de marketing utilizado es un problema real difícil en el que los algoritmos de inducción tienden a obtener “*small disjuncts*” (reglas específicas que representan un pequeño número de ejemplos), un problema más común en los datasets de lo que podría parecer a primera vista. Sin embargo, el problema de los “*small disjuncts*” no es un problema determinante en los procesos de inducción para descubrimiento de subgrupos. Esto se debe a que es suficiente con obtener relaciones parciales, como subgrupos con características interesantes, con una desviación significativa de la del resto del dataset.

El conocimiento extraído para cada uno de los valores de la variable objetivo es comprensible para el usuario debido a la utilización de la lógica difusa, y al pequeño número de reglas y condiciones en los antecedentes de las reglas (menos del 10% de las 104 variables). Es más, las reglas obtenidas con el algoritmo SDIGA son muy sencillas, debido a la aplicación del algoritmo de ascensión de colinas que optimiza cada regla extraída incrementando su simplicidad.

Las siguientes tablas (2.38 a 2.40) muestran las reglas correspondientes a los valores mostrados en la Tabla 2.37. Hay que resaltar que sólo 7 de las variables del dataset son continuas, y el resto son categóricas. Utilizamos tres etiquetas lingüísticas para las variables continuas (como la variable *Tamaño del Stand*), pero las variables categóricas (como la variable *Empleados*) tienen distintos números de valores posibles.

Tabla 2.38. Reglas para eficiencia Baja

Nº	Regla
1	IF (Employees = (Huge OR High OR Normal OR Very Few) AND Annual sales = (Very Huge OR Huge OR High OR Few) AND Gratefulness pamphlet = Only to quality contacts AND Bar = No AND Food/Drink = Yes) THEN Efficiency = Low
2	IF (Kind of tracking of contacts = All AND Thank-you letter = No AND Stand with different heights = No AND Stewardesses = Yes AND Bar = No) THEN Efficiency = Low
3	IF (Zone = (North OR South) AND Important improvement image of the company = Medium AND Thank-you letter = No AND Stand with different heights = No) THEN Efficiency = Low
4	IF (Zone = (East OR South) AND Employees = (Very High OR High OR Normal OR Few) AND Annual sales = (Very High OR Normal OR Few) AND Thank-you letter = NO AND Contact tracking = (No OR All) AND Carpet = No AND Bar = No) THEN Efficiency = Low

Tabla 2.39. Reglas para eficiencia Media

Nº	Regla
1	IF (Zone = (North OR Center OR South) AND Sector = (Starting OR Deformation OR Accessories OR CAD_CAM) AND Thank-you letter = All AND Thank-you pamphlet = (No OR Only Quality) AND Bar = Yes) THEN Efficiency = Medium
2	IF (Employees = (Huge OR Normal OR Very Few) AND Important quality contacts = (High OR Very High) AND Carpet = Yes AND Stewardesses = No AND Bar = No) THEN Efficiency = Medium
3	IF (Telephone calls = No AND Bar = Yes AND Food/Drink = Yes) THEN Efficiency = Medium
4	IF (Zone = Center AND Stewardesses = Yes) THEN Efficiency = Medium
5	IF (Important extracted information = (Very Low OR Low OR Medium OR High) AND Food/Drink = No) THEN Efficiency = Medium
6	IF (Zone = North AND Important improvement company image = (Medium OR High) AND Stewardesses = Yes) THEN Efficiency = Medium

Tabla 2.40. Reglas para eficiencia Alta

N <sup>a</sup>	Regla
1	IF (Employees = (High OR Normal) AND Annual sales = (Very Huge OR Few) AND Thank-you pamphlet = (No OR Only quality) THEN Efficiency = High
2	IF (Thank-you letter = (No OR Only quality) AND Columns = Yes AND Bar = No AND Food/Drink = Yes THEN Efficiency = High
3	IF (Zone = Center AND Thank-you pamphlet = No) THEN Efficiency = High
4	IF (Employees= (Huge OR Very High OR High OR Very Few) AND Satisfaction public relations = (Very Low OR Medium OR Very High) AND Columns = Yes AND Food/Drink = No) THEN Efficiency = High
5	IF (Satisfaction improvement company image = (Low OR Very High) AND Telephone calls = No) THEN Efficiency = High
6	IF (Employees = Huge OR Normal) AND Publicity in exhibitor's catalogue = Yes AND Bar = Yes AND Food/Drink = No) THEN Efficiency = High

Los expertos en marketing del Departamento de Organización y Marketing de la Universidad de Mondragón analizaron los resultados obtenidos, e indicaron que:

- Los expositores que obtuvieron peores resultados provenían de la zona Sur, no realizaban seguimiento de los contactos realizados y, además, no podían optimizar (cerrando una venta o dando más información después de la feria) los contactos realizados en el certamen ferial. Hay que resaltar que la feria se celebró en la zona Norte, y que los expositores provenían mayoritariamente de esta zona. Así, los peores resultados obtenidos por los expositores provenientes de zonas más lejanas pueden explicarse debido a la distancia y al desconocimiento de las peculiaridades de la feria.
- Los expositores que obtuvieron unos mejores resultados fueron los procedentes de la zona Centro, que no enviaron folletos de agradecimiento a todos sus contactos. Son empresas medianas o grandes, con volúmenes anuales de ventas tanto muy grandes como pequeños.
- También, los expositores que obtuvieron mejores resultados tienen niveles salariales muy altos o pequeños. Las compañías más grandes pueden invertir grandes cantidades de dinero en la preparación de la feria, por lo que sus resultados son mejores. Las compañías pequeñas gastan poco dinero en la muestra, por lo que sus expectativas sobre su participación son peores. Pero, si obtienen buenos resultados, mejores de lo que esperaban, la evaluación de su rendimiento en la feria de muestras es muy alto.

#### 2.4.1.2 Conclusiones

Se ha mostrado aquí la aplicación del sistema genético difuso para la extracción de reglas difusas de descubrimiento de subgrupos a un problema de marketing. La propuesta incluye

un AG en un proceso iterativo para extraer reglas difusas descriptivas, con diferentes ventajas:

- Obtiene un conjunto de reglas difusas reducido.
- Las reglas extraídas son interpretables debido a la utilización de variables lingüísticas para las variables continuas, y debido al número de variables que intervienen en cada regla (en este problema, el promedio de variables por regla es de 4,3).
- La lógica difusa permite al usuario incorporar directamente conocimiento lingüístico en el proceso de minería de datos, mezclar este conocimiento con información no lingüística para variables categóricas con valores no numéricos.
- La utilización de reglas DNF aporta una estructura más flexible a las reglas, permitiendo que cada variable tome más de un valor. Este tipo de estructura de regla nos permite describir el conocimiento extraído de forma más flexible y además realizar cambios en la granularidad inicial en cada regla de forma descriptiva.
- El algoritmo nos permite describir conocimiento de distintas zonas del espacio de ejemplos, debido al mecanismo iterativo con penalización (que no eliminación) de los ejemplos cubiertos. Este mecanismo es similar a la incorporación de un esquema de pesos en los ejemplos para modificar un algoritmo de cubrimiento cuando se adaptan algoritmos de clasificación de reglas par la tarea de descubrimiento de subgrupos. A pesar de la penalización aplicada para obtener distintas reglas, el algoritmo nos permite obtener reglas solapadas describiendo conocimiento desde distintas perspectivas debido a que los ejemplos cubiertos no son eliminados.

En definitiva, la aplicación de la propuesta a este problema de extracción de conocimiento en certámenes feriales ha permitido que los expertos establezcan la validez del conocimiento extraído. Este conocimiento ha permitido a los expertos la obtención de conclusiones novedosas sobre los datos disponibles.

#### **2.4.2 Problema de e-learning: extracción de conocimiento en datos de la plataforma Moodle sobre asignaturas de la Universidad de Córdoba**

En esta sección examinamos el caso de estudio Moodle. Primero describiremos nuestro problema específico y después mostraremos los resultados experimentales obtenidos en la ejecución de diferentes algoritmos de descubrimiento de subgrupos. Por último analizaremos distintas reglas desde el punto de vista del profesor con el ánimo de mejorar los cursos de e-learning.

### 2.4.2.1 Descripción del problema

Hemos utilizado los datos de utilización por parte de los alumnos del sistema Moodle, que es uno de los sistemas de e-learning más utilizados [Fla03]. Moodle tiene una amplia y diversa comunidad de usuarios en más de 75 idiomas y más de 160 países [Moo07].

El objetivo que se pretende conseguir con la aplicación de descubrimiento de subgrupos es analizar qué relación puede tener la realización de actividades complementarias de una asignatura realizadas en un sistema de enseñanza a distancia con la nota final obtenida por los estudiantes en dicha asignatura. La calificación final se utiliza como variable a caracterizar, utilizando las diferentes calificaciones para dividir los datos en clases y codificados como valores del consecuente de las reglas.

La información descubierta en forma de reglas se mostrará al profesor para que la pueda utilizar para tomar decisiones sobre si, o bien, fomentar aun más el uso de determinado tipo de actividades ya que ha comprobado que están relacionadas con la obtención de una alta puntuación, o por el contrario, eliminar determinadas actividades al estar más relacionadas con bajas puntuaciones.

En nuestro caso, se dispone de la información correspondiente a 192 cursos, correspondientes a distintas asignaturas de las titulaciones que se imparten en la Universidad de Córdoba. De entre ellos, se han seleccionado los 5 cursos que han hecho un mayor uso de las principales actividades y recursos, con un número total de 300 alumnos.

Tabla 2.41. Atributos utilizados para cada alumno

Nombre	Descripción
course	Número identificador del curso
n_assignment	Nº de trabajos realizados
n_assignment_a	Nº de trabajos aprobados
n_assignment_s	Nº de trabajos suspendidos
n_quiz	Nº de cuestionarios realizados
n_quiz_a	Nº de cuestionarios aprobados
n_quiz_s	Nº de cuestionarios suspendidos
n_messages	Nº de mensajes enviados al chat
n_messages_ap	Nº de mensajes enviados por el alumno al profesor del curso
n_posts	Nº de mensajes enviados al foro
n_read	Nº de mensajes leídos del foro

La base de datos de Moodle dispone de una gran cantidad de información muy detallada almacenada en multitud de tablas dentro de una base de datos relacional. Por esta razón, ha sido necesario realizar una primera etapa de preprocesado de la información. En primer lugar, se ha creado una nueva tabla resumen, Tabla 2.41, con la información que se ha considerado más importante para nuestro objetivo. Posteriormente se procedió a la transformación al formato requerido por las implementaciones de los algoritmos que se van a utilizar. Esta tabla almacena un resumen por fila de todas las actividades realizadas por

cada alumno en el curso, así como la nota final obtenida por cada alumno en dicha asignatura, discretizada con los valores categóricos tradicionales de sobresaliente, notable, aprobado y suspenso. Finalmente, se ha exportado toda la información de la tabla resumen a un fichero tipo texto con formato de datos KEEL [ADG+03] debido a que los algoritmos de descubrimiento de subgrupos se encuentran implementados dentro de esta plataforma.

Vamos a utilizar diferentes algoritmos de descubrimiento de subgrupos para evaluar los resultados obtenidos y para analizar qué algoritmos descubren la información de mayor interés y utilidad para el profesor del curso. Nuestro objetivo es presentar los resultados al profesor en forma de reglas para permitir el uso de esta información en la toma de decisiones relacionadas con las actividades complementarias del curso. Por ejemplo el profesor puede decidir promover el uso de cierto tipo de actividades para obtener unos mejores resultados, o por el contrario eliminar ciertas actividades porque están asociadas con notas más bajas.

El sistema Moodle contiene una gran cantidad de información detallada sobre los contenidos de los cursos, usuarios, utilización, etcétera, almacenados en una base de datos relacional. Hemos aplicado un paso de preprocesamiento a la información, obteniendo una nueva tabla resumen (ver Tabla 2.42) con información más importante relacionada con nuestro objetivo.

Tabla 2.42. Atributos utilizados para cada alumno.

Name	Description
course	Identification of the course
n_assignment	Number of assignments completed
n_assignment_a	Number of assignments passed
n_assignment_s	Number of assignments failed
n_quiz	Number of quizzes completed
n_quiz_a	Number of quizzes passed
n_quiz_s	Number of quizzes failed
n_messages	Number of messages sent to the chat
n_messages_ap	Number of messages sent to the teacher
n_posts	Number of messages sent to the forum
n_read	Number of forum messages read
mark	Discretized student's mark

La Tabla 2.42 contiene un resumen de las actividades completadas y la nota obtenida por cada estudiante en un curso de e-learning. Hemos discretizado las calificaciones en clases (suspenso, aprobado, notable y sobresaliente) para codificar los cómo los valores del consecuente de la regla.

Se ha tenido acceso a la información correspondiente a 192 cursos diferentes de la Universidad de Córdoba. De todos estos, se han elegido solo 5 cursos (con un total de 293 alumnos) con la mayor utilización de las actividades y recursos disponibles en Moodle.

El algoritmo está implementado para su utilización en la plataforma de minería de datos KEEL [Kee07]. Se ha exportado toda la información de la tabla resumen a un fichero

de texto con el formato utilizado en esta plataforma [ADG+03] (que es similar al formato ARFF utilizado en WEKA [WF05]). Este formato tiene dos secciones: la primera contiene información de cabecera (el nombre de la relación, así como una lista de los atributos y sus tipos); la segunda contiene los datos en sí (una línea de declaración de datos y las líneas correspondientes a los valores de los ejemplos del conjunto de datos, en este caso una línea por cada estudiante, en los que hay una columna para cada valor de los atributos. En la Tabla 2.43 se muestra un ejemplo de fichero en formato de la plataforma KEEL, correspondiente al conjunto de datos de e-learning.

Tabla 2.43. Tabla resumen de datos en formato KEEL

---

```

@relation student_summarization
@attribute course <C29, C46, C88, C110, C111>
@attribute n_assignment integer
...
@attribute mark <FAIL, PASS, GOOD, EXCELENT>
@data
C110,10,10,6,0,12,9,3,0, GOOD
C110,9,9,0,0,11,8,3,0, PASS
C110,11,11,0,0,13,5,8,0, FAIL
C110,11,11,0,0,11,6,5,0, FAIL
C110,13,13,7,0,0,0,0, EXCELENT
C110,8,8,7,0,7,6,1,0, FAIL

```

---

#### 2.4.2.2 Resultados experimentales de la aplicación de los algoritmos de descubrimiento de subgrupos

Para hacer verificar la aplicabilidad de la propuesta, se han comparado los resultados del algoritmo SDIGA con los de otros algoritmos clásicos de descubrimiento de subgrupos, como Apriori-SD [KL06] y CN2-SD [LKFT04]. Apriori-SD y CN2-SD son algoritmos deterministas, mientras que SDIGA es no determinista. Para llevar a cabo la comparación, se sigue siendo crecimiento: para los algoritmos clásicos deterministas se ha realizado un conjunto de ejecuciones, variando uno de sus parámetros cada vez. En el caso de Apriori-SD, se han utilizado cuatro valores de confianza mínima (0.6, 0.7, 0.8 y 0.9) con un soporte mínimo de 0.2. En el caso del algoritmo CN2-SD, hemos utilizado el parámetro  $\gamma$  (valores 0.9, 0.7, 0.5 y aditivo) con un valor 2 para el tamaño de estrella.

Para el algoritmo no determinista SDIGA se han realizado ejecuciones para cuatro valores de confianza mínima (0.6, 0.7, 0.8 y 0.9) con cinco ejecuciones cada una, utilizando los siguientes parámetros:

- Tamaño de la población: 100.
- Número máximo de evaluaciones de individuos en cada ejecución del AG: 10000.

- Probabilidad de cruce: 0.6.
- Probabilidad de mutación: 0.01.
- Número de etiquetas lingüísticas para las variables continuas: 5 (muy alto, alto, medio, bajo, muy bajo).
- Pesos para la función de adaptación: 3 para la precisión, 1 para la cobertura y 4 para la relevancia. Este conjunto de pesos se han elegido de acuerdo a los resultados obtenidos en el estudio experimental.

Como ya se ha comentado, SDIGA se puede utilizar para obtener los tipos de reglas: canónicas (no DNF) y DNF. Hemos realizado la experimentación para ambos tipos de reglas.

La Tabla 2.44 muestra resultados obtenidos por los algoritmos clásicos con sus diferentes valores de parámetros y las medias de las cinco ejecuciones del algoritmo SDIGAs (utilizando ambos tipos de reglas, dotados como SDIGA y SDIGA DNF) para cada valor de la confianza mínima. La tabla muestra el número total de reglas obtenidas, el número de atributos en el antecedente de las reglas y los valores de las medidas de calidad. Estas medidas de calidad son:

- Cobertura del conjunto de reglas, tal como se define en (1.2).
- Relevancia del conjunto de reglas, como se define en (1.7).
- Precisión del conjunto reglas, tal como se define en (1.11).

Tabla 2.44. Resultados obtenidos por los distintos algoritmos sobre el conjunto de datos de e-learning.

Algoritmo		Nº reglas	Nº atributos	Cobertura	Relevancia	Precisión
Apriori-SD	CfMin					
	0,6	8	1,0	0,6220	26,1321	0,6130
	0,7	9	1,3	0,6685	29,5409	0,6130
	0,8	6	1,5	0,3613	42,1091	0,6130
	0,9	5	2,0	0,2253	36,8100	0,6312
CN2-SD	Esq. Pesos					
	$\gamma=0.5$	13	5,5	0,4151	44,9486	0,7157
	$\gamma=0.7$	17	5,5	0,3980	48,4380	0,7191
	$\gamma=0.9$	16	5,3	0,3878	50,2812	0,7294
	add	32	5,7	0,5084	54,4237	0,7123
SDIGA	CfMin					
	0,6	7,8	2,0	0,0878	21,9924	0,8088
	0,7	6,2	2,1	0,0766	16,7925	0,7502
	0,8	6,0	2,2	0,1271	25,2460	0,7792
	0,9	4,8	2,0	0,1288	33,8351	0,7546
SDIGA DNF	CfMin					
	0,6	7,8	3,1	0,3071	40,6689	0,7575
	0,7	9,4	3,6	0,2629	45,5539	0,8162
	0,8	7,4	3,2	0,2625	42,9744	0,7598
	0,9	5,4	3,0	0,1639	25,7814	0,7882

Analizando el número de reglas y atributos de la Tabla 2.44 podemos observar que:

- Los algoritmos SDIGA, SDIGA DNF y Apriori-SD descubren los conjuntos de reglas con un menor número de reglas (con valores bastante similares); por el contrario, CN2-SD descubre conjuntos de reglas más grandes.
- Con respecto al número de atributos, Apriori-SD y SDIGA obtienen un menor número de atributos (con valores similares) seguidos por SDIGA DNF. Por último, CN2-SD obtiene el mayor número de atributos.

Desde el punto de vista nuestro problema estamos interesados en descubrir una pequeña cantidad de reglas con pocos atributos para facilitar la interpretación y comprensión de estas reglas por parte del profesor. De esta forma el algoritmo CN2-SD no es el más apropiado para nuestro problema debido al hecho de que uno descubre demasiadas reglas y el otro descubre reglas con demasiados atributos.

Analizando las medidas de calidad de la Tabla 2.44 observamos que:

- La medida de precisión (o confianza) indica nuestro caso el número de estudiantes que cumplen el antecedente de la regla y corresponden a la clase asociada (es decir, el número de ejemplos asociados con la clase). SDIGA y SDIGA DNF obtienen los mejores valores seguidos por CN2-SD y Apriori-SD.
- La cobertura es, como el soporte, una medida de la generalidad de la regla. En nuestro caso mire el número de estudiantes que cumplen el antecedente de la regla. Apriori-SD y CN2-SD obtienen los mayores valores, seguidos por SDIGA DNF y SDIGA.
- La relevancia es una medida de la relevancia cuantitativa y el interés de una regla. CN2-SD y SDIGA DNF obtienen los mejores valores, seguidos por Apriori-SD y SDIGA.

De acuerdo con los valores de estas medidas de calidad, el algoritmo más deseable sería aquel que simultáneamente obtuviese los mayores valores para todas las medidas. Como hemos visto, ninguno de los algoritmos alcanza este objetivo.

Entre estas medidas, la precisión es posiblemente la más importante, puesto que representa la fiabilidad o confianza de la regla. Para tomar decisiones fiables, el profesor quiere usar reglas con alta confianza. Podemos observar la Tabla 2.44 que ambas versiones de SDIGA descubren reglas con alta precisión y la relevancia razonable.

### **2.4.2.3 Utilización de las reglas obtenidas por SDIGA**

En esta sección, describiremos algunos ejemplos de reglas obtenidas y como éstos pueden ser útiles en la toma de decisiones de los cursos. Las reglas de descubrimiento de subgrupos

revelar información interesante sobre el comportamiento de los estudiantes, y pueden ayudar a profesor a descubrir relaciones beneficiosas o perjudiciales entre la utilización de los recursos educativos disponibles en el sistema y el aprendizaje de los alumnos. El instructor puede utilizar el conocimiento descubierto por estas reglas para tomar decisiones sobre las actividades de los cursos de Moodle.

Primero, describiremos algunos ejemplos de reglas descubiertas por el algoritmo SDIGA y analizaremos su significado desde un punto de vista pedagógico con la intención de mejorar el curso.

*IF course = C110 AND n\_assignment = High  
AND n\_posts = High  
THEN mark = Good  
(Accuracy: 0.9285, Significance: 6.5348, Coverage: 0.1575)*

Esta regla muestra que en el curso *ProjectManagement* (C110), los estudiantes que han completado un alto número de trabajos y ha enviado muchos mensajes al foro, han obtenido buenos resultados. El profesor puede continuar promoviendo este tipo de actividades en su curso por su efectividad de cara a las notas finales obtenidas por los estudiantes.

*IF course = C29 AND n\_messages\_ap = Very low  
THEN mark = Fail  
(Accuracy: 0.8560, Significance: 59.1774, Coverage: 0.2520)*

En el curso *AppliedComputerScienceBasis* (C29), muchos de los estudiantes que han enviado muy pocos mensajes al profesor han suspendido. Utilizando esta información, el profesor puede dirigir más atención a estos estudiantes porque tienen una gran probabilidad de suspender.

Es importante resaltar que también se han descubierto reglas que aportan información ciertamente obvia al profesor. Algunos ejemplos de este tipo de reglas son las siguientes:

*IF n\_quiz\_a = Very low  
THEN mark = Fail  
(Accuracy: 0.6280, Significance: 6.500, Coverage: 0.0205)*

Ésta regla muestra que si el número de cuestionarios superados por un alumno es muy bajo el resultado suele ser un suspenso. Esta regla es completamente lógica para el profesor (los estudiantes que no superan los cuestionarios on-line no suelen aprobar un examen escrito), y no aporta ninguna información nueva sobre cómo mejorar el curso.

*IF n\_quiz\_a = Very high  
THEN mark = Excelent  
(Accuracy: 0.7819, Significance: 35.7308, Coverage: 0.1280)*

Ésta otra regla es la contraria a la anterior, y establece que los alumnos que obtienen muy buenos resultados en los cuestionarios suelen obtener excelentes notas finales.

A continuación se describen algunos ejemplos de reglas descubiertas por el algoritmo SDIGA DNF.

```
IF course = C110 OR C88
AND n_posts = High OR Very High
AND n_quiz_a = Medium OR High OR Very High
THEN mark = Good
(Accuracy: 0.7382, Significance: 43.4771, Coverage: 0.2431)
```

Esta regla muestra que si los estudiantes de los cursos *ProjectManagement* (C110) o *ComputerScienceBasis* (C88) han enviado un número mensajes al foro alto o muy alto, y además han obtenido puntuaciones en los cuestionarios medios, altas o muy altas, entonces obtienen buenas notas.

```
IF course = C29 OR C110 OR C111
AND n_assignment_s = Very High OR High OR Medium
AND n_quiz_s = Very High OR High OR Medium
AND n_messages_ap = Very low OR Low
THEN mark = Fail
(Accuracy: 0.8667, Significance: 61.8034, Coverage: 0.4726)
```

Esta regla muestra que si los estudiantes de los cursos *ProgrammingForEngineers* (C29), *ProjectManagement* (C110) o *ComputerScienceBasis* (C88) han suspendido un número de trabajos muy alto, alto o medio, y el enviado pocos o muy pocos mensajes al profesor, entonces suelen obtener suspensos como notas finales.

Estas reglas que pertenecen a conjuntos de reglas descubiertas por el algoritmo SDIGA DNF presentaron una mayor cobertura que las anteriores. En las reglas DNF se puede utilizar más de un valor por variable en la regla, permitiendo las cubrir más ejemplos.

#### 2.4.2.4 Conclusiones

Se ha presentado aquí la aplicación de algoritmos de descripción de subgrupos en un problema de e-learning, con el caso de estudio del sistema de gestión de cursos Moodle.

La comparación de los resultados obtenidos por los distintos algoritmos de descubierto subgrupos muestra la viabilidad de los algoritmos evolutivos de descubrimiento de subgrupos para este problema. El particular, SDIGA obtienen un menor número de reglas que son altamente comprensibles para el profesor. También obtienen resultados similares a los de los otros algoritmos en las medidas de calidad de las reglas, y resultados óptimos en la precisión de las reglas.

Una vez obtenidas las reglas, el objetivo es mostrar las los profesores, para facilitar decisiones para la mejora de los cursos. Hemos visto como los profesores pueden tomar decisiones relacionadas con las actividades de los cursos y el tipo de estudiantes para mejorar el curso utilizando la información aportada por estas reglas.

## **2.5 Conclusiones**

---

En este capítulo, se ha introducido un modelo evolutivo para la extracción de reglas difusas de descripción de subgrupos. El modelo está formado por un AG híbrido con un proceso de optimización local, que obtiene una regla, y que se sitúa dentro de un proceso iterativo que permite la extracción de un conjunto de reglas distintas.

Se ha desarrollado un análisis de componentes para determinar que medidas de calidad utilizar en el proceso de selección de reglas. En este sentido, se ha determinado que de entre las medidas de calidad estudiadas, no se puede determinar que una sea mejor que otra para todos los problemas, sino que los resultados dependen del problema. Sin embargo, en conjunto, podemos considerar que las mejores métricas son la Confianza difusa y la completitud nítida medida sólo sobre los ejemplos de la clase.

El modelo se ha comparado con otros algoritmos clásicos de descubrimiento de subgrupos utilizando problemas sintéticos disponibles en el repositorio UCI, obteniendo buenos resultados y demostrando su validez.

Por último, el modelo se ha aplicado a la extracción de conocimiento en dos problemas reales, uno con datos de marketing y otro con datos de e-learning, cuyos resultados han sido útiles a los expertos para obtener nuevo conocimiento de los datos disponibles.

## Capítulo 3

# Un modelo evolutivo multiobjetivo de extracción de reglas de descubrimiento de subgrupos

---

Como se ha indicado previamente, en el área de descubrimiento de subgrupos cualquier algoritmo de inducción de reglas debe optimizar simultáneamente distintos objetivos. La forma más adecuada de abordarlos es mediante algoritmos de optimización multiobjetivo en los que se busca un conjunto de soluciones alternativas (reglas en este caso) óptimas en el sentido de que ninguna otra solución dentro del espacio de búsqueda sea superior a ella en todos los objetivos considerados. El experto utilizará el conjunto de reglas de salida para seleccionar todas o un subconjunto de ellas para la descripción de los subgrupos en función de la información de preferencia particular del problema.

En este capítulo, se introduce nuestra propuesta de algoritmo evolutivo multiobjetivo para la extracción de reglas de descripción de subgrupos, se presenta la aplicación de nuestra propuesta a la extracción de conocimiento en forma de reglas de descripción de subgrupos a dos problemas reales: uno de marketing y otro de e-learning, y se analizan las conclusiones obtenidas.

### 3.1 Descripción del modelo

---

En esta sección se describe el algoritmo de minería de datos MESDIF (*Multiobjective Evolutionary Subgroup Discovery Fuzzy rules*), un AG multiobjetivo para la extracción de reglas que describen subgrupos.

El algoritmo extrae reglas cuyo antecedente representa una conjunción de variables y cuyo consecuente está prefijado. Esta forma, cada ejecución del algoritmo evolutivo multiobjetivo obtiene un número variable de reglas distintas expresando información de un solo valor de la variable objetivo. Como el objetivo es obtener un conjunto de reglas que describen subgrupos para todos los valores de la variable objetivo, el algoritmo evolutivo debe ser ejecutado tantas veces como valores distintos tenga la variable objetivo. Esto asegura la extracción de conocimiento para todas las clases. Este algoritmo puede generar

reglas difusas y/o nítidas para problemas con variables continuas y/o categóricas, tanto en formato canónico como DNF.

El AG multiobjetivo está basado en el enfoque SPEA2 [ZLT02], que incorpora el concepto de elitismo, utilizando un archivo o población secundaria (elite) de tamaño fijo de soluciones no dominadas obtenidas durante el proceso de búsqueda. Para la actualización del la población elite se considera tanto el número de soluciones almacenadas cercanas a una nueva solución como la información sobre su dominancia.

SPEA2 se basa en su antecesor, el *Strength Pareto Evolutionary Algorithm*, SPEA [ZTQ97], tratando de eliminar sus debilidades potenciales e incorporando los avances más recientes en el diseño de un algoritmo evolutivo multiobjetivo potente y actualizado. A diferencia de SPEA, SPEA2 utiliza una estrategia de cálculo de fitness de grano fino que incorpora información de densidad. Por otro lado, el tamaño del conjunto elite es fijo, por lo que cuando el número de individuos no dominados es menor que el tamaño predefinido, el conjunto se rellena con individuos dominados; en SPEA, el tamaño del conjunto puede variar con el tiempo. Además, la técnica de segmentación, a la que se llama cuando el frente de soluciones no dominadas supera el tamaño fijado para el conjunto elite, se ha sustituido por un método alternativo de truncado que tiene características similares pero que no pierde elementos frontera. Por último, otra diferencia con respecto a SPEA es que sólo los miembros del conjunto elite participan en el proceso de selección.

Las principales diferencias de SPEA2 con respecto a SPEA son las siguientes:

- Dispone de un nuevo *esquema mejorado de cálculo del fitness* que, para cada individuo, tiene en cuenta a cuantos individuos domina y por cuantos es dominado: los individuos que son dominados por los mismos miembros del conjunto elite tienen valores de fitness idénticos. Esto significa que en el caso en que el conjunto elite contiene un único individuo, todos los miembros de la población tienen la misma clasificación independientemente de si unos se dominan a otros o no. Como resultado, la presión selectiva disminuye de forma sustancial y en este caso particular SPEA se comporta como un algoritmo de búsqueda aleatorio.
- Incorpora una *técnica de estimación de densidad* basada en el vecino más cercano, que permite guiar de forma más precisa el proceso de búsqueda: Si muchos individuos de la generación actual no se dominan unos a otros, se puede obtener muy poca o ninguna información del orden parcial definido por la relación de dominancia. En esta situación, que es muy probable que ocurra cuando se utilizan más de dos objetivos, se debe utilizar información de densidad para guiar el proceso de búsqueda de forma más efectiva. La agrupación (*clustering*) utiliza esta información, pero sólo con respecto a los miembros del conjunto elite y no a la población.

- Utiliza un nuevo método de *truncado de la población elite* que garantiza la conservación de las soluciones límite: aunque la técnica de segmentación utilizada en SPEA es capaz de reducir el conjunto de soluciones no dominadas sin destruir sus características, puede perder soluciones frontera. Sin embargo, estas soluciones deberían mantenerse en el conjunto para obtener diversidad en las soluciones no dominadas.

Para preservar la diversidad a nivel fenotípico, nuestro modelo de AG multiobjetivo utiliza una técnica de nichos que considera la proximidad en valores de los objetivos y un objetivo original basado en la novedad para promover reglas que aporten información sobre ejemplos no descritos por otras reglas de la población.

La Figura 3.1 muestra el esquema del modelo propuesto.

*Paso 1. Inicialización:*

Generar una población inicial  $P_0$  y crear una población elite vacía  $P'_0 = \emptyset$ .  
Poner  $t = 0$ .

Repetir

*Paso 2. Asignación de Fitness:*

Calcular los valores de fitness de los individuos de  $P_t$  y  $P'_t$ .

*Paso 3. Selección de entorno:*

Copiar todos los individuos no dominados de  $P_t$  y  $P'_t$  a  $P'_{t+1}$ . Como el tamaño de  $P'_{t+1}$  tiene que ser exactamente el número de individuos a guardar ( $N$ ), debemos usar una función de truncado o rellenado.

*Paso 4. Reproducción:*

Realizar selección por torneo binario con reemplazo sobre  $P'_{t+1}$  aplicando después los operadores de cruce y mutación, obteniendo  $P_{t+1}$ .

*Paso 5. Incrementar el contador de generación*

( $t = t+1$ )

Mientras no se verifique la condición de parada.

*Paso 6.*

Devolver todos los individuos no dominados de  $P'_{t+1}$ .

*Figura 3.1. Esquema de funcionamiento del algoritmo propuesto.*

Una vez esbozadas las bases de modelo, se describen en detalle algunos aspectos importantes como el esquema de representación, la definición de los objetivos del algoritmo, el esquema de reproducción y los operadores genéticos utilizados, y el procedimiento de generación de la población inicial.

### 3.1.1 Esquema de representación

Como hemos comentado al describir la propuesta mono-objetivo, la representación genética de las soluciones es el aspecto más determinante de las características de cualquier propuesta de AG. En [CHHM01] se puede encontrar una descripción detallada de los

enfoques aplicados para la representación. En una tarea de descubrimiento de subgrupos, se consideran varias variables descriptivas y una única variable objetivo de interés. Para este fin, el enfoque “*Cromosoma = Regla*” es más adecuado puesto que el objetivo es encontrar un conjunto de reglas reducido en el que la calidad de cada regla se evalúa de forma independiente al resto, y no es necesario evaluar de forma conjunta el conjunto de reglas. Este es el esquema de codificación que se utiliza en esta propuesta evolutiva, de forma que cada individuo codifica una sola regla, y un conjunto de reglas se codifica mediante un subconjunto de la población completa.

El AG multiobjetivo descubre reglas difusas, tanto en formato canónico como DNF, cuyo consecuente está prefijado a uno de los valores posibles de la variable objetivo. Así, todos los individuos de la población se asocian con el mismo valor de la variable objetivo, por lo que el cromosoma sólo representa el antecedente de la regla. De esta forma, el esquema de representación que se sigue es el mismo que el descrito en la Sección 2.1.1.1 para la propuesta mono-objetivo.

### 3.1.2 Definición de los objetivos del algoritmo

El proceso de inducción de reglas intenta obtener reglas con una alta precisión predictiva, comprensibles e interesantes. En esta propuesta, se definen tres objetivos, y el algoritmo intenta maximizar todos los objetivos definidos:

- *Confianza*. Definida como en (2.9), determina la frecuencia relativa de los ejemplos que satisfacen la regla completa (antecedente y consecuente) entre aquellos que sólo cumplen el antecedente. Utilizamos una adaptación de a expresión de precisión de Quinlan para generar reglas de clasificación difusas [CDH98]: la suma del grado de pertenencia de los ejemplos de esta clase (los ejemplos cubiertos por esta regla) a la zona delimitada por el antecedente, dividida por la suma del grado de pertenencia de todos los ejemplos que satisfacen el antecedente de esta regla (independientemente de su clase) a la misma zona (por legibilidad, se reproduce la ecuación (2.9) introducida en el Capítulo 2):

$$Conf(R^i) = \frac{\sum_{E^k \in E / E^k \in Class_j} APC(E^k, R^i)}{\sum_{E^k \in E} APC(E^k, R^i)}$$

donde *APC* (*Antecedent Part Compatibility*), calculada según la expresión (2.4), es el grado de compatibilidad entre un ejemplo y el antecedente de una regla difusa, es decir, el grado de pertenencia para el ejemplo al subespacio difuso delimitado por el antecedente de la regla (en el caso de reglas no difusas, los grados de pertenencia son los correspondientes a conjuntos clásicos, 0 ó 1).

- *Compleitud (o soporte)*. Mide el grado de cubrimiento que la regla ofrece a los ejemplos de esa clase, calculada como el cociente entre el número de ejemplos que pertenecen a la clase que son cubiertos por la regla y el número total de ejemplos de la misma clase, tal como se definió en (2.14):

$$Comp_{Clase}(R_i) = \frac{n(Clase.Conc_i)}{n(Clase)}$$

- *Soporte original*. Este objetivo es una medida del nivel de originalidad de la regla comparado con el resto de reglas. A diferencia de los otros dos objetivos, que se calculan para cada regla de forma individual, para el cálculo de este objetivo se tienen en cuenta las otras reglas. Se calcula sumando, para cada ejemplo que pertenece al antecedente de la regla, el factor  $1/k$ , donde  $k$  es el número de reglas de la población que describen información sobre ese ejemplo. Esta medida promueve la diversidad de la población a nivel fenotípico al cubrir ejemplos no descritos por otras reglas de la población.

El último objetivo, soporte original, es un objetivo artificial que realmente es una restricción en las reglas para obtener un frente de Pareto óptimo con un alto grado global de cobertura (mejorando la diversidad de la población). Está relacionado con la cooperación entre reglas, dirigiendo el proceso evolutivo a la obtención de reglas que describan información sobre ejemplos no descritos por las otras reglas. La utilización de este objetivo es importante porque el algoritmo propuesto no es de cubrimiento y las reglas obtenidas pueden estar solapadas. De esta forma, este objetivo intenta promover la obtención de reglas que pertenezcan a diferentes partes del espacio de búsqueda, evitando la convergencia de la población a una parte de este espacio de búsqueda.

### 3.1.3 Cálculo del fitness

Para evitar el hecho de que los individuos dominados por los mismos individuos de la población elite tengan idénticos valores de fitness, en el cálculo del fitness de cada individuo se tienen en cuenta tanto los individuos dominados como los individuos a los que domina. La asignación de fitness para las reglas extraídas se realiza de la siguiente forma:

1. Para cada individuo tanto de la población como de la población elite se calcula el valor de los objetivos que se definen para el problema a resolver, y estos valores se utilizan para calcular qué individuos son dominados, y cuantos individuos domina cada individuo no dominado. Entonces, la fuerza (*strength*) de cada individuo se calcula como el número de individuos a los que domina.
2. Se determina el fitness inicial (*raw fitness*) de cada individuo, como la suma de la fuerza de sus dominadores (tanto en la población como en la población elite).

3. El cálculo del fitness inicial aporta un mecanismo de nichos basado en el concepto de la dominancia de Pareto, pero puede fallar cuando muchos de los individuos son no dominados. Para evitarlo, se incluye información adicional sobre densidad para discriminar entre individuos con los mismos valores de fitness inicial. La técnica de estimación de densidad utilizada es una adaptación del método del k-ésimo vecino más cercano [Sil86], donde la densidad en un punto es función decreciente de la distancia al punto k-ésimo más cercano. En esta propuesta se toma la inversa de la distancia al vecino k-ésimo más cercano como estimación de densidad:

$$D(i) = \frac{1}{\sigma_i^k + 2} \quad (3.1)$$

donde  $\sigma_i^k$  indica la distancia de un individuo  $i$  al k-ésimo más cercano (teniendo en cuenta tanto los individuos de la población como de la población elite), y 2 se añade al denominador para asegurar que sus valores son mayores que 0 y que  $D(i) < 1$ .

4. El valor de fitness de cada individuo es la suma de su valor de fitness inicial y su densidad.

### 3.1.4 Selección de entorno

En este algoritmo se establece un tamaño fijo para la población elite, de forma que es necesario definir una función de truncado y otra de rellenado.

La función de truncado permite eliminar soluciones no dominadas de la población elite si excede el tamaño definido. Para ello se utiliza un esquema de nichos definido en torno a la densidad medida según el k-ésimo vecino más cercano, en el que, en un proceso iterativo, en cada iteración se elimina de la población elite aquel individuo que está más cerca de otros respecto a los valores de los objetivos.

La función de rellenado permite añadir elementos dominados tanto de la población como de la población elite hasta completar el tamaño de la misma (ordenando los individuos según su valor de fitness).

### 3.1.5 Esquema de reproducción y operadores genéticos

Se utiliza el siguiente esquema de reproducción:

- Se une la población original con la población elite y se determinan cuáles son los elementos no dominados de la unión de ambas poblaciones.
- Se aplica un esquema de selección por torneo binario sobre los individuos no dominados.

- A la población resultante, se le aplica recombinación a través del operador de cruce en dos puntos y un operador de mutación uniforme sesgado con el que la mitad de las mutaciones realizadas tienen el efecto de eliminar la variable correspondiente, para incrementar la generalidad de las reglas, de la misma forma que se definió en la Sección 2.1.1.3 para el algoritmo evolutivo mono-objetivo.

### 3.1.6 Generación de la población inicial

La población inicial del algoritmo se genera de forma aleatoria sesgada, de forma que habrá una parte de la población que se genere de forma completamente aleatoria, y otra parte que se generará obligando a que en esos individuos intervengan como máximo el porcentaje indicado de las variables del conjunto de datos.

De esta forma, obligamos a que en la población inicial haya más diversidad y aparezcan reglas más complejas y más sencillas.

## 3.2 Comparación entre MESDIF y otros algoritmos de descubrimiento de subgrupos

---

Esta comparación pretende verificar la aplicabilidad de la propuesta de algoritmo genético multiobjetivo para la extracción de reglas difusas de descripción de subgrupos. Para ello, se han comparado sus resultados con los de los algoritmos CN2-SD [LKFT04], Apriori-SD [KL06] y el algoritmo SDIGA presentado en el capítulo anterior de esta memoria.

### 3.2.1 Características de la experimentación

Para la experimentación se han utilizado los mismos conjuntos de datos del repositorio UCI utilizados en el capítulo anterior. Los experimentos, de igual forma se han llevado a cabo mediante validación cruzada con 10 particiones para la estimación de error. Como cada ejecución del algoritmo obtiene reglas correspondientes al mismo valor de la variable objetivo, se debe ejecutar para cada uno de los valores de la variable objetivo. Por último, como la propuesta es no-determinista, se han llevado a cabo 5 ejecuciones sobre cada conjunto de particiones de entrenamiento/prueba. Después de obtener las reglas con el algoritmo SDIGA, se han calculado las medidas de Cobertura (*Cob*), Soporte (*Sop*), Relevancia (*Rel*) y Atipicidad (*WRAcc*) de las reglas obtenidas, con las expresiones definidas en el Capítulo 1 de esta memoria, y los correspondientes valores para los conjuntos de reglas (*COB*, *SOP*, *REL* y *WRACC* respectivamente) y la complejidad (*TAM*).

La experimentación se ha realizado para obtener reglas tanto de tipo canónico como DNF. Los parámetros utilizados en esta experimentación son los siguientes:

- Tamaño de la población: 100.
- Máximo número de evaluaciones de individuos en cada ejecución del AG: 10000.
- Probabilidad de mutación: 0.01.
- Número de etiquetas lingüísticas para las variables continuas: 3, 5 y 7.

### 3.2.2 Análisis de resultados

Las Tablas 3.1 a 3.17 muestran los resultados obtenidos por la propuesta y mejores resultados de nuestra propuesta mono-objetivo SDIGA, CN2-SD [LKFT04] y Apriori-SD [KL06] para los distintos conjuntos de datos. Los resultados muestran para nuestra propuesta las medias de los valores obtenidos en las particiones de prueba para todas las ejecuciones.

En estas tablas, se marca con un punto (“•”) la experimentación con mejores resultados de todos los algoritmos, con asterisco (“\*”) la experimentación con mejores resultados para el algoritmo MESDIF en cualquiera de sus versiones, y con un signo mas (“+”) la experimentación con mejores resultados para cada uno de los grupos (algoritmos clásicos y mejor experimentación de SDIGA, MESDIF con reglas canónicas, y MESDIF con reglas DNF).

Las tablas incluyen los resultados obtenidos con:

- La mejor experimentación de los algoritmos CN2-SD, Apriori-SD y SDIGA.
- El algoritmo MESDIF (para 4 tamaños del conjunto elite, 3, 4, 5 y 10, y para 3, 5 y 7 etiquetas para las variables lingüísticas).
- El algoritmo MESDIF obteniendo reglas DNF (MESDIF -DNF).

Para cada medida, se muestra el valor de la media de los resultados obtenidos por los conjuntos de reglas. “COB” es la cobertura media del conjunto de reglas calculada como en (1.2), “SOP” es el soporte total de un conjunto de reglas calculada como en (1.3), “TAM” es el número de reglas del conjunto inducido, “REL” es el promedio de la relevancia del conjunto de reglas calculada como en (1.7), y “WRACC” es la media de la atipicidad del conjunto de reglas calculado como en (1.9).

Tabla 3.1. Comparación de algoritmos de descubrimiento de subgrupos para Australian

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,310	0,591	2,64	16,348	0,120		
SDIGA DNF 5et CfMin 0.9	0,160	0,707	2,50	7,169	0,058		
CN2-SD ( $\gamma=0.7$ )	0,492	0,970	2,60	24,000	0,185 •		
Etiquetas Elite							
MESDIF	3	3	<b>0,322</b>	0,783	<b>6,00</b>	<b>6,648</b>	<b>0,064</b>
		4	0,253	0,785	8,00	5,906	0,052
		5	0,247	0,790	10,00	5,871	0,053
		10	0,201	<b>0,807</b>	19,98	5,665	0,049
	5	3	<b>0,372</b>	0,936	<b>6,00</b>	7,346	0,053
		4	0,326	0,918	8,00	7,130	0,054
		5	0,311	0,941	10,00	<b>7,594</b>	<b>0,060</b>
		10	0,247	<b>0,948</b>	20,00	6,706	0,054
	7	3	<b>0,370</b>	0,938	<b>6,00</b>	<b>9,825</b>	<b>0,078</b> *
		4	0,290	0,941	8,00	7,155	0,060
		5	0,297	0,950	10,00	8,902	0,070
		10	0,268	<b>0,960</b>	20,00	9,018	0,072
Etiquetas Elite							
MESDIF DNF	3	3	<b>0,365</b>	0,857	<b>6,00</b>	5,771	0,048
		4	0,322	<b>0,859</b>	7,94	6,085	0,051
		5	0,290	0,857	9,94	<b>6,477</b>	<b>0,054</b>
		10	0,241	0,855	19,12	6,161	0,049
	5	3	<b>0,375</b>	0,855	<b>6,00</b>	4,801	0,042
		4	0,349	0,907	7,98	5,912	0,052
		5	0,335	0,897	9,94	<b>6,866</b>	<b>0,057</b>
		10	0,286	<b>0,914</b>	19,14	6,637	0,057
	5	3	<b>0,382</b>	0,883	<b>6,00</b>	5,390	0,051
		4	0,375	<b>0,896</b>	7,96	<b>7,105</b>	<b>0,061</b> +
		5	0,318	0,871	9,90	6,383	0,055
		10	0,272	0,870	18,84	6,838	0,057

Para el conjunto de datos Australian, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA.

Tabla 3.2. Comparación de algoritmos de descubrimiento de subgrupos para Breast-w

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,430	0,692	2,42	17,869	0,121 <sup>+</sup>		
SDIGA DNF 5et CfMin 0.9	0,398	0,693	4,08	19,455	0,131		
CN2-SD ( $\gamma=0.7$ )	0,260	0,860	9,20	26,600	0,111		
Etiquetas Elite							
MESDIF	3	3	0,464	0,890	<b>5,62</b>	15,261	0,093
		4	0,481	0,910	7,02	16,690	0,097
		5	0,487	0,931	8,42	17,057	0,100
		10	<b>0,508</b>	<b>0,950</b>	11,90	<b>19,409</b>	<b>0,116</b>
	5	3	0,466	0,886	<b>5,68</b>	14,868	0,090
		4	0,478	0,903	6,88	16,750	0,098
		5	0,489	0,935	8,42	17,047	0,100
		10	<b>0,500</b>	<b>0,939</b>	11,82	<b>19,594</b>	<b>0,118</b>
	7	3	0,468	0,898	<b>5,68</b>	14,989	0,092
		4	0,475	0,903	7,04	16,594	0,096
		5	0,488	0,921	8,36	16,797	0,100
		10	<b>0,500</b>	<b>0,931</b>	11,54	<b>19,733</b>	<b>0,120</b> <sup>•</sup>
Etiquetas Elite							
MESDIF DNF	3	3	0,471	0,976	<b>5,98</b>	9,298	0,064
		4	0,464	0,974	7,88	13,242	0,090
		5	0,462	0,986	9,90	14,344	0,097
		10	<b>0,485</b>	<b>0,996</b>	18,90	<b>16,987</b>	<b>0,116</b> <sup>+</sup>
	5	3	0,466	0,967	<b>6,00</b>	9,794	0,067
		4	0,458	0,975	7,96	12,656	0,088
		5	0,457	0,979	9,92	14,727	0,101
		10	<b>0,477</b>	<b>0,995</b>	18,84	<b>16,480</b>	<b>0,114</b>
	5	3	0,456	0,973	<b>6,00</b>	9,190	0,062
		4	0,478	0,980	7,96	11,795	0,080
		5	0,467	0,984	9,92	14,288	0,098
		10	<b>0,483</b>	<b>0,995</b>	18,60	<b>16,364</b>	<b>0,114</b>

Para el conjunto de datos Breast-w, los mejores resultados los obtiene el algoritmo multiobjetivo MESDIF, que además mejora los resultados del algoritmo mono-objetivo SDIGA.

Tabla 3.3. Comparación de algoritmos de descubrimiento de subgrupos para Bridges

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,299	0,505	3,04	0,805	0,024	
SDIGA DNF 5et CfMin 0.9	0,299	0,813	2,08	1,204	0,038	
CN2-SD ( $\gamma=0.7$ )	0,721	0,840	1,90	21,200	-0,001 •	
Etiquetas Elite						
MESDIF	3	<b>0,196</b>	0,569	<b>6,00</b>	0,613	0,007
	4	0,180	0,570	8,00	0,610	0,012
	5	0,192	0,686	9,98	<b>0,627</b>	0,014
	10	0,195	<b>0,829</b>	19,50	0,578	<b>0,017</b> +
	3	<b>0,242</b>	0,531	<b>6,00</b>	<b>0,750</b>	0,013
	4	0,223	0,692	8,00	0,639	0,010
	5	0,215	0,746	9,96	0,645	<b>0,015</b>
	10	0,194	<b>0,855</b>	17,92	0,613	0,012
	3	0,188	0,470	<b>6,00</b>	<b>0,566</b>	<b>0,020</b>
	4	<b>0,214</b>	0,664	8,00	0,536	0,018
	5	0,209	0,679	9,70	0,544	0,017
	10	0,202	<b>0,845</b>	16,56	0,499	0,014
Etiquetas Elite						
MESDIF DNF	3	<b>0,326</b>	0,777	<b>5,98</b>	0,716	0,018 *
	4	0,289	0,757	7,86	0,715	0,021
	5	0,307	0,763	9,22	0,674	0,017
	10	0,307	<b>0,798</b>	15,88	<b>0,748</b>	<b>0,025</b>
	3	<b>0,329</b>	0,742	<b>5,98</b>	0,660	0,015
	4	0,304	0,754	7,88	<b>0,797</b>	<b>0,024</b>
	5	0,287	<b>0,755</b>	9,40	0,637	0,017
	10	0,252	0,729	16,46	0,712	0,017
	3	<b>0,372</b>	0,827	<b>6,00</b>	0,578	0,009
	4	0,356	0,846	7,86	<b>0,665</b>	0,015
	5	0,346	0,870	9,74	0,649	0,013
	10	0,336	<b>0,902</b>	17,20	0,653	<b>0,016</b>

Para el conjunto de datos Bridges, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA.

Tabla 3.4. Comparación de algoritmos de descubrimiento de subgrupos para Diabetes

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,378	0,812	2,00	5,236	0,035		
SDIGA DNF 5et CfMin 0.9	0,265	0,961	2,00	4,652	0,039		
CN2-SD ( $\gamma=0.7$ )	0,299	0,950	5,40	15,200	0,086 •		
Etiquetas Elite							
MESDIF	3	3	<b>0,163</b>	0,513	<b>6,00</b>	1,613	0,011
		4	0,133	<b>0,540</b>	8,00	2,273	0,012
		5	0,142	0,540	10,00	2,406	0,017
		10	0,121	0,533	20,00	<b>2,514</b>	<b>0,018</b> +
	5	3	<b>0,219</b>	0,452	<b>6,00</b>	1,531	0,009
		4	0,190	<b>0,453</b>	8,00	1,944	0,013
		5	0,166	0,437	10,00	<b>2,029</b>	<b>0,014</b>
		10	0,142	0,416	20,00	2,024	0,012
	7	3	<b>0,168</b>	<b>0,380</b>	<b>6,00</b>	<b>2,297</b>	<b>0,011</b>
		4	0,146	0,363	8,00	1,985	0,009
		5	0,152	0,369	10,00	2,056	0,010
		10	0,127	0,327	19,98	2,080	0,009
Etiquetas Elite							
MESDIF DNF	3	3	<b>0,205</b>	0,571	<b>5,94</b>	2,466	0,022
		4	0,181	0,561	7,96	3,049	0,024
		5	0,172	<b>0,577</b>	9,86	<b>3,263</b>	<b>0,027</b> *
		10	0,130	0,529	18,74	2,901	0,023
	5	3	<b>0,290</b>	0,562	<b>6,00</b>	1,309	0,013
		4	0,252	<b>0,569</b>	8,00	1,815	0,019
		5	0,229	0,545	10,00	2,221	0,019
		10	0,164	0,522	19,92	<b>2,248</b>	<b>0,019</b>
	5	3	<b>0,314</b>	0,555	<b>6,00</b>	1,479	0,014
		4	0,293	<b>0,556</b>	7,98	1,665	0,015
		5	0,248	0,534	9,92	1,599	0,014
		10	0,201	0,528	19,78	<b>1,910</b>	<b>0,015</b>

Para el conjunto de datos Diabetes, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF obtiene peores resultados que el algoritmo mono-objetivo SDIGA.

Tabla 3.5. Comparación de algoritmos de descubrimiento de subgrupos para Echo

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,329	0,704	2,00	1,003	0,030	
SDIGA DNF 5et CfMin 0.9	0,267	0,744	2,02	1,456	0,043	
CN2-SD ( $\gamma=0.7$ )	1,295	0,820	3,40	23,100	0,243 •	
Etiquetas Elite						
MESDIF	3	<b>0,254</b>	0,688	<b>6,00</b>	0,658	0,018
	4	0,209	0,652	8,00	0,676	0,017
	5	0,204	0,697	10,00	0,656	0,016
	10	0,186	<b>0,803</b>	19,94	<b>0,755</b>	<b>0,019</b> +
	3	0,168	0,392	<b>6,00</b>	0,928	0,012
	4	<b>0,187</b>	0,496	8,00	<b>0,938</b>	0,016
	5	0,160	0,531	10,00	0,913	0,017
	10	0,164	<b>0,737</b>	19,74	0,877	<b>0,017</b>
	3	<b>0,271</b>	0,691	<b>6,00</b>	0,880	0,023
	4	0,227	0,731	8,00	0,844	<b>0,023</b>
	5	0,223	0,738	10,00	<b>0,956</b>	0,021
	10	0,178	<b>0,850</b>	19,74	0,914	0,017
Etiquetas Elite						
MESDIF DNF	3	<b>0,265</b>	0,638	<b>6,00</b>	0,821	0,020
	4	0,264	0,632	7,94	0,815	0,024
	5	0,246	<b>0,653</b>	9,80	<b>1,009</b>	<b>0,030</b> *
	10	0,190	0,618	17,96	0,851	0,024
	3	<b>0,326</b>	0,726	<b>6,00</b>	0,693	0,015
	4	0,305	<b>0,738</b>	7,98	0,803	0,023
	5	0,283	0,691	9,98	0,918	<b>0,028</b>
	10	0,244	0,713	19,04	<b>0,986</b>	0,026
	3	<b>0,359</b>	<b>0,786</b>	<b>6,00</b>	0,614	0,017
	4	0,316	0,744	7,98	0,779	0,019
	5	0,311	0,756	10,00	<b>0,871</b>	0,018
	10	0,255	0,758	19,38	0,845	<b>0,020</b>

Para el conjunto de datos Echo, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF obtiene peores resultados que el algoritmo mono-objetivo SDIGA.

Tabla 3.6. Comparación de algoritmos de descubrimiento de subgrupos para German

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,082	0,177	8,56	0,615	0,006		
SDIGA DNF 5et CfMin 0.9	0,027	0,085	25,98	0,875	0,004		
CN2-SD ( $\gamma=0.7$ )	0,141	0,900	8,40	19,800	0,034 <sup>•</sup>		
Etiquetas Elite							
MESDIF	3	3	<b>0,241</b>	0,551	<b>6,00</b>	1,226	0,013
		4	0,210	0,537	8,00	1,768	0,016
		5	0,204	<b>0,557</b>	10,00	2,115	0,018
		10	0,176	0,517	20,00	<b>2,810</b>	<b>0,022</b>
	5	3	<b>0,401</b>	0,511	<b>6,00</b>	0,837	0,008
		4	0,386	<b>0,529</b>	8,00	1,508	0,017
		5	0,364	0,525	10,00	1,496	0,014
		10	0,267	0,479	20,00	<b>2,333</b>	<b>0,018</b>
	7	3	<b>0,447</b>	<b>0,521</b>	<b>6,00</b>	0,938	0,014
		4	0,390	0,502	8,00	1,766	0,019
		5	0,365	0,498	10,00	2,145	0,020
		10	0,328	0,471	20,00	<b>2,675</b>	<b>0,024</b> <sup>+</sup>
Etiquetas Elite							
MESDIF DNF	3	3	0,343	<b>0,541</b>	<b>5,98</b>	1,439	0,016
		4	<b>0,346</b>	0,533	7,98	1,599	0,018
		5	0,291	0,521	10,00	1,859	0,020
		10	0,246	0,506	19,78	<b>2,860</b>	<b>0,026</b> <sup>*</sup>
	5	3	<b>0,409</b>	0,541	<b>6,00</b>	0,974	0,011
		4	0,407	<b>0,546</b>	7,98	1,323	0,015
		5	0,386	0,533	9,98	1,449	0,018
		10	0,347	0,543	19,90	<b>2,139</b>	<b>0,023</b>
	5	3	0,420	0,519	<b>6,00</b>	0,840	0,008
		4	<b>0,435</b>	<b>0,545</b>	8,00	1,243	0,015
		5	0,401	0,531	10,00	1,848	0,020
		10	0,374	0,542	19,86	<b>2,104</b>	<b>0,022</b>

Para el conjunto de datos German, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA.

Tabla 3.7. Comparación de algoritmos de descubrimiento de subgrupos para Heart

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,504	0,852	2,00	1,790	0,059		
SDIGA DNF 5et CfMin 0.9	0,464	0,971	2,00	2,359	0,083		
CN2-SD ( $\gamma=0.7$ )	0,435	0,980	1,80	30,600	0,122 •		
Etiquetas Elite							
MESDIF	3	3	0,281	0,683	<b>6,00</b>	1,655	0,033
		4	<b>0,297</b>	0,791	8,00	2,329	0,047
		5	0,283	0,854	10,00	2,547	0,051
		10	0,242	<b>0,935</b>	20,00	<b>3,068</b>	<b>0,058</b> +
	5	3	<b>0,246</b>	0,622	<b>6,00</b>	1,879	0,040
		4	0,223	0,641	8,00	1,964	0,040
		5	0,219	0,674	10,00	2,192	0,041
		10	0,224	<b>0,913</b>	19,94	<b>2,549</b>	<b>0,051</b>
	7	3	<b>0,300</b>	0,724	<b>6,00</b>	<b>3,192</b>	<b>0,067</b>
		4	0,274	0,774	8,00	2,642	0,058
		5	0,283	0,818	10,00	2,884	0,063
		10	0,267	<b>0,953</b>	19,78	2,864	0,062
Etiquetas Elite							
MESDIF DNF	3	3	<b>0,310</b>	0,730	<b>6,00</b>	1,980	0,052
		4	0,288	0,727	7,98	2,442	0,057
		5	0,297	<b>0,788</b>	9,94	2,880	<b>0,065</b>
		10	0,250	0,773	19,84	<b>3,117</b>	0,062 *
	5	3	<b>0,369</b>	0,826	<b>6,00</b>	1,497	0,039
		4	0,327	<b>0,839</b>	8,00	2,109	0,049
		5	0,334	0,832	9,96	1,952	0,047
		10	0,277	0,824	19,94	<b>2,354</b>	<b>0,053</b>
	5	3	<b>0,401</b>	0,832	<b>6,00</b>	1,313	0,034
		4	0,369	0,830	7,98	1,783	0,041
		5	0,375	<b>0,847</b>	9,96	2,118	0,048
		10	0,314	0,841	19,94	<b>2,480</b>	<b>0,053</b>

Para el conjunto de datos Heart, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF obtiene peores resultados que el algoritmo mono-objetivo SDIGA.

Tabla 3.8. Comparación de algoritmos de descubrimiento de subgrupos para Hepatitis

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,235	0,550	2,68	0,875	0,019		
SDIGA DNF 5et CfMin 0.9	0,286	0,737	2,34	0,864	0,027		
CN2-SD ( $\gamma=0.7$ )	0,686	0,990	2,70	25,000	0,049		
<b>Etiquetas Elite</b>							
MESDIF	3	3	0,272	0,693	<b>6,00</b>	1,140	0,021
		4	<b>0,307</b>	0,758	8,00	1,007	0,019
		5	0,300	0,774	10,00	1,101	0,021
		10	0,278	<b>0,829</b>	19,98	<b>1,143</b>	<b>0,026</b>
	5	3	<b>0,419</b>	0,784	<b>6,00</b>	<b>1,283</b>	<b>0,032</b>
		4	0,415	0,887	8,00	0,988	0,025
		5	0,409	0,895	10,00	1,195	0,030
		10	0,297	<b>0,915</b>	19,94	1,017	0,022
	7	3	<b>0,521</b>	0,931	<b>6,00</b>	1,226	0,042
		4	0,467	<b>0,936</b>	8,00	1,250	0,036
		5	0,463	0,931	10,00	1,271	0,042
		10	0,381	0,934	19,82	<b>1,340</b>	<b>0,043</b>
<b>Etiquetas Elite</b>							
MESDIF DNF	3	3	<b>0,260</b>	0,688	<b>5,98</b>	0,995	0,025
		4	0,257	0,700	7,96	1,263	0,031
		5	0,255	0,708	9,90	1,194	0,029
		10	0,255	<b>0,788</b>	18,58	<b>1,353</b>	<b>0,033</b>
	5	3	<b>0,327</b>	0,716	<b>5,98</b>	0,775	0,016
		4	0,294	0,687	8,00	0,953	0,022
		5	0,294	0,728	9,92	1,156	<b>0,029</b>
		10	0,266	<b>0,782</b>	19,36	<b>1,164</b>	0,028
	5	3	0,348	0,805	<b>6,00</b>	0,908	0,026
		4	0,327	0,756	8,00	0,997	0,026
		5	<b>0,354</b>	<b>0,830</b>	9,94	1,195	0,027
		10	0,318	0,829	19,52	<b>1,281</b>	<b>0,031</b>

Para el conjunto de datos Hepatitis, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA, aunque con un mayor número de reglas.

Tabla 3.9. Comparación de algoritmos de descubrimiento de subgrupos para Hypothyroid

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,288	0,665	2,74	11,776	0,016	
SDIGA DNF 5et CfMin 0.9	0,416	0,817	2,76	18,643	0,022	
CN2-SD ( $\gamma=0.7$ )	0,509	1,000	3,40	28,300	0,073 •	
Etiquetas Elite						
MESDIF	3	<b>0,321</b>	0,995	<b>6,00</b>	5,439	<b>0,009</b>
	4	0,257	<b>0,995</b>	8,00	6,940	0,008
	5	0,224	0,972	10,00	7,854	0,008
	10	0,161	0,986	20,00	<b>8,396</b>	0,008
	3	<b>0,320</b>	0,941	<b>6,00</b>	10,774	0,016
	4	0,307	0,964	8,00	12,331	<b>0,016</b>
	5	0,293	0,966	10,00	12,052	0,015
	10	0,261	<b>0,980</b>	20,00	<b>13,749</b>	0,015
	3	0,278	0,975	<b>6,00</b>	14,606	0,013
	4	0,260	0,984	8,00	14,001	0,013
	5	0,269	0,974	9,96	12,621	0,012
	10	<b>0,291</b>	<b>0,987</b>	19,98	<b>14,722</b>	<b>0,015</b> +
Etiquetas Elite						
MESDIF DNF	3	<b>0,269</b>	0,660	<b>5,90</b>	5,816	0,009
	4	0,250	0,678	7,72	5,977	0,009
	5	0,229	0,659	8,96	<b>7,107</b>	<b>0,011</b>
	10	0,219	<b>0,761</b>	11,90	6,555	0,010
	3	<b>0,332</b>	0,932	<b>5,74</b>	8,832	0,012
	4	0,308	0,931	7,44	11,667	0,014
	5	0,295	<b>0,954</b>	8,82	9,657	0,013
	10	0,297	0,947	12,06	<b>12,072</b>	<b>0,015</b>
	3	0,360	0,915	<b>5,76</b>	11,334	0,014
	4	0,350	0,953	7,36	<b>14,845</b>	<b>0,016</b> *
	5	<b>0,361</b>	0,961	8,66	12,689	0,015
	10	0,348	<b>0,975</b>	13,16	12,828	0,016

Para el conjunto de datos Hypothyroid, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA, aunque con un mayor número de reglas.

Tabla 3.10. Comparación de algoritmos de descubrimiento de subgrupos para Ionosphere

Algoritmo		COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9		0,416	0,500	2,08	1,017	0,038		
SDIGA DNF 5et CfMin 0.9		0,078	0,385	2,92	1,845	0,023		
CN2-SD ( $\gamma=0.7$ )		0,354	0,980	4,20	14,900	0,145 <sup>•</sup>		
MESDIF	Etiqu Elite							
	3	3	<b>0,370</b>	0,596	<b>6,00</b>	2,892	0,046	
		4	0,343	0,607	8,00	3,231	0,048	
		5	0,331	0,629	10,00	2,984	0,045	
		10	0,295	<b>0,638</b>	19,74	<b>3,809</b>	<b>0,056</b> <sup>*</sup>	
	5	3	<b>0,448</b>	<b>0,625</b>	<b>6,00</b>	2,168	0,037	
		4	0,392	0,613	8,00	2,528	0,044	
		5	0,347	0,586	10,00	2,466	0,043	
		10	0,283	0,566	19,90	<b>3,623</b>	<b>0,051</b>	
	7	3	<b>0,431</b>	<b>0,595</b>	<b>5,98</b>	2,316	0,037	
		4	0,386	0,588	8,00	2,759	<b>0,048</b>	
		5	0,344	0,570	10,00	2,967	0,047	
		10	0,253	0,495	19,56	<b>3,279</b>	0,046	
	MESDIF DNF	Etiqu Elite						
		3	3	<b>0,337</b>	0,609	<b>5,98</b>	2,577	0,038
			4	0,296	0,620	7,88	2,657	0,038
5			0,275	0,615	9,68	2,862	0,040	
10			0,242	<b>0,638</b>	16,52	<b>3,116</b>	<b>0,043</b>	
5		3	<b>0,358</b>	0,602	<b>5,98</b>	2,020	0,035	
		4	0,331	0,626	7,80	2,420	0,041	
		5	0,294	0,603	9,62	2,591	0,041	
		10	0,246	<b>0,640</b>	18,06	<b>3,003</b>	<b>0,047</b>	
5		3	<b>0,377</b>	0,604	<b>5,98</b>	1,965	0,031	
		4	0,323	0,610	7,98	1,913	0,034	
		5	0,328	0,620	9,90	2,418	0,042	
		10	0,275	<b>0,656</b>	19,28	<b>3,065</b>	<b>0,046</b> <sup>+</sup>	

Para el conjunto de datos Ionosphere, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA, pero lo consigue con conjuntos de reglas más grandes.

Tabla 3.11. Comparación de algoritmos de descubrimiento de subgrupos para Iris

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,304	0,985	3,10	8,178	0,176	
SDIGA DNF 5et CfMin 0.9	0,311	1,000	3,00	8,416	0,181	
CN2-SD ( $\gamma=0.7$ )	0,768	0,880	2,90	17,600	0,052 •	
Etiquetas Elite						
MESDIF	3	<b>0,120</b>	<b>0,860</b>	<b>8,96</b>	<b>3,350</b>	<b>0,071</b>
	4	0,092	<b>0,860</b>	11,88	2,565	0,054
	5	0,076	<b>0,860</b>	14,72	2,140	0,045
	10	0,052	<b>0,860</b>	23,66	1,489	0,031
	3	<b>0,217</b>	0,912	<b>8,50</b>	<b>6,452</b>	<b>0,134</b> *
	4	0,208	0,917	9,50	6,229	0,129
	5	0,204	<b>0,920</b>	9,90	6,125	0,126
	10	0,205	<b>0,920</b>	10,02	6,146	0,127
	3	<b>0,144</b>	0,544	5,54	<b>4,669</b>	<b>0,095</b>
	4	0,144	<b>0,545</b>	5,52	4,635	0,094
	5	0,142	0,543	5,44	4,650	0,094
	10	0,139	0,525	<b>5,30</b>	4,586	0,093
Etiquetas Elite						
MESDIF DNF	3	<b>0,203</b>	0,857	<b>5,26</b>	<b>5,440</b>	<b>0,115</b>
	4	0,176	0,857	6,34	4,646	0,099
	5	0,163	0,857	6,82	4,444	0,095
	10	0,136	<b>0,859</b>	8,42	3,781	0,080
	3	0,195	0,852	<b>5,66</b>	5,664	0,118
	4	<b>0,201</b>	<b>0,863</b>	5,96	<b>5,886</b>	<b>0,122</b> +
	5	0,198	<b>0,863</b>	6,10	5,877	0,122
	10	0,189	0,860	6,64	5,803	0,120
	3	<b>0,240</b>	0,888	<b>7,58</b>	4,858	0,102
	4	0,236	0,893	8,82	5,265	0,110
	5	0,209	0,841	9,78	4,932	0,103
	10	0,216	<b>0,895</b>	11,30	<b>5,407</b>	<b>0,113</b>

Para el conjunto de datos Iris, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF obtiene peores resultados que el algoritmo mono-objetivo SDIGA.

Tabla 3.12. Comparación de algoritmos de descubrimiento de subgrupos para Tic-Tac-Toe

Algoritmo		COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9		0,162	0,221	9,20	5,135	0,027	
SDIGA DNF 5et CfMin 0.9		0,351	0,422	6,48	5,866	0,030	
CN2-SD ( $\gamma=0.7$ )		0,182	0,800	9,60	21,900	0,055 •	
Etiquetas Elite							
MESDIF	3	3	<b>0,210</b>	0,588	<b>6,00</b>	<b>5,005</b>	<b>0,042</b> +
		4	0,189	0,588	7,98	4,869	0,038
		5	0,177	0,594	9,70	4,507	0,035
		10	0,172	<b>0,680</b>	14,62	4,173	0,031
	5	3	<b>0,210</b>	0,584	<b>6,00</b>	<b>5,009</b>	<b>0,042</b>
		4	0,187	0,580	7,94	4,975	0,038
		5	0,176	0,589	9,54	4,554	0,035
		10	0,177	<b>0,707</b>	14,90	4,093	0,031
	7	3	<b>0,209</b>	0,577	<b>6,00</b>	4,883	<b>0,041</b>
		4	0,186	0,582	7,96	<b>4,987</b>	0,039
		5	0,177	0,590	9,72	4,607	0,034
		10	0,172	<b>0,693</b>	15,04	4,195	0,031
Etiquetas Elite							
MESDIF DNF	3	3	0,322	0,714	<b>6,00</b>	3,660	0,032
		4	0,308	0,764	7,72	<b>4,929</b>	<b>0,045</b> *
		5	0,336	0,834	9,40	4,122	0,038
		10	<b>0,373</b>	<b>0,976</b>	18,06	4,318	0,037
	5	3	0,322	0,696	<b>5,96</b>	3,704	0,032
		4	0,319	0,772	7,76	3,968	0,037
		5	0,342	0,855	9,60	4,167	<b>0,039</b>
		10	<b>0,375</b>	<b>0,969</b>	17,54	<b>4,330</b>	0,037
	5	3	0,333	0,735	<b>5,98</b>	3,712	0,033
		4	0,326	0,772	7,74	4,566	0,042
		5	0,344	0,857	9,68	<b>4,631</b>	<b>0,042</b>
		10	<b>0,366</b>	<b>0,953</b>	17,88	4,235	0,037

Para el conjunto de datos Ionosphere, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA. Para este conjunto de datos, MESDIF obtiene resultados cercanos a CN2-SD.

Tabla 3.13. Comparación de algoritmos de descubrimiento de subgrupos para Vote

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,422	0,802	3,06	18,243	0,180		
SDIGA DNF 5et CfMin 0.9	0,492	0,931	2,28	20,335	0,208 <sup>+</sup>		
CN2-SD ( $\gamma=0.7$ )	0,831	0,850	1,80	6,000	0,138		
Etiquetas Elite							
MESDIF	3	3	0,422	0,962	<b>6,00</b>	18,924	0,181
		4	0,429	0,965	7,86	<b>19,937</b>	<b>0,187</b> •
		5	<b>0,432</b>	0,970	9,20	19,189	0,182
		10	0,421	<b>0,980</b>	15,00	18,771	0,178
	5	3	0,422	0,963	<b>6,00</b>	18,625	0,180
		4	0,430	0,966	7,92	<b>19,685</b>	<b>0,185</b>
		5	<b>0,433</b>	0,970	9,22	19,342	0,183
		10	0,421	<b>0,980</b>	14,86	18,652	0,178
	7	3	0,419	0,963	<b>6,00</b>	18,754	0,180
		4	0,428	0,965	7,86	<b>19,541</b>	<b>0,185</b>
		5	<b>0,436</b>	0,971	9,28	19,129	0,182
		10	0,421	<b>0,980</b>	14,98	18,774	0,178
Etiquetas Elite							
MESDIF DNF	3	3	0,413	0,969	<b>5,68</b>	14,481	0,149
		4	<b>0,416</b>	0,969	7,04	15,584	0,157
		5	0,401	0,969	8,60	15,748	0,156
		10	0,394	<b>0,977</b>	13,84	<b>17,819</b>	<b>0,168</b>
	5	3	0,406	0,960	<b>5,68</b>	14,451	0,147
		4	0,403	0,964	7,24	15,518	0,155
		5	<b>0,407</b>	0,974	8,48	16,586	0,161
		10	0,395	<b>0,975</b>	13,40	<b>17,968</b>	<b>0,170</b> <sup>+</sup>
	5	3	<b>0,408</b>	0,961	<b>5,68</b>	14,563	0,149
		4	0,404	0,965	7,06	16,066	0,157
		5	0,399	0,969	8,54	16,469	0,160
		10	0,394	<b>0,976</b>	13,72	<b>17,315</b>	<b>0,167</b>

Para el conjunto de datos Vote, los mejores resultados los obtiene el algoritmo multiobjetivo MESDIF, mejorando los resultados del algoritmo mono-objetivo SDIGA, que ya mejoraba a CN2-SD.

Tabla 3.14. Comparación de algoritmos de descubrimiento de subgrupos para Balance

Algoritmo	COB	SOP	TAM	REL	WRACC		
SDIGA 5et CfMin 0.9	0,388	0,507	3,00	4,738	0,042		
SDIGA DNF 5et CfMin 0.9	0,471	0,776	3,00	9,374	0,070 •		
CN2-SD ( $\gamma=0.7$ )	0,380	1,000	4,20	5,600	0,085		
Etiquetas Elite							
MESDIF	3	3	0,177	0,530	<b>9,00</b>	3,171	0,020
		4	0,173	0,635	11,92	3,325	0,021
		5	<b>0,178</b>	0,746	14,92	3,408	0,022
		10	0,163	<b>0,904</b>	28,10	<b>3,516</b>	<b>0,022</b> +
	5	3	0,074	0,280	<b>8,72</b>	2,746	0,012
		4	0,076	0,351	10,84	2,984	0,014
		5	0,087	0,430	12,62	<b>3,409</b>	0,015
		10	<b>0,090</b>	<b>0,537</b>	16,22	3,338	<b>0,016</b>
	7	3	0,068	0,283	<b>8,76</b>	2,686	0,013
		4	0,078	0,384	11,16	3,001	0,015
		5	<b>0,079</b>	0,429	12,66	<b>3,036</b>	<b>0,015</b>
		10	0,077	<b>0,520</b>	18,00	2,918	0,013
Etiquetas Elite							
MESDIF DNF	3	3	<b>0,312</b>	0,799	<b>9,00</b>	4,625	0,038
		4	0,295	0,806	11,82	4,649	0,036
		5	0,287	0,842	14,92	4,869	0,037
		10	0,254	<b>0,912</b>	28,44	<b>5,912</b>	<b>0,042</b> *
	5	3	<b>0,396</b>	0,898	<b>9,00</b>	3,598	0,032
		4	0,377	0,916	11,94	4,227	0,033
		5	0,376	0,933	14,98	4,759	0,042
		10	0,363	<b>0,981</b>	28,62	<b>5,613</b>	<b>0,046</b>
	5	3	<b>0,433</b>	0,901	<b>9,00</b>	2,406	0,015
		4	0,394	0,901	11,98	3,157	0,021
		5	0,384	0,935	15,00	3,750	0,028
		10	0,376	<b>0,977</b>	29,18	<b>4,406</b>	<b>0,033</b>

Para el conjunto de datos Balance, los mejores resultados los obtiene SDIGA, por lo que el algoritmo multiobjetivo MESDIF obtiene peores resultados que el algoritmo mono-objetivo SDIGA, aunque mejores que los de los algoritmos clásicos.

Tabla 3.15. Comparación de algoritmos de descubrimiento de subgrupos para Car

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,014	0,048	16,76	1,935	0,002	
SDIGA DNF 5et CfMin 0.9	0,137	0,703	4,04	33,018	0,045 +	
CN2-SD ( $\gamma=0.7$ )	0,260	0,940	5,80	25,000	0,043	
Etiquetas Elite						
MESDIF	3	<b>0,160</b>	0,582	<b>10,40</b>	<b>13,515</b>	<b>0,026</b>
	4	0,128	0,579	13,36	12,086	0,022
	5	0,119	0,652	16,40	11,463	0,020
	10	0,101	<b>0,769</b>	27,28	10,257	0,017
	3	<b>0,160</b>	0,578	<b>10,34</b>	<b>13,330</b>	<b>0,025</b>
	4	0,128	0,567	13,30	11,813	0,021
	5	0,117	0,637	16,40	11,538	0,020
	10	0,104	<b>0,808</b>	27,80	10,608	0,018
	3	<b>0,163</b>	0,609	<b>10,46</b>	<b>13,511</b>	<b>0,026</b> +
	4	0,129	0,581	13,34	12,284	0,022
	5	0,118	0,642	16,28	11,253	0,020
	10	0,102	<b>0,809</b>	27,86	10,283	0,017
Etiquetas Elite						
MESDIF DNF	3	<b>0,296</b>	0,928	<b>11,30</b>	18,145	0,037
	4	0,269	0,954	15,12	18,975	0,038
	5	0,254	0,963	17,10	20,633	<b>0,039</b>
	10	0,208	<b>0,985</b>	26,74	<b>21,326</b>	0,038
	3	<b>0,288</b>	0,924	<b>11,28</b>	18,657	0,038
	4	0,277	0,937	14,72	19,118	0,038
	5	0,253	0,963	17,62	19,571	0,037
	10	0,211	<b>0,990</b>	25,68	<b>22,238</b>	<b>0,039</b> •
	3	<b>0,304</b>	0,931	<b>11,30</b>	17,444	0,035
	4	0,273	0,962	14,96	19,613	<b>0,039</b>
	5	0,254	0,972	17,68	19,415	0,038
	10	0,213	<b>0,984</b>	25,88	<b>21,892</b>	0,039

Para el conjunto de datos Car, los mejores resultados los obtiene el algoritmo multiobjetivo MESDIF, mejorando los resultados del algoritmo mono-objetivo SDIGA, que ya mejoraba a CN2-SD.

Tabla 3.16. Comparación de algoritmos de descubrimiento de subgrupos para Glass

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,078	0,532	7,28	1,796	0,013	
SDIGA DNF 5et CfMin 0.9	0,054	0,592	6,72	2,109	0,015	
CN2-SD ( $\gamma=0.7$ )	0,628	0,950	9,10	17,000	0,133 <sup>•</sup>	
Etiquetas Elite						
MESDIF	3	<b>0,083</b>	0,338	<b>18,00</b>	<b>1,515</b>	0,005
	4	0,072	0,365	24,00	1,323	0,005
	5	0,066	0,402	29,96	1,303	0,005
	10	0,045	<b>0,465</b>	59,84	1,137	<b>0,006</b>
	3	<b>0,118</b>	0,389	<b>18,00</b>	<b>1,644</b>	<b>0,005</b>
	4	0,102	0,444	24,00	1,420	0,005
	5	0,091	0,484	30,00	1,360	0,004
	10	0,071	<b>0,578</b>	59,50	1,227	0,003
	3	<b>0,132</b>	0,557	<b>18,00</b>	<b>1,821</b>	<b>0,006</b> <sup>+</sup>
	4	0,117	0,571	23,98	1,797	0,006
	5	0,107	0,594	29,90	1,647	0,005
	10	0,088	<b>0,611</b>	57,66	1,425	0,003
Etiquetas Elite						
MESDIF DNF	3	<b>0,154</b>	<b>0,509</b>	<b>15,78</b>	<b>3,573</b>	0,016
	4	0,129	0,498	19,22	3,555	0,017 <sup>*</sup>
	5	0,115	0,495	22,48	3,184	<b>0,017</b>
	10	0,083	0,474	31,28	2,630	0,015
	3	<b>0,164</b>	0,600	<b>17,26</b>	3,063	0,015
	4	0,148	<b>0,613</b>	21,64	<b>3,289</b>	<b>0,016</b>
	5	0,119	0,584	25,44	2,820	0,013
	10	0,081	0,480	37,16	2,425	0,011
	3	<b>0,182</b>	0,634	<b>17,26</b>	<b>3,204</b>	0,012
	4	0,163	<b>0,643</b>	22,32	3,059	<b>0,013</b>
	5	0,155	0,630	26,32	2,856	0,011
	10	0,152	0,594	39,72	2,398	0,010

Para el conjunto de datos Glass, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA.

Tabla 3.17. Comparación de algoritmos de descubrimiento de subgrupos para Wine

Algoritmo	COB	SOP	TAM	REL	WRACC	
SDIGA 5et CfMin 0.9	0,088	0,677	5,12	3,486	0,058	
SDIGA DNF 5et CfMin 0.9	0,084	0,697	5,08	3,299	0,056	
CN2-SD ( $\gamma=0.7$ )	1,022	0,990	1,40	25,700	0,167 •	
Etiquetas Elite						
MESDIF	3	<b>0,071</b>	0,451	<b>9,00</b>	<b>2,446</b>	<b>0,042</b>
	4	0,062	0,453	12,00	2,120	0,037
	5	0,060	0,464	14,98	2,044	0,035
	10	0,050	<b>0,481</b>	29,78	1,683	0,030
	3	<b>0,146</b>	0,580	<b>9,00</b>	<b>2,715</b>	<b>0,035</b> +
	4	0,121	0,599	12,00	2,497	0,033
	5	0,116	0,624	14,92	2,596	0,033
	10	0,093	<b>0,721</b>	28,26	2,283	0,031
	3	<b>0,095</b>	0,462	<b>9,00</b>	2,356	0,033
	4	0,089	0,555	11,96	<b>2,425</b>	<b>0,033</b>
	5	0,085	0,600	14,48	2,389	0,031
	10	0,091	<b>0,794</b>	21,90	2,420	0,032
Etiquetas Eilte						
MESDIF DNF	3	<b>0,162</b>	<b>0,720</b>	<b>8,26</b>	<b>4,222</b>	<b>0,075</b> *
	4	0,145	0,687	10,26	3,878	0,068
	5	0,134	0,700	11,88	3,883	0,068
	10	0,108	0,666	15,90	3,431	0,060
	3	<b>0,197</b>	0,706	<b>8,88</b>	3,656	<b>0,064</b>
	4	0,181	<b>0,716</b>	11,46	<b>3,736</b>	0,062
	5	0,163	0,713	13,88	3,661	0,063
	10	0,129	0,699	20,30	3,164	0,055
	3	<b>0,195</b>	0,629	<b>8,92</b>	2,586	0,045
	4	0,175	<b>0,658</b>	11,60	2,666	<b>0,047</b>
	5	0,162	0,656	14,00	<b>2,769</b>	0,044
	10	0,123	0,643	22,88	2,634	0,044

Para el conjunto de datos Wine, los mejores resultados los obtiene CN2-SD, y el algoritmo multiobjetivo MESDIF mejora los resultados del algoritmo mono-objetivo SDIGA.

### 3.2.3 Conclusiones

En general, el algoritmo multiobjetivo MESDIF de extracción de reglas difusas de descripción de subgrupos mejora los resultados del algoritmo mono-objetivo SDIGA. No supera a los resultados del algoritmo CN2-SD, pero se acerca a los resultados obtenidos por éste.

## 3.4 Aplicaciones

---

A continuación se detalla la experimentación y resultados obtenidos de la aplicación de esta propuesta sobre los dos problemas reales utilizados también para el algoritmo mono-objetivo SDIGA. El primero contiene datos de marketing y el segundo datos de e-learning. El objetivo en el primer problema es extraer información que permita mejorar la eficiencia de los expositores en futuras muestras, mientras que en el segundo es tratar de extraer conocimiento para mejorar los resultados académicos de los usuarios del sistema de e-learning Moodle.

### 3.4.1 Extracción de conocimiento en certámenes feriales

Tal como se describió el problema en la Sección 2.4.1, el objetivo es la extracción automática de información sobre variables relevantes que permitan obtener datos desconocidos, que determinen en parte la eficiencia de los stands de un certamen ferial.

#### 3.4.1.1 Resultados de la experimentación sobre el dataset de marketing

Para analizar el comportamiento de la propuesta multiobjetivo MESDIF sobre el problema de marketing planteado, se ha realizado en primer lugar una comparación con el algoritmo evolutivo de inducción de reglas de descripción de subgrupos SDIGA descrito en el Capítulo 2 de esta memoria.

La experimentación, para ambos algoritmos, se ha realizado con 5 ejecuciones para cada una de las 3 clases del atributo objetivo (*eficacia baja, media y alta*), y con los siguientes parámetros comunes:

- Tamaño de la población: 100
- Número de evaluaciones: 10.000
- Probabilidad de cruce: 0,6
- Probabilidad de mutación: 0,01
- Etiquetas lingüísticas para las variables continuas: 3

Además, en el caso del algoritmo multiobjetivo MESDIF, el tamaño de la población elite es 25. El algoritmo SDIGA necesita un valor de confianza mínima bajo el cual no van a evolucionar reglas, que en esta experimentación se ha fijado al valor 0,6. En el AG multiobjetivo, la solución final estará formada por todas las soluciones del conjunto de soluciones no dominadas que superen el mismo umbral de confianza.

En las siguientes tablas (Tabla 3.18, Tabla 3.19 y Tabla 3.20) se muestran los mejores resultados obtenidos con ambos algoritmos para todas las clases de la variable objetivo (*eficacia baja, media y alta*). En ellas se muestran el número de variables que intervienen

en cada regla (columna etiquetada como  $N_V$ ) y los valores para cada uno de los objetivos considerados (*Comp.* para la completitud (2.8), *Conf.* para la confianza (2.9), *Int.* para el interés (2.10) y *S.O.* para el soporte original).

Tabla 3.18. Resultados para eficacia Baja.

MESDIF				SDIGA		
$N_V$	Comp	Conf	S.O.	$N_V$	Comp	Conf
9	5,26	100,00	0,05	3	5,26	100,00
11	15,79	66,67	0,18	4	2,63	100,00
7	42,10	61,54	0,60	5	2,63	100,00
6	44,74	64,92	0,85			
11	21,05	100,00	0,24			
10	18,42	87,50	0,42			
8	5,26	76,92	0,05			
9	36,84	73,68	0,49			
11	34,21	87,16	0,41			
7	23,68	60,00	0,52			

Tabla 3.19. Resultados para eficacia Media.

MESDIF				SDIGA		
$N_V$	Comp	Conf	S.O.	$N_V$	Comp	Conf
1	95,27	65,58	6,78	4	0,68	100,00
5	1,35	100,00	0,07	7	2,70	66,67
2	79,05	68,02	5,27	2	2,03	100,00
3	5,40	72,73	0,33	4	4,05	100,00
3	40,54	77,92	2,26	3	3,38	100,00
3	20,27	68,18	1,46	5	8,11	100,00
5	32,43	87,27	1,60	2	45,95	69,39
2	87,16	67,55	5,92			
4	64,86	71,57	3,81			
2	93,92	65,57	6,58			
3	54,73	72,73	2,98			
3	82,43	67,78	5,39			
3	35,81	82,81	1,89			
5	11,49	100,00	0,60			
2	90,54	66,34	6,35			
3	71,62	70,54	4,46			
1	98,65	64,89	7,08			
1	61,49	68,94	3,48			
5	44,59	72,53	2,07			
3	86,49	64,97	5,89			
4	23,65	83,33	0,97			
3	76,35	68,27	4,85			
4	36,49	80,60	1,91			
3	52,70	73,77	2,70			
4	50,00	73,27	2,38			

Tabla 3.20. Resultados para eficacia Alta.

MESDIF				SDIGA		
<i>N<sub>r</sub></i>	<i>Comp</i>	<i>Conf</i>	<i>S.O.</i>	<i>N<sub>r</sub></i>	<i>Comp</i>	<i>Conf</i>
5	2,38	100,00	0,08	4	7,14	75,00
9	28,57	93,75	0,37			
7	50,00	69,93	0,73			
9	23,81	71,43	0,34			
11	19,05	100,00	0,22			
11	9,52	76,92	0,11			
7	26,19	71,43	0,55			
6	57,14	61,24	0,91			

Como se puede observar MESDIF permite obtener conjuntos de reglas con mayor cardinalidad (mayor número de reglas) que el algoritmo SDIGA. Estas reglas, con valores adecuados de confianza, completitud e interés, describen más información sobre los tres subgrupos (*eficacia baja, media y alta*). Esto es debido a que el enfoque multiobjetivo nos permite obtener un conjunto de soluciones adecuadas según los distintos objetivos.

En MESDIF la diversidad a nivel fenotípico en la población durante el proceso evolutivo (y por tanto en la solución final) se potencia a través de dos vías:

- a) Mediante la inclusión de un nuevo objetivo que considera la aportación original (en cuanto a ejemplos cubiertos) de una regla. Esto permite obtener conjuntos de reglas con mayor soporte e incrementa las posibilidades de obtener un conjunto de reglas que describan información sobre todos los ejemplos, y no solo sobre la mayoría.
- b) Mediante un esquema de nichos implementado en el operador de truncado, que, en caso de tener que reducir la población elite, elimina reglas con valores similares para los distintos objetivos.

En el algoritmo SDIGA la obtención de un conjunto de reglas con suficiente diversidad se potencia mediante la inclusión del AG en un esquema iterativo que continúa mientras las reglas obtenidas describan información sobre nuevos ejemplos (nichos secuenciales a nivel fenotípico), pero la experimentación muestra que para este problema, son mejores los resultados obtenidos por el AG multiobjetivo.

MESDIF elimina la compensación entre medidas de calidad y permite obtener conjuntos de reglas con un nivel elevado de confianza, completitud e interés. Es especialmente significativo el alto nivel de completitud obtenido en las distintas reglas con el AG multiobjetivo, incluso para las clases *eficacia alta y baja*, difíciles de describir en este problema.

En este aspecto, los resultados muestran que con el algoritmo SDIGA, se obtienen en ocasiones reglas con un mayor grado de confianza, especialmente para las clases *eficacia baja y media* (Tabla 3.18 y Tabla 3.19). No obstante, en SDIGA los altos valores en el

objetivo relativo a la confianza sesgan la búsqueda y convierten la completitud en un objetivo difícil de alcanzar para las clases *eficacia baja* y *alta*.

Ambas propuestas permiten obtener conjuntos de reglas descriptivas por el uso de etiquetas lingüísticas para las variables continuas y por el bajo número de variables implicadas (por debajo del 10% de las 104 variables). En este aspecto hay que destacar que las reglas obtenidas por el algoritmo SDIGA son más sencillas que las generadas por la propuesta multiobjetivo. La aplicación en SDIGA de un algoritmo de ascensión de colinas que optimiza cada una de las reglas obtenidas permite aumentar la simplicidad de las mismas.

En segundo lugar, se ha realizado otra experimentación seleccionando un tamaño de población elite pequeño para dirigir la evolución hacia un conjunto Pareto limitado, con el objetivo de obtener un conjunto de reglas pequeño. Para ello, se han utilizado los siguientes parámetros:

- Tamaño de la población: 100.
- Tamaño de la población elite: 5.
- Número máximo de evaluaciones de individuos en cada ejecución del AG: 10.000.
- Probabilidad de cruce: 0,7.
- Probabilidad de mutación: 0,01.
- Número de etiquetas lingüísticas para las variables continuas: 3

La Tabla 3.21 muestra los mejores resultados obtenidos para todas las clases de la variable objetivo (*baja*, *media* y *alta* eficiencia). En esta tabla, para cada una de las reglas obtenidas se muestra:

- el número de variables que participan en la regla (*# Var*),
- la *Completitud* (*Comp*) tal como se define en (2.8) y se utiliza en nuestra propuesta,
- la *Confianza* (*Conf*) de cada regla como está definida en (2.9),
- la *Cobertura* (*Cob*) como se define en (1.1),
- el *Sopote* (*Sop*) como se define en (1.3),
- la *Relevancia* (*Rel*) tal como se define en (1.6), y
- la *Atipicidad* (*WRAcc*) de la regla como se calcula en (1.8).

Hay que resaltar que altos valores de completitud (*Comp<sub>c</sub>*, expresión (2.8)) significa que la regla cubre muchos de los ejemplos de la clase, y altos valores de confianza (*Conf*, expresión (2.9)) significa que la regla tiene pocos ejemplos negativos.

Tabla 3.21. Resultados para Baja, Media y Alta eficiencia

Eficiencia	# Var.	Comp	Conf	Cob	Sop	Rel	WRAcc
Baja	8	0.079	0.820	0.026	0.013	5.026	0.007
	4	0.026	1.000	0.004	0.004	3.584	0.001
	5	0.395	0.724	0.127	0.066	25.684	0.042
	6	0.289	0.759	0.088	0.048	19.672	0.031
Media	6	0.088	0.892	0.658	0.057	6.623	0.008
	1	0.959	0.657	0.947	0.623	0.605	0.004
	2	0.574	0.802	0.469	0.373	12.104	0.065
	2	0.845	0.676	0.811	0.548	3.447	0.017
	4	0.182	0.750	0.158	0.118	2.441	0.011
Alta	5	0.095	0.595	0.031	0.017	6.565	0.010
	3	0.024	1.000	0.004	0.004	3.383	0.001
	4	0.047	0.722	0.013	0.009	3.812	0.004

La experimentación muestra que:

- Las reglas generadas tienen valores adecuados de confianza (*Conf*, expresión (2.9)) y completitud (*Comp*, expresión (2.8)).
- El algoritmo induce conjuntos de reglas con una alta confianza (mayor que el valor de la confianza mínima).
- No obstante, el soporte de las reglas, excepto en algunos casos, es bajo. El problema de marketing utilizado es un problema real difícil en el que los algoritmos de inducción tienden a obtener “small disjunts” (reglas específicas que representan un pequeño número de ejemplos. Sin embargo, el problema de los “small disjunts” no es un problema determinante en los procesos de inducción para descubrimiento de subgrupos porque es suficiente con obtener relaciones parciales, como subgrupos con características interesantes, con una desviación significativa de la del resto del dataset.
- Los resultados muestran que las clases de eficiencia *Baja* y *Alta* son las más interesantes para la tarea de descubrimiento de subgrupos, pero también las más difíciles
- El conocimiento extraído para cada uno de los valores de la variable objetivo es comprensible por los usuarios debido a la utilización de reglas DNF difusas, y al pequeño número de reglas y condiciones en los antecedentes de las reglas (menos del 10% de las 104 variables). Es más, las reglas obtenidas con el algoritmo *MESDIF* son muy sencillas.

Las siguientes tablas (Tabla 3.22, Tabla 3.23 y Tabla 3.24) muestran las reglas extraídas para los tres niveles de eficiencia (*baja media y alta*), y cuyas medidas de calidad se muestran en la Tabla 3.21.

Tabla 3.22. Reglas para eficiencia Baja.

Nº	Regla
1	IF (Publicity utility = None OR Medium OR High) AND (Number of annual fairs = 2-5 OR 6-10 OR 11-15 OR >15) AND (Use of consultants = NO) AND (Importance improvement image of the company = None OR Low OR Medium) AND (Addressees if only clients = NO) AND (Stand size = Medium OR High) AND (Valuation assembly/disassembly = Low OR Medium) AND (Indicator flags = NO) THEN Efficiency = Low
2	IF (Stand size = Medium OR High) AND (Telemarketing = ALL OR Only quality) AND (Gifts = NO) AND (Indicator flags = NO) THEN Efficiency = Low
3	IF (Use of consultants = NO) AND (Importance improvement image of the company = None OR Low OR Medium) AND (Stand size = Medium OR High) AND (Valuation assembly/disassembly = Low OR Medium) AND (Indicator flags = NO) THEN Efficiency = Low
4	IF (Publicity utility = None OR Low OR High) AND (Importance improvement image of the company = None OR Low OR Medium) AND (Addressees if only clients = NO) AND Stand size = Medium OR High) AND (Valuation assembly/disassembly = Low OR Medium) AND (Indicator flags = NO) THEN Efficiency = Low

Tabla 3.23. Reglas para eficiencia Media.

Nº	Regla
1	IF (Satisfaction relation clients = None OR High) AND (Importance public relations = Very high) AND (Global satisfaction = Medium OR High OR Very high) AND (Quality visitors valuation = Low OR High) AND (Gifts = NO) AND (Inserts = NO) THEN Efficiency = Medium
2	IF (Previous promotion = YES) THEN Efficiency = Medium
3	IF (Satisfaction relation clients = None OR High) AND (Global satisfaction = Medium OR High OR Very high) THEN Efficiency = Medium
4	IF (Global satisfaction = Medium OR High OR Very high) AND (Inserts = NO) THEN Efficiency = Medium
5	IF (Satisfaction relation clients = None OR High) AND (Previous promotion = YES) AND (Company advertising mention = YES) AND (Inserts = NO) THEN Efficiency = Medium

Tabla 3.24. Reglas para eficiencia Alta.

Nº	Regla
1	IF (Importance new contacts = Low OR Medium OR Very High) AND (Visitor information valuation = Medium OR High) AND (Gratefulness letter = All OR Only quality) AND (Telemarketing = None OR Only quality) AND (Little gifts before fair = YES) THEN Efficiency = High
2	IF (Employees = 251-500 OR >500) AND (Follow-up modality = Only quality) AND (Telemarketing = NO OR Only quality) THEN Efficiency = High
3	IF (Employees =251-500 OR >500) AND (Visitor information valuation = Medium OR High) AND (Gratefulness letter = All OR Only quality) AND (Telemarketing = NO OR Only quality) THEN Efficiency = High

Como ya se ha indicado, el dataset utilizado en esta experimentación contiene variables continuas y categóricas. Las variables continuas (como *Tamaño del Stand*) se consideran variables lingüísticas que utilizan etiquetas lingüísticas definidas mediante particiones uniformes con funciones de pertenencia triangulares. Las variables categóricas (como *Número de ferias anuales*) pueden tomar los valores previamente definidos y discretizados en el cuestionario por los expertos.

### 3.4.1.2 Conclusiones

Los expertos en marketing del Departamento de Organización y Marketing de la Universidad de Mondragón analizaron los resultados obtenidos, indicando que:

- Los expositores que obtuvieron peores resultados eran aquellos con stands de tamaño medio o grande, que no usaban banderas señalizadas y con una valoración baja o media de los servicios de montaje y desmontaje.
- Las compañías con resultados medios fueron aquellas cuya satisfacción con la relación mantenida con los clientes era alta o ninguna, y con una satisfacción global media, alta o muy alta.
- Por último, los expositores con mejores resultados (alta eficiencia) eran compañías grandes o muy grandes que utilizan telemarketing con los contactos de calidad.

Como conclusiones podemos destacar que el uso de un algoritmo de descubrimiento de subgrupos para este problema es adecuado porque es la tarea de escurrimiento de subgrupos que objetivo no es generar un conjunto de reglas que cubran todos los ejemplos del dataset, sino reglas individuales que, dada una propiedad de interés de los datos, describan de forma interpretable los subgrupos más interesantes para el usuario.

A pesar de las características de problema (elevado número de variables y valores perdidos, pequeño número de ejemplos y pocas variables continuas) este enfoque multiobjetivo al problema permite obtener conjuntos de reglas, con un balance adecuado entre las medidas de calidad especificadas en el algoritmo, que son fácilmente interpretable es, y que tienen niveles altos de confianza y completitud.

Las reglas difusas DNF aportan una estructura más flexible a las reglas, permitiendo que cada variable tome más de un valor, y facilitando la extracción de reglas más generales. En este tipo de reglas difusas, la lógica difusa mejora la interoperabilidad de las reglas extraídas debido al uso de una representación del conocimiento más cercana al experto, permitiendo además la utilización de variables continuas sin necesidad de realizar una discretización previa.

La inclusión en el algoritmo multiobjetivo de un objetivo (el soporte original) que es una restricción, nos permite obtener reglas con valores altos en los otros objetivos (confianza y soporte), describiendo además información sobre ejemplos de los que las otras reglas no habían obtenido información. Esto permite la inclusión de un nivel original de promoción de la diversidad en el algoritmo multiobjetivo.

### 3.4.2 Extracción de conocimiento en datos de la plataforma Moodle sobre asignaturas de la Universidad de Córdoba

Para la realización de las pruebas se han utilizado cuatro algoritmos distintos: los algoritmos clásicos Apriori-SD y CN2-SD y los algoritmos evolutivos SDIGA y MESDIF. Se han realizado varias ejecuciones de los diferentes algoritmos para obtener los valores medios de las medidas de evaluación de la calidad de las reglas.

En los dos algoritmos clásicos se han realizado 5 ejecuciones distintas variando uno de sus parámetros. En el caso del Apriori-SD se ha variado el soporte mínimo (0.03, 0.1, 0.2, 0.3, y 0.4) para diferentes valores de confianza mínima (0.6, 0.7, 0.8, 0.9). En el caso del CN2-SD se ha variado el tamaño de la estrella (1, 2, 3, 4, 5) para diferentes valores del parámetro  $\gamma$  (0.9, 0.7, 0.5 y aditivo).

En los algoritmos evolutivos se han realizado 5 ejecuciones para cada una de las 4 clases del atributo objetivo nota (sobresaliente, notable, aprobado y suspenso) para diferentes valores de confianza mínima (0.6, 0.7, 0.8, 0.9). Además, para el algoritmo evolutivo multiobjetivo hemos utilizado una población elite de tamaño 5. Para ambos algoritmos los siguientes parámetros son comunes:

- Tamaño de población: 100.
- Número de evaluaciones: 10.000.
- Probabilidad de cruce: 0,6.
- Probabilidad de mutación: 0,01.
- Etiquetas lingüísticas para las variables continuas: 5 (muy alto, alto, medio, bajo y muy bajo).

En la Tabla 3.25 se muestran los resultados obtenidos en términos de valores promedio de: el número de reglas total descubierto, el número de atributos en el antecedente de las reglas y los valores para las medidas de soporte, cobertura, precisión y relevancia de las reglas.

Tabla 3.25. Resultados de los algoritmos.

Algoritmo	Número Reglas	Número Atributos	Soporte	Cobertura	Confianza	Relevancia
SDIGA CfMin 0,6	8,4	2,43	0,7260	0,2921	0,8284	20,2476
SDIGA CfMin 0,7	6,8	2,61	0,6253	0,1816	0,8732	21,8973
SDIGA CfMin 0,8	4,2	2,93	0,4137	0,1167	0,9573	19,6746
SDIGA CfMin 0,9	3,0	2,80	0,0226	0,0075	1,0000	5,6190
MESDIF CfMin 0,6	7,8	1,95	0,9288	0,3829	0,6755	8,7596
MESDIF CfMin 0,7	5,8	1,55	0,9219	0,5267	0,5769	11,1724
MESDIF CfMin 0,8	5,4	1,49	0,9493	0,5904	0,5162	12,9659
MESDIF CfMin 0,9	6,0	1,92	0,9164	0,4874	0,6111	10,8591
Apriori-SD CfMin 0,6	9,8	1,04	0,5924	0,6001	0,6157	27,3901
Apriori-SD CfMin 0,7	10,4	1,32	0,5513	0,6232	0,6301	31,4304
Apriori-SD CfMin 0,8	5,0	0,83	0,3734	0,1451	0,3842	21,2968
Apriori-SD CfMin 0,9	4,6	1,17	0,2089	0,1164	0,3787	21,0734
CN2-SD ( $\gamma=0.5$ )	15,6	5,64	0,9342	0,4461	0,7143	45,8554
CN2-SD ( $\gamma=0.7$ )	18,4	5,69	0,9876	0,4600	0,7177	47,0058
CN2-SD ( $\gamma=0.9$ )	25,2	5,72	0,9890	0,4703	0,7184	47,2862
CN2-SD (add)	31,5	5,77	1,0000	0,5038	0,7129	54,7134

Analizando el número de reglas y número de variables podemos realizar las siguientes observaciones:

- Los algoritmos evolutivos descubren un menor número de reglas y en cambio CN2-SD es el que mayor número de reglas descubre.
- Con respecto al número de atributos Apriori-SD y MESDIF son los que obtienen un menor número de atributos, nuevamente CN2-SD obtiene un mayor número de atributos.
- Desde el punto de vista de nuestro problema interesa tener una cantidad no muy elevada de reglas y con pocos atributos para facilitar la comprensibilidad de dichas reglas al profesor. Por lo tanto el algoritmo CN2-SD no es el más apropiado.

Con respecto a las medidas utilizadas se puede observar que:

- Para el soporte, es precisamente el algoritmo CN2-SD el que presenta mayores valores muy cercanos a 1, indicando que las reglas cumplen casi el 100 % de los estudiantes. Esto es debido a la naturaleza del propio algoritmo que añade muchos atributos en las reglas hasta poder cubrir a todas las instancias de datos. Valores de soporte altos muy cercanos al anterior muestra también el algoritmo multiobjetivo, con la ventaja de utilizar sólo la mitad de atributos en las reglas. Apriori-SD y SDIGA son los que presentan valores más bajos de soporte.
- La medida de cobertura es al igual que el soporte una medida de la generalidad de la regla, midiendo en este caso el número de alumnos que cumplen el antecedente de la regla. En este caso, es el algoritmo Apriori-SD el que presenta los valores más altos, muy seguido del algoritmo MESDIF y CN2-SD, y por último SDIGA.
- La medida confianza o exactitud de la regla, indica el número de estudiantes cubiertos por el antecedente de la regla y que corresponde a la clase asociada a la

misma (en términos de clasificación hablaríamos de correctamente clasificados por la regla). El algoritmo que presenta unos valores más altos muy cercanos al 100% es SDIGA, seguido de CN2-SD, MESDIF y Apriori-SD.

- La medida de relevancia es una medida cuantitativa de la relevancia y del interés de la regla. El algoritmo CN2-SD es el que presenta valores de relevancia más altos, seguidos del algoritmo Apriori-SD, después SDIGA y por último el multiobjetivo MESDIF. Esto se debe a que los algoritmos evolutivos aquí presentados no utilizan la relevancia como medida de calidad durante el proceso de minería de datos.

Con respecto a los valores de estas cuatro medidas, el mejor algoritmo sería aquel que presentara los valores más altos en todas ellas. Como se ha podido comprobar no hay un único algoritmo que presente los valores más altos simultáneamente en las cuatro medidas utilizadas, por lo que no se puede elegir un mejor algoritmo.

Con respecto a la comprensibilidad de las reglas para su utilización directa en la toma de decisiones del profesor del curso, los algoritmos evolutivos presentan las reglas con una mayor interpretabilidad debido a que utilizan el formato para los atributos de ETIQUETA = VALOR, donde el valor en lugar de números, son etiquetas lingüísticas proporcionadas por el experto de más fácil interpretación para el profesor. El algoritmo Apriori-SD, utiliza también el mismo formato de regla pero los valores en lugar de etiquetas son valores numéricos, por lo que son algo menos interpretables. Por otro lado, el algoritmo CN2-SD utiliza valores numéricos y los operadores igual, mayor que, menor que y distinto, de forma que las reglas obtenidas son las más difíciles de interpretar.

A continuación se van a mostrar algunos ejemplos de reglas descubiertas con los algoritmos evolutivos y se va a analizar su significado aplicado para una posible mejora del curso.

*SI course = 110 Y n\_assignment = Alto Y n\_posts = Alto  
ENTONCES nota = Notable  
Soporte: 0.70454544 Confianza: 0.7230769*

Para el curso 110, los alumnos que han realizado muchos trabajos y han enviado muchos mensajes al foro han obtenido una nota alta. El profesor de este curso debe seguir fomentando este tipo de actividades ya que ha podido comprobar su efectividad en la nota final obtenidas por los alumnos que las realizan.

*SI course = 88 Y n\_messages = Muy Alto  
ENTONCES nota = Suspenso  
Soporte: 0.19298245 Confianza: 0.9444444*

Para el curso 88, los alumnos que han enviado muchos mensajes al chat, luego han suspendido. El profesor de este curso puede eliminar el chat debido a que no ha aportado beneficio a los alumnos, al contrario ha podido ser una fuente de distracción.

*SI n\_read = Muy Bajo  
ENTONCES nota = Suspenso  
Soporte: 0.73240235 Confianza: 0.6103379*

Para cualquier curso si el número de mensajes leídos del foro es muy bajo entonces la nota final obtenida es de suspenso. El profesor a partir de esta información puede prestar más atención a estos alumnos, ya que van a tender a suspender y podría intentar motivarlos todavía a tiempo para poder aprobar la asignatura.

*SI n\_read = Alto Y n\_messages\_ap = Muy Bajo  
ENTONCES nota = Suspenso  
Soporte: 0.11759777 Confianza: 0.7500000*

Para cualquier curso si el número de mensajes leídos del foro es alto pero el número de mensajes enviados al profesor es bajo, entonces la nota obtenida es de suspenso. Esta regla puede parecer que contradice a la regla anterior, pero aporta información sobre otro grupo de alumnos distinto menos numeroso y que también tiende a suspender.

Al igual que antes el profesor puede prestar más atención a estos alumnos e intentar motivarlos a tiempo para poder aprobar.

Finalmente, hay que indicar que también se han encontrado reglas que o bien no aportan ninguna información nueva o bien daban información obvia para el profesor. Por ejemplo, la regla

*SI n\_quiz\_a = Muy baja  
ENTONCES nota = Suspenso  
Soporte: 0.93296087 Confianza: 0.72661173*

indica que si el número de cuestionarios aprobados es muy bajo entonces la nota final obtenida es suspenso. Para el profesor esto es totalmente lógico (el que aprueba los cuestionarios en línea luego aprueba el examen en papel) y no le aporta nada nuevo de cómo mejorar el curso.

### 3.5 Conclusiones

---

En este capítulo, hemos introducido un modelo evolutivo multiobjetivo para la extracción de reglas difusas de descripción de subgrupos. El modelo se basa en el algoritmo SPEA2 y obtiene como solución un conjunto de reglas.

Este modelo aporta distintas ventajas sobre el modelo mono-objetivo, como son:

- Al fijar el tamaño del conjunto elite, podemos limitar la cantidad de soluciones que se obtendrán en cada ejecución, es decir, el número de reglas.
- La eliminación de la necesidad de indicar los pesos asociados a cada uno de los objetivos (como ocurría en el modelo mono-objetivo) permite que el modelo sea menos sensible al tipo de problema al que se aplica.

Los resultados obtenidos por el algoritmo multiobjetivo MESDIF mejoran los obtenidos por el algoritmo mono-objetivo SDIGA.

Por último, el modelo se ha aplicado a la extracción de conocimiento en dos problemas reales, uno con datos de marketing y otro con datos de e-learning, cuyos resultados han sido útiles a los expertos para obtener nuevo conocimiento de los datos disponibles.



# Capítulo 4

## Conclusiones

---

En este capítulo, se resumen brevemente los resultados obtenidos y se destacan las conclusiones principales obtenidas en esta memoria. Se presentan también las publicaciones asociadas a esta memoria y se comentan algunos aspectos relacionados con los trabajos futuros que siguen la línea aquí desarrollada y sobre otras líneas de investigación que se pueden derivar.

### 4.1 Resultados obtenidos

---

Hemos estudiado el problema de la extracción de conocimiento bajo el enfoque descriptivo, en particular el problema de la extracción de reglas de descripción de subgrupos. Una vez analizado el problema y determinados los aspectos a resolver en el mismo, hemos estudiado la aplicación de AGs y lógica difusa al mismo.

Como consecuencia de esto, en esta memoria hemos presentado distintos algoritmos evolutivos para la extracción de reglas difusas de descripción de subgrupos, capaces de manejar tanto variables categóricas como numéricas, y permitiendo la representación del conocimiento extraído mediante dos tipos de reglas, canónicas y DNF.

Los siguientes apartados resumen brevemente los resultados obtenidos, presentando algunas conclusiones sobre los mismos.

#### 4.1.1 Algoritmo evolutivo de extracción de reglas difusas de descripción de subgrupos

Hemos propuesto un modelo evolutivo para la extracción de reglas difusas y/o nítidas de descripción de subgrupos, SDIGA [DGHM07], que se refleja en el Capítulo 2 de esta memoria.

Este modelo evolutivo sigue el enfoque IRL para la codificación de reglas difusas o nítidas con dos tipos de estructuras (canónica y DNF). El algoritmo evolutivo obtiene una única regla en cada ejecución perteneciente a una clase predeterminada de la variable

objetivo. El proceso iterativo permite la extracción de conjuntos de reglas distintas pertenecientes a la misma clase de la variable objetivo, gracias a la penalización de los ejemplos cubiertos por las reglas previamente obtenidas. Aseguramos la extracción de reglas pertenecientes a todas las clases de la variable objetivo ejecutando el algoritmo para cada uno de sus valores.

Se ha llevado a cabo además un estudio sobre la granularidad y sobre la influencia del uso de reglas canónicas y DNF. Se ha determinado que en gran parte de los problemas no existen diferencias significativas entre la aplicación un tipo u otro de regla, siendo finalmente el experto que vaya a interpretar y usar las reglas quien decida el tipo de reglas que más le interesa.

Para determinar la validez de nuestra propuesta de algoritmo de descubrimiento de subgrupos se ha realizado una experimentación para comparar sus resultados con los de otros algoritmos clásicos de descubrimiento de subgrupos como CN2-SD y APRIORI-SD, y otros algoritmos como CN2 y CN2-Wracc. De los resultados de la comparativa se puede concluir que la propuesta nos permite obtener reglas de descubrimiento de subgrupos:

- altamente descriptivas, debido a la utilización de la lógica difusa como herramienta de representación del conocimiento, permitiendo una representación cercana al razonamiento humano, y permitiendo la utilización posterior de este conocimiento para actuar sobre el dominio;
- de tipo canónico o DNF en función del criterio del experto;
- nítidas o difusas, en función del tipo de variables del problema;
- muy generales y representativas del conocimiento de los ejemplos de los distintos valores de la variable objetivo;
- altamente compactas;
- que describen conocimiento sobre los distintos ejemplos del problema debido a la inclusión de un mecanismo de penalización de ejemplos ya cubiertos;
- solapadas en ocasiones, permitiendo describir el conocimiento desde distintos puntos de vista;
- que permite además la obtención de reglas que cubran pocos ejemplos, denominadas “*small disjuncts*” [HAP89, WH00], algo muy frecuente en problemas reales, para describir conocimiento específico pero interesante para el usuario. Los *small disjuncts* son disyunciones que sólo cubren unos pocos ejemplos de entrenamiento, y que tienen una tasa de error mucho mayor que la de otras disyunciones. Esto hace interesantes a los *small disjuncts* puesto que suelen tener un gran impacto sobre la precisión obtenida por el modelo.

Además, se ha aplicado la propuesta a dos problemas reales. El primero es un problema de *marketing* en el que el objetivo es, a partir de los datos obtenidos en una feria de muestras,

extraer información que permita a los participantes mejorar la eficiencia de sus *stands* en futuras muestras, donde la eficiencia se define como el grado de consecución de los objetivos marcados para el certamen. El segundo es un problema sobre datos de *e-learning* en el que, a partir de los datos disponibles sobre la utilización del sistema Moodle de *e-learning* por parte de los alumnos, se intenta extraer conocimiento que permita mejorar los resultados académicos de los usuarios del sistema. La aplicación del modelo propuesto a estos dos problemas ha permitido la extracción de conocimiento novedoso y de utilidad para los expertos en los dominios de los problemas.

#### **4.1.2 Algoritmo evolutivo multiobjetivo para la extracción de reglas difusas de descripción de subgrupos**

En el Capítulo 3 de esta memoria se recoge la propuesta desarrollada de algoritmo evolutivo multiobjetivo de extracción de reglas difusas para descripción de subgrupos, MESDIF [BDG+06], que permite generar reglas tanto en formato canónico como DNF. El AG multiobjetivo está basado en el enfoque del algoritmo SPEA2 [ZLT02], aplicando los conceptos de elitismo en la selección de reglas (utilizando una población secundaria o élite) y búsqueda de soluciones óptimas en el frente de Pareto. Utiliza una técnica de nichos que considera la proximidad en valores de los objetivos para preservar la diversidad a nivel fenotípico, y un objetivo original basado en la novedad para promover reglas que aporten información sobre ejemplos no descritos por otras reglas de la población.

El AG multiobjetivo elimina la compensación entre medidas de calidad, permite obtener conjuntos de reglas con valores elevados de las medidas de calidad utilizadas, y hace que el modelo sea menos sensible al tipo de problema al que se aplica. Además, al poder fijar el tamaño del conjunto elite, podemos limitar la cantidad de soluciones que se obtendrán en cada ejecución, es decir, el número de reglas.

Para comparar los resultados de esta propuesta respecto a la propuesta del algoritmo mono-objetivo, se ha desarrollado una experimentación que permite extraer las siguientes conclusiones:

- MESDIF elimina la compensación entre medidas de calidad y permite obtener conjuntos de reglas con un nivel elevado de confianza, completitud e interés.
- Ambas propuestas permiten obtener conjuntos de reglas descriptivas por el uso de etiquetas lingüísticas para las variables continuas y por el bajo número de variables implicadas.
- Las reglas obtenidas por el algoritmo SDIGA son más sencillas que las generadas por MESDIF, debido a que la aplicación en SDIGA de un algoritmo de ascensión de colinas que optimiza cada una de las reglas obtenidas permite aumentar la simplicidad de las mismas.

- La inclusión en MESDIF de un objetivo (el soporte original) que es una restricción, nos permite obtener reglas con valores altos en los otros objetivos (confianza y completitud), describiendo además información sobre ejemplos de los que las otras reglas no habían obtenido información. Esto permite la inclusión de un nivel adicional de promoción de la diversidad en el algoritmo multiobjetivo MESDIF.

Por último, se ha aplicado la propuesta a los problemas reales de extracción de información en datos de marketing y sobre datos de utilización del sistema de e-learning Moodle, en los que se ha podido extraer conocimiento novedoso y de utilidad para los expertos en el dominio del problema. En estos casos, el algoritmo multiobjetivo MESDIF aporta con respecto a SDIGA las ventajas de poder controlar la cantidad de reglas que queremos obtener (fijando el tamaño del conjunto elite), y ser menos sensible al tipo de problema al eliminar la necesidad de indicar los pesos asociados a cada objetivo.

## 4.2 Publicaciones asociadas al trabajo desarrollado en esta memoria

---

A continuación se presenta un listado de las publicaciones asociadas a esta memoria.

- Revistas internacionales:
  - M.J. del Jesus, P. González, F. Herrera, M. Mesonero (2007). *Evolutionary fuzzy rule induction process for subgroup discovery: a case study in marketing*. IEEE Transactions on Fuzzy Systems 15:4, 578-592.
- Capítulos de libro:
  - M.J. del Jesus, P. González, F. Herrera (2007). *Subgroup discovery with linguistic rules*. In: H. Bustince, F. Herrera, J. Montero (Eds.) Fuzzy sets and their extensions: representation, aggregation and models, Springer, 410-430.
  - M.J. del Jesus, P. González, F. Herrera, M. Mesonero (2005). *Evolutionary Induction of Descriptive Rules in a Market Problem*. In: D. Ruan, G. Chen, E.E. Kerre, G. Wets (Eds.) Intelligent Data Mining. Techniques and Applications, Studies in Computational Intelligence 5, Springer-Verlag, 267-292.
  - M.J. del Jesus, P. González, F. Herrera (2004). *Extracción de conocimiento con algoritmos evolutivos y reglas difusas*. En: J. Hernández, M.J. Ramírez y C. Ferri (Eds.) Introducción a la minería de datos, Pearson, 383-420.

- Publicaciones en congresos internacionales:
  - M.J. del Jesus, P. González, F. Herrera (2007). *Multiobjective genetic algorithm for extracting subgroup discovery fuzzy rules*. 2007 IEEE Symposium on Computational Intelligence in Multicriteria Decision Making (IEEE MCDM 2007). Omnipress. Honolulu (USA), 50-57.
  - F.J. Berlanga, M.J. del Jesus, P. González, F. Herrera, M. Mesonero (2006). *Multiobjective Evolutionary Induction of Subgroup Discovery Fuzzy Rules: A Case Study in Marketing*. 6th Industrial Conference on Data Mining (ICDM 2006). Lecture Notes in Computer Science 4065, Springer 2006, Leipzig (Germany), 337-349.
  - F.J. Berlanga, M.J. del Jesus, P. González, F. Herrera (2005). *Multiobjective evolutionary induction of subgroup discovery rules in a market problem*. 2nd International Conference on Machine Intelligence (ACIDCA-ICMI05). Tozeur (Tunisia), 610-617.
  - M.J. del Jesus, P. González, F. Herrera, M. Mesonero. *Evolutionary induction of descriptive fuzzy rules in a market problem*. I International Workshop on Genetic Fuzzy Systems (GFS'05). Granada (Spain), 57-63.
  
- Publicaciones en congresos nacionales
  - C. Romero, P. González, S. Ventura, M.J. del Jesus, F. Herrera (2007). *Aplicación de algoritmos evolutivos de descubrimiento de subgrupos en e-learning: un caso de estudio analizando cursos de Moodle*. V Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB07). Tenerife, 493-500.
  - M.J. del Jesus, P. González, F. Herrera (2005). *Inducción evolutiva multiobjetivo de reglas de descripción de subgrupos en un problema de marketing*. IV Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB'05). Granada, 661-669.
  - M.J. del Jesus, P. González, F. Herrera, M. Mesonero (2004). *Extracción de reglas DNF Difusas en un problema de Marketing*. XII Congreso Español de Tecnologías y lógica Difusa (ESTYLF'04). Jaén, 351-356.
  - M.J. del Jesus, P. González, F. Herrera, M. Mesonero. *Algoritmo Evolutivo de Extracción de Reglas de Asociación aplicado a un Problema de Marketing*. III Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB'04). Cordoba, 102-104.

### 4.3 Trabajos futuros

---

A continuación presentamos algunas líneas de trabajo que quedan abiertas relacionadas con los temas tratados en la memoria, además de las extensiones sobre las propuestas presentadas que serán objeto de estudios posteriores.

- Desarrollo de nuevas medidas de calidad adecuadas para el problema de descubrimiento de subgrupos. El descubrimiento de subgrupos es un problema a medio camino entre la inducción descriptiva y la predictiva, para el que no existe un consenso en las medidas a utilizar. En la bibliografía especializada se proponen muchas medidas, pero cualquier algoritmo de minería de datos debe considerar un conjunto limitado de medidas de calidad. De hecho se sabe, por ejemplo, que un enfoque multiobjetivo no funciona adecuadamente con más de 2 ó 3 objetivos. El desarrollo de nuevas medidas de calidad que reflejen de forma adecuada y compacta características de las existentes, sería muy relevante para el avance de la investigación en el área.
- Estudio de la inclusión de nuevas medidas de interés para la evaluación y selección de reglas. En la tarea de descubrimiento de subgrupos, un objetivo fundamental es la extracción de reglas interesantes para el usuario. La inclusión de medidas de interés objetivas para la evaluación y selección de reglas es un aspecto particularmente importante cuando se utilizan reglas difusas como forma de expresión del conocimiento extraído.
- Desarrollo de nuevos modelos multiobjetivo. En esta memoria, se ha presentado un modelo evolutivo multiobjetivo para la tarea de descubrimiento de subgrupos basado en el enfoque del algoritmo SPEA2. Existen otros enfoques modernos de algoritmos evolutivos multiobjetivo cuyas características también podrían adaptarse bien para la tarea de descubrimiento de subgrupos. Entre estos, cabe destacar los algoritmos *Pareto Archived Evolution Strategy (PAES)* [KC00] y *Non-dominated Sorting Genetic Algorithm II (NSGA II)* [DPAM02].
- Estudio de la influencia de la selección de características en problemas de alta dimensionalidad. Cuando nos enfrentamos a problemas en los que existen muchas variables, la aplicación de algoritmos de descubrimiento de subgrupos se hace computacionalmente muy costosa. La aplicación previa de mecanismos de selección de características podría aliviar este problema. Existen múltiples propuestas de algoritmos de selección de características para minería de datos

predictiva, pero sin embargo no se ha estudiado la influencia de este tipo de preprocesamiento en minería de datos descriptiva. Por eso, sería necesario realizar un estudio que determinase la influencia del mecanismo de selección de características en los resultados obtenidos por el algoritmo de descubrimiento de subgrupos.

- Extensión de las propuestas para la detección y descomposición de anomalías. Los datos anómalos, atípicos o extremos (*outliers*) son datos que se alejan estadísticamente del resto, pero no son datos erróneos. El objetivo sería detectar estos datos para obtener una descripción más completa del dominio.



# Apéndices

---

## Apéndice A. Descripción de los conjuntos de datos sintéticos del repositorio UCI utilizados en las experimentaciones

---

En la **Tabla A.1** se muestra un resumen de las propiedades de las bases de ejemplos utilizadas en las experimentaciones llevadas a cabo en esta memoria. Todas las bases de ejemplos están disponibles en el repositorio UCI<sup>2</sup> que contiene bases de ejemplos para aprendizaje automático [UCI94].

*Tabla A.1 Propiedades de los dataset del repositorio UCI utilizados en las experimentaciones*

Nombre	Variables	Variables discretas	Variables Continuas	Nº Clases	Nº Ejemplos
Australian	14	8	6	2	690
Breast-w	9	9	0	2	699
Bridges	7	4	3	2	102
Diabetes	8	0	8	2	768
Echo	6	1	5	2	131
German	20	13	7	2	1000
Heart	13	6	7	2	270
Hepatitis	19	13	6	2	155
Hypothyroid	25	18	7	2	3163
Ionosphere	34	0	34	2	351
Iris	4	0	4	3	150
Tic-tac-toe	9	9	0	2	958
Vote	16	16	0	2	435
Balance	4	0	4	3	625
Car	6	6	0	4	1728
Glass	9	0	9	6	214
Wine	13	0	13	3	178

A continuación se describen brevemente estas bases de ejemplos:

- *Australian*: denominado Australian Credit Approval está relacionado con datos de tarjetas de crédito. Esta base de ejemplos es interesante porque hay una Buena mezcla de atributos – continuos, nominales con pocos valores y nominales con

---

<sup>2</sup> [www.ics.uci.edu/~mllearn/MLRepository.html](http://www.ics.uci.edu/~mllearn/MLRepository.html)

muchos valores. Además tiene pocos valores perdidos. Contiene 690 ejemplos distribuidos en 14 atributos más el atributo de clase. 6 de los atributos son numéricos y 8 categóricos.

- *Breast-W*: este dominio de cáncer de mama fue obtenido por el Instituto de Oncología del Centro Médico Universitario de Ljubljana, Yugoslavia, y cuyos datos fueron aportados por M. Zwitter y M. Soklic. Este dataset tiene 699 ejemplos. Cada ejemplo tiene 9 variables categóricas, y una variable objetivo con 2 posibles clases: *Benign* o *Malignant*. Hay 458 ejemplos de la clase *Benign* (65.5%) y 241 de la clase *Malignant* (34.5%).
- *Bridges*: Esta base de ejemplos contiene datos sobre distintos tipos de puentes, como el propósito, la edad, los materiales o el número de carriles.
- *Diabetes* (Pima Indians Diabetes Database): este problema intenta realizar el diagnóstico de una variable binaria para deducir si un paciente muestra signos de diabetes de acuerdo con el criterio de la Organización Mundial de la Salud. Este dataset tiene 768 ejemplos, con 8 variables numéricas. La variable objetivo tiene 2 valores: “*tested negative*” y “*tested positive*” en diabetes. Hay 500 ejemplos de la clase *Tested negative* (65%) y 268 de la clase *Tested positive* (35%).
- *Echo*: Este conjunto contiene datos para clasificar si un paciente sobrevivirá al menos un año después de un ataque al corazón. Todos los pacientes de la base han sufrido en algún momento un ataque al corazón. Algunos siguen vivos y otros no.
- *German*: Base de ejemplos de créditos alemanes. Tiene 1000 ejemplos. Este conjunto se ha editado y se han añadido varias variables indicadoras para hacerlo más adecuado para algoritmos que no pueden manejar atributos categóricos. Consta de 20 variables (7 numéricas y 13 categóricas).
- *Heart*: Esta base de ejemplos contiene 13 variables (extraídas de un conjunto mayor de 75) de las cuales 6 son reales, 1 ordenado, 3 binarias y 3 nominales. La variable de clase es la presencia o ausencia de enfermedad coronaria. No contiene valores perdidos y consta de 270 ejemplos.
- *Hepatitis*: Base de ejemplos con datos sobre enfermos de hepatitis, muchas variables son patologías que pueden sufrir o no, y el atributo de clase es si el enfermo está vivo o ha fallecido.
- *Hypothyroid*: Esta base de ejemplos contiene distintos datos sobre enfermos de hipotiroidismo, y cuyo atributo de clase es si el individuo está enfermo o no.
- *Ionosphere*: Base de ejemplos de clasificación de retornos a los radares desde la ionosfera. Los datos se recolectaron mediante un sistema que consta de un array de 16 antenas de alta frecuencia. El objetivo eran electrones libres en la ionosfera.

Los retornos de tipo "Good" son los que muestran evidencias de algún tipo de estructura en la ionosfera.

- *Iris*: Esta es tal vez la más conocida base de ejemplos recogida en la bibliografía de reconocimiento de patrones. El conjunto de datos contiene 3 clases de 50 casos cada uno, donde cada clase se refiere a un tipo de planta del iris. Una clase es linealmente independiente de las otras dos, pero no así estas 2 entre sí. El atributo clase es el tipo de planta. Se trata de un dominio muy sencillo.
- *Tic-tac-toe*: Esta base de ejemplos contiene todas las posibles configuraciones de tablero del juego tic-tac-toe. Contiene 958 ejemplos, y todos los atributos pueden tomar 1 de 3 posibles valores. Codifica el conjunto completo de posibles configuraciones de tablero al final de una partida de tic-tac-toe.
- *Balance*: Base de ejemplos de escalas de balanzas de pesos y distancias. Este conjunto de datos se generó para modelar resultados de experimentos psicológicos. Cada ejemplo es clasificado como equilibrado, escorado a la izquierda o escorado a la derecha.
- *Glass*: Base de ejemplos procedente del servicio de ciencia forense de los Estados Unidos, que identifica 6 tipos de crystal, en función de su contenido de distintos minerales.
- *Wine*: Estos datos son los resultados de análisis químicos de vinos crecidos en una región de Italia, pero procedentes de tres cultivos diferentes. El análisis determinó las cantidades de 13 componentes encontrados en cada uno de de los tres tipos de vino. En el conjunto de datos inicial había unas 30 variables, pero solo está disponible la versión reducida de 13 variables.



## Apéndice B. Tablas de la experimentación sobre los distintos conjuntos de datos sintéticos del repositorio UCI

---

Este apéndice contiene las tablas correspondientes a las experimentaciones realizadas para los algoritmos SDIGA y MESDIF, reflejando las medias para las 5 ejecuciones de cada una de las bases de ejemplos. Para cada base de ejemplos, hay una tabla con los resultados de la experimentación para obtener reglas canónicas (no DNF) y reglas DNF.

Para el algoritmo SDIGA, las siguientes tablas muestran resultados para las medidas de calidad incluidas en la función fitness y para el resto de medidas de calidad consideradas en la bibliografía especializada. El contenido de las tablas es el siguiente:

- En la primera columna, se indican las medidas de calidad utilizadas en el algoritmo para la generación de reglas, que pueden ser:
  - Confianza difusa (FConf), Completitud (Comp) definida sobre los ejemplos de la clase, e Interés (Int).
  - Confianza difusa (FConf), Completitud difusa (FConf) e Interés (Int).
  - Confianza nítida (CConf), Completitud nítida (CComp) e Interés (Int).
- N° Et: Número de etiquetas utilizadas para las variables continuas.
- CNFMin: Valor umbral de confianza para la generación de reglas.
- NReg: Número medio de reglas obtenidas.
- NVar: Número medio de variables por regla.
- Cob: Cobertura.
- Rel: Relevancia.
- Atip: Atipicidad.
- Prec: Precisión
- Comp: Completitud, medida sobre el número de ejemplos de la clase.
- CComp: Completitud nítida.
- FComp: Completitud difusa.
- FConf: Confianza difusa.
- CConf: Confianza nítida
- Int: Interés de la regla (sólo para reglas canónicas).

En estas tablas, un asterisco (\*) indica los mejores resultados de cada combinación de medidas de calidad, y un signo más (+) indica los mejores resultados para cada valor del número de variables.

Tabla A.2 Resumen de la experimentación de SDIGA para Australian con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas fitness:	3	0.6	3,58	<b>4,21</b>	<b>0,196</b>	5,844	<b>0,052</b>	0,717	<b>0,619</b>	<b>0,456</b>	<b>0,164</b>	0,773	<b>0,714</b>	0,889	+	
		0.7	3,12	4,32	0,113	6,093	0,043	0,718	0,548	0,280	0,116	0,730	0,684	0,883		
		0.8	3,12	4,34	0,110	5,706	0,041	0,711	0,544	0,274	0,113	0,769	0,688	<b>0,892</b>		
		0.9	<b>3,06</b>	4,30	0,120	<b>6,098</b>	0,044	<b>0,723</b>	0,569	0,277	0,123	<b>0,778</b>	0,711	0,881		
	FConf, Comp e Interés	5	0.6	4,66	3,31	0,303	10,996	0,092	0,723	0,537	<b>0,777</b>	0,246	0,660	0,642	<b>0,862</b>	
			0.7	3,18	3,26	0,290	14,847	0,111	0,781	0,558	0,699	0,254	0,749	0,741	0,853	
			0.8	3,00	<b>3,23</b>	0,276	14,647	0,108	0,789	0,545	0,679	0,248	0,762	0,739	0,849	
			0.9	<b>2,64</b>	3,28	<b>0,310</b>	<b>16,348</b>	<b>0,120</b>	<b>0,803</b>	<b>0,591</b>	0,670	<b>0,274</b>	<b>0,793</b>	<b>0,771</b>	0,847	*
		7	0.6	4,22	3,34	0,344	10,437	0,100	0,705	0,568	<b>0,858</b>	0,270	0,618	0,599	0,871	
			0.7	3,30	<b>3,17</b>	0,348	12,725	0,115	0,732	0,603	0,805	0,285	0,659	0,656	<b>0,874</b>	
			0.8	2,90	3,29	0,366	<b>13,362</b>	<b>0,118</b>	<b>0,743</b>	0,631	0,770	0,298	<b>0,714</b>	<b>0,690</b>	0,865	
			0.9	<b>2,54</b>	3,29	<b>0,379</b>	12,516	0,116	0,734	<b>0,638</b>	0,707	<b>0,304</b>	0,662	0,648	0,862	+
Medidas fitness:	3	0.6	3,36	<b>3,34</b>	<b>0,346</b>	<b>15,354</b>	<b>0,126</b>	<b>0,761</b>	<b>0,610</b>	<b>0,833</b>	<b>0,297</b>	<b>0,719</b>	<b>0,705</b>	0,876	*	
		0.7	4,02	3,51	0,281	12,657	0,103	0,719	0,501	0,833	0,242	0,695	0,610	0,882		
		0.8	3,68	3,60	0,288	12,891	0,105	0,731	0,509	0,808	0,248	0,668	0,650	<b>0,890</b>		
		0.9	<b>3,06</b>	3,75	0,289	13,110	0,106	0,725	0,508	0,672	0,251	0,630	0,586	0,884		
	FConf, FComp e Interés	5	0.6	3,82	3,34	0,292	13,282	0,107	0,733	0,519	0,810	0,250	0,687	<b>0,666</b>	0,881	
			0.7	3,64	<b>3,28</b>	0,293	13,370	0,108	0,732	0,520	<b>0,829</b>	0,251	0,688	0,661	0,864	
			0.8	4,00	3,41	0,269	12,016	0,097	0,713	0,474	0,797	0,229	0,652	0,617	<b>0,881</b>	
			0.9	<b>3,06</b>	3,35	<b>0,319</b>	<b>14,784</b>	<b>0,118</b>	<b>0,747</b>	<b>0,567</b>	0,725	<b>0,275</b>	<b>0,704</b>	0,666	0,870	+
		7	0.6	3,84	<b>3,23</b>	0,296	13,347	0,108	0,733	0,525	<b>0,818</b>	0,253	0,695	0,659	0,868	
			0.7	4,42	3,42	0,230	10,671	0,085	0,684	0,412	0,785	0,197	0,574	0,535	<b>0,875</b>	
			0.8	3,84	3,37	0,294	13,455	0,108	0,724	0,522	0,815	0,252	0,648	0,626	0,869	
			0.9	<b>2,80</b>	3,44	<b>0,323</b>	<b>14,989</b>	<b>0,120</b>	<b>0,763</b>	<b>0,571</b>	0,700	<b>0,279</b>	<b>0,718</b>	<b>0,703</b>	0,861	+
Medidas fitness:	3	0.6	4,44	3,11	0,024	1,303	0,006	0,445	0,097	0,419	0,021	0,475	0,438	0,654		
		0.7	4,50	3,17	0,023	1,223	0,006	0,444	0,098	0,402	0,021	0,473	0,409	0,668		
		0.8	<b>4,00</b>	<b>3,09</b>	<b>0,028</b>	1,502	0,008	0,434	0,122	<b>0,448</b>	<b>0,026</b>	0,418	0,408	0,625		
		0.9	4,52	3,24	0,027	<b>1,666</b>	<b>0,009</b>	<b>0,481</b>	<b>0,124</b>	0,422	0,025	<b>0,525</b>	<b>0,464</b>	<b>0,686</b>	*	
	CConf, CComp e Interés	5	0.6	4,36	3,15	<b>0,025</b>	<b>1,160</b>	<b>0,005</b>	<b>0,446</b>	<b>0,063</b>	0,396	<b>0,019</b>	0,370	<b>0,346</b>	<b>0,670</b>	+
			0.7	3,78	<b>2,86</b>	0,024	0,881	0,004	0,390	0,056	<b>0,492</b>	0,017	<b>0,375</b>	0,315	0,600	
			0.8	<b>3,56</b>	2,89	0,020	0,800	0,003	0,361	0,045	0,461	0,013	0,350	0,297	0,571	
			0.9	3,60	2,94	0,022	0,875	0,003	0,405	0,062	0,405	0,016	0,366	0,312	0,636	
		7	0.6	<b>3,76</b>	2,83	0,011	0,604	0,002	0,347	0,031	0,452	0,008	0,258	0,216	0,566	
			0.7	3,92	<b>2,77</b>	0,012	0,692	0,003	0,346	0,033	<b>0,495</b>	0,010	0,296	0,227	0,544	
			0.8	3,88	3,04	<b>0,015</b>	<b>0,820</b>	<b>0,003</b>	<b>0,422</b>	<b>0,033</b>	0,377	<b>0,011</b>	<b>0,345</b>	<b>0,288</b>	<b>0,672</b>	+
			0.9	4,18	2,86	0,013	0,667	0,002	0,363	0,029	0,443	0,010	0,260	0,218	0,585	

Variables	Continuas	Ejemplos	Clases
14	6	600	2

Tabla A.3 Resumen de la experimentación de SDIGA para Australian con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas <i>fitness</i> :	3	0.6	4,30	5,25	<b>0,197</b>	5,522	0,052	0,721	0,665	<b>0,527</b>	<b>0,158</b>	0,713	0,704	
		0.7	3,12	<b>5,03</b>	0,114	5,616	0,043	0,730	0,606	0,270	0,112	0,743	0,717	
		0.8	2,70	5,04	0,134	6,848	0,051	0,749	0,655	0,286	0,129	0,762	0,760	
		0.9	<b>2,30</b>	5,18	0,143	<b>7,344</b>	<b>0,055</b>	<b>0,780</b>	<b>0,733</b>	0,272	0,140	<b>0,817</b>	<b>0,827</b> +	
	FConf y Comp	5	0.6	4,64	<b>5,14</b>	<b>0,230</b>	5,543	0,057	0,702	0,619	<b>0,628</b>	<b>0,172</b>	0,672	0,649
			0.7	3,14	5,17	0,148	6,394	0,052	0,728	0,599	0,341	0,129	0,718	0,704
			0.8	3,60	5,18	0,135	5,737	0,046	0,707	0,533	0,349	0,116	0,699	0,682
			0.9	<b>2,50</b>	5,45	0,160	<b>7,169</b>	<b>0,058</b>	<b>0,769</b>	<b>0,707</b>	0,315	0,145	<b>0,818</b>	<b>0,790</b> +
		7	0.6	4,80	5,01	<b>0,222</b>	6,586	0,063	0,709	0,569	<b>0,631</b>	0,170	0,657	0,647
			0.7	3,90	4,85	0,153	6,502	0,054	0,698	0,505	0,431	0,132	0,616	0,576
			0.8	3,56	4,85	0,163	7,443	0,059	0,727	0,543	0,422	0,140	0,693	0,663
			0.9	<b>2,40</b>	<b>4,82</b>	0,217	<b>9,409</b>	<b>0,076</b>	<b>0,790</b>	<b>0,715</b>	0,417	<b>0,184</b>	<b>0,797</b>	<b>0,794</b> *
Medidas <i>fitness</i> :	3	0.6	4,86	3,66	0,275	11,955	0,098	0,703	0,476	0,854	0,235	0,617	0,591	
		0.7	4,84	3,67	0,254	11,137	0,090	0,686	0,440	<b>0,855</b>	0,217	0,596	0,572	
		0.8	<b>3,36</b>	<b>3,64</b>	<b>0,345</b>	<b>15,138</b>	<b>0,124</b>	<b>0,749</b>	<b>0,597</b>	0,826	<b>0,297</b>	0,692	0,675 *	
		0.9	3,58	3,77	0,321	14,178	0,115	0,740	0,555	0,812	0,276	<b>0,694</b>	<b>0,677</b>	
	Fconf y Fcomp	5	0.6	4,92	<b>3,74</b>	0,255	11,135	0,091	0,694	0,446	<b>0,856</b>	0,218	0,606	0,561
			0.7	5,34	3,87	0,227	9,903	0,081	0,673	0,394	<b>0,856</b>	0,193	0,565	0,534
			0.8	4,66	3,94	0,287	12,218	0,100	0,711	0,493	0,823	0,243	0,681	<b>0,655</b>
			0.9	<b>4,34</b>	3,92	<b>0,300</b>	<b>13,078</b>	<b>0,107</b>	<b>0,724</b>	<b>0,521</b>	0,854	<b>0,257</b>	<b>0,682</b>	0,648 +
		7	0.6	4,94	4,08	0,255	11,054	0,090	0,684	0,441	0,857	0,217	0,617	0,579
			0.7	4,94	3,88	0,273	11,637	0,094	0,693	0,469	<b>0,858</b>	0,230	0,625	0,598
			0.8	<b>3,72</b>	<b>3,88</b>	<b>0,335</b>	<b>14,618</b>	<b>0,120</b>	<b>0,735</b>	<b>0,580</b>	0,837	<b>0,287</b>	<b>0,701</b>	<b>0,670</b> +
			0.9	4,18	3,96	0,308	13,260	0,109	0,726	0,532	0,831	0,262	0,692	0,659
Medidas <i>fitness</i> :	3	0.6	25,08	<b>5,00</b>	0,049	<b>2,816</b>	<b>0,016</b>	0,660	0,186	0,588	0,045	0,736	0,691	
		0.7	<b>23,32</b>	5,09	0,049	2,772	0,016	<b>0,667</b>	0,191	0,549	<b>0,045</b>	0,741	<b>0,691</b> +	
		0.8	23,70	5,04	0,048	2,725	0,016	0,659	<b>0,193</b>	0,583	0,045	0,740	0,690	
		0.9	24,72	5,03	<b>0,050</b>	2,770	0,016	0,660	0,186	<b>0,594</b>	0,045	<b>0,745</b>	0,683	
	CConf y CComp	5	0.6	35,50	<b>5,45</b>	<b>0,048</b>	2,860	0,016	0,656	0,174	0,692	0,042	0,733	0,663
			0.7	35,20	5,49	0,048	<b>2,881</b>	<b>0,016</b>	<b>0,664</b>	<b>0,180</b>	0,672	<b>0,042</b>	<b>0,751</b>	<b>0,674</b> *
			0.8	36,52	5,47	0,048	2,872	0,016	0,662	0,169	<b>0,692</b>	0,041	0,738	0,666
			0.9	<b>32,90</b>	5,46	0,047	2,839	0,016	0,654	0,177	0,666	0,041	0,719	0,661
		7	0.6	<b>39,18</b>	5,77	0,044	2,619	0,014	0,651	0,165	0,686	0,038	0,738	0,652
			0.7	39,88	5,71	0,044	2,780	0,015	0,648	0,168	0,693	0,039	0,720	0,651
			0.8	41,12	5,73	0,045	<b>2,845</b>	<b>0,015</b>	0,661	<b>0,172</b>	0,691	0,039	<b>0,744</b>	<b>0,674</b> +
			0.9	40,54	<b>5,71</b>	<b>0,045</b>	2,772	0,015	<b>0,661</b>	0,169	<b>0,702</b>	<b>0,040</b>	0,736	0,673

Variables	Continuas	Ejemplos	Clases
14	6	600	2

Tabla A.4 Resumen de la experimentación de SDIGA para Breast-w con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas fitness:	3	0.6	4,50	<b>2,15</b>	0,419	12,212	0,094	0,709	0,608	<b>0,842</b>	0,366	0,698	0,698	0,577		
		0.7	4,20	2,36	<b>0,474</b>	13,835	0,106	0,811	<b>0,686</b>	0,826	<b>0,411</b>	0,794	0,794	<b>0,670</b>		
		0.8	2,70	2,40	0,429	17,013	0,117	0,835	0,681	0,787	0,381	0,838	0,838	0,650		
		0.9	<b>2,52</b>	2,43	0,422	<b>17,325</b>	<b>0,118</b>	<b>0,840</b>	0,674	0,757	0,378	<b>0,852</b>	<b>0,852</b>	0,646	+	
FConf, Comp e Interés	5	0.6	4,72	<b>2,18</b>	0,428	12,167	0,095	0,713	0,615	<b>0,839</b>	0,368	0,697	0,697	0,588		
		0.7	4,10	2,33	<b>0,497</b>	13,537	0,107	0,817	<b>0,709</b>	0,830	<b>0,430</b>	0,807	0,807	<b>0,677</b>		
		0.8	2,58	2,41	0,425	17,245	0,118	0,839	0,679	0,781	0,378	0,847	0,847	0,647		
		0.9	<b>2,42</b>	2,42	0,430	<b>17,869</b>	<b>0,121</b>	<b>0,845</b>	0,692	0,771	0,382	<b>0,858</b>	<b>0,858</b>	0,649	+	
	7	0.6	4,80	<b>2,13</b>	0,414	12,109	0,093	0,702	0,598	<b>0,840</b>	0,362	0,689	0,689	0,572		
		0.7	3,92	2,31	<b>0,500</b>	14,534	0,113	0,828	<b>0,725</b>	0,826	<b>0,436</b>	0,823	0,823	<b>0,672</b>		
		0.8	<b>2,42</b>	2,36	0,447	<b>18,046</b>	<b>0,124</b>	<b>0,855</b>	0,715	0,783	0,397	<b>0,890</b>	<b>0,890</b>	0,649	*	
		0.9	2,44	2,37	0,447	17,590	0,123	0,847	0,705	0,774	0,397	0,864	0,864	0,653		
Medidas fitness:	3	0.6	4,78	<b>2,23</b>	0,417	11,793	0,093	0,714	0,601	<b>0,836</b>	0,361	0,685	0,685	0,600		
		0.7	4,18	2,34	<b>0,475</b>	14,372	0,109	0,821	0,693	0,828	<b>0,416</b>	0,803	0,803	<b>0,665</b>		
		0.8	2,76	2,39	0,431	17,142	0,119	0,840	0,684	0,786	0,385	0,843	0,843	0,645		
		0.9	<b>2,34</b>	2,38	0,442	<b>18,576</b>	<b>0,124</b>	<b>0,852</b>	<b>0,712</b>	0,771	0,394	<b>0,875</b>	<b>0,875</b>	0,648	*	
FConf, FComp e Interés	5	0.6	4,42	<b>2,13</b>	0,428	12,723	0,097	0,713	0,625	<b>0,833</b>	0,372	0,709	0,709	0,581		
		0.7	3,90	2,33	<b>0,500</b>	13,716	0,109	0,819	<b>0,714</b>	0,831	<b>0,431</b>	0,816	0,816	<b>0,677</b>		
		0.8	<b>2,62</b>	2,37	0,446	<b>17,400</b>	<b>0,122</b>	<b>0,848</b>	0,705	0,790	0,396	<b>0,871</b>	<b>0,871</b>	0,649	+	
		0.9	<b>2,62</b>	2,41	0,419	16,893	0,116	0,828	0,670	0,777	0,370	0,832	0,832	0,649		
	7	0.6	4,56	<b>2,13</b>	0,432	12,442	0,097	0,715	0,623	<b>0,837</b>	0,374	0,718	0,718	0,582		
		0.7	3,94	2,35	<b>0,483</b>	13,939	0,109	0,819	0,698	0,824	<b>0,420</b>	0,806	0,806	<b>0,673</b>		
		0.8	2,64	2,41	0,414	17,372	0,117	0,837	0,667	0,781	0,369	0,839	0,839	0,645		
		0.9	<b>2,46</b>	2,39	0,440	<b>17,939</b>	<b>0,123</b>	<b>0,850</b>	<b>0,703</b>	0,779	0,391	<b>0,876</b>	<b>0,876</b>	0,650	+	
Medidas fitness:	3	0.6	<b>10,86</b>	<b>2,48</b>	0,078	6,938	0,033	0,727	0,166	0,583	0,077	0,741	0,741	0,620		
		0.7	11,78	2,50	<b>0,080</b>	7,325	<b>0,035</b>	<b>0,744</b>	<b>0,173</b>	<b>0,629</b>	<b>0,080</b>	0,749	0,749	0,621	*	
		0.8	11,08	2,48	0,078	<b>7,328</b>	0,035	0,740	0,172	0,585	0,077	<b>0,750</b>	<b>0,750</b>	<b>0,624</b>		
		0.9	11,86	2,48	0,073	7,009	0,033	0,730	0,164	0,592	0,072	0,737	0,737	0,624		
CConf, CComp e Interés	5	0.6	11,32	<b>2,47</b>	0,077	7,370	0,035	0,739	0,171	0,592	0,076	<b>0,755</b>	<b>0,755</b>	0,625		
		0.7	<b>11,14</b>	2,49	<b>0,079</b>	<b>7,442</b>	<b>0,036</b>	0,740	<b>0,174</b>	0,601	<b>0,079</b>	0,737	0,737	0,626	+	
		0.8	11,56	2,49	0,079	7,328	0,035	0,734	0,173	0,598	0,078	0,736	0,736	0,625		
		0.9	11,26	2,50	0,077	7,280	0,034	<b>0,741</b>	0,172	<b>0,605</b>	0,076	0,750	0,750	<b>0,629</b>		
	7	0.6	<b>11,42</b>	<b>2,49</b>	0,077	<b>7,274</b>	<b>0,034</b>	<b>0,737</b>	<b>0,170</b>	0,602	0,076	<b>0,742</b>	<b>0,742</b>	0,617	+	
		0.7	12,34	2,50	0,070	6,726	0,032	0,724	0,158	0,584	0,069	0,718	0,718	0,629		
		0.8	12,02	2,55	<b>0,079</b>	7,113	0,034	0,734	0,170	<b>0,626</b>	<b>0,078</b>	0,737	0,737	0,630		
		0.9	12,34	2,52	0,071	6,589	0,031	0,730	0,154	0,585	0,070	0,730	0,730	<b>0,632</b>		

Variables	Continuas	Ejemplos	Clases
9	0	699	2

Tabla A.5 Resumen de la experimentación de SDIGA para Breast-w con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas <i>fitness</i> :	3	0.6	6,60	5,32	0,290	15,122	0,099	0,788	0,526	<b>0,970</b>	0,267	0,779	0,779	
		0.7	7,40	<b>5,32</b>	0,269	14,697	0,093	0,772	0,495	0,963	0,247	0,770	0,770	
		0.8	6,46	5,34	0,308	15,217	0,100	0,775	0,542	0,960	0,283	0,760	0,760	
		0.9	<b>4,08</b>	5,61	<b>0,398</b>	<b>19,455</b>	<b>0,131</b>	<b>0,815</b>	<b>0,693</b>	0,934	<b>0,368</b>	<b>0,787</b>	<b>0,787</b>	+
FConf y Comp	5	0.6	6,92	<b>5,28</b>	0,288	14,222	0,095	0,767	0,513	0,967	0,262	0,755	0,755	
		0.7	6,52	5,34	0,307	15,972	0,105	0,785	0,558	<b>0,968</b>	0,280	0,778	0,778	
		0.8	6,54	5,40	0,305	15,593	0,103	0,785	0,548	0,967	0,280	0,779	0,779	
		0.9	<b>4,28</b>	5,54	<b>0,375</b>	<b>19,891</b>	<b>0,129</b>	<b>0,823</b>	<b>0,667</b>	0,944	<b>0,353</b>	<b>0,804</b>	<b>0,804</b>	*
	7	0.6	6,90	<b>5,22</b>	0,281	13,993	0,094	0,773	0,504	0,965	0,255	0,775	0,775	
		0.7	6,56	5,30	0,303	15,717	0,103	0,789	0,550	<b>0,967</b>	0,278	0,795	0,795	
		0.8	6,56	5,44	0,323	15,725	0,104	0,794	0,567	0,959	0,296	<b>0,799</b>	<b>0,799</b>	
		0.9	<b>4,04</b>	5,64	<b>0,407</b>	<b>19,068</b>	<b>0,131</b>	<b>0,814</b>	<b>0,701</b>	0,938	<b>0,374</b>	0,790	0,790	+
Medidas <i>fitness</i> :	3	0.6	6,92	<b>5,22</b>	0,285	14,995	0,098	0,778	0,520	<b>0,970</b>	0,261	0,784	0,784	
		0.7	7,60	5,47	0,268	13,863	0,091	0,755	0,485	0,966	0,245	0,715	0,715	
		0.8	6,62	5,41	0,300	15,973	0,102	0,787	0,541	0,963	0,278	0,775	0,775	
		0.9	<b>3,92</b>	5,29	<b>0,421</b>	<b>20,833</b>	<b>0,141</b>	<b>0,829</b>	<b>0,742</b>	0,940	<b>0,387</b>	<b>0,819</b>	<b>0,819</b>	*
Fconf y Fcomp	5	0.6	7,08	<b>5,21</b>	0,281	14,240	0,094	0,767	0,508	0,966	0,255	0,741	0,741	
		0.7	7,16	5,22	0,272	14,368	0,094	0,774	0,501	<b>0,967</b>	0,249	0,760	0,760	
		0.8	6,34	5,41	0,311	16,078	0,106	0,797	0,559	0,962	0,286	<b>0,790</b>	<b>0,790</b>	
		0.9	<b>4,84</b>	5,64	<b>0,353</b>	<b>17,723</b>	<b>0,115</b>	<b>0,804</b>	<b>0,613</b>	0,935	<b>0,331</b>	0,772	0,772	+
	7	0.6	6,58	<b>5,19</b>	0,302	15,221	0,100	0,779	0,540	<b>0,970</b>	0,275	0,761	0,761	
		0.7	6,58	5,19	0,303	15,349	0,101	0,780	0,546	0,965	0,277	0,757	0,757	
		0.8	6,38	5,31	0,306	16,383	0,106	0,784	0,557	0,960	0,282	0,779	0,779	
		0.9	<b>4,28</b>	5,47	<b>0,388</b>	<b>19,114</b>	<b>0,126</b>	<b>0,812</b>	<b>0,679</b>	0,933	<b>0,361</b>	<b>0,786</b>	<b>0,786</b>	+
Medidas <i>fitness</i> :	3	0.6	22,82	5,45	0,120	<b>8,285</b>	<b>0,045</b>	0,735	0,227	0,937	0,115	0,734	0,734	+
		0.7	<b>22,54</b>	5,43	<b>0,123</b>	8,243	0,044	<b>0,737</b>	<b>0,227</b>	0,936	<b>0,117</b>	0,742	0,742	
		0.8	23,80	<b>5,41</b>	0,121	8,242	0,044	0,735	0,225	<b>0,946</b>	0,115	<b>0,750</b>	<b>0,750</b>	
		0.9	23,54	5,47	0,120	8,144	0,044	0,731	0,224	0,939	0,114	0,725	0,725	
CConf y CComp	5	0.6	23,00	5,40	0,114	8,179	0,043	0,731	0,219	<b>0,939</b>	0,108	<b>0,742</b>	<b>0,742</b>	
		0.7	<b>22,88</b>	5,47	<b>0,122</b>	8,262	<b>0,045</b>	0,730	<b>0,227</b>	0,932	<b>0,116</b>	0,729	0,729	+
		0.8	23,62	<b>5,39</b>	0,120	<b>8,270</b>	0,044	0,730	0,223	0,934	0,115	0,727	0,727	
		0.9	22,90	5,39	0,115	8,165	0,044	<b>0,732</b>	0,220	0,934	0,109	0,733	0,733	
	7	0.6	<b>21,62</b>	5,36	<b>0,128</b>	<b>8,872</b>	<b>0,048</b>	<b>0,742</b>	<b>0,242</b>	0,940	<b>0,123</b>	<b>0,745</b>	<b>0,745</b>	*
		0.7	23,12	5,41	0,117	8,265	0,044	0,733	0,223	0,935	0,111	0,745	0,745	
		0.8	22,10	5,45	0,120	8,183	0,044	0,734	0,225	0,933	0,114	0,743	0,743	
		0.9	23,62	<b>5,36</b>	0,119	8,277	0,044	0,733	0,223	<b>0,942</b>	0,113	0,732	0,732	

Variables	Continuas	Ejemplos	Clases
9	0	699	2

Tabla A.6 Resumen de la experimentación de SDIGA para Bridges con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	3,04	2,76	<b>0,299</b>	<b>0,805</b>	<b>0,024</b>	<b>0,650</b>	0,505	<b>0,662</b>	<b>0,251</b>	<b>0,637</b>	0,632	1,043	*	
		0.7	3,06	2,79	0,288	0,652	0,014	0,629	0,469	0,597	0,230	0,615	0,610	1,059		
		0.8	3,02	2,79	0,284	0,723	0,020	0,649	0,472	0,596	0,235	0,618	<b>0,636</b>	<b>1,074</b>		
		0.9	<b>2,54</b>	<b>2,73</b>	0,281	0,704	0,013	0,609	<b>0,507</b>	0,551	0,223	0,570	0,557	1,059		
	FConf, Comp e Interés	5	0.6	4,70	2,98	0,266	0,589	<b>0,016</b>	<b>0,582</b>	0,361	<b>0,807</b>	0,219	0,465	0,430	<b>0,981</b>	
			0.7	4,08	<b>2,79</b>	<b>0,281</b>	<b>0,705</b>	0,015	0,578	<b>0,382</b>	0,807	<b>0,228</b>	<b>0,494</b>	<b>0,463</b>	0,967	+
			0.8	4,28	2,85	0,266	0,646	0,015	0,559	0,378	0,801	0,217	0,455	0,427	0,950	
			0.9	<b>3,04</b>	3,02	0,208	0,697	0,012	0,542	0,331	0,555	0,159	0,399	0,383	0,962	
		7	0.6	4,96	3,08	0,285	0,505	0,017	0,634	0,416	<b>0,771</b>	0,252	0,519	0,463	1,014	
			0.7	4,48	<b>2,96</b>	<b>0,304</b>	<b>0,535</b>	<b>0,019</b>	<b>0,649</b>	<b>0,429</b>	0,759	<b>0,272</b>	<b>0,566</b>	<b>0,511</b>	1,005	+
			0.8	4,62	3,06	0,295	0,487	0,017	0,640	0,409	0,755	0,263	0,525	0,477	1,011	
			0.9	<b>3,40</b>	3,14	0,232	0,484	0,016	0,612	0,351	0,555	0,202	0,458	0,428	<b>1,016</b>	
Medidas <i>fitness</i> :	3	0.6	4,22	2,67	0,314	0,557	0,018	0,597	0,382	0,820	0,268	0,506	0,490	0,970		
		0.7	3,98	2,55	0,337	0,549	0,017	0,569	0,391	0,837	0,278	0,481	0,467	0,932		
		0.8	3,98	<b>2,51</b>	<b>0,397</b>	<b>0,622</b>	<b>0,020</b>	0,606	<b>0,446</b>	<b>0,845</b>	<b>0,317</b>	<b>0,537</b>	<b>0,526</b>	0,986	*	
		0.9	<b>3,04</b>	2,93	0,322	0,546	0,019	<b>0,623</b>	0,381	0,663	0,261	0,496	0,462	<b>1,052</b>		
	FConf, FComp e Interés	5	0.6	4,70	<b>2,63</b>	<b>0,285</b>	0,386	0,009	0,484	0,323	0,873	0,218	0,366	0,345	0,845	
			0.7	5,20	2,79	0,255	0,434	<b>0,013</b>	0,503	0,305	0,883	0,203	0,365	0,348	0,875	
			0.8	4,76	2,66	0,283	<b>0,474</b>	0,012	0,498	<b>0,327</b>	<b>0,883</b>	<b>0,222</b>	<b>0,375</b>	<b>0,367</b>	0,853	+
			0.9	<b>3,58</b>	3,37	0,265	0,469	0,007	<b>0,578</b>	0,303	0,663	0,212	0,364	0,342	<b>1,045</b>	
		7	0.6	5,46	2,95	0,215	0,354	0,006	0,477	0,252	0,860	0,177	0,317	0,276	0,837	
			0.7	5,20	<b>2,84</b>	0,247	0,349	0,008	0,482	0,280	0,870	0,195	0,338	0,307	0,832	
			0.8	5,42	2,95	0,218	<b>0,377</b>	<b>0,009</b>	0,483	0,269	<b>0,882</b>	0,178	0,322	0,297	0,833	
			0.9	<b>3,82</b>	3,29	<b>0,291</b>	0,358	0,006	<b>0,559</b>	<b>0,325</b>	0,673	<b>0,209</b>	<b>0,347</b>	<b>0,324</b>	<b>1,028</b>	+
Medidas <i>fitness</i> :	3	0.6	11,08	3,37	0,135	0,581	0,014	0,616	0,258	<b>0,763</b>	0,120	0,673	<b>0,599</b>	1,044		
		0.7	<b>10,30</b>	3,34	0,138	0,544	<b>0,015</b>	0,613	0,263	0,734	0,122	0,668	0,583	1,044		
		0.8	10,44	3,39	<b>0,144</b>	<b>0,620</b>	0,014	<b>0,621</b>	<b>0,279</b>	0,749	<b>0,128</b>	<b>0,680</b>	0,594	<b>1,049</b>	*	
		0.9	10,58	<b>3,34</b>	0,135	0,544	0,014	0,613	0,266	0,746	0,122	0,675	0,576	1,044		
	CConf, CComp e Interés	5	0.6	12,44	3,10	0,116	0,450	<b>0,013</b>	0,609	0,215	<b>0,759</b>	0,106	0,644	0,569	<b>1,032</b>	
			0.7	<b>11,80</b>	3,11	0,121	0,422	0,012	0,610	0,218	0,742	0,112	0,644	0,558	1,027	
			0.8	12,54	<b>3,07</b>	0,118	0,438	0,013	<b>0,613</b>	0,215	0,752	0,110	<b>0,666</b>	<b>0,588</b>	1,024	
			0.9	12,58	3,13	<b>0,124</b>	<b>0,476</b>	0,013	0,610	<b>0,222</b>	0,750	<b>0,112</b>	0,644	0,562	1,028	+
		7	0.6	12,72	2,96	0,122	0,419	0,012	0,614	0,204	0,759	0,111	0,656	0,567	1,005	
			0.7	<b>12,00</b>	3,02	0,119	0,410	0,013	0,614	0,199	0,725	0,108	0,648	0,555	1,006	
			0.8	12,72	<b>2,94</b>	0,122	<b>0,436</b>	0,013	0,615	0,201	<b>0,767</b>	0,110	<b>0,676</b>	<b>0,590</b>	0,996	+
			0.9	12,00	3,03	<b>0,124</b>	0,433	<b>0,013</b>	<b>0,619</b>	<b>0,214</b>	0,749	<b>0,111</b>	0,654	0,582	<b>1,012</b>	

Variables	Continuas	Ejemplos	Clases
7	3	102	2

Tabla A.7 Resumen de la experimentación de SDIGA para Bridges con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas <i>fitness</i> :	3	0.6	2,04	4,35	0,433	0,513	<b>0,016</b>	<b>0,629</b>	0,808	<b>0,728</b>	0,343	0,520	0,517	
		0.7	<b>2,00</b>	4,31	0,439	<b>0,565</b>	0,015	<b>0,629</b>	<b>0,830</b>	<b>0,728</b>	<b>0,348</b>	0,523	<b>0,527</b>	+
		0.8	<b>2,00</b>	<b>4,28</b>	0,437	0,507	0,015	0,628	0,820	0,727	0,347	<b>0,527</b>	0,514	
		0.9	<b>2,00</b>	4,31	<b>0,443</b>	0,398	0,015	0,623	0,820	0,728	0,347	0,513	0,497	
FConf y Comp	5	0.6	2,06	5,28	0,298	1,057	0,035	0,638	0,805	0,498	0,230	0,579	0,579	
		0.7	2,10	5,28	0,292	1,035	0,033	0,632	0,775	0,493	0,226	0,563	0,565	
		0.8	<b>2,04</b>	<b>5,24</b>	<b>0,299</b>	1,160	0,037	0,643	<b>0,822</b>	0,502	<b>0,232</b>	0,591	0,596	
		0.9	2,08	5,27	0,299	<b>1,204</b>	<b>0,038</b>	<b>0,648</b>	0,813	<b>0,506</b>	0,231	<b>0,608</b>	<b>0,616</b>	*
	7	0.6	3,36	4,85	0,246	0,590	0,012	0,589	0,484	<b>0,588</b>	0,168	0,463	0,435	
		0.7	2,94	4,86	0,258	0,803	0,017	0,611	0,529	0,576	0,187	0,524	0,483	
		0.8	2,80	4,76	<b>0,280</b>	0,807	0,017	0,607	<b>0,589</b>	0,561	0,196	0,511	0,489	
		0.9	<b>2,66</b>	<b>4,72</b>	0,272	<b>0,960</b>	<b>0,019</b>	<b>0,623</b>	0,584	0,556	<b>0,200</b>	<b>0,538</b>	<b>0,524</b>	+
Medidas <i>fitness</i> :	3	0.6	2,14	2,55	<b>0,274</b>	0,199	0,006	0,168	0,308	<b>0,951</b>	<b>0,048</b>	0,076	0,079	
		0.7	2,06	<b>2,46</b>	0,220	0,211	<b>0,009</b>	<b>0,184</b>	0,285	0,936	0,040	0,097	0,088	
		0.8	<b>2,04</b>	2,49	0,255	0,136	0,007	0,167	0,285	0,941	0,042	0,070	0,072	
		0.9	2,08	2,49	0,258	<b>0,260</b>	0,008	0,177	<b>0,315</b>	0,945	0,045	<b>0,103</b>	<b>0,094</b>	+
Fconf y Fcomp	5	0.6	3,10	3,26	0,091	0,242	0,005	<b>0,283</b>	0,166	0,904	0,020	0,112	0,070	
		0.7	2,80	2,99	<b>0,194</b>	0,289	0,006	0,232	<b>0,244</b>	<b>0,929</b>	<b>0,033</b>	0,094	0,083	
		0.8	2,58	3,01	0,157	<b>0,345</b>	<b>0,007</b>	0,244	0,241	0,921	0,030	<b>0,119</b>	<b>0,088</b>	+
		0.9	<b>2,42</b>	<b>2,78</b>	0,160	0,242	0,007	0,230	0,235	0,922	0,031	0,113	0,082	
	7	0.6	3,22	3,39	0,137	0,298	0,008	0,276	0,197	0,918	0,025	0,093	0,087	
		0.7	<b>3,04</b>	<b>3,28</b>	0,136	0,286	0,007	0,270	0,216	0,920	0,026	0,112	0,092	
		0.8	3,22	3,41	<b>0,144</b>	0,380	<b>0,010</b>	0,272	<b>0,250</b>	<b>0,934</b>	<b>0,031</b>	<b>0,142</b>	<b>0,101</b>	*
		0.9	3,16	3,41	0,101	<b>0,398</b>	0,007	<b>0,278</b>	0,173	0,911	0,019	0,111	0,095	
Medidas <i>fitness</i> :	3	0.6	6,70	3,88	0,182	0,715	0,019	0,591	0,379	0,724	0,148	0,611	0,553	
		0.7	7,00	3,93	0,184	0,735	<b>0,021</b>	<b>0,606</b>	0,366	0,713	0,151	0,626	0,590	
		0.8	<b>6,14</b>	3,70	<b>0,202</b>	<b>0,762</b>	0,020	0,597	<b>0,409</b>	<b>0,761</b>	<b>0,172</b>	<b>0,663</b>	<b>0,608</b>	+
		0.9	6,64	<b>3,68</b>	0,177	0,716	0,018	0,577	0,376	0,751	0,150	0,611	0,555	
CConf y CComp	5	0.6	9,54	3,88	0,206	<b>0,716</b>	0,019	0,639	<b>0,376</b>	0,797	0,173	0,652	0,608	
		0.7	<b>8,86</b>	3,82	0,211	0,663	0,018	0,640	0,368	0,799	0,177	<b>0,663</b>	0,626	
		0.8	9,46	<b>3,80</b>	0,213	0,621	0,017	0,634	0,367	0,819	0,173	0,644	0,615	
		0.9	9,30	3,85	<b>0,214</b>	0,678	<b>0,021</b>	<b>0,641</b>	0,375	<b>0,833</b>	<b>0,178</b>	0,639	<b>0,629</b>	*
	7	0.6	<b>9,88</b>	4,23	<b>0,211</b>	0,600	<b>0,014</b>	<b>0,630</b>	<b>0,372</b>	0,816	<b>0,164</b>	<b>0,625</b>	<b>0,563</b>	+
		0.7	10,24	4,16	0,207	0,624	0,012	0,621	0,358	<b>0,832</b>	0,156	0,609	0,547	
		0.8	10,32	4,20	0,201	0,602	0,011	0,617	0,339	0,824	0,152	0,582	0,542	
		0.9	10,06	<b>4,15</b>	0,208	<b>0,629</b>	0,010	0,612	0,345	0,824	0,157	0,585	0,539	

Variables	Continuas	Ejemplos	Clases
7	3	102	2

Tabla A.8 Resumen de la experimentación de SDIGA para Diabetes con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int		
Medidas <i>fitness</i> :	3	0.6	2,90	3,14	0,274	4,107	0,029	0,661	0,657	<b>0,543</b>	0,188	<b>0,757</b>	0,595	0,914			
		0.7	2,92	3,15	0,272	4,043	0,028	0,658	0,651	0,541	0,187	0,755	0,587	<b>0,914</b>			
		0.8	<b>2,00</b>	<b>2,25</b>	<b>0,378</b>	<b>5,236</b>	<b>0,035</b>	<b>0,686</b>	<b>0,812</b>	0,527	<b>0,247</b>	0,671	<b>0,708</b>	0,904	*		
		0.9	<b>2,00</b>	<b>2,25</b>	<b>0,378</b>	<b>5,236</b>	<b>0,035</b>	<b>0,686</b>	<b>0,812</b>	0,527	<b>0,247</b>	0,671	<b>0,708</b>	0,904	*		
	FConf, Comp e Interés	5	0.6	3,68	2,52	0,196	1,935	0,016	0,521	0,423	<b>0,601</b>	0,129	0,469	0,430	0,704		
			0.7	2,36	2,56	0,267	2,671	0,021	0,588	0,548	0,366	0,158	0,574	0,495	<b>0,815</b>		
			0.8	2,22	2,55	0,253	2,752	0,021	0,596	0,554	0,342	0,155	0,558	0,528	0,813		
			0.9	<b>2,14</b>	<b>2,30</b>	<b>0,279</b>	<b>2,971</b>	<b>0,024</b>	<b>0,604</b>	<b>0,588</b>	0,365	<b>0,168</b>	<b>0,581</b>	<b>0,548</b>	0,803	+	
		7	0.6	4,56	2,66	0,168	0,831	<b>0,004</b>	0,442	0,322	<b>0,672</b>	0,102	0,360	0,316	0,611		
			0.7	2,80	2,96	0,178	1,204	0,004	0,494	0,331	0,355	0,103	0,402	0,317	0,715		
			0.8	2,84	2,94	0,164	0,865	0,002	0,478	0,314	0,319	0,094	0,388	0,312	0,688		
			0.9	<b>2,40</b>	<b>2,63</b>	<b>0,213</b>	<b>1,575</b>	<b>0,002</b>	<b>0,496</b>	<b>0,377</b>	0,334	<b>0,120</b>	<b>0,434</b>	<b>0,389</b>	<b>0,718</b>	+	
Medidas <i>fitness</i> :	3	0.6	4,26	2,72	0,294	<b>1,226</b>	<b>0,016</b>	0,532	0,446	<b>0,688</b>	0,176	<b>0,490</b>	0,338	0,854	*		
		0.7	3,10	<b>2,65</b>	0,314	1,104	0,011	<b>0,533</b>	<b>0,475</b>	0,615	<b>0,181</b>	0,488	<b>0,364</b>	0,875			
		0.8	<b>2,94</b>	2,73	<b>0,315</b>	0,726	0,006	0,512	0,456	0,518	0,167	0,467	0,305	<b>0,903</b>			
		0.9	3,04	2,84	0,291	0,485	0,008	0,511	0,415	0,527	0,159	0,463	0,291	0,890			
	FConf, FComp e Interés	5	0.6	3,42	2,41	0,001	0,131	<b>0,000</b>	0,244	<b>0,014</b>	<b>0,772</b>	0,001	<b>0,202</b>	<b>0,039</b>	0,425	+	
			0.7	<b>2,80</b>	2,53	<b>0,002</b>	<b>0,163</b>	0,000	0,263	0,014	0,602	0,001	0,154	0,035	0,470		
			0.8	3,10	2,68	0,002	0,104	0,000	<b>0,282</b>	0,014	0,546	<b>0,002</b>	0,146	0,034	<b>0,493</b>		
			0.9	3,22	<b>2,32</b>	0,001	0,066	0,000	0,236	0,012	0,670	0,001	0,142	0,014	0,415		
		7	0.6	6,32	<b>3,20</b>	0,002	0,166	0,000	0,360	0,015	<b>0,685</b>	0,002	0,218	0,049	0,571		
			0.7	5,94	3,31	0,002	0,201	0,000	0,362	0,014	0,520	0,002	0,201	0,053	0,571		
			0.8	<b>5,64</b>	3,25	<b>0,008</b>	<b>0,279</b>	0,000	0,379	<b>0,027</b>	0,555	<b>0,004</b>	<b>0,233</b>	<b>0,097</b>	0,593	+	
			0.9	5,96	3,38	0,003	0,259	<b>0,001</b>	<b>0,385</b>	0,017	0,481	0,002	0,216	0,094	<b>0,595</b>	+	
Medidas <i>fitness</i> :	3	0.6	6,04	3,36	0,022	0,963	0,003	0,455	0,220	0,279	0,029	<b>0,478</b>	0,313	0,798			
		0.7	6,96	3,46	<b>0,025</b>	<b>1,116</b>	<b>0,004</b>	<b>0,472</b>	<b>0,225</b>	0,301	<b>0,031</b>	0,471	<b>0,322</b>	<b>0,822</b>	+		
		0.8	6,22	3,22	0,018	0,938	0,003	0,434	0,187	0,339	0,024	0,474	0,314	0,756			
		0.9	<b>5,32</b>	<b>3,09</b>	0,019	0,775	0,002	0,401	0,199	<b>0,413</b>	0,027	0,436	0,270	0,702			
	CConf, CComp e Interés	5	0.6	12,54	3,82	<b>0,038</b>	<b>1,195</b>	<b>0,007</b>	<b>0,550</b>	0,155	<b>0,328</b>	<b>0,035</b>	<b>0,615</b>	<b>0,344</b>	0,821	*	
			0.7	12,76	3,79	0,033	1,021	0,006	0,538	0,143	0,325	0,031	0,595	0,319	0,826		
			0.8	13,94	3,88	0,032	1,130	0,006	0,549	0,149	0,309	0,032	0,602	0,338	<b>0,840</b>		
			0.9	<b>12,16</b>	<b>3,78</b>	0,035	1,167	0,006	0,543	<b>0,159</b>	0,322	0,035	0,607	0,332	0,828		
		7	0.6	<b>5,04</b>	3,22	<b>0,013</b>	0,549	<b>0,002</b>	<b>0,433</b>	<b>0,071</b>	0,277	<b>0,012</b>	<b>0,450</b>	<b>0,236</b>	<b>0,645</b>	+	
			0.7	6,08	3,22	0,011	0,463	0,001	0,423	0,067	0,335	0,011	0,416	0,196	0,636		
			0.8	5,16	3,16	0,013	<b>0,577</b>	0,001	0,429	0,069	0,301	0,012	0,444	0,226	0,628		
			0.9	5,36	<b>3,02</b>	0,009	0,353	0,001	0,386	0,057	<b>0,389</b>	0,009	0,341	0,166	0,582		

Variables	Continuas	Ejemplos	Clases
8	8	768	2

Tabla A.9 Resumen de la experimentación de SDIGA para Diabetes con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	2,88	4,96	0,212	3,824	0,032	0,646	0,891	<b>0,350</b>	0,170	<b>0,633</b>	0,645	
		0.7	2,86	4,95	0,209	3,725	0,031	0,645	0,892	0,347	0,168	0,627	0,645	
		0.8	<b>2,00</b>	<b>3,92</b>	<b>0,265</b>	<b>4,652</b>	<b>0,039</b>	<b>0,649</b>	<b>0,961</b>	0,346	<b>0,183</b>	0,584	<b>0,669</b> *	
		0.9	<b>2,00</b>	<b>3,92</b>	0,263	4,633	0,038	0,645	<b>0,961</b>	0,342	0,182	0,584	0,662	
	FConf y Comp	5	0.6	2,10	6,89	0,097	3,463	0,023	0,676	0,828	0,139	0,104	0,588	0,732
			0.7	2,14	6,94	0,098	3,492	0,024	0,677	0,827	0,143	0,104	0,590	0,735
			0.8	<b>2,00</b>	<b>6,84</b>	<b>0,103</b>	<b>3,649</b>	<b>0,025</b>	<b>0,678</b>	<b>0,849</b>	<b>0,145</b>	<b>0,108</b>	<b>0,591</b>	0,750 +
			0.9	<b>2,00</b>	6,87	0,100	3,503	0,024	0,678	0,845	0,141	0,107	0,589	<b>0,750</b> +
		7	0.6	3,02	7,63	0,122	1,612	0,014	0,603	0,702	0,205	0,105	<b>0,637</b>	0,601
			0.7	3,06	7,59	0,120	1,685	0,015	0,597	0,689	<b>0,213</b>	0,104	0,632	0,568
			0.8	2,12	<b>7,13</b>	<b>0,169</b>	<b>2,312</b>	<b>0,021</b>	<b>0,606</b>	0,796	0,209	<b>0,124</b>	0,606	0,610 +
			0.9	<b>2,00</b>	7,23	0,161	1,905	0,018	0,595	<b>0,802</b>	0,190	0,120	0,601	<b>0,613</b>
Medidas fitness:	3	0.6	2,34	1,58	0,001	0,059	0,000	0,127	0,011	0,855	0,001	0,094	0,026	
		0.7	<b>2,14</b>	<b>1,50</b>	0,001	0,084	0,000	0,107	0,007	<b>0,868</b>	0,001	0,066	0,030	
		0.8	2,52	1,75	<b>0,001</b>	0,078	0,000	0,152	0,015	0,834	<b>0,001</b>	0,152	0,041	
		0.9	2,52	1,77	0,001	<b>0,132</b>	<b>0,001</b>	<b>0,189</b>	<b>0,017</b>	0,800	0,001	<b>0,183</b>	<b>0,062</b> +	
	Fconf y Fcomp	5	0.6	5,22	2,89	<b>0,006</b>	<b>0,527</b>	<b>0,002</b>	<b>0,324</b>	0,044	0,727	0,005	0,329	<b>0,186</b> +
			0.7	4,86	2,84	0,006	0,449	0,001	0,323	<b>0,048</b>	0,710	<b>0,005</b>	<b>0,341</b>	0,174
			0.8	<b>4,48</b>	<b>2,43</b>	0,005	0,382	0,001	0,265	0,036	0,755	0,004	0,255	0,129
			0.9	4,98	2,67	0,004	0,336	0,001	0,271	0,034	<b>0,773</b>	0,004	0,261	0,131
		7	0.6	9,64	3,79	<b>0,007</b>	0,466	0,001	<b>0,382</b>	<b>0,055</b>	0,705	<b>0,006</b>	<b>0,411</b>	0,161
			0.7	8,22	3,52	<b>0,007</b>	<b>0,611</b>	<b>0,002</b>	0,361	0,048	<b>0,734</b>	0,005	0,373	<b>0,213</b> *
			0.8	<b>7,54</b>	3,57	0,007	0,434	0,001	0,345	0,046	0,673	0,005	0,343	0,144
			0.9	10,54	<b>3,52</b>	0,006	0,522	0,002	0,360	0,049	0,732	0,005	0,386	0,202
Medidas fitness:	3	0.6	2,50	2,42	0,009	0,458	0,001	0,240	0,171	0,642	0,018	<b>0,255</b>	0,203	
		0.7	2,64	<b>2,21</b>	0,014	0,425	0,000	0,180	0,175	<b>0,737</b>	0,018	0,200	0,130	
		0.8	<b>2,48</b>	2,46	<b>0,020</b>	<b>0,710</b>	<b>0,003</b>	<b>0,254</b>	<b>0,223</b>	0,640	<b>0,025</b>	0,252	<b>0,232</b> +	
		0.9	2,78	2,45	0,012	0,489	0,001	0,222	0,201	0,694	0,019	0,227	0,168	
	CConf y CComp	5	0.6	29,90	5,23	0,030	1,339	0,004	0,524	0,281	<b>0,420</b>	0,033	0,534	0,413
			0.7	26,50	5,28	<b>0,031</b>	<b>1,451</b>	0,004	<b>0,533</b>	<b>0,285</b>	0,367	<b>0,035</b>	<b>0,550</b>	<b>0,421</b> *
			0.8	25,42	<b>5,14</b>	0,031	1,235	0,004	0,513	0,273	0,401	0,032	0,512	0,390
			0.9	<b>24,10</b>	5,25	0,031	1,385	<b>0,005</b>	0,526	0,283	0,365	0,034	0,534	0,418
		7	0.6	74,90	5,96	<b>0,027</b>	1,060	<b>0,002</b>	<b>0,539</b>	<b>0,223</b>	0,645	<b>0,031</b>	<b>0,579</b>	<b>0,416</b> +
			0.7	72,98	6,04	0,026	<b>1,086</b>	0,002	0,533	0,217	0,632	0,029	0,576	0,398
			0.8	<b>72,18</b>	5,93	0,026	1,063	0,002	0,528	0,222	0,624	0,030	0,566	0,393
			0.9	72,70	<b>5,89</b>	0,027	1,083	0,002	0,523	0,215	<b>0,660</b>	0,029	0,550	0,374

Variables	Continuas	Ejemplos	Clases
8	8	768	2

Tabla A.10 Resumen de la experimentación de SDIGA para Echo con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas fitness:	3	0.6	3,02	2,87	0,325	0,943	0,026	<b>0,606</b>	0,668	<b>0,576</b>	<b>0,212</b>	<b>0,637</b>	0,627	<b>0,877</b>	*	
		0.7	2,62	2,93	0,309	<b>1,058</b>	<b>0,033</b>	0,599	0,654	0,514	0,200	0,632	0,622	0,873		
		0.8	<b>2,00</b>	<b>2,65</b>	0,329	1,003	0,030	0,590	<b>0,704</b>	0,424	0,207	0,594	<b>0,637</b>	0,872		
		0.9	<b>2,00</b>	<b>2,65</b>	<b>0,329</b>	0,997	0,029	0,588	0,702	0,424	0,205	0,591	0,634	0,868		
	FConf, Comp e Interés	5	0.6	3,30	2,36	0,321	1,120	<b>0,022</b>	<b>0,573</b>	0,538	<b>0,570</b>	0,217	<b>0,621</b>	<b>0,567</b>	0,770	+
			0.7	2,32	2,27	0,394	<b>1,165</b>	0,013	0,549	0,566	0,508	0,243	0,590	0,533	<b>0,791</b>	
			0.8	<b>2,00</b>	2,23	0,374	0,855	0,014	0,540	<b>0,587</b>	0,453	0,236	0,593	0,508	0,790	
		0.9	<b>2,00</b>	<b>2,20</b>	<b>0,395</b>	1,096	0,018	0,546	0,584	0,499	<b>0,245</b>	0,582	0,526	0,779		
	7	0.6	3,84	<b>2,26</b>	0,272	0,343	0,007	0,418	0,322	<b>0,722</b>	0,182	0,334	0,287	0,612		
		0.7	3,06	2,57	0,360	0,238	0,011	0,517	0,416	0,672	0,242	0,392	0,355	<b>0,757</b>		
		0.8	<b>2,18</b>	2,27	0,407	<b>0,495</b>	0,010	0,489	0,461	0,632	<b>0,265</b>	0,413	0,384	0,718		
		0.9	2,32	2,32	<b>0,409</b>	0,449	<b>0,014</b>	<b>0,519</b>	<b>0,469</b>	0,626	0,264	<b>0,432</b>	<b>0,417</b>	0,747	+	
Medidas fitness:	3	0.6	3,42	<b>1,86</b>	0,311	0,209	0,012	0,368	0,374	<b>0,856</b>	0,219	0,334	0,311	0,553		
		0.7	2,26	1,88	<b>0,394</b>	0,170	0,017	0,420	<b>0,457</b>	0,787	<b>0,278</b>	0,396	<b>0,377</b>	0,627		
		0.8	2,18	1,96	0,380	0,261	<b>0,023</b>	0,425	0,439	0,778	0,272	0,371	0,365	0,614		
		0.9	<b>2,14</b>	2,04	0,362	<b>0,295</b>	0,022	<b>0,440</b>	0,450	0,740	0,258	<b>0,427</b>	0,368	<b>0,632</b>	+	
	FConf, FComp e Interés	5	0.6	3,32	<b>1,90</b>	0,261	0,172	0,012	0,318	0,292	<b>0,872</b>	0,186	0,288	0,269	0,458	
			0.7	<b>2,36</b>	2,29	<b>0,381</b>	<b>0,346</b>	<b>0,020</b>	<b>0,477</b>	<b>0,447</b>	0,762	<b>0,274</b>	<b>0,459</b>	<b>0,428</b>	0,679	*
			0.8	2,38	2,27	0,381	0,261	0,018	0,470	0,431	0,749	0,273	0,420	0,397	<b>0,679</b>	
		0.9	2,40	2,03	0,369	0,224	0,015	0,410	0,405	0,793	0,263	0,381	0,363	0,593		
	7	0.6	3,64	<b>2,29</b>	0,255	0,181	0,012	0,391	0,283	<b>0,762</b>	0,183	0,283	0,265	0,545		
		0.7	3,06	2,55	0,331	<b>0,254</b>	<b>0,016</b>	0,476	0,369	0,741	0,235	0,370	0,353	0,674		
		0.8	2,80	2,52	0,355	0,225	0,016	0,489	0,386	0,727	0,252	0,356	0,350	0,702		
		0.9	<b>2,38</b>	2,50	<b>0,356</b>	0,250	0,016	<b>0,502</b>	<b>0,392</b>	0,666	<b>0,253</b>	<b>0,384</b>	<b>0,366</b>	<b>0,710</b>	+	
Medidas fitness:	3	0.6	4,72	3,04	0,070	0,898	0,021	0,449	0,267	0,639	0,051	0,436	0,378	0,705		
		0.7	<b>4,52</b>	<b>2,89</b>	0,062	0,793	0,016	0,403	0,239	<b>0,669</b>	0,044	0,375	0,306	0,653		
		0.8	4,72	3,02	<b>0,087</b>	<b>0,991</b>	<b>0,023</b>	<b>0,460</b>	<b>0,289</b>	0,663	<b>0,062</b>	<b>0,463</b>	<b>0,395</b>	<b>0,725</b>	*	
		0.9	4,54	2,96	0,068	0,801	0,016	0,416	0,257	0,654	0,045	0,387	0,338	0,681		
	CConf, CComp e Interés	5	0.6	<b>10,48</b>	3,68	<b>0,039</b>	0,457	0,007	0,508	0,122	0,352	0,027	0,342	0,219	0,757	
			0.7	11,00	3,68	0,039	<b>0,496</b>	<b>0,007</b>	0,505	<b>0,130</b>	<b>0,373</b>	0,028	<b>0,369</b>	<b>0,224</b>	0,752	+
			0.8	11,38	<b>3,65</b>	0,039	0,467	0,006	0,511	0,128	0,366	<b>0,028</b>	0,367	0,220	0,760	
		0.9	11,42	3,66	0,035	0,437	0,007	<b>0,513</b>	0,115	0,344	0,025	0,332	0,212	<b>0,764</b>		
	7	0.6	<b>8,86</b>	3,38	<b>0,034</b>	<b>0,526</b>	<b>0,008</b>	0,491	<b>0,092</b>	<b>0,386</b>	<b>0,024</b>	0,294	<b>0,219</b>	0,684	+	
		0.7	8,88	3,45	0,034	0,522	0,007	<b>0,503</b>	0,092	0,316	0,023	<b>0,304</b>	0,208	<b>0,695</b>		
		0.8	9,34	<b>3,35</b>	0,029	0,432	0,008	0,487	0,085	0,385	0,021	0,269	0,175	0,676		
		0.9	9,38	3,51	0,027	0,388	0,005	0,487	0,073	0,342	0,018	0,254	0,146	0,693		

Variables	Continuas	Ejemplos	Clases
6	5	131	2

Tabla A.11 Resumen de la experimentación de SDIGA para Echo con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas <i>fitness</i> :	3	0.6	<b>2,00</b>	3,92	0,315	1,219	0,036	0,584	0,832	0,422	0,189	0,561	0,573		
		0.7	<b>2,00</b>	3,92	0,315	1,219	0,036	0,584	0,832	0,422	0,189	0,561	0,573		
		0.8	<b>2,00</b>	3,93	0,314	<b>1,226</b>	0,035	0,582	0,830	0,420	0,188	0,558	0,568		
		0.9	<b>2,00</b>	<b>3,91</b>	<b>0,315</b>	1,212	<b>0,036</b>	<b>0,586</b>	<b>0,834</b>	<b>0,423</b>	<b>0,189</b>	<b>0,564</b>	<b>0,578</b>	+	
	FConf y Comp	5	0.6	<b>2,00</b>	4,94	<b>0,272</b>	1,394	0,038	0,599	<b>0,750</b>	0,379	<b>0,167</b>	<b>0,614</b>	0,593	
			0.7	2,02	<b>4,88</b>	0,268	1,419	0,038	0,598	0,744	0,375	0,166	0,605	0,590	
			0.8	2,02	4,97	0,267	<b>1,456</b>	<b>0,043</b>	<b>0,607</b>	0,744	<b>0,385</b>	0,166	0,608	<b>0,599</b>	*
			0.9	<b>2,00</b>	4,96	0,263	1,344	0,036	0,593	0,738	0,365	0,163	0,607	0,578	
		7	0.6	2,16	5,34	0,267	1,155	0,024	0,568	0,739	0,345	0,151	0,597	0,582	
			0.7	2,18	<b>5,18</b>	0,282	1,125	<b>0,030</b>	0,575	0,749	<b>0,373</b>	0,158	0,593	0,613	
			0.8	2,08	5,30	<b>0,283</b>	1,116	0,028	0,567	0,767	0,346	0,159	0,598	0,599	
			0.9	<b>2,00</b>	5,32	0,282	<b>1,269</b>	0,029	<b>0,576</b>	<b>0,789</b>	0,354	<b>0,162</b>	<b>0,606</b>	<b>0,617</b>	+
Medidas <i>fitness</i> :	3	0.6	2,16	1,48	0,001	0,007	0,000	0,100	0,006	0,878	0,000	0,019	0,000		
		0.7	2,24	1,48	0,001	0,023	<b>0,000</b>	0,097	0,006	0,911	0,001	0,026	0,009		
		0.8	2,34	1,58	<b>0,004</b>	<b>0,035</b>	0,000	<b>0,108</b>	<b>0,017</b>	0,876	<b>0,002</b>	<b>0,051</b>	<b>0,009</b>	+	
		0.9	<b>2,06</b>	<b>1,34</b>	0,003	0,020	0,000	0,060	0,010	<b>0,924</b>	0,001	0,014	0,003		
	Fconf y Fcomp	5	0.6	2,40	1,71	0,010	0,166	0,002	0,122	0,046	0,884	0,007	<b>0,121</b>	0,066	
			0.7	<b>2,12</b>	<b>1,38</b>	0,005	0,043	0,001	0,062	0,029	<b>0,929</b>	0,004	0,057	0,023	
			0.8	2,62	1,76	0,011	0,164	0,003	0,140	0,046	0,878	0,007	0,113	0,064	
			0.9	2,24	1,81	<b>0,012</b>	<b>0,192</b>	<b>0,005</b>	<b>0,152</b>	<b>0,049</b>	0,852	<b>0,009</b>	0,120	<b>0,088</b>	+
		7	0.6	4,48	2,72	0,015	0,247	0,005	<b>0,253</b>	0,062	0,832	0,010	0,167	0,099	
			0.7	<b>3,60</b>	2,55	<b>0,030</b>	<b>0,352</b>	<b>0,008</b>	0,233	<b>0,085</b>	0,840	<b>0,016</b>	<b>0,183</b>	<b>0,129</b>	*
			0.8	4,10	2,69	0,021	0,315	0,006	0,246	0,066	0,830	0,012	0,181	0,126	
			0.9	3,88	<b>2,48</b>	0,016	0,242	0,005	0,221	0,066	<b>0,845</b>	0,010	0,181	0,112	
Medidas <i>fitness</i> :	3	0.6	<b>2,10</b>	<b>1,47</b>	0,016	0,179	0,005	0,106	0,076	0,911	0,010	0,077	0,075		
		0.7	2,18	1,53	0,026	0,225	0,005	0,106	0,105	<b>0,921</b>	0,012	0,085	0,091		
		0.8	2,12	1,61	0,028	0,320	0,007	0,130	0,110	0,870	0,019	0,116	0,129		
		0.9	2,18	1,68	<b>0,033</b>	<b>0,437</b>	<b>0,012</b>	<b>0,163</b>	<b>0,156</b>	0,885	<b>0,024</b>	<b>0,149</b>	<b>0,175</b>	+	
	CConf y CComp	5	0.6	<b>7,30</b>	4,39	<b>0,102</b>	<b>0,785</b>	0,012	<b>0,514</b>	<b>0,302</b>	0,443	<b>0,063</b>	<b>0,500</b>	<b>0,396</b>	+
			0.7	7,50	4,32	0,077	0,713	0,008	0,469	0,268	0,494	0,048	0,426	0,297	
			0.8	7,94	4,22	0,081	0,731	<b>0,014</b>	0,492	0,277	0,515	0,057	0,467	0,345	
			0.9	7,50	<b>4,18</b>	0,088	0,746	0,013	0,480	0,280	<b>0,548</b>	0,057	0,468	0,359	
		7	0.6	<b>15,60</b>	4,74	0,081	0,711	<b>0,011</b>	0,519	0,264	0,617	0,054	0,488	0,340	
			0.7	<b>15,60</b>	<b>4,71</b>	0,082	0,703	0,010	0,521	0,272	<b>0,624</b>	0,055	0,502	0,358	
			0.8	16,90	4,79	<b>0,088</b>	<b>0,720</b>	0,010	<b>0,536</b>	<b>0,293</b>	0,592	<b>0,059</b>	<b>0,508</b>	<b>0,375</b>	*
			0.9	15,86	4,73	0,082	0,702	0,007	0,509	0,245	0,575	0,051	0,453	0,325	

Variables	Continuas	Ejemplos	Clases
6	5	131	2

Tabla A.12 Resumen de la experimentación de SDIGA para German con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	8,56	4,40	<b>0,082</b>	<b>0,615</b>	<b>0,006</b>	<b>0,555</b>	<b>0,177</b>	0,363	<b>0,060</b>	0,313	<b>0,270</b>	<b>0,982</b>	*	
		0.7	9,48	<b>4,32</b>	0,078	0,487	0,005	0,548	0,170	<b>0,378</b>	0,055	<b>0,313</b>	0,258	0,979		
		0.8	8,68	4,58	0,057	0,386	0,003	0,530	0,128	0,181	0,038	0,259	0,197	0,980		
		0.9	<b>8,18</b>	4,60	0,050	0,363	0,003	0,524	0,111	0,155	0,035	0,261	0,170	0,979		
	FConf, Comp e Interés	5	0.6	4,82	<b>3,13</b>	<b>0,138</b>	0,353	<b>0,002</b>	0,414	<b>0,193</b>	<b>0,708</b>	<b>0,077</b>	0,243	0,221	0,752	+
			0.7	5,68	3,45	0,103	0,258	0,001	0,408	0,146	0,671	0,057	0,178	0,152	0,764	
			0.8	5,44	3,90	0,076	<b>0,398</b>	0,002	<b>0,486</b>	0,116	0,313	0,041	<b>0,255</b>	<b>0,229</b>	<b>0,879</b>	
			0.9	<b>4,38</b>	3,76	0,103	0,317	0,001	0,443	0,118	0,349	0,042	0,210	0,160	0,865	
		7	0.6	4,00	2,71	0,259	0,244	<b>0,003</b>	0,371	0,274	0,827	<b>0,128</b>	<b>0,221</b>	<b>0,218</b>	0,710	+
			0.7	3,36	<b>2,49</b>	0,242	<b>0,269</b>	0,002	0,328	0,258	<b>0,840</b>	0,110	0,193	0,194	0,646	
			0.8	2,86	3,17	0,213	0,221	0,002	<b>0,407</b>	0,221	0,510	0,093	0,211	0,198	<b>0,786</b>	
			0.9	<b>2,58</b>	2,83	<b>0,263</b>	0,237	0,002	0,372	<b>0,275</b>	0,573	0,107	0,203	0,203	0,739	
Medidas <i>fitness</i> :	3	0.6	14,42	4,39	0,023	0,326	0,001	0,474	0,028	0,642	0,015	0,196	0,133	0,912		
		0.7	13,08	<b>4,31</b>	<b>0,028</b>	0,312	<b>0,001</b>	0,476	<b>0,033</b>	<b>0,665</b>	<b>0,019</b>	0,199	0,148	0,902	+	
		0.8	13,38	4,58	0,006	0,290	0,000	0,497	0,012	0,147	0,004	0,220	0,126	0,954		
		0.9	<b>12,78</b>	4,62	0,007	<b>0,328</b>	0,001	<b>0,509</b>	0,012	0,126	0,005	<b>0,233</b>	<b>0,153</b>	<b>0,965</b>		
	FConf, FComp e Interés	5	0.6	5,86	3,19	0,123	<b>0,288</b>	0,001	0,379	0,127	0,728	0,054	0,180	0,172	0,734	
			0.7	5,78	<b>3,16</b>	0,133	0,262	<b>0,002</b>	0,396	0,139	<b>0,788</b>	0,060	<b>0,208</b>	<b>0,192</b>	0,746	+
			0.8	<b>5,24</b>	3,57	0,103	0,266	0,001	0,436	0,106	0,436	0,048	0,183	0,176	0,838	
			0.9	5,46	3,66	<b>0,158</b>	0,258	0,001	<b>0,456</b>	<b>0,160</b>	0,329	<b>0,072</b>	0,186	0,181	<b>0,900</b>	
		7	0.6	3,50	2,48	<b>0,282</b>	<b>0,233</b>	<b>0,003</b>	0,341	<b>0,287</b>	0,834	<b>0,126</b>	<b>0,230</b>	<b>0,226</b>	0,667	*
			0.7	3,08	<b>2,39</b>	0,224	0,127	0,002	0,298	0,229	<b>0,838</b>	0,101	0,172	0,164	0,597	
			0.8	3,04	2,90	0,185	0,188	0,001	<b>0,388</b>	0,189	0,514	0,079	0,181	0,182	<b>0,766</b>	
			0.9	<b>2,52</b>	2,72	0,198	0,164	0,001	0,319	0,201	0,606	0,077	0,151	0,151	0,660	
Medidas <i>fitness</i> :	3	0.6	14,74	4,41	<b>0,010</b>	0,677	<b>0,001</b>	<b>0,534</b>	0,042	0,146	<b>0,009</b>	0,501	<b>0,374</b>	0,969	*	
		0.7	14,16	4,42	0,010	<b>0,704</b>	0,000	0,522	<b>0,044</b>	0,150	0,009	<b>0,511</b>	0,335	0,969		
		0.8	14,82	4,57	0,009	0,687	0,001	0,526	0,039	0,142	0,009	0,486	0,351	<b>0,972</b>		
		0.9	<b>12,86</b>	<b>4,39</b>	0,010	0,671	0,001	0,516	0,038	<b>0,153</b>	0,009	0,485	0,345	0,950		
	CConf, CComp e Interés	5	0.6	<b>6,20</b>	<b>3,40</b>	<b>0,008</b>	0,493	0,001	0,446	<b>0,012</b>	0,231	0,005	0,258	0,227	0,815	
			0.7	6,80	3,41	0,007	0,360	0,001	0,438	0,010	<b>0,300</b>	0,005	0,236	0,216	0,803	
			0.8	7,26	3,45	0,007	0,487	0,001	0,457	0,011	0,252	0,005	<b>0,282</b>	<b>0,260</b>	0,818	
			0.9	7,34	3,45	0,007	<b>0,514</b>	<b>0,001</b>	<b>0,464</b>	0,011	0,231	<b>0,005</b>	0,273	0,246	<b>0,838</b>	+
		7	0.6	<b>3,94</b>	3,04	<b>0,007</b>	<b>0,439</b>	<b>0,001</b>	0,402	<b>0,010</b>	0,291	<b>0,005</b>	<b>0,264</b>	<b>0,257</b>	0,712	
			0.7	5,26	3,22	0,006	0,434	0,001	<b>0,417</b>	0,009	<b>0,324</b>	0,005	0,237	0,227	<b>0,742</b>	+
			0.8	4,34	<b>2,99</b>	0,005	0,334	0,000	0,378	0,006	0,323	0,003	0,190	0,190	0,680	
			0.9	4,24	3,11	0,005	0,388	0,001	0,411	0,008	0,282	0,004	0,216	0,207	0,734	

Variables	Continuas	Ejemplos	Clases
20	7	1000	2

Tabla A.13 Resumen de la experimentación de SDIGA para German con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas fitness:	3	0.6	32,40	7,12	0,018	0,862	0,002	0,512	0,058	0,295	0,015	0,269	0,250		
		0.7	29,20	7,11	0,020	0,836	0,003	0,512	0,066	<b>0,302</b>	0,016	0,277	0,241		
		0.8	<b>25,98</b>	<b>7,04</b>	<b>0,027</b>	<b>0,875</b>	<b>0,004</b>	<b>0,521</b>	<b>0,085</b>	0,200	<b>0,020</b>	<b>0,309</b>	<b>0,280</b>	*	
		0.9	29,30	7,13	0,016	0,796	0,002	0,507	0,049	0,238	0,012	0,270	0,238		
	FConf y Comp	5	0.6	<b>28,24</b>	<b>7,49</b>	<b>0,024</b>	0,586	<b>0,002</b>	<b>0,514</b>	<b>0,069</b>	<b>0,319</b>	<b>0,017</b>	<b>0,279</b>	<b>0,223</b>	+
			0.7	33,62	7,55	0,016	<b>0,638</b>	0,001	0,507	0,047	0,302	0,012	0,272	0,213	
			0.8	30,78	7,56	0,015	0,565	0,001	0,506	0,036	0,217	0,009	0,255	0,197	
			0.9	32,76	7,67	0,011	0,607	0,001	0,498	0,031	0,186	0,007	0,256	0,188	
		7	0.6	26,44	<b>7,58</b>	0,030	0,656	0,002	0,500	0,069	<b>0,398</b>	0,020	0,257	0,214	
			0.7	26,78	7,73	0,037	<b>0,711</b>	0,002	<b>0,507</b>	0,077	0,392	0,023	<b>0,275</b>	0,232	
			0.8	27,32	7,77	0,022	0,681	0,001	0,499	0,048	0,265	0,013	0,251	0,211	
			0.9	<b>23,46</b>	7,58	<b>0,052</b>	0,692	<b>0,003</b>	0,502	<b>0,108</b>	0,305	<b>0,030</b>	0,273	<b>0,236</b>	+
Medidas fitness:		3	0.6	37,40	6,97	0,007	<b>0,723</b>	0,001	0,482	0,013	0,791	0,003	<b>0,241</b>	<b>0,216</b>	+
			0.7	35,72	<b>6,81</b>	0,007	0,716	<b>0,001</b>	0,478	0,013	<b>0,796</b>	0,003	0,237	0,216	
			0.8	<b>34,10</b>	7,08	0,007	0,708	0,001	<b>0,486</b>	0,012	0,385	0,003	0,226	0,207	
			0.9	34,50	6,96	<b>0,008</b>	0,713	0,001	0,480	<b>0,013</b>	0,428	<b>0,003</b>	0,230	0,208	
	Fconf y Fcomp	5	0.6	35,64	7,29	<b>0,007</b>	0,662	0,001	0,480	0,012	0,779	0,003	0,234	0,208	
			0.7	35,06	<b>7,17</b>	0,007	<b>0,715</b>	<b>0,001</b>	0,483	<b>0,013</b>	<b>0,786</b>	<b>0,003</b>	<b>0,243</b>	<b>0,219</b>	*
			0.8	33,96	7,29	0,007	0,669	0,001	0,487	0,011	0,400	0,003	0,223	0,202	
			0.9	<b>33,60</b>	7,30	0,007	0,692	0,001	<b>0,489</b>	0,013	0,473	0,003	0,239	0,216	
	7	0.6	28,76	7,12	0,008	0,675	<b>0,001</b>	0,462	<b>0,013</b>	<b>0,781</b>	0,004	0,235	0,217	+	
		0.7	<b>26,28</b>	<b>7,12</b>	<b>0,008</b>	0,666	0,001	0,450	0,013	0,776	0,004	0,229	0,216		
		0.8	29,46	7,35	0,008	<b>0,703</b>	0,001	0,474	0,013	0,503	<b>0,004</b>	<b>0,247</b>	<b>0,234</b>		
		0.9	30,24	7,46	0,008	0,698	0,001	<b>0,477</b>	0,013	0,414	0,004	0,231	0,214		
CConf y CComp	3	0.6	79,70	7,38	<b>0,019</b>	1,072	0,002	<b>0,586</b>	<b>0,050</b>	0,599	<b>0,016</b>	<b>0,588</b>	<b>0,521</b>	+	
		0.7	79,64	7,43	0,019	1,071	0,002	0,583	0,048	<b>0,615</b>	0,016	0,577	0,512		
		0.8	83,22	<b>7,37</b>	0,019	<b>1,090</b>	<b>0,002</b>	0,581	0,049	0,598	0,015	0,568	0,508		
		0.9	<b>78,92</b>	7,41	0,019	1,042	0,002	0,580	0,048	0,573	0,015	0,559	0,494		
	5	0.6	37,30	7,74	<b>0,023</b>	<b>1,103</b>	<b>0,003</b>	<b>0,596</b>	<b>0,056</b>	0,423	<b>0,017</b>	0,604	<b>0,546</b>	+	
		0.7	36,74	<b>7,70</b>	0,021	1,082	0,002	0,581	0,053	0,441	0,016	0,578	0,526		
		0.8	<b>35,34</b>	7,77	0,022	1,090	0,002	0,594	0,054	0,406	0,017	<b>0,605</b>	0,537		
		0.9	41,34	7,70	0,021	1,043	0,002	0,590	0,053	<b>0,442</b>	0,016	0,595	0,534		
	7	0.6	24,26	7,73	0,022	0,986	0,002	0,569	0,046	<b>0,373</b>	0,015	0,554	0,494		
		0.7	<b>23,58</b>	7,69	<b>0,023</b>	<b>1,111</b>	<b>0,002</b>	<b>0,580</b>	<b>0,047</b>	0,356	<b>0,016</b>	<b>0,581</b>	<b>0,547</b>	+	
		0.8	26,88	7,73	0,022	1,054	0,002	0,578	0,046	0,363	0,016	0,573	0,519		
		0.9	23,70	<b>7,65</b>	0,020	1,104	0,002	0,563	0,044	0,371	0,014	0,543	0,497		

Variables	Continuas	Ejemplos	Clases
20	7	1000	2

Tabla A.14 Resumen de la experimentación de SDIGA para Heart con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas fitness:	3	0.6	3,30	3,01	0,367	1,468	0,045	0,606	0,665	<b>0,667</b>	0,225	0,569	0,578	0,895		
		0.7	2,76	2,68	0,438	1,516	0,047	0,603	0,747	0,646	0,256	0,615	0,597	<b>0,896</b>		
		0.8	<b>2,00</b>	<b>2,27</b>	<b>0,504</b>	<b>1,790</b>	<b>0,059</b>	<b>0,614</b>	<b>0,852</b>	0,616	<b>0,300</b>	<b>0,616</b>	<b>0,632</b>	0,886	+	
		0.9	<b>2,00</b>	2,36	0,486	1,731	0,058	0,613	0,833	0,596	0,291	0,593	0,622	0,890		
	FConf, Comp e Interés	5	0.6	2,72	2,16	0,371	1,321	0,048	0,525	0,538	<b>0,695</b>	0,232	0,502	0,493	0,710	
			0.7	2,60	2,16	0,391	<b>1,556</b>	<b>0,054</b>	<b>0,570</b>	<b>0,591</b>	0,667	<b>0,250</b>	<b>0,563</b>	<b>0,545</b>	<b>0,751</b>	+
			0.8	<b>2,02</b>	<b>2,09</b>	<b>0,402</b>	1,277	0,048	0,517	0,559	0,647	0,246	0,500	0,499	0,715	
		0.9	2,04	2,18	0,368	1,047	0,041	0,512	0,520	0,584	0,226	0,494	0,468	0,735		
	7	0.6	3,70	2,09	0,418	1,953	0,059	0,572	0,575	<b>0,824</b>	0,273	0,591	0,585	0,749		
		0.7	2,60	2,09	0,469	2,108	0,068	0,572	0,622	0,764	0,305	0,572	0,568	0,775		
		0.8	<b>2,00</b>	<b>1,90</b>	<b>0,507</b>	2,012	0,066	0,559	0,665	0,741	0,319	0,577	0,572	0,762		
		0.9	<b>2,00</b>	2,08	0,501	<b>2,426</b>	<b>0,078</b>	<b>0,621</b>	<b>0,678</b>	0,690	<b>0,330</b>	<b>0,628</b>	<b>0,616</b>	<b>0,812</b>	*	
Medidas fitness:	3	0.6	3,96	2,95	0,392	1,869	0,064	0,608	0,569	<b>0,789</b>	0,268	0,555	0,516	0,887		
		0.7	3,36	2,73	0,426	2,357	0,076	<b>0,651</b>	0,632	0,744	0,300	0,627	<b>0,632</b>	0,888		
		0.8	2,06	<b>2,39</b>	0,465	<b>2,460</b>	<b>0,082</b>	0,642	<b>0,694</b>	0,655	<b>0,326</b>	<b>0,632</b>	0,613	0,877	+	
		0.9	<b>2,00</b>	2,54	<b>0,470</b>	2,112	0,076	0,630	0,675	<b>0,627</b>	0,320	0,619	0,572	<b>0,891</b>		
	FConf, FComp e Interés	5	0.6	4,08	2,40	0,453	1,913	0,071	<b>0,615</b>	0,599	<b>0,821</b>	0,307	<b>0,606</b>	<b>0,569</b>	<b>0,841</b>	
			0.7	2,98	2,35	0,445	2,315	<b>0,075</b>	0,600	0,595	0,776	0,302	0,575	0,563	0,809	
			0.8	<b>2,04</b>	2,25	<b>0,500</b>	2,085	0,075	0,593	<b>0,653</b>	0,719	<b>0,327</b>	0,594	0,560	0,819	
		0.9	2,06	<b>2,25</b>	0,446	<b>2,523</b>	0,074	0,597	0,597	0,667	0,298	0,565	0,548	0,815	+	
	7	0.6	3,08	2,09	0,505	2,173	0,076	0,598	0,656	<b>0,840</b>	0,335	<b>0,592</b>	<b>0,592</b>	0,818		
		0.7	2,64	2,08	0,496	2,399	0,076	0,588	0,646	0,801	0,326	0,591	0,584	0,789		
		0.8	<b>2,00</b>	<b>1,99</b>	0,497	2,042	0,066	0,571	0,630	0,737	0,314	0,584	0,582	0,789		
		0.9	<b>2,00</b>	2,07	<b>0,523</b>	<b>2,507</b>	<b>0,078</b>	<b>0,599</b>	<b>0,679</b>	0,743	<b>0,339</b>	0,586	0,586	<b>0,820</b>	*	
Medidas fitness:	3	0.6	18,02	4,41	0,051	1,294	0,015	0,581	0,195	0,500	0,045	0,610	0,487	0,893		
		0.7	18,60	<b>4,35</b>	0,053	<b>1,318</b>	<b>0,016</b>	<b>0,590</b>	<b>0,207</b>	0,504	<b>0,049</b>	<b>0,634</b>	<b>0,509</b>	0,891	*	
		0.8	<b>17,10</b>	4,42	<b>0,056</b>	1,290	0,016	0,583	0,207	0,476	0,049	0,608	0,498	<b>0,895</b>		
		0.9	17,34	4,37	0,052	1,297	0,015	0,571	0,190	<b>0,518</b>	0,046	0,611	0,477	0,880		
	CConf, CComp e Interés	5	0.6	2,98	2,59	0,032	0,699	<b>0,008</b>	<b>0,359</b>	0,070	0,504	<b>0,022</b>	0,323	<b>0,295</b>	<b>0,540</b>	
			0.7	2,96	2,46	0,024	0,582	0,006	0,309	0,061	0,570	0,016	0,278	0,226	0,474	
			0.8	<b>2,86</b>	2,68	0,029	0,579	0,006	0,348	<b>0,075</b>	0,496	0,020	<b>0,323</b>	0,270	0,525	
		0.9	3,00	<b>2,39</b>	<b>0,032</b>	<b>0,785</b>	0,008	0,312	0,069	<b>0,609</b>	0,022	0,319	0,294	0,458	+	
	7	0.6	2,36	2,03	0,019	0,295	0,002	0,205	0,038	0,665	0,011	0,133	0,113	<b>0,337</b>		
		0.7	<b>2,12</b>	1,78	<b>0,028</b>	<b>0,484</b>	<b>0,006</b>	<b>0,210</b>	<b>0,056</b>	0,695	<b>0,019</b>	<b>0,177</b>	<b>0,173</b>	0,305	+	
		0.8	2,22	<b>1,69</b>	0,014	0,352	0,003	0,162	0,038	<b>0,762</b>	0,011	0,156	0,131	0,241		
		0.9	2,34	1,97	0,025	0,432	0,004	0,209	0,045	0,698	0,016	0,161	0,143	0,323		

Variables	Continuas	Ejemplos	Clases
13	7	270	2

Tabla A.15 Resumen de la experimentación de SDIGA para Heart con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas fitness:	3	0.6	2,28	3,41	0,423	2,220	0,079	0,651	0,887	0,626	0,319	<b>0,606</b>	0,659		
		0.7	2,02	3,47	0,436	2,389	0,082	0,654	0,963	0,596	0,333	0,602	0,664		
		0.8	<b>2,00</b>	3,36	0,457	<b>2,426</b>	0,083	<b>0,657</b>	0,968	0,619	0,343	0,601	0,682	+	
		0.9	<b>2,00</b>	<b>3,29</b>	<b>0,464</b>	2,359	<b>0,083</b>	0,655	<b>0,971</b>	<b>0,627</b>	<b>0,347</b>	0,602	<b>0,685</b>		
	FConf y Comp	5	0.6	3,00	4,68	0,266	2,758	0,064	0,669	0,722	<b>0,526</b>	0,190	0,592	0,659	
			0.7	2,82	4,37	0,284	2,437	0,064	0,661	0,742	0,525	0,200	0,584	0,655	
			0.8	<b>2,00</b>	4,09	0,322	2,820	0,071	0,679	0,898	0,467	0,227	0,605	0,734	
			0.9	<b>2,00</b>	<b>3,93</b>	<b>0,344</b>	<b>3,056</b>	<b>0,079</b>	<b>0,689</b>	<b>0,932</b>	0,506	<b>0,245</b>	<b>0,617</b>	<b>0,744</b>	*
		7	0.6	3,46	6,06	0,168	<b>1,276</b>	0,017	<b>0,585</b>	0,602	0,306	0,109	<b>0,629</b>	0,583	
			0.7	3,42	5,92	0,170	1,165	0,017	0,575	0,588	<b>0,307</b>	0,108	0,617	0,540	
			0.8	2,04	<b>5,65</b>	0,233	1,179	0,019	0,566	0,782	0,263	<b>0,140</b>	0,580	<b>0,591</b>	+
			0.9	<b>2,02</b>	5,68	<b>0,234</b>	1,115	<b>0,019</b>	0,566	<b>0,783</b>	0,264	0,138	0,588	0,584	
Medidas fitness:	3	0.6	2,10	1,22	0,108	<b>0,044</b>	-0,001	0,080	0,108	<b>0,974</b>	0,055	0,088	<b>0,079</b>		
		0.7	2,08	1,19	0,111	0,026	<b>0,000</b>	0,079	0,111	0,971	0,057	0,077	0,076		
		0.8	<b>2,00</b>	1,23	<b>0,128</b>	0,008	-0,001	<b>0,087</b>	<b>0,128</b>	0,956	<b>0,065</b>	<b>0,089</b>	0,077	+	
		0.9	<b>2,00</b>	<b>1,15</b>	<b>0,128</b>	0,008	-0,001	0,077	0,126	<b>0,974</b>	0,065	0,078	0,077		
	Fconf y Fcomp	5	0.6	2,12	1,39	0,115	0,024	<b>0,000</b>	0,093	0,114	<b>0,953</b>	0,060	0,075	0,074	
			0.7	2,02	1,37	0,123	0,023	-0,001	<b>0,099</b>	0,123	0,935	0,063	0,091	0,081	
			0.8	<b>2,00</b>	<b>1,25</b>	<b>0,129</b>	<b>0,052</b>	-0,001	0,094	<b>0,129</b>	0,949	<b>0,066</b>	<b>0,097</b>	<b>0,097</b>	+
			0.9	<b>2,00</b>	1,29	0,128	0,024	-0,001	0,094	0,127	0,944	0,065	0,087	0,087	
		7	0.6	2,48	2,09	0,339	<b>0,390</b>	0,020	<b>0,311</b>	0,377	<b>0,930</b>	0,205	<b>0,323</b>	<b>0,299</b>	*
			0.7	2,08	1,95	<b>0,341</b>	0,370	<b>0,021</b>	0,305	<b>0,381</b>	0,876	<b>0,206</b>	0,295	0,284	
			0.8	2,04	<b>1,77</b>	0,326	0,279	0,019	0,281	0,363	0,896	0,196	0,280	0,280	
			0.9	<b>2,00</b>	1,92	0,332	0,359	0,018	0,290	0,367	0,868	0,197	0,289	0,284	
Medidas fitness:	3	0.6	<b>27,92</b>	5,04	<b>0,069</b>	<b>1,747</b>	0,022	0,613	<b>0,266</b>	0,713	<b>0,062</b>	0,685	0,578		
		0.7	29,48	5,03	0,068	1,704	<b>0,023</b>	<b>0,620</b>	0,263	0,723	0,062	<b>0,691</b>	<b>0,586</b>	*	
		0.8	29,92	<b>5,01</b>	0,067	1,666	0,021	0,611	0,257	0,715	0,060	0,663	0,571		
		0.9	29,52	5,01	0,068	1,703	0,022	0,613	0,255	<b>0,739</b>	0,060	0,668	0,573		
	CConf y CComp	5	0.6	30,72	5,47	0,063	1,539	0,019	0,607	0,218	0,756	0,051	0,668	0,557	
			0.7	30,10	<b>5,41</b>	<b>0,069</b>	1,606	0,021	0,610	<b>0,230</b>	<b>0,767</b>	<b>0,055</b>	0,676	0,580	
			0.8	29,78	5,45	0,065	1,552	0,019	0,603	0,229	0,727	0,052	0,667	0,557	
			0.9	<b>29,66</b>	5,51	0,066	<b>1,639</b>	<b>0,021</b>	<b>0,615</b>	0,224	0,742	0,053	<b>0,685</b>	<b>0,586</b>	+
		7	0.6	28,36	<b>5,61</b>	0,065	1,507	0,018	0,598	0,208	0,727	0,050	0,661	0,541	
			0.7	29,84	5,61	<b>0,068</b>	1,615	0,020	0,609	0,210	0,748	0,052	<b>0,686</b>	<b>0,578</b>	+
			0.8	29,38	5,64	0,068	1,618	<b>0,020</b>	<b>0,610</b>	<b>0,214</b>	<b>0,751</b>	<b>0,053</b>	0,677	0,574	
			0.9	<b>28,12</b>	5,61	0,068	<b>1,624</b>	0,020	0,608	0,210	0,735	0,053	0,673	0,567	

Variables	Continuas	Ejemplos	Clases
13	7	270	2

Tabla A.16 Resumen de la experimentación de SDIGA para Hepatitis con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	5,64	4,85	0,162	0,744	0,014	0,602	0,365	0,525	0,133	0,545	0,426	0,996		
		0.7	5,56	4,85	0,154	0,746	0,014	0,604	0,372	0,514	0,128	0,559	0,438	0,991		
		0.8	5,16	<b>4,63</b>	0,187	0,813	0,017	<b>0,623</b>	0,415	<b>0,536</b>	0,153	<b>0,582</b>	<b>0,481</b>	<b>0,997</b>	*	
		0.9	<b>2,68</b>	4,96	<b>0,235</b>	<b>0,875</b>	<b>0,019</b>	0,619	<b>0,550</b>	0,433	<b>0,180</b>	0,582	0,464	0,964		
	FConf, Comp e Interés	5	0.6	5,14	4,41	0,201	<b>0,782</b>	0,016	0,533	0,332	<b>0,774</b>	0,164	0,428	0,357	0,884	
			0.7	5,02	<b>4,27</b>	0,165	0,661	0,014	0,511	0,285	0,757	0,140	0,401	0,314	0,873	
			0.8	4,34	4,41	<b>0,255</b>	0,722	<b>0,019</b>	<b>0,579</b>	<b>0,383</b>	0,753	<b>0,217</b>	<b>0,445</b>	<b>0,377</b>	<b>0,934</b>	+
			0.9	<b>3,74</b>	4,56	0,223	0,526	0,016	0,565	0,365	0,653	0,192	0,403	0,339	0,930	
		7	0.6	5,40	4,17	0,211	0,708	0,018	0,521	0,311	<b>0,809</b>	0,166	0,394	0,342	0,884	
			0.7	5,22	<b>4,00</b>	0,211	<b>0,711</b>	0,018	0,528	0,324	0,799	0,169	<b>0,430</b>	<b>0,381</b>	0,880	
			0.8	4,90	4,24	0,239	0,709	0,018	0,553	0,331	0,777	0,187	0,397	0,380	<b>0,938</b>	
			0.9	<b>3,28</b>	4,27	<b>0,266</b>	0,673	<b>0,019</b>	<b>0,555</b>	<b>0,382</b>	0,697	<b>0,212</b>	0,414	0,380	0,930	+
Medidas <i>fitness</i> :	3	0.6	6,24	3,96	0,230	0,588	0,019	0,518	0,293	0,840	0,173	0,344	0,323	0,900		
		0.7	5,22	<b>3,61</b>	0,308	<b>0,673</b>	<b>0,024</b>	0,538	0,386	<b>0,843</b>	<b>0,233</b>	0,405	<b>0,384</b>	0,890	+	
		0.8	5,38	4,39	0,265	0,636	0,018	<b>0,565</b>	0,338	0,772	0,202	<b>0,406</b>	0,360	<b>0,972</b>		
		0.9	<b>4,02</b>	3,96	<b>0,314</b>	0,659	0,024	0,531	<b>0,420</b>	0,738	0,213	0,393	0,351	0,953		
	FConf, FComp e Interés	5	0.6	4,76	3,78	0,255	0,632	0,019	0,488	0,331	<b>0,831</b>	0,187	0,348	0,329	0,851	
			0.7	4,74	<b>3,69</b>	0,279	0,725	0,021	0,496	0,350	0,816	0,203	0,389	0,373	0,852	
			0.8	4,34	3,92	<b>0,330</b>	0,764	0,024	<b>0,573</b>	0,407	0,788	<b>0,249</b>	<b>0,437</b>	<b>0,420</b>	<b>0,959</b>	*
			0.9	<b>3,64</b>	4,14	0,314	<b>0,775</b>	<b>0,027</b>	0,542	<b>0,414</b>	0,742	0,226	0,412	0,372	0,947	
		7	0.6	4,66	<b>3,53</b>	0,264	0,712	0,021	0,464	0,343	<b>0,855</b>	0,182	0,340	0,319	0,827	
			0.7	4,74	3,64	0,283	0,580	0,016	0,502	0,337	0,824	0,209	0,351	0,329	0,870	
			0.8	4,54	4,00	0,322	0,711	0,023	<b>0,571</b>	0,393	0,775	0,243	<b>0,424</b>	<b>0,402</b>	<b>0,961</b>	
			0.9	<b>3,34</b>	3,79	<b>0,348</b>	<b>0,857</b>	<b>0,027</b>	0,547	<b>0,443</b>	0,715	<b>0,244</b>	0,411	0,397	0,947	+
Medidas <i>fitness</i> :	3	0.6	12,16	4,48	0,104	<b>0,801</b>	0,011	0,583	<b>0,205</b>	0,644	0,088	0,555	0,462	1,010		
		0.7	13,28	4,44	0,105	0,736	0,011	0,592	0,192	0,628	0,088	0,560	0,481	1,015		
		0.8	<b>11,92</b>	<b>4,36</b>	<b>0,109</b>	0,773	0,010	<b>0,594</b>	0,201	0,623	<b>0,092</b>	<b>0,586</b>	<b>0,504</b>	<b>1,015</b>	+	
		0.9	12,16	4,45	0,106	0,792	<b>0,011</b>	0,579	0,199	<b>0,652</b>	0,089	0,560	0,471	0,990		
	CConf, CComp e Interés	5	0.6	10,74	<b>4,10</b>	0,107	<b>0,893</b>	0,011	0,578	0,178	<b>0,637</b>	0,092	0,549	0,504	0,965	
			0.7	11,26	4,11	<b>0,112</b>	0,878	0,011	0,589	0,181	0,617	<b>0,095</b>	0,550	0,495	0,993	
			0.8	<b>9,70</b>	4,25	0,101	0,770	0,012	<b>0,598</b>	0,178	0,549	0,090	0,555	0,504	<b>0,995</b>	
			0.9	10,18	4,21	0,105	0,892	<b>0,013</b>	0,595	<b>0,186</b>	0,583	0,091	<b>0,560</b>	<b>0,525</b>	0,988	*
		7	0.6	<b>9,52</b>	<b>4,12</b>	0,096	0,727	0,010	0,578	0,150	0,494	<b>0,085</b>	0,507	0,433	0,995	
			0.7	9,90	4,21	0,096	0,706	0,009	0,582	0,148	0,521	0,082	0,495	0,448	0,999	
			0.8	10,68	4,15	<b>0,098</b>	0,801	0,010	0,583	<b>0,158</b>	<b>0,563</b>	0,084	0,523	0,483	0,993	
			0.9	10,32	4,16	0,096	<b>0,815</b>	<b>0,011</b>	<b>0,591</b>	0,157	0,525	0,083	<b>0,559</b>	<b>0,485</b>	<b>1,002</b>	+

Variables	Continuas	Ejemplos	Clases
19	6	155	2

Tabla A.17 Resumen de la experimentación de SDIGA para Hepatitis con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	3,60	5,92	0,234	0,876	0,023	0,584	0,598	0,524	0,162	0,562	0,414	
		0.7	2,94	<b>5,59</b>	0,250	0,670	0,022	0,585	0,606	<b>0,535</b>	0,174	0,526	0,403	
		0.8	2,62	5,80	0,273	<b>0,962</b>	0,025	0,613	0,703	0,502	0,202	0,643	<b>0,496</b>	
		0.9	<b>2,34</b>	5,75	<b>0,286</b>	0,864	<b>0,027</b>	<b>0,614</b>	<b>0,737</b>	0,518	<b>0,208</b>	<b>0,663</b>	0,486 *	
FConf y Comp	5	0.6	4,58	<b>6,56</b>	0,113	0,816	0,012	0,564	0,443	0,342	0,093	0,480	0,360	
		0.7	4,26	6,71	0,129	0,738	0,012	0,572	0,470	<b>0,350</b>	0,104	0,486	0,355	
		0.8	4,18	6,60	0,123	<b>0,856</b>	0,012	0,578	0,491	0,305	0,104	<b>0,529</b>	0,405	
		0.9	<b>3,22</b>	6,72	<b>0,156</b>	0,730	<b>0,014</b>	<b>0,593</b>	<b>0,542</b>	0,333	<b>0,129</b>	0,526	<b>0,430</b> +	
	7	0.6	5,58	6,50	0,099	0,925	0,013	0,565	0,366	<b>0,349</b>	0,076	0,433	0,395	
		0.7	5,90	<b>6,17</b>	0,093	0,846	0,014	0,568	0,338	0,329	0,075	0,447	0,398	
		0.8	5,42	6,29	0,108	0,809	0,011	0,563	0,364	0,331	0,085	0,445	0,354	
		0.9	<b>4,12</b>	6,45	<b>0,131</b>	<b>0,951</b>	<b>0,016</b>	<b>0,593</b>	<b>0,425</b>	0,347	<b>0,104</b>	<b>0,484</b>	<b>0,453</b> +	
Medidas fitness:	3	0.6	7,60	4,07	0,203	0,686	0,017	0,500	0,274	<b>0,857</b>	0,149	0,350	0,329	
		0.7	5,86	<b>3,62</b>	0,251	0,631	0,017	0,468	0,329	0,851	0,173	0,356	0,310	
		0.8	4,68	3,79	0,308	<b>0,823</b>	0,023	0,528	0,400	0,814	0,221	<b>0,418</b>	<b>0,392</b>	
		0.9	<b>3,82</b>	3,67	<b>0,352</b>	0,753	<b>0,027</b>	<b>0,533</b>	<b>0,454</b>	0,802	<b>0,242</b>	0,405	0,380 *	
Fconf y Fcomp	5	0.6	7,88	4,33	0,182	0,692	0,013	0,505	0,248	<b>0,843</b>	0,136	0,342	0,302	
		0.7	6,66	4,12	0,209	0,731	0,017	0,491	0,280	0,829	0,149	0,335	0,314	
		0.8	4,82	<b>3,88</b>	0,305	0,723	0,022	0,533	0,376	0,826	0,225	<b>0,396</b>	<b>0,371</b>	
		0.9	<b>3,90</b>	3,99	<b>0,311</b>	<b>0,902</b>	<b>0,026</b>	<b>0,535</b>	<b>0,393</b>	0,786	<b>0,227</b>	0,377	0,363 +	
	7	0.6	6,96	4,46	0,188	0,746	0,015	0,507	0,251	<b>0,830</b>	0,139	0,347	0,319	
		0.7	6,74	4,40	0,196	0,714	0,015	0,500	0,260	0,820	0,141	0,315	0,303	
		0.8	6,38	<b>4,34</b>	0,221	<b>0,837</b>	0,018	0,524	0,293	0,823	0,158	<b>0,370</b>	<b>0,359</b>	
		0.9	<b>5,04</b>	4,36	<b>0,278</b>	0,749	<b>0,019</b>	<b>0,541</b>	<b>0,358</b>	0,787	<b>0,201</b>	0,353	0,322 +	
Medidas fitness:	3	0.6	13,66	<b>4,64</b>	0,108	0,842	0,012	0,560	0,228	0,689	<b>0,088</b>	0,534	0,444	
		0.7	13,02	4,80	0,109	0,816	0,011	0,547	0,228	0,659	0,078	0,487	0,402	
		0.8	<b>12,06</b>	4,77	<b>0,113</b>	<b>0,892</b>	<b>0,012</b>	<b>0,577</b>	<b>0,243</b>	0,644	0,088	<b>0,569</b>	<b>0,464</b> +	
		0.9	13,88	4,74	0,112	0,828	0,011	0,562	0,232	<b>0,705</b>	0,084	0,526	0,435	
CConf y CComp	5	0.6	15,32	5,05	<b>0,122</b>	<b>0,892</b>	<b>0,013</b>	<b>0,597</b>	0,274	<b>0,723</b>	<b>0,094</b>	<b>0,601</b>	<b>0,528</b> +	
		0.7	<b>13,74</b>	5,05	0,115	0,848	0,013	0,584	0,273	0,692	0,088	0,578	0,495	
		0.8	14,80	5,08	0,115	0,853	0,012	0,587	0,263	0,668	0,091	0,578	0,482	
		0.9	14,60	<b>5,03</b>	0,109	0,808	0,012	0,578	<b>0,278</b>	0,680	0,086	0,566	0,465	
	7	0.6	16,56	5,26	0,111	0,805	0,010	0,576	0,266	0,719	0,083	0,561	0,459	
		0.7	16,44	5,25	0,119	0,910	0,012	0,589	<b>0,281</b>	0,717	0,090	0,586	0,485	
		0.8	<b>15,84</b>	<b>5,23</b>	0,114	0,946	<b>0,013</b>	0,592	0,261	0,724	0,087	0,575	0,500	
		0.9	15,92	5,25	<b>0,122</b>	<b>0,975</b>	0,012	<b>0,593</b>	0,275	<b>0,751</b>	<b>0,091</b>	<b>0,592</b>	<b>0,506</b> *	

Variables	Continuas	Ejemplos	Clases
19	6	155	2

Tabla A.18 Resumen de la experimentación de SDIGA para Hypothroid con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int
Medidas <i>fitness</i> :	3	0.6	<b>2,74</b>	3,10	0,288	<b>11,776</b>	<b>0,016</b>	0,801	0,665	0,658	<b>0,256</b>	0,676	0,757	1,207	+
		0.7	2,80	<b>2,91</b>	<b>0,309</b>	10,797	0,016	0,784	<b>0,678</b>	<b>0,665</b>	0,254	<b>0,689</b>	<b>0,758</b>	<b>1,213</b>	
		0.8	2,92	3,36	0,269	10,363	0,014	<b>0,803</b>	0,579	0,655	0,246	0,663	0,713	1,204	
		0.9	2,90	3,01	0,285	10,301	0,015	0,800	0,607	0,664	0,246	0,686	0,744	1,209	
FConf, Comp e Interés	5	0.6	3,48	3,26	0,328	<b>10,657</b>	0,013	<b>0,859</b>	<b>0,699</b>	0,805	0,299	<b>0,788</b>	<b>0,846</b>	1,205	*
		0.7	<b>3,22</b>	3,27	0,345	10,470	<b>0,013</b>	0,852	0,674	0,799	0,314	0,739	0,804	1,209	
		0.8	3,40	3,51	0,333	9,225	0,012	0,832	0,631	0,802	0,303	0,717	0,757	1,211	
		0.9	3,26	<b>3,25</b>	<b>0,346</b>	9,419	0,012	0,856	0,665	<b>0,806</b>	<b>0,315</b>	0,769	0,813	<b>1,213</b>	
	7	0.6	3,98	3,38	0,268	<b>8,419</b>	0,011	0,752	0,493	0,942	0,254	0,735	0,725	<b>1,078</b>	+
		0.7	3,64	3,30	0,247	8,258	0,010	0,714	0,457	0,942	0,235	0,693	0,687	1,029	
		0.8	3,18	<b>3,14</b>	<b>0,316</b>	8,169	0,012	<b>0,766</b>	<b>0,516</b>	0,939	<b>0,302</b>	0,726	<b>0,738</b>	1,054	
		0.9	<b>2,94</b>	3,17	0,313	7,997	<b>0,012</b>	0,756	0,501	<b>0,947</b>	0,298	<b>0,751</b>	0,738	1,032	
Medidas <i>fitness</i> :	3	0.6	<b>3,10</b>	3,91	0,379	1,725	<b>0,006</b>	0,606	0,410	0,958	0,308	<b>0,426</b>	<b>0,385</b>	1,099	+
		0.7	3,14	3,95	0,384	1,597	0,006	<b>0,618</b>	0,414	0,957	<b>0,318</b>	0,417	0,380	<b>1,121</b>	
		0.8	3,16	3,93	0,386	1,317	0,006	0,594	0,415	0,959	0,307	0,406	0,375	1,098	
		0.9	<b>3,10</b>	<b>3,59</b>	<b>0,404</b>	<b>1,728</b>	0,006	0,562	<b>0,452</b>	<b>0,963</b>	0,294	0,416	0,376	1,086	
FConf, FComp e Interés	5	0.6	3,64	2,96	0,347	2,237	0,008	0,443	0,390	0,966	0,244	0,341	0,297	0,844	
		0.7	<b>3,40</b>	<b>2,72</b>	0,375	2,667	0,008	0,428	0,429	<b>0,970</b>	0,240	0,339	0,317	0,850	
		0.8	3,64	2,87	0,375	2,657	0,009	<b>0,469</b>	0,415	0,966	0,269	0,350	0,333	0,875	
		0.9	3,58	2,87	<b>0,389</b>	<b>3,288</b>	<b>0,009</b>	0,467	<b>0,448</b>	0,967	<b>0,271</b>	<b>0,375</b>	<b>0,358</b>	<b>0,882</b>	+
	7	0.6	3,12	2,68	0,389	<b>5,200</b>	<b>0,010</b>	<b>0,416</b>	<b>0,474</b>	0,972	<b>0,234</b>	<b>0,320</b>	<b>0,316</b>	<b>0,820</b>	*
		0.7	<b>2,70</b>	<b>2,20</b>	<b>0,402</b>	4,023	0,009	0,317	0,473	<b>0,980</b>	0,189	0,277	0,277	0,748	
		0.8	2,82	2,52	0,353	3,676	0,008	0,333	0,423	0,974	0,190	0,249	0,245	0,733	
		0.9	2,90	2,67	0,339	4,326	0,009	0,394	0,412	0,970	0,200	0,309	0,297	0,783	
Medidas <i>fitness</i> :	3	0.6	4,44	2,73	<b>0,176</b>	<b>5,206</b>	<b>0,008</b>	<b>0,735</b>	<b>0,387</b>	0,551	<b>0,186</b>	<b>0,748</b>	<b>0,754</b>	<b>0,983</b>	*
		0.7	4,64	2,77	0,170	4,631	0,008	0,704	0,378	0,581	0,183	0,686	0,685	0,978	
		0.8	4,64	2,67	0,161	4,796	0,007	0,678	0,367	<b>0,598</b>	0,170	0,679	0,701	0,914	
		0.9	<b>4,40</b>	<b>2,66</b>	0,175	4,790	0,008	0,689	0,382	0,580	0,185	0,683	0,700	0,937	
CConf, CComp e Interés	5	0.6	5,26	2,61	0,179	4,322	0,007	0,719	0,320	<b>0,680</b>	0,173	0,728	0,734	0,931	
		0.7	5,52	2,75	0,182	4,067	0,007	<b>0,744</b>	0,331	0,643	0,178	<b>0,751</b>	<b>0,755</b>	<b>0,972</b>	
		0.8	<b>5,06</b>	<b>2,59</b>	<b>0,191</b>	<b>4,821</b>	<b>0,008</b>	0,724	<b>0,355</b>	0,653	<b>0,189</b>	0,734	0,739	0,928	+
		0.9	5,46	2,67	0,179	4,311	0,007	0,741	0,335	0,640	0,178	0,741	0,748	0,957	
	7	0.6	8,50	2,58	0,129	3,345	0,005	<b>0,827</b>	0,228	<b>0,636</b>	0,130	<b>0,861</b>	<b>0,860</b>	<b>1,081</b>	
		0.7	<b>8,14</b>	2,51	<b>0,137</b>	<b>3,645</b>	<b>0,006</b>	0,791	0,235	0,629	0,137	0,814	0,808	1,038	
		0.8	8,16	2,53	0,137	3,598	0,006	0,802	<b>0,245</b>	0,625	<b>0,138</b>	0,837	0,822	1,046	+
		0.9	8,32	<b>2,49</b>	0,121	3,176	0,005	0,795	0,213	0,619	0,122	0,825	0,815	1,040	

Variables	Continuas	Ejemplos	Clases
25	7	3163	2

Tabla A.19 Resumen de la experimentación de SDIGA para Hypothyroid con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas fitness:	3	0.6	2,88	6,54	0,223	14,208	0,014	0,868	0,830	0,545	0,257	0,781	0,880		
		0.7	2,82	<b>6,11</b>	0,231	13,935	0,014	0,874	0,833	<b>0,548</b>	0,266	0,787	0,893		
		0.8	<b>2,78</b>	6,36	<b>0,232</b>	<b>14,364</b>	<b>0,015</b>	<b>0,882</b>	<b>0,881</b>	0,528	<b>0,271</b>	<b>0,793</b>	<b>0,910</b>	+	
		0.9	<b>2,78</b>	6,22	0,208	12,163	0,013	0,852	0,794	0,489	0,249	0,755	0,838		
FConf y Comp	5	0.6	3,32	6,30	0,359	<b>18,738</b>	0,020	0,872	0,751	<b>0,839</b>	0,303	0,781	0,853		
		0.7	2,88	6,08	0,406	18,491	0,021	<b>0,896</b>	0,798	0,831	0,339	<b>0,834</b>	<b>0,906</b>		
		0.8	3,10	<b>6,00</b>	0,365	16,673	0,019	0,874	0,725	0,820	0,308	0,819	0,873		
		0.9	<b>2,76</b>	6,12	<b>0,416</b>	18,643	<b>0,022</b>	0,893	<b>0,817</b>	0,824	<b>0,352</b>	0,823	0,889	*	
	7	0.6	3,38	6,92	0,347	17,384	0,020	<b>0,880</b>	<b>0,720</b>	0,917	0,286	0,857	<b>0,909</b>		
		0.7	3,28	6,63	0,355	<b>17,456</b>	<b>0,020</b>	0,877	0,705	<b>0,922</b>	0,291	<b>0,863</b>	0,903	+	
		0.8	3,28	6,75	0,341	16,891	0,019	0,876	0,705	0,899	0,282	0,856	0,890		
		0.9	<b>3,04</b>	<b>6,37</b>	<b>0,367</b>	15,279	0,019	0,869	0,671	0,912	<b>0,303</b>	0,835	0,859		
Medidas fitness:	3	0.6	2,38	3,54	0,215	<b>0,464</b>	0,002	<b>0,248</b>	0,239	0,970	0,050	<b>0,113</b>	<b>0,107</b>	+	
		0.7	2,22	3,53	0,268	0,319	0,002	0,209	0,297	0,975	0,058	0,103	0,086		
		0.8	<b>2,20</b>	<b>3,42</b>	0,253	0,118	0,002	0,198	0,280	0,973	0,051	0,067	0,054		
		0.9	2,34	3,50	<b>0,289</b>	0,153	<b>0,002</b>	0,199	<b>0,320</b>	<b>0,977</b>	<b>0,059</b>	0,101	0,066		
Fconf y Fcomp	5	0.6	2,92	3,65	0,187	<b>0,648</b>	0,001	0,214	0,223	0,973	0,010	0,078	0,062		
		0.7	2,82	3,67	0,181	0,638	<b>0,001</b>	<b>0,225</b>	0,211	0,973	0,011	0,081	<b>0,082</b>	+	
		0.8	2,86	3,64	<b>0,202</b>	0,517	0,001	0,208	<b>0,235</b>	<b>0,974</b>	<b>0,012</b>	0,068	0,069		
		0.9	<b>2,54</b>	<b>3,57</b>	0,195	0,399	0,001	0,193	0,226	0,973	0,011	<b>0,083</b>	0,055		
	7	0.6	3,20	4,35	0,059	6,037	0,004	<b>0,342</b>	0,198	0,968	<b>0,008</b>	<b>0,214</b>	<b>0,214</b>		
		0.7	2,88	4,33	0,056	6,045	0,003	0,336	0,182	0,967	0,006	0,201	0,199		
		0.8	<b>2,74</b>	4,15	<b>0,092</b>	<b>6,809</b>	<b>0,004</b>	0,305	<b>0,247</b>	<b>0,971</b>	0,008	0,178	0,198	*	
		0.9	2,76	<b>3,92</b>	0,092	4,101	0,003	0,296	0,186	0,967	0,008	0,154	0,166		
Medidas fitness:	3	0.6	3,40	2,29	0,101	<b>3,662</b>	<b>0,005</b>	<b>0,459</b>	0,227	0,711	0,101	<b>0,431</b>	<b>0,456</b>	+	
		0.7	2,90	2,35	0,098	3,258	0,005	0,441	0,240	0,655	0,107	0,402	0,413		
		0.8	2,74	2,40	<b>0,104</b>	3,198	0,005	0,452	<b>0,247</b>	0,668	<b>0,107</b>	0,406	0,418		
		0.9	<b>2,60</b>	<b>1,98</b>	0,088	2,391	0,004	0,352	0,202	<b>0,715</b>	0,093	0,336	0,323		
CConf y CComp	5	0.6	4,04	<b>3,06</b>	0,167	4,252	0,007	0,594	0,324	<b>0,737</b>	0,150	0,567	0,578		
		0.7	3,92	3,45	<b>0,174</b>	<b>5,230</b>	<b>0,008</b>	<b>0,640</b>	<b>0,376</b>	0,712	<b>0,159</b>	<b>0,599</b>	<b>0,612</b>	+	
		0.8	<b>3,56</b>	3,22	0,148	4,565	0,007	0,583	0,318	0,706	0,131	0,524	0,545		
		0.9	3,82	3,25	0,153	4,099	0,006	0,588	0,300	0,699	0,138	0,542	0,538		
	7	0.6	6,62	3,62	0,185	5,796	0,008	0,735	0,385	0,731	0,174	0,696	0,697		
		0.7	6,34	<b>3,49</b>	<b>0,221</b>	<b>6,441</b>	<b>0,010</b>	<b>0,745</b>	<b>0,434</b>	<b>0,740</b>	<b>0,204</b>	<b>0,705</b>	<b>0,718</b>	*	
		0.8	5,66	3,54	0,188	6,115	0,009	0,730	0,400	0,701	0,176	0,692	0,708		
		0.9	<b>5,00</b>	3,58	0,205	6,098	0,009	0,738	0,417	0,657	0,192	0,679	0,700		

Variables	Continuas	Ejemplos	Clases
25	7	3163	2

Tabla A.20 Resumen de la experimentación de SDIGA para Ionosphere con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int
Medidas <i>fitness</i> :	3	0.6	3,52	4,54	0,113	2,581	0,035	0,540	0,352	<b>0,562</b>	0,108	0,628	0,413	0,702	
		0.7	3,60	4,84	<b>0,120</b>	<b>2,769</b>	<b>0,036</b>	<b>0,581</b>	0,367	0,511	<b>0,113</b>	<b>0,662</b>	0,449	<b>0,771</b>	*
		0.8	<b>3,40</b>	<b>4,54</b>	0,117	2,623	0,036	0,558	<b>0,373</b>	0,521	0,112	0,628	<b>0,480</b>	0,711	
		0.9	<b>3,46</b>	4,74	0,105	2,448	0,032	0,551	0,358	0,510	0,105	0,623	0,424	0,729	
FConf, Comp e Interés	5	0.6	2,22	2,00	0,414	0,766	0,035	<b>0,441</b>	0,502	0,890	0,298	0,430	0,409	<b>0,567</b>	
		0.7	2,14	1,89	<b>0,430</b>	0,857	0,038	0,437	<b>0,512</b>	0,916	<b>0,309</b>	<b>0,436</b>	0,420	0,553	
		0.8	2,14	<b>1,77</b>	0,418	1,011	0,038	0,412	0,495	<b>0,939</b>	0,300	0,406	0,409	0,514	
		0.9	<b>2,08</b>	1,89	0,416	<b>1,017</b>	<b>0,038</b>	0,431	0,500	0,898	0,298	0,418	<b>0,424</b>	0,536	+
	7	0.6	2,02	1,63	<b>0,445</b>	0,685	0,036	0,387	0,504	<b>0,970</b>	<b>0,321</b>	0,387	0,388	0,489	
		0.7	2,08	1,75	0,432	<b>0,811</b>	0,036	0,403	<b>0,507</b>	0,947	0,313	<b>0,421</b>	<b>0,403</b>	0,508	+
		0.8	<b>2,00</b>	<b>1,59</b>	0,439	0,730	<b>0,036</b>	0,381	0,502	0,965	0,318	0,393	0,384	0,481	
		0.9	2,04	1,73	0,431	0,705	0,035	<b>0,409</b>	0,495	0,917	0,309	0,418	0,402	<b>0,518</b>	
Medidas <i>fitness</i> :	3	0.6	3,56	3,10	<b>0,279</b>	0,760	0,026	0,509	<b>0,370</b>	0,729	<b>0,206</b>	0,531	0,350	0,750	
		0.7	4,02	<b>3,05</b>	0,276	0,888	<b>0,027</b>	<b>0,523</b>	0,360	<b>0,791</b>	0,202	0,510	<b>0,414</b>	<b>0,761</b>	*
		0.8	<b>3,12</b>	3,44	0,170	0,712	0,017	0,487	0,263	0,471	0,125	<b>0,541</b>	0,323	0,748	
		0.9	3,38	3,06	0,238	<b>0,891</b>	0,024	0,473	0,322	0,633	0,176	0,491	0,374	0,686	
FConf, FComp e Interés	5	0.6	2,08	1,84	<b>0,435</b>	0,548	0,034	<b>0,407</b>	<b>0,492</b>	0,925	<b>0,314</b>	0,383	0,370	<b>0,536</b>	
		0.7	2,18	<b>1,73</b>	0,422	<b>0,681</b>	<b>0,034</b>	0,397	0,482	<b>0,961</b>	0,304	<b>0,399</b>	<b>0,382</b>	0,510	+
		0.8	<b>2,00</b>	1,82	0,411	0,653	0,034	0,395	0,471	0,899	0,299	0,399	0,363	0,510	
		0.9	2,04	1,81	0,390	0,566	0,032	0,385	0,446	0,876	0,281	0,393	0,359	0,502	
	7	0.6	2,04	1,60	0,425	<b>0,693</b>	<b>0,034</b>	0,379	0,483	0,964	0,306	0,382	<b>0,381</b>	0,482	+
		0.7	2,06	1,63	<b>0,439</b>	0,581	0,034	<b>0,385</b>	<b>0,496</b>	0,966	<b>0,315</b>	<b>0,389</b>	0,379	<b>0,494</b>	
		0.8	<b>2,00</b>	1,62	0,428	0,531	0,034	0,366	0,484	0,951	0,308	0,373	0,355	0,470	
		0.9	<b>2,00</b>	<b>1,55</b>	0,421	0,473	0,032	0,348	0,471	<b>0,968</b>	0,302	0,348	0,348	0,449	
Medidas <i>fitness</i> :	3	0.6	4,14	3,23	0,496	2,002	<b>0,049</b>	<b>0,640</b>	0,687	0,848	0,304	0,648	<b>0,617</b>	0,918	*
		0.7	3,86	3,22	0,524	1,949	0,049	0,619	<b>0,716</b>	<b>0,875</b>	<b>0,315</b>	0,643	0,573	0,920	
		0.8	3,00	<b>3,20</b>	<b>0,529</b>	<b>2,044</b>	0,047	0,608	0,708	0,754	0,302	0,630	0,588	0,920	
		0.9	<b>2,62</b>	3,31	0,429	1,524	0,032	0,605	0,594	0,560	0,231	<b>0,650</b>	0,604	<b>0,927</b>	
CConf, CComp e Interés	5	0.6	2,16	2,13	0,836	<b>0,892</b>	<b>0,037</b>	<b>0,564</b>	0,909	<b>0,955</b>	0,456	<b>0,577</b>	<b>0,571</b>	0,928	+
		0.7	2,22	2,18	0,819	0,704	0,034	0,555	0,879	0,942	0,448	0,548	0,532	0,929	
		0.8	<b>2,00</b>	<b>2,08</b>	<b>0,881</b>	0,596	0,035	0,546	<b>0,938</b>	0,945	<b>0,472</b>	0,544	0,534	<b>0,940</b>	
		0.9	2,02	2,13	0,832	0,661	0,033	0,542	0,896	0,897	0,447	0,547	0,516	0,932	
	7	0.6	2,12	2,16	0,824	<b>0,953</b>	<b>0,036</b>	<b>0,563</b>	0,890	0,940	0,452	0,547	0,535	0,920	+
		0.7	2,06	<b>2,05</b>	<b>0,903</b>	0,647	0,036	0,545	<b>0,962</b>	<b>0,984</b>	<b>0,483</b>	<b>0,556</b>	<b>0,535</b>	<b>0,940</b>	
		0.8	2,04	2,17	0,804	0,605	0,031	0,541	0,864	0,863	0,429	0,529	0,510	0,913	
		0.9	<b>2,02</b>	2,14	0,818	0,635	0,030	0,547	0,872	0,886	0,441	0,548	0,524	0,919	

Variables	Continuas	Ejemplos	Clases
34	34	351	2

Tabla A.21 Resumen de la experimentación de SDIGA para Ionosphere con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	8,34	<b>5,08</b>	0,071	<b>2,553</b>	0,029	<b>0,643</b>	0,266	<b>0,386</b>	0,070	0,649	<b>0,521</b>	*
		0.7	8,72	5,10	0,058	2,101	0,024	0,625	0,237	0,360	0,058	<b>0,663</b>	0,467	
		0.8	<b>7,52</b>	5,43	<b>0,081</b>	2,518	<b>0,029</b>	0,642	<b>0,297</b>	0,354	<b>0,078</b>	0,651	0,505	
		0.9	8,56	5,35	0,058	2,208	0,024	0,630	0,244	0,343	0,061	0,638	0,480	
FConf y Comp	5	0.6	3,30	<b>7,85</b>	0,048	1,229	0,015	0,493	0,312	<b>0,380</b>	0,057	0,448	0,351	
		0.7	2,90	7,90	0,066	1,816	0,022	0,520	0,380	0,347	0,076	0,543	0,435	
		0.8	2,92	8,74	<b>0,078</b>	<b>1,845</b>	<b>0,023</b>	<b>0,555</b>	<b>0,385</b>	0,322	<b>0,079</b>	<b>0,568</b>	<b>0,436</b>	+
		0.9	<b>2,64</b>	8,13	0,069	1,681	0,021	0,522	0,376	0,340	0,076	0,508	0,430	
	7	0.6	2,60	6,37	<b>0,050</b>	<b>1,375</b>	<b>0,015</b>	0,389	0,334	<b>0,560</b>	0,058	0,445	<b>0,374</b>	
		0.7	2,48	6,68	0,043	1,198	0,014	<b>0,410</b>	<b>0,367</b>	0,446	0,059	<b>0,476</b>	0,372	+
		0.8	<b>2,34</b>	<b>6,06</b>	0,038	0,798	0,010	0,342	0,289	0,521	0,045	0,384	0,294	
		0.9	<b>2,34</b>	6,92	0,050	1,260	0,015	0,405	0,358	0,465	<b>0,059</b>	0,448	0,367	
Medidas fitness:	3	0.6	4,28	<b>3,16</b>	<b>0,294</b>	1,108	<b>0,029</b>	0,529	<b>0,401</b>	<b>0,779</b>	<b>0,216</b>	0,535	0,412	*
		0.7	4,62	3,50	0,268	0,938	0,027	<b>0,550</b>	0,361	0,768	0,197	0,550	0,397	
		0.8	<b>3,62</b>	3,29	0,258	1,000	0,028	0,533	0,348	0,650	0,191	<b>0,554</b>	<b>0,412</b>	
		0.9	3,86	3,19	0,248	<b>1,113</b>	0,026	0,504	0,340	0,639	0,182	0,512	0,409	
Fconf y Fcomp	5	0.6	2,60	3,21	0,317	0,561	0,027	0,438	0,374	0,816	0,228	0,371	0,311	
		0.7	<b>2,54</b>	<b>3,02</b>	<b>0,326</b>	0,643	<b>0,028</b>	0,424	<b>0,382</b>	<b>0,830</b>	<b>0,236</b>	0,352	0,325	
		0.8	2,82	3,30	0,314	0,695	0,028	0,466	0,379	0,767	0,224	0,435	0,348	
		0.9	2,78	3,40	0,304	<b>0,788</b>	0,028	<b>0,475</b>	0,371	0,719	0,221	<b>0,452</b>	<b>0,370</b>	+
	7	0.6	2,32	<b>2,36</b>	0,297	0,573	0,026	0,338	0,362	<b>0,925</b>	0,215	0,333	0,306	
		0.7	2,16	2,72	<b>0,327</b>	0,598	0,027	<b>0,371</b>	<b>0,385</b>	0,863	<b>0,230</b>	0,326	0,303	+
		0.8	2,18	2,53	0,292	0,688	<b>0,028</b>	0,362	0,353	0,826	0,204	<b>0,346</b>	<b>0,308</b>	
		0.9	<b>2,08</b>	2,80	0,256	<b>0,767</b>	0,026	0,350	0,315	0,778	0,179	0,341	0,283	
Medidas fitness:	3	0.6	2,40	2,02	0,848	<b>0,607</b>	<b>0,012</b>	<b>0,528</b>	0,919	<b>0,897</b>	<b>0,435</b>	<b>0,532</b>	<b>0,527</b>	+
		0.7	<b>2,00</b>	2,01	0,827	0,513	0,001	0,501	0,879	0,841	0,390	0,498	0,500	
		0.8	<b>2,00</b>	<b>1,99</b>	<b>0,859</b>	0,470	0,008	0,502	<b>0,940</b>	0,878	0,407	0,508	0,501	
		0.9	<b>2,00</b>	2,09	0,814	0,455	0,008	0,501	0,894	0,839	0,376	0,506	0,495	
CConf y CComp	5	0.6	2,56	<b>2,00</b>	0,833	0,634	<b>0,027</b>	<b>0,555</b>	0,939	<b>0,918</b>	<b>0,422</b>	<b>0,554</b>	<b>0,559</b>	*
		0.7	2,06	<b>2,00</b>	<b>0,848</b>	0,470	0,019	0,524	<b>0,962</b>	0,891	0,402	0,527	0,525	
		0.8	<b>2,00</b>	<b>2,00</b>	0,809	<b>0,722</b>	0,018	0,523	0,922	0,853	0,378	0,526	0,525	
		0.9	<b>2,00</b>	<b>2,00</b>	0,801	0,564	0,017	0,519	0,930	0,834	0,369	0,519	0,521	
	7	0.6	3,08	<b>2,00</b>	<b>0,817</b>	0,562	<b>0,021</b>	<b>0,567</b>	<b>0,943</b>	<b>0,907</b>	<b>0,407</b>	<b>0,567</b>	<b>0,572</b>	+
		0.7	2,12	<b>2,00</b>	0,764	<b>0,820</b>	0,019	0,533	0,927	0,808	0,355	0,533	0,536	
		0.8	<b>2,00</b>	<b>2,00</b>	0,790	0,590	0,015	0,518	0,926	0,821	0,355	0,521	0,519	
		0.9	<b>2,00</b>	<b>2,00</b>	0,796	0,610	0,010	0,514	0,915	0,820	0,354	0,515	0,515	

Variables	Continuas	Ejemplos	Clases
34	34	351	2

Tabla A.22 Resumen de la experimentación de SDIGA para Iris con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	<b>3,10</b>	<b>2,38</b>	<b>0,304</b>	<b>8,178</b>	<b>0,176</b>	<b>0,677</b>	<b>0,985</b>	<b>0,853</b>	<b>0,243</b>	<b>0,844</b>	<b>0,915</b>	<b>0,086</b>	*	
		0.7	<b>3,10</b>	<b>2,38</b>	<b>0,304</b>	<b>8,178</b>	<b>0,176</b>	<b>0,677</b>	<b>0,985</b>	<b>0,853</b>	<b>0,243</b>	<b>0,844</b>	<b>0,915</b>	<b>0,086</b>	*	
		0.8	<b>3,10</b>	<b>2,38</b>	<b>0,304</b>	<b>8,178</b>	<b>0,176</b>	<b>0,677</b>	<b>0,985</b>	<b>0,853</b>	<b>0,243</b>	<b>0,844</b>	<b>0,915</b>	<b>0,086</b>	*	
		0.9	<b>3,10</b>	<b>2,38</b>	<b>0,304</b>	<b>8,178</b>	<b>0,176</b>	<b>0,677</b>	<b>0,985</b>	<b>0,853</b>	<b>0,243</b>	<b>0,844</b>	<b>0,915</b>	<b>0,086</b>	*	
	FConf, Comp e Interés	5	0.6	3,90	<b>2,27</b>	0,220	6,578	0,137	0,628	0,865	0,795	0,182	0,897	0,853	0,006	
			0.7	3,90	<b>2,27</b>	0,223	6,563	0,137	0,628	0,859	<b>0,801</b>	0,180	0,892	0,853	<b>0,014</b>	
			0.8	3,30	2,32	0,253	7,502	0,157	0,661	0,947	0,780	0,204	0,897	0,906	-0,001	
			0.9	<b>3,00</b>	<b>2,33</b>	<b>0,264</b>	<b>7,976</b>	<b>0,165</b>	<b>0,681</b>	<b>0,979</b>	0,760	<b>0,213</b>	<b>0,906</b>	<b>0,963</b>	-0,004	+
		7	0.6	5,10	2,49	0,121	3,977	0,080	0,552	0,720	0,536	0,125	0,818	0,787	-0,008	
			0.7	5,02	2,48	0,121	3,992	0,081	0,553	0,720	<b>0,539</b>	0,126	0,824	0,785	-0,008	
			0.8	4,90	<b>2,47</b>	<b>0,124</b>	<b>4,095</b>	<b>0,083</b>	<b>0,559</b>	<b>0,741</b>	0,529	<b>0,129</b>	<b>0,837</b>	<b>0,813</b>	-0,009	
			0.9	<b>4,90</b>	2,49	0,123	4,038	0,082	0,556	0,736	0,527	0,128	0,833	0,803	<b>-0,007</b>	+
Medidas <i>fitness</i> :	3	0.6	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,260	<b>0,824</b>	<b>0,903</b>	0,074		
		0.7	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,261	0,824	<b>0,903</b>	0,075	*	
		0.8	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,261	0,823	<b>0,903</b>	<b>0,075</b>		
		0.9	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	<b>0,262</b>	0,823	<b>0,903</b>	0,073		
	FConf, FComp e Interés	5	0.6	3,10	<b>1,73</b>	0,219	6,420	0,135	0,514	0,720	<b>0,915</b>	0,175	0,677	0,701	-0,021	
			0.7	3,10	<b>1,73</b>	0,218	6,460	0,136	0,515	0,716	<b>0,915</b>	0,172	<b>0,679</b>	<b>0,703</b>	<b>-0,015</b>	+
			0.8	<b>3,00</b>	<b>1,73</b>	<b>0,224</b>	<b>6,533</b>	<b>0,138</b>	0,516	<b>0,727</b>	0,905	<b>0,178</b>	0,675	0,698	-0,022	
			0.9	<b>3,00</b>	<b>1,73</b>	0,223	6,519	0,138	<b>0,517</b>	<b>0,727</b>	0,903	0,177	0,672	0,700	-0,018	
		7	0.6	3,74	1,74	0,142	4,298	0,089	0,459	0,684	0,831	0,132	0,712	<b>0,694</b>	-0,040	
			0.7	<b>3,64</b>	<b>1,73</b>	0,140	4,246	0,088	0,453	0,674	0,819	0,131	0,702	0,681	<b>-0,038</b>	
			0.8	3,66	1,73	0,143	4,328	0,090	0,454	0,682	0,819	0,133	0,705	0,671	-0,038	
			0.9	3,76	1,74	<b>0,147</b>	<b>4,467</b>	<b>0,092</b>	<b>0,463</b>	<b>0,691</b>	<b>0,832</b>	<b>0,135</b>	<b>0,714</b>	0,684	-0,040	+
Medidas <i>fitness</i> :	3	0.6	4,04	1,75	0,177	5,842	0,118	0,513	<b>0,750</b>	<b>0,920</b>	0,166	<b>0,665</b>	0,744	<b>0,056</b>		
		0.7	<b>4,00</b>	<b>1,75</b>	<b>0,178</b>	<b>5,878</b>	<b>0,119</b>	<b>0,514</b>	0,750	<b>0,920</b>	0,167	0,665	<b>0,750</b>	0,055	+	
		0.8	<b>4,00</b>	<b>1,75</b>	<b>0,178</b>	<b>5,878</b>	<b>0,119</b>	<b>0,514</b>	0,750	<b>0,920</b>	0,167	0,665	<b>0,750</b>	0,055	+	
		0.9	<b>4,00</b>	<b>1,75</b>	<b>0,178</b>	<b>5,878</b>	<b>0,119</b>	<b>0,514</b>	0,750	<b>0,920</b>	<b>0,167</b>	0,665	<b>0,750</b>	0,055		
	CConf, CComp e Interés	5	0.6	5,92	2,48	0,179	5,683	0,115	<b>0,593</b>	<b>0,821</b>	0,725	<b>0,158</b>	<b>0,936</b>	0,840	0,018	
			0.7	5,94	2,46	0,173	5,522	0,112	0,581	0,807	0,719	0,155	0,909	0,821	<b>0,022</b>	
			0.8	<b>5,68</b>	<b>2,43</b>	<b>0,179</b>	<b>5,719</b>	<b>0,116</b>	0,588	0,811	0,724	0,157	0,924	<b>0,846</b>	0,016	*
			0.9	6,10	2,46	0,172	5,470	0,111	0,577	0,798	<b>0,749</b>	0,152	0,917	0,813	0,019	
		7	0.6	<b>5,92</b>	2,10	0,154	5,062	0,102	<b>0,604</b>	0,856	0,761	0,152	0,965	<b>0,929</b>	-0,038	
			0.7	<b>5,92</b>	<b>2,09</b>	<b>0,155</b>	<b>5,090</b>	<b>0,102</b>	0,604	<b>0,868</b>	0,761	<b>0,154</b>	<b>0,969</b>	0,927	-0,039	+
			0.8	6,06	2,12	0,152	4,969	0,100	0,598	0,851	0,763	0,149	0,954	0,907	-0,037	
			0.9	6,10	2,11	0,150	4,936	0,100	0,597	0,843	<b>0,764</b>	0,148	0,957	0,907	<b>-0,036</b>	

Variables	Continuas	Ejemplos	Clases
4	4	150	3

Tabla A.23 Resumen de la experimentación de SDIGA para Iris con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas fitness:	3	0.6	<b>3,00</b>	<b>2,97</b>	<b>0,311</b>	<b>8,416</b>	<b>0,181</b>	<b>0,687</b>	<b>1,000</b>	<b>0,853</b>	<b>0,239</b>	<b>0,842</b>	<b>0,940</b>	+	
		0.7	<b>3,00</b>	<b>2,97</b>	<b>0,311</b>	<b>8,416</b>	<b>0,181</b>	<b>0,687</b>	<b>1,000</b>	<b>0,853</b>	<b>0,239</b>	0,842	<b>0,940</b>	+	
		0.8	<b>3,00</b>	<b>2,97</b>	<b>0,311</b>	<b>8,416</b>	<b>0,181</b>	<b>0,687</b>	<b>1,000</b>	<b>0,853</b>	<b>0,239</b>	<b>0,842</b>	<b>0,940</b>	+	
		0.9	<b>3,00</b>	<b>2,97</b>	<b>0,311</b>	<b>8,416</b>	<b>0,181</b>	<b>0,687</b>	<b>1,000</b>	<b>0,853</b>	<b>0,239</b>	0,842	<b>0,940</b>	+	
	FConf y Comp	5	0.6	<b>3,00</b>	2,51	0,280	8,881	0,182	0,704	<b>1,000</b>	0,827	0,225	0,925	0,974	
			0.7	<b>3,00</b>	2,49	<b>0,280</b>	<b>8,896</b>	<b>0,183</b>	<b>0,705</b>	<b>1,000</b>	<b>0,828</b>	0,225	0,926	<b>0,981</b>	*
			0.8	<b>3,00</b>	<b>2,47</b>	0,280	8,867	0,182	0,704	0,999	0,825	<b>0,226</b>	0,925	0,974	
			0.9	<b>3,00</b>	2,52	0,276	8,768	0,180	0,703	0,999	0,816	0,224	<b>0,926</b>	0,981	
		7	0.6	5,42	3,51	0,144	4,462	0,091	0,562	0,830	0,603	0,129	0,875	0,807	
			0.7	5,36	3,50	0,146	4,588	0,094	0,568	0,825	<b>0,608</b>	0,128	0,875	0,818	
			0.8	4,74	3,38	0,152	4,784	0,097	0,574	<b>0,852</b>	0,592	0,136	0,894	0,828	
			0.9	<b>3,94</b>	<b>3,01</b>	<b>0,164</b>	<b>5,362</b>	<b>0,109</b>	<b>0,598</b>	0,836	0,576	<b>0,144</b>	<b>0,931</b>	<b>0,887</b>	+
Medidas fitness:	3	0.6	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,261	<b>0,824</b>	<b>0,903</b>	+	
		0.7	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,260	0,824	<b>0,903</b>	+	
		0.8	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	0,261	0,824	<b>0,903</b>	+	
		0.9	<b>3,00</b>	<b>2,00</b>	<b>0,333</b>	<b>8,146</b>	<b>0,176</b>	<b>0,668</b>	<b>1,000</b>	<b>0,860</b>	<b>0,261</b>	0,824	<b>0,903</b>	+	
	Fconf y Fcomp	5	0.6	<b>3,00</b>	2,10	<b>0,319</b>	8,972	0,191	0,703	<b>1,000</b>	0,893	0,242	0,895	0,945	
			0.7	<b>3,00</b>	2,06	0,316	<b>9,143</b>	<b>0,193</b>	<b>0,708</b>	<b>1,000</b>	<b>0,896</b>	0,243	<b>0,897</b>	0,954	*
			0.8	<b>3,00</b>	2,08	0,318	9,033	0,192	0,705	<b>1,000</b>	0,893	0,243	0,895	0,946	
			0.9	<b>3,00</b>	<b>2,05</b>	0,314	9,110	0,192	0,708	<b>1,000</b>	0,891	<b>0,244</b>	0,896	<b>0,954</b>	
		7	0.6	4,32	2,32	<b>0,339</b>	8,232	0,180	0,670	<b>0,980</b>	<b>0,977</b>	0,219	0,867	0,897	
			0.7	4,00	2,31	0,327	8,272	0,180	0,675	0,969	0,931	0,215	0,884	0,907	
			0.8	3,06	2,09	0,323	<b>8,923</b>	<b>0,190</b>	<b>0,697</b>	0,975	0,897	<b>0,224</b>	<b>0,913</b>	<b>0,941</b>	+
			0.9	<b>3,00</b>	<b>2,08</b>	0,324	8,735	0,185	0,682	0,959	0,893	0,220	0,892	0,918	
Medidas fitness:	3	0.6	<b>4,00</b>	1,88	0,174	5,735	0,116	0,508	0,748	<b>0,920</b>	0,163	0,635	<b>0,745</b>		
		0.7	<b>4,00</b>	<b>1,83</b>	<b>0,175</b>	<b>5,779</b>	<b>0,117</b>	<b>0,510</b>	<b>0,749</b>	<b>0,920</b>	<b>0,165</b>	<b>0,644</b>	<b>0,745</b>	+	
		0.8	<b>4,00</b>	1,88	0,174	5,724	0,116	0,508	0,747	<b>0,920</b>	0,163	0,635	<b>0,745</b>		
		0.9	<b>4,00</b>	1,88	0,174	5,724	0,116	0,508	0,748	<b>0,920</b>	0,162	0,633	<b>0,745</b>		
	CConf y CComp	5	0.6	4,52	2,98	0,200	6,042	0,125	0,613	0,864	0,781	0,161	0,823	0,911	
			0.7	4,60	<b>2,96</b>	0,200	6,098	0,126	0,618	0,874	<b>0,800</b>	0,162	<b>0,844</b>	0,919	
			0.8	4,44	3,00	0,203	6,155	0,128	0,619	0,866	0,792	0,162	0,832	<b>0,925</b>	
			0.9	<b>4,38</b>	2,99	<b>0,208</b>	<b>6,336</b>	<b>0,131</b>	<b>0,621</b>	<b>0,877</b>	0,792	<b>0,163</b>	0,818	0,919	*
		7	0.6	5,26	2,97	<b>0,192</b>	<b>6,199</b>	<b>0,125</b>	0,622	<b>0,857</b>	0,808	<b>0,154</b>	<b>0,897</b>	0,882	+
			0.7	5,40	3,00	0,189	6,072	0,122	0,619	0,844	0,811	0,150	0,882	0,890	
			0.8	<b>5,20</b>	<b>2,91</b>	0,191	6,119	0,124	<b>0,623</b>	0,857	0,809	0,154	0,884	<b>0,903</b>	
			0.9	5,64	2,96	0,181	5,818	0,116	0,604	0,828	<b>0,824</b>	0,146	0,883	0,861	

Variables	Continuas	Ejemplos	Clases
4	4	150	3

Tabla A.24 Resumen de la experimentación de SDIGA para Tic-Tac-Toe con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	10,64	3,64	0,156	5,659	<b>0,029</b>	<b>0,766</b>	0,216	<b>0,864</b>	0,123	0,814	0,814	0,903	+	
		0.7	9,20	<b>3,62</b>	<b>0,162</b>	5,135	0,027	0,750	<b>0,221</b>	0,753	<b>0,124</b>	0,810	0,810	<b>0,904</b>		
		0.8	<b>7,50</b>	3,94	0,108	5,948	0,029	0,747	0,175	0,509	0,087	0,803	0,803	0,902		
		0.9	7,90	3,98	0,088	<b>6,148</b>	0,026	0,753	0,152	0,435	0,073	<b>0,824</b>	<b>0,824</b>	0,903		
	FConf, Comp e Interés	5	0.6	10,26	<b>3,60</b>	<b>0,169</b>	5,084	0,026	0,748	<b>0,224</b>	<b>0,835</b>	<b>0,130</b>	0,796	0,796	0,903	
			0.7	9,94	3,64	0,160	5,432	0,028	0,756	0,220	0,791	0,124	0,814	0,814	0,902	
			0.8	<b>7,64</b>	3,93	0,107	5,979	0,027	<b>0,759</b>	0,171	0,506	0,086	<b>0,831</b>	<b>0,831</b>	<b>0,903</b>	
			0.9	7,82	3,91	0,108	<b>6,277</b>	<b>0,029</b>	0,747	0,177	0,489	0,087	0,797	0,797	0,901	+
		7	0.6	10,96	<b>3,65</b>	<b>0,154</b>	5,295	0,027	<b>0,757</b>	<b>0,211</b>	<b>0,858</b>	<b>0,120</b>	0,813	0,813	<b>0,904</b>	
			0.7	9,78	3,70	0,150	5,056	0,025	0,735	0,204	0,754	0,116	0,771	0,771	0,904	
			0.8	7,42	3,86	0,125	6,084	<b>0,030</b>	0,753	0,194	0,535	0,100	0,817	0,817	0,901	*
			0.9	<b>7,14</b>	3,96	0,097	<b>6,085</b>	0,027	0,747	0,164	0,431	0,078	<b>0,820</b>	<b>0,820</b>	0,902	
Medidas <i>fitness</i> :	3	0.6	11,24	3,68	0,150	5,642	0,027	<b>0,759</b>	0,208	<b>0,886</b>	0,117	<b>0,818</b>	<b>0,818</b>	0,903	*	
		0.7	9,40	<b>3,57</b>	<b>0,165</b>	5,305	0,028	0,754	<b>0,224</b>	0,787	<b>0,126</b>	0,803	0,803	<b>0,904</b>		
		0.8	8,34	3,98	0,106	<b>5,837</b>	0,026	0,752	0,166	0,531	0,087	0,801	0,801	0,903		
		0.9	<b>7,40</b>	3,87	0,117	5,697	<b>0,028</b>	0,731	0,187	0,426	0,088	0,785	0,785	0,903		
	FConf, FComp e Interés	5	0.6	10,88	<b>3,71</b>	<b>0,150</b>	5,194	0,025	0,749	<b>0,204</b>	<b>0,859</b>	<b>0,117</b>	0,798	0,798	0,904	
			0.7	10,94	3,87	0,124	5,489	0,025	<b>0,759</b>	0,179	0,785	0,099	<b>0,821</b>	<b>0,821</b>	<b>0,904</b>	+
			0.8	8,44	3,95	0,107	<b>5,746</b>	0,026	0,740	0,170	0,542	0,086	0,781	0,781	0,900	
			0.9	<b>7,80</b>	3,91	0,116	5,672	<b>0,028</b>	0,728	0,183	0,456	0,090	0,755	0,755	0,901	
		7	0.6	10,66	<b>3,62</b>	<b>0,162</b>	5,331	0,028	0,752	<b>0,221</b>	<b>0,866</b>	<b>0,126</b>	0,810	0,810	0,903	+
			0.7	9,26	3,65	0,153	5,309	0,029	<b>0,757</b>	0,213	0,760	0,120	<b>0,812</b>	<b>0,812</b>	0,903	
			0.8	<b>7,08</b>	3,77	0,139	<b>5,864</b>	<b>0,032</b>	0,744	0,212	0,522	0,108	0,797	0,797	0,900	
			0.9	<b>7,08</b>	3,92	0,113	5,823	0,027	0,743	0,179	0,438	0,088	0,806	0,806	<b>0,904</b>	
Medidas <i>fitness</i> :	3	0.6	9,50	<b>3,52</b>	<b>0,176</b>	5,238	<b>0,030</b>	<b>0,755</b>	<b>0,237</b>	<b>0,829</b>	<b>0,136</b>	0,803	0,803	0,903		
		0.7	10,08	3,72	0,146	5,163	0,026	0,748	0,200	0,772	0,113	0,802	0,802	<b>0,904</b>		
		0.8	8,06	3,86	0,118	<b>5,827</b>	0,027	0,751	0,182	0,566	0,094	<b>0,810</b>	<b>0,810</b>	0,902	+	
		0.9	<b>7,58</b>	3,86	0,113	5,749	0,026	0,728	0,177	0,465	0,087	0,784	0,784	0,902		
	CConf, CComp e Interés	5	0.6	10,72	<b>3,63</b>	<b>0,163</b>	5,376	0,028	<b>0,757</b>	<b>0,222</b>	<b>0,861</b>	<b>0,127</b>	0,815	0,815	0,903	
			0.7	10,20	3,69	0,150	5,417	0,028	0,746	0,211	0,791	0,116	0,786	0,786	<b>0,903</b>	
			0.8	<b>6,44</b>	3,77	0,137	5,386	0,027	0,727	0,200	0,481	0,103	0,769	0,769	0,903	
			0.9	6,56	3,92	0,112	<b>6,286</b>	<b>0,028</b>	0,753	0,183	0,436	0,088	<b>0,831</b>	<b>0,831</b>	0,903	*
		7	0.6	10,82	3,66	<b>0,156</b>	5,527	<b>0,028</b>	<b>0,764</b>	<b>0,215</b>	<b>0,871</b>	<b>0,122</b>	<b>0,830</b>	<b>0,830</b>	0,903	+
			0.7	9,48	<b>3,64</b>	0,154	5,439	0,027	0,752	0,213	0,776	0,119	0,809	0,809	<b>0,904</b>	
			0.8	<b>7,30</b>	3,86	0,111	<b>5,577</b>	0,027	0,740	0,176	0,466	0,087	0,805	0,805	0,903	
			0.9	7,40	4,07	0,089	5,555	0,022	0,731	0,142	0,405	0,071	0,768	0,768	0,904	

Variables	Continuas	Ejemplos	Clases
9	0	958	2

Tabla A.25 Resumen de la experimentación de SDIGA para Tic-Tac-Toe con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CCConf
Medidas <i>fitness</i> :	3	0.6	8,40	<b>3,23</b>	<b>0,405</b>	4,619	0,022	0,682	<b>0,455</b>	<b>0,902</b>	<b>0,253</b>	0,729	0,729	
		0.7	7,10	3,48	0,362	4,821	0,027	0,683	0,420	0,755	0,223	0,742	0,742	
		0.8	<b>6,72</b>	3,64	0,337	<b>6,133</b>	<b>0,030</b>	<b>0,698</b>	0,408	0,678	0,205	<b>0,780</b>	<b>0,780</b>	*
		0.9	7,02	3,54	0,366	5,316	0,028	0,678	0,431	0,737	0,218	0,749	0,749	
FConf y Comp	5	0.6	8,66	<b>3,46</b>	<b>0,371</b>	4,935	0,024	<b>0,693</b>	<b>0,426</b>	<b>0,903</b>	<b>0,235</b>	0,752	0,752	
		0.7	7,84	3,55	0,350	4,946	0,028	0,678	0,412	0,775	0,214	0,739	0,739	
		0.8	7,12	3,56	0,361	5,185	0,028	0,674	0,425	0,740	0,212	0,732	0,732	
		0.9	<b>6,48</b>	3,57	0,351	<b>5,866</b>	<b>0,030</b>	0,690	0,422	0,721	0,216	<b>0,759</b>	<b>0,759</b>	+
	7	0.6	8,28	<b>3,39</b>	<b>0,402</b>	4,241	0,021	0,674	<b>0,451</b>	<b>0,905</b>	<b>0,249</b>	0,721	0,721	
		0.7	7,88	3,70	0,330	5,260	0,026	0,685	0,390	0,732	0,198	0,753	0,753	
		0.8	<b>5,84</b>	3,42	0,387	5,013	0,026	0,670	0,448	0,719	0,228	0,733	0,733	
		0.9	8,22	3,66	0,335	<b>5,606</b>	<b>0,031</b>	<b>0,687</b>	0,404	0,729	0,206	<b>0,754</b>	<b>0,754</b>	+
Medidas <i>fitness</i> :	3	0.6	8,32	<b>3,31</b>	<b>0,398</b>	4,114	0,024	0,683	<b>0,451</b>	<b>0,900</b>	<b>0,251</b>	0,745	0,745	
		0.7	8,30	3,70	0,306	<b>5,564</b>	0,026	<b>0,696</b>	0,367	0,753	0,190	<b>0,752</b>	<b>0,752</b>	+
		0.8	7,46	3,57	0,351	5,079	<b>0,026</b>	0,673	0,410	0,724	0,206	0,745	0,745	
		0.9	<b>7,32</b>	3,65	0,339	4,929	0,025	0,670	0,398	0,708	0,202	0,718	0,718	
Fconf y Fcomp	5	0.6	8,22	3,52	0,355	4,758	0,024	<b>0,698</b>	0,410	<b>0,884</b>	0,230	<b>0,766</b>	<b>0,766</b>	
		0.7	7,44	3,62	0,333	4,976	0,028	0,688	0,395	0,760	0,207	0,763	0,763	
		0.8	<b>5,32</b>	<b>3,17</b>	<b>0,452</b>	4,495	<b>0,029</b>	0,652	<b>0,511</b>	0,703	<b>0,259</b>	0,697	0,697	
		0.9	6,90	3,50	0,368	<b>5,492</b>	0,029	0,679	0,431	0,732	0,219	0,741	0,741	*
	7	0.6	8,84	3,66	0,342	<b>5,168</b>	0,025	<b>0,696</b>	0,400	<b>0,884</b>	<b>0,225</b>	<b>0,752</b>	<b>0,752</b>	+
		0.7	<b>7,02</b>	3,58	0,356	4,982	<b>0,027</b>	0,679	0,416	0,767	0,215	0,743	0,743	
		0.8	7,58	3,76	0,321	4,907	0,025	0,675	0,378	0,713	0,193	0,731	0,731	
		0.9	7,16	<b>3,49</b>	<b>0,387</b>	4,847	0,026	0,663	<b>0,444</b>	0,737	0,221	0,723	0,723	
Medidas <i>fitness</i> :	3	0.6	7,56	<b>3,27</b>	<b>0,412</b>	4,544	0,024	<b>0,692</b>	<b>0,465</b>	<b>0,877</b>	<b>0,264</b>	<b>0,747</b>	<b>0,747</b>	
		0.7	7,32	3,40	0,376	4,990	0,027	0,677	0,434	0,750	0,225	0,731	0,731	
		0.8	6,08	3,41	0,387	<b>5,629</b>	<b>0,031</b>	0,674	0,455	0,726	0,227	0,728	0,728	+
		0.9	<b>5,74</b>	3,44	0,379	5,369	0,028	0,680	0,441	0,712	0,225	0,743	0,743	
CCConf y CComp	5	0.6	7,88	<b>3,22</b>	<b>0,439</b>	3,575	0,022	0,661	<b>0,487</b>	<b>0,910</b>	<b>0,269</b>	0,700	0,700	
		0.7	8,30	3,73	0,316	<b>5,786</b>	0,028	<b>0,695</b>	0,382	0,753	0,197	<b>0,765</b>	<b>0,765</b>	*
		0.8	6,48	3,58	0,339	5,769	0,027	0,685	0,404	0,707	0,204	0,748	0,748	
		0.9	<b>6,28</b>	3,41	0,385	5,426	<b>0,030</b>	0,681	0,452	0,705	0,230	0,739	0,739	
	7	0.6	9,30	3,66	0,331	4,883	0,025	<b>0,704</b>	0,386	<b>0,876</b>	0,220	<b>0,764</b>	<b>0,764</b>	
		0.7	7,72	3,63	0,327	5,690	0,027	0,692	0,391	0,741	0,202	0,756	0,756	+
		0.8	<b>6,52</b>	<b>3,45</b>	<b>0,371</b>	5,138	0,033	0,681	<b>0,441</b>	0,722	<b>0,223</b>	0,756	0,756	
		0.9	7,22	3,65	0,324	<b>5,760</b>	<b>0,033</b>	0,694	0,398	0,705	0,201	0,756	0,756	

Variables	Continuas	Ejemplos	Clases
9	0	958	2

Tabla A.26 Resumen de la experimentación de SDIGA para Vote con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int		
Medidas fitness:	3	0.6	4,92	3,32	0,373	13,327	0,137	0,807	0,655	<b>0,970</b>	0,339	0,812	0,812	<b>0,759</b>			
		0.7	4,44	3,42	0,380	14,949	0,153	0,834	0,704	0,965	0,351	0,845	0,845	0,742			
		0.8	4,28	3,52	0,371	14,461	0,148	0,823	0,679	0,962	0,345	0,825	0,825	0,746			
		0.9	<b>3,06</b>	<b>3,19</b>	<b>0,422</b>	<b>18,243</b>	<b>0,180</b>	<b>0,871</b>	<b>0,802</b>	0,943	<b>0,400</b>	<b>0,891</b>	<b>0,891</b>	0,704	*		
	FConf, Comp e Interés	5	0.6	5,22	3,41	0,359	12,921	0,132	0,796	0,633	<b>0,980</b>	0,326	0,804	0,804	0,751		
			0.7	4,24	3,32	0,395	15,644	0,159	0,845	0,728	0,966	0,367	0,865	0,865	0,736		
			0.8	4,58	3,63	0,361	14,933	0,148	0,829	0,676	0,966	0,336	0,841	0,841	<b>0,753</b>		
			0.9	<b>3,16</b>	<b>3,24</b>	<b>0,414</b>	<b>17,733</b>	<b>0,176</b>	<b>0,855</b>	<b>0,785</b>	0,939	<b>0,392</b>	<b>0,867</b>	<b>0,867</b>	0,709	+	
		7	0.6	4,82	<b>3,22</b>	0,382	13,142	0,136	0,804	0,666	<b>0,976</b>	0,342	0,816	0,816	0,750		
			0.7	4,58	3,31	0,383	14,255	0,148	0,829	0,691	0,969	0,352	0,844	0,844	<b>0,756</b>		
			0.8	4,14	3,37	0,391	15,403	0,158	0,833	0,720	0,965	0,363	0,845	0,845	0,739		
			0.9	<b>3,10</b>	<b>3,29</b>	<b>0,404</b>	<b>17,194</b>	<b>0,172</b>	<b>0,849</b>	<b>0,767</b>	0,941	<b>0,382</b>	<b>0,854</b>	<b>0,854</b>	0,714	+	
Medidas fitness:	3	0.6	5,14	3,28	0,375	13,089	0,137	0,804	0,662	<b>0,981</b>	0,337	0,819	0,819	<b>0,753</b>			
		0.7	4,42	3,43	0,384	14,740	0,152	0,829	0,704	0,962	0,355	0,836	0,836	0,741			
		0.8	4,64	3,55	0,368	14,251	0,146	0,820	0,676	0,968	0,339	0,831	0,831	0,750			
		0.9	<b>3,20</b>	<b>3,22</b>	<b>0,422</b>	<b>17,734</b>	<b>0,177</b>	<b>0,860</b>	<b>0,789</b>	0,947	<b>0,399</b>	<b>0,878</b>	<b>0,878</b>	0,704	+		
	FConf, FComp e Interés	5	0.6	4,86	3,30	0,368	12,758	0,131	0,786	0,642	<b>0,981</b>	0,328	0,802	0,802	0,745		
			0.7	4,64	3,47	0,370	14,112	0,145	0,827	0,674	0,968	0,342	0,838	0,838	<b>0,751</b>		
			0.8	4,44	3,48	0,373	14,432	0,149	0,815	0,686	0,965	0,344	0,824	0,824	0,741		
			0.9	<b>3,06</b>	<b>3,16</b>	<b>0,425</b>	<b>18,085</b>	<b>0,180</b>	<b>0,862</b>	<b>0,802</b>	0,950	<b>0,402</b>	<b>0,882</b>	<b>0,882</b>	0,701	+	
		7	0.6	5,20	3,45	0,365	13,057	0,131	0,799	0,639	<b>0,980</b>	0,327	0,813	0,813	<b>0,766</b>		
			0.7	4,52	3,53	0,370	14,822	0,150	0,829	0,688	0,965	0,343	0,837	0,837	0,748		
			0.8	4,32	3,62	0,370	14,877	0,151	0,820	0,690	0,963	0,343	0,821	0,821	0,744		
			0.9	<b>2,86</b>	<b>3,12</b>	<b>0,430</b>	<b>18,478</b>	<b>0,183</b>	<b>0,867</b>	<b>0,813</b>	0,957	<b>0,407</b>	<b>0,893</b>	<b>0,893</b>	0,698	*	
Medidas fitness:	3	0.6	<b>7,58</b>	5,08	<b>0,089</b>	<b>5,313</b>	<b>0,044</b>	<b>0,604</b>	<b>0,199</b>	<b>0,883</b>	<b>0,082</b>	0,585	0,585	0,699	*		
		0.7	7,66	<b>5,00</b>	0,077	4,760	0,038	0,584	0,174	0,859	0,071	0,574	0,574	0,692			
		0.8	7,88	5,10	0,085	4,958	0,042	0,600	0,189	0,873	0,078	0,598	0,598	0,700			
		0.9	7,98	5,13	0,086	5,008	0,042	0,603	0,191	0,878	0,078	<b>0,601</b>	<b>0,601</b>	<b>0,709</b>			
	CConf, CComp e Interés	5	0.6	<b>7,02</b>	4,94	<b>0,086</b>	<b>5,064</b>	<b>0,042</b>	0,580	<b>0,193</b>	0,853	<b>0,078</b>	0,586	0,586	0,678	+	
			0.7	7,28	<b>4,84</b>	0,080	4,730	0,039	0,562	0,180	0,869	0,074	0,561	0,561	0,656		
			0.8	7,70	5,19	0,084	4,979	0,042	0,610	0,189	<b>0,877</b>	0,077	<b>0,635</b>	<b>0,635</b>	0,705		
			0.9	8,18	5,20	0,081	4,843	0,040	<b>0,611</b>	0,181	0,871	0,074	0,625	0,625	<b>0,713</b>		
		7	0.6	7,58	5,10	0,084	4,776	0,040	0,592	0,184	0,861	0,077	0,593	0,593	0,700		
			0.7	7,74	5,11	<b>0,085</b>	<b>5,076</b>	<b>0,042</b>	<b>0,598</b>	<b>0,191</b>	<b>0,882</b>	<b>0,079</b>	<b>0,598</b>	<b>0,598</b>	0,691	*	
			0.8	<b>7,34</b>	<b>4,88</b>	0,079	4,677	0,039	0,574	0,177	0,868	0,072	0,583	0,583	0,670		
			0.9	7,86	5,13	0,079	4,498	0,037	0,589	0,172	0,859	0,072	0,578	0,578	<b>0,707</b>		

Variables	Continuas	Ejemplos	Clases
16	0	435	2

Tabla A.27 Resumen de la experimentación de SDIGA para Vote con reglas DNF

		N° Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	
Medidas fitness:	3	0.6	4,86	2,92	0,299	12,120	0,123	0,696	0,564	<b>0,987</b>	0,277	0,719	0,719		
		0.7	4,02	3,18	0,368	15,167	0,154	0,836	0,703	0,963	0,341	0,869	0,869		
		0.8	3,80	3,23	0,364	14,804	0,150	0,821	0,688	0,962	0,337	0,850	0,850		
		0.9	<b>2,28</b>	<b>2,17</b>	<b>0,492</b>	<b>20,335</b>	<b>0,208</b>	<b>0,886</b>	<b>0,931</b>	0,962	<b>0,462</b>	<b>0,923</b>	<b>0,923</b>	*	
	FConf y Comp	5	0.6	4,68	2,85	0,310	12,725	0,129	0,701	0,588	<b>0,987</b>	0,287	0,726	0,726	
			0.7	4,12	3,31	0,356	14,621	0,148	0,827	0,677	0,964	0,330	0,859	0,859	
			0.8	3,82	3,08	0,380	15,524	0,158	0,832	0,722	0,963	0,352	0,849	0,849	
			0.9	<b>2,28</b>	<b>2,20</b>	<b>0,487</b>	<b>20,131</b>	<b>0,206</b>	<b>0,881</b>	<b>0,920</b>	0,961	<b>0,458</b>	<b>0,918</b>	<b>0,918</b>	+
		7	0.6	4,64	2,83	0,313	12,619	0,128	0,703	0,589	<b>0,988</b>	0,289	0,721	0,721	
			0.7	3,90	3,17	0,373	15,070	0,154	0,829	0,703	0,963	0,345	0,847	0,847	
			0.8	4,04	3,30	0,355	14,888	0,150	0,829	0,679	0,962	0,330	0,848	0,848	
			0.9	<b>2,28</b>	<b>2,26</b>	<b>0,481</b>	<b>19,948</b>	<b>0,204</b>	<b>0,880</b>	<b>0,910</b>	0,953	<b>0,452</b>	<b>0,915</b>	<b>0,915</b>	+
Medidas fitness:	3	0.6	4,84	2,93	0,299	11,983	0,123	0,692	0,564	<b>0,988</b>	0,275	0,716	0,716		
		0.7	3,98	3,22	0,366	14,924	0,152	0,832	0,694	0,964	0,339	0,875	0,875		
		0.8	3,86	3,15	0,369	15,133	0,154	0,833	0,703	0,962	0,342	0,859	0,859		
		0.9	<b>2,26</b>	<b>2,19</b>	<b>0,489</b>	<b>20,220</b>	<b>0,207</b>	<b>0,885</b>	<b>0,925</b>	0,961	<b>0,459</b>	<b>0,923</b>	<b>0,923</b>	*	
	Fconf y Fcomp	5	0.6	4,58	2,81	0,311	12,774	0,129	0,701	0,591	<b>0,987</b>	0,288	0,722	0,722	
			0.7	3,92	3,12	0,379	15,867	0,159	0,842	0,725	0,963	0,352	0,865	0,865	
			0.8	3,98	3,23	0,362	14,823	0,151	0,826	0,686	0,961	0,336	0,850	0,850	
			0.9	<b>2,26</b>	<b>2,19</b>	<b>0,489</b>	<b>20,178</b>	<b>0,206</b>	<b>0,885</b>	<b>0,924</b>	0,961	<b>0,459</b>	<b>0,923</b>	<b>0,923</b>	+
		7	0.6	4,76	2,91	0,306	12,180	0,124	0,700	0,573	<b>0,989</b>	0,280	0,723	0,723	
			0.7	4,26	3,36	0,347	14,199	0,144	0,819	0,659	0,965	0,321	0,838	0,838	
			0.8	3,88	3,24	0,366	15,089	0,153	0,830	0,696	0,962	0,339	0,853	0,853	
			0.9	<b>2,30</b>	<b>2,28</b>	<b>0,480</b>	<b>19,988</b>	<b>0,203</b>	<b>0,880</b>	<b>0,908</b>	0,954	<b>0,452</b>	<b>0,912</b>	<b>0,912</b>	+
Medidas fitness:	3	0.6	<b>7,14</b>	<b>4,15</b>	0,079	4,374	0,037	0,519	0,171	0,862	0,072	0,530	0,530		
		0.7	8,12	4,44	0,085	4,971	0,042	0,569	0,189	<b>0,892</b>	0,079	0,605	0,605		
		0.8	7,68	4,40	<b>0,088</b>	<b>4,989</b>	<b>0,042</b>	<b>0,577</b>	<b>0,192</b>	0,870	<b>0,082</b>	<b>0,619</b>	<b>0,619</b>	*	
		0.9	7,74	4,23	0,082	4,830	0,040	0,528	0,182	0,884	0,076	0,510	0,510		
	CConf y CComp	5	0.6	6,84	<b>3,87</b>	0,071	3,772	0,032	0,476	0,150	0,869	0,065	0,497	0,497	
			0.7	<b>6,66</b>	4,09	0,077	4,334	0,037	0,515	0,169	0,863	0,071	0,538	0,538	
			0.8	7,24	4,26	<b>0,085</b>	<b>4,875</b>	<b>0,040</b>	<b>0,541</b>	<b>0,184</b>	0,880	<b>0,079</b>	<b>0,569</b>	<b>0,569</b>	+
			0.9	7,76	4,20	0,082	4,777	0,040	0,531	0,181	<b>0,889</b>	0,076	0,546	0,546	
		7	0.6	7,56	4,21	0,074	4,177	0,035	0,527	0,161	0,869	0,068	0,551	0,551	
			0.7	7,20	4,11	0,079	4,379	0,037	0,507	0,171	<b>0,886</b>	0,072	0,538	0,538	
			0.8	7,96	4,48	<b>0,081</b>	<b>4,811</b>	<b>0,040</b>	<b>0,565</b>	<b>0,181</b>	0,878	<b>0,076</b>	<b>0,584</b>	<b>0,584</b>	+
			0.9	<b>6,94</b>	<b>3,95</b>	0,074	4,138	0,035	0,494	0,160	0,857	0,068	0,509	0,509	

Variables	Continuas	Ejemplos	Clases
16	0	435	2

Tabla A.28 Resumen de la experimentación de SDIGA para Balance con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	7,40	2,39	0,291	5,331	0,049	<b>0,535</b>	0,487	<b>0,856</b>	0,150	<b>0,664</b>	<b>0,618</b>	0,391	*	
		0.7	6,46	2,31	0,315	<b>5,368</b>	<b>0,050</b>	0,524	0,501	0,802	<b>0,152</b>	0,636	0,593	0,391		
		0.8	<b>3,00</b>	<b>2,00</b>	<b>0,388</b>	4,738	0,042	0,434	<b>0,507</b>	0,499	0,135	0,476	0,449	0,392		
		0.9	<b>3,00</b>	<b>2,00</b>	0,386	4,613	0,042	0,435	0,503	0,495	0,133	0,476	0,450	<b>0,393</b>		
	FConf, Comp e Interés	5	0.6	33,50	<b>4,09</b>	<b>0,061</b>	<b>1,791</b>	<b>0,015</b>	<b>0,426</b>	<b>0,094</b>	<b>0,797</b>	<b>0,043</b>	<b>0,217</b>	<b>0,217</b>	0,238	+
			0.7	27,38	4,19	0,055	1,781	0,015	0,416	0,086	0,650	0,039	0,194	0,194	0,238	
			0.8	<b>24,36</b>	4,63	0,023	0,743	0,006	0,373	0,036	0,292	0,017	0,093	0,093	<b>0,238</b>	
			0.9	24,58	4,69	0,021	0,795	0,007	0,369	0,035	0,297	0,016	0,080	0,080	0,238	
		7	0.6	34,22	<b>4,25</b>	<b>0,046</b>	<b>1,426</b>	<b>0,012</b>	<b>0,404</b>	<b>0,077</b>	<b>0,744</b>	<b>0,032</b>	<b>0,177</b>	<b>0,164</b>	0,238	+
			0.7	30,14	4,44	0,037	1,222	0,010	0,392	0,060	0,609	0,027	0,136	0,136	0,238	
			0.8	<b>25,76</b>	4,75	0,016	0,578	0,005	0,361	0,027	0,297	0,012	0,063	0,063	0,238	
			0.9	26,52	4,74	0,016	0,581	0,004	0,360	0,026	0,267	0,012	0,062	0,062	<b>0,238</b>	
Medidas <i>fitness</i> :	3	0.6	8,90	2,04	0,311	<b>5,810</b>	0,058	<b>0,571</b>	<b>0,561</b>	<b>0,909</b>	<b>0,185</b>	<b>0,622</b>	<b>0,622</b>	0,391	*	
		0.7	4,86	2,01	<b>0,398</b>	5,805	<b>0,059</b>	0,507	0,553	0,782	0,170	0,560	0,528	0,391		
		0.8	<b>3,00</b>	<b>2,00</b>	0,385	4,605	0,042	0,433	0,507	0,496	0,133	0,474	0,448	0,395		
		0.9	<b>3,00</b>	<b>2,00</b>	0,388	4,561	0,042	0,434	0,507	0,499	0,133	0,475	0,449	<b>0,395</b>		
	FConf, FComp e Interés	5	0.6	33,60	<b>4,13</b>	<b>0,058</b>	<b>1,678</b>	<b>0,014</b>	<b>0,419</b>	<b>0,089</b>	<b>0,783</b>	<b>0,041</b>	<b>0,205</b>	<b>0,205</b>	0,238	+
			0.7	31,64	4,41	0,040	1,298	0,011	0,396	0,064	0,647	0,029	0,143	0,143	<b>0,238</b>	
			0.8	28,98	4,73	0,018	0,635	0,005	0,364	0,029	0,307	0,014	0,069	0,069	0,238	
			0.9	<b>27,50</b>	4,67	0,021	0,810	0,007	0,371	0,036	0,293	0,016	0,085	0,085	0,238	
		7	0.6	48,64	<b>4,31</b>	<b>0,034</b>	<b>1,217</b>	<b>0,010</b>	<b>0,393</b>	<b>0,056</b>	<b>0,808</b>	<b>0,025</b>	<b>0,168</b>	<b>0,153</b>	0,238	+
			0.7	38,54	4,44	0,032	1,028	0,009	0,385	0,051	0,650	0,023	0,133	0,127	0,238	
			0.8	<b>31,74</b>	4,80	0,013	0,452	0,004	0,355	0,021	0,295	0,010	0,050	0,050	0,238	
			0.9	31,88	4,78	0,014	0,502	0,004	0,358	0,022	0,287	0,010	0,056	0,056	<b>0,238</b>	
Medidas <i>fitness</i> :	3	0.6	5,00	<b>2,29</b>	<b>0,360</b>	<b>6,173</b>	<b>0,066</b>	<b>0,544</b>	<b>0,509</b>	<b>0,810</b>	<b>0,171</b>	<b>0,589</b>	<b>0,542</b>	0,392	*	
		0.7	3,02	2,53	0,308	4,436	0,042	0,471	0,407	0,478	0,128	0,496	0,437	0,394		
		0.8	<b>3,00</b>	2,54	0,306	4,485	0,043	0,471	0,409	0,478	0,129	0,495	0,439	0,394		
		0.9	3,02	2,53	0,308	4,421	0,043	0,474	0,412	0,480	0,128	0,505	0,439	<b>0,395</b>		
	CConf, CComp e Interés	5	0.6	32,04	<b>4,07</b>	<b>0,063</b>	<b>1,784</b>	<b>0,015</b>	<b>0,426</b>	<b>0,096</b>	<b>0,784</b>	<b>0,044</b>	<b>0,220</b>	<b>0,220</b>	0,238	+
			0.7	29,10	4,27	0,049	1,577	0,013	0,410	0,077	0,645	0,035	0,177	0,177	0,238	
			0.8	26,28	4,67	0,021	0,712	0,006	0,368	0,033	0,284	0,015	0,082	0,082	0,238	
			0.9	<b>25,74</b>	4,61	0,024	0,935	0,007	0,370	0,037	0,281	0,017	0,090	0,090	<b>0,238</b>	
		7	0.6	12,22	2,80	0,148	4,364	0,036	<b>0,547</b>	<b>0,223</b>	<b>0,772</b>	0,095	<b>0,513</b>	<b>0,513</b>	0,238	
			0.7	8,88	<b>2,80</b>	<b>0,149</b>	<b>4,605</b>	<b>0,036</b>	0,539	0,222	0,640	<b>0,101</b>	0,503	0,503	0,239	+
			0.8	5,86	3,54	0,095	3,164	0,024	0,467	0,142	0,290	0,064	0,332	0,332	0,238	
			0.9	<b>4,82</b>	3,23	0,109	3,716	0,028	0,481	0,159	0,283	0,072	0,384	0,384	<b>0,241</b>	

Variables	Continuas	Ejemplos	Clases
4	4	625	3

Tabla A.29 Resumen de la experimentación de SDIGA para Balance con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	5,00	2,80	<b>0,535</b>	6,978	<b>0,073</b>	<b>0,531</b>	<b>0,786</b>	<b>0,918</b>	<b>0,209</b>	<b>0,522</b>	<b>0,555</b> *	
		0.7	<b>3,00</b>	<b>2,67</b>	0,471	<b>9,374</b>	0,070	0,506	0,776	0,598	0,186	0,458	0,534	
		0.8	<b>3,00</b>	<b>2,67</b>	0,475	9,287	0,070	0,506	0,772	0,599	0,186	0,458	0,534	
		0.9	<b>3,00</b>	<b>2,67</b>	0,479	9,336	0,069	0,505	0,769	0,599	0,186	0,458	0,534	
FConf y Comp	5	0.6	4,50	2,99	0,572	4,461	0,062	<b>0,471</b>	0,671	<b>0,897</b>	0,252	<b>0,514</b>	<b>0,514</b>	
		0.7	<b>3,00</b>	2,69	0,690	4,782	<b>0,069</b>	0,436	<b>0,779</b>	0,858	<b>0,284</b>	0,444	0,443	
		0.8	<b>3,00</b>	<b>2,67</b>	<b>0,696</b>	4,812	0,068	0,434	0,778	0,858	0,283	0,444	0,443	
		0.9	<b>3,00</b>	2,69	0,690	<b>4,814</b>	0,069	0,435	0,776	0,857	0,283	0,444	0,443 +	
	7	0.6	5,52	<b>3,55</b>	0,404	4,530	0,052	<b>0,500</b>	0,751	<b>0,808</b>	0,183	<b>0,560</b>	<b>0,514</b>	
		0.7	<b>3,00</b>	3,67	0,451	5,041	0,056	0,456	<b>0,914</b>	0,600	<b>0,193</b>	0,472	0,474	
		0.8	<b>3,00</b>	3,67	0,450	<b>5,762</b>	<b>0,062</b>	0,471	0,907	0,613	0,191	0,475	0,492 +	
		0.9	<b>3,00</b>	3,67	<b>0,477</b>	5,072	0,057	0,451	0,913	0,616	0,193	0,472	0,468	
Medidas fitness:	3	0.6	<b>3,00</b>	<b>2,00</b>	0,639	<b>3,110</b>	0,044	0,401	0,811	0,753	0,230	0,384	0,407	
		0.7	<b>3,00</b>	<b>2,00</b>	0,642	2,892	0,043	0,401	0,814	0,751	<b>0,230</b>	<b>0,385</b>	0,407	
		0.8	<b>3,00</b>	<b>2,00</b>	<b>0,643</b>	3,030	0,043	0,400	0,809	<b>0,754</b>	0,229	0,383	0,406	
		0.9	<b>3,00</b>	<b>2,00</b>	0,641	3,010	<b>0,044</b>	<b>0,403</b>	<b>0,814</b>	0,752	0,230	0,384	<b>0,409</b> +	
Fconf y Fcomp	5	0.6	4,50	2,97	0,574	4,540	0,062	<b>0,471</b>	0,667	<b>0,896</b>	0,252	<b>0,520</b>	<b>0,519</b>	
		0.7	<b>3,00</b>	<b>2,67</b>	0,695	<b>4,823</b>	0,069	0,434	0,782	0,859	0,284	0,445	0,444	
		0.8	<b>3,00</b>	<b>2,67</b>	<b>0,696</b>	4,810	0,069	0,435	<b>0,786</b>	0,859	<b>0,284</b>	0,445	0,444	
		0.9	<b>3,00</b>	2,69	0,689	4,788	<b>0,069</b>	0,435	0,779	0,858	0,284	0,444	0,443 *	
	7	0.6	<b>3,00</b>	<b>2,00</b>	<b>0,811</b>	0,975	0,013	0,352	0,970	0,829	0,249	0,354	0,354	
		0.7	<b>3,00</b>	<b>2,00</b>	0,809	0,822	0,015	0,353	<b>0,981</b>	<b>0,839</b>	<b>0,253</b>	0,352	0,354	
		0.8	<b>3,00</b>	<b>2,00</b>	0,796	0,829	0,014	0,352	0,975	0,819	0,252	0,350	0,354	
		0.9	<b>3,00</b>	<b>2,00</b>	0,777	<b>1,104</b>	<b>0,017</b>	<b>0,358</b>	0,969	0,804	0,248	<b>0,358</b>	<b>0,361</b> +	
Medidas fitness:	3	0.6	3,08	2,02	0,781	1,261	0,028	<b>0,370</b>	<b>0,827</b>	<b>0,861</b>	0,228	<b>0,393</b>	<b>0,373</b>	
		0.7	<b>3,00</b>	<b>2,00</b>	<b>0,784</b>	1,173	0,025	0,365	0,816	0,852	0,228	0,388	0,367	
		0.8	<b>3,00</b>	<b>2,00</b>	0,780	<b>1,278</b>	<b>0,028</b>	0,369	0,826	0,859	<b>0,230</b>	0,389	0,371 +	
		0.9	<b>3,00</b>	<b>2,00</b>	0,781	1,171	0,026	0,365	0,818	0,854	0,227	0,386	0,367	
CConf y CComp	5	0.6	4,50	2,99	0,575	4,467	0,062	<b>0,470</b>	0,674	<b>0,899</b>	0,252	<b>0,514</b>	<b>0,514</b>	
		0.7	<b>3,00</b>	<b>2,67</b>	<b>0,695</b>	4,802	0,068	0,434	0,777	0,857	0,283	0,444	0,443	
		0.8	<b>3,00</b>	2,69	0,691	4,769	<b>0,069</b>	0,436	<b>0,780</b>	0,858	<b>0,284</b>	0,444	0,443	
		0.9	<b>3,00</b>	2,71	0,684	<b>4,826</b>	0,069	0,437	0,770	0,856	0,283	0,443	0,442 *	
	7	0.6	4,44	2,93	0,634	3,881	0,061	<b>0,463</b>	0,801	<b>0,932</b>	0,188	<b>0,525</b>	<b>0,501</b>	
		0.7	<b>3,00</b>	<b>2,65</b>	<b>0,764</b>	<b>4,154</b>	0,069	0,434	<b>0,914</b>	0,890	0,202	0,459	0,443 +	
		0.8	<b>3,00</b>	2,66	0,761	4,083	0,068	0,434	0,910	0,890	<b>0,203</b>	0,459	0,441	
		0.9	<b>3,00</b>	<b>2,65</b>	0,763	4,121	<b>0,069</b>	0,435	0,913	0,888	0,201	0,460	0,443	

Variables	Continuas	Ejemplos	Clases
4	4	625	3

Tabla A.30 Resumen de la experimentación de SDIGA para Car con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas <i>fitness</i> :	3	0.6	18,34	5,06	0,011	1,675	0,002	0,249	0,037	<b>0,776</b>	0,003	0,201	0,201	0,276		
		0.7	17,62	<b>5,02</b>	0,007	1,532	0,002	0,251	0,026	0,770	0,002	0,209	0,209	0,274		
		0.8	<b>16,32</b>	5,15	0,010	1,689	0,002	0,250	0,035	0,761	0,002	0,193	0,193	0,279		
		0.9	19,14	5,10	<b>0,012</b>	<b>1,774</b>	<b>0,002</b>	<b>0,254</b>	<b>0,041</b>	0,770	<b>0,003</b>	<b>0,214</b>	<b>0,214</b>	<b>0,280</b>	+	
	FConf, Comp e Interés	5	0.6	<b>15,38</b>	<b>4,99</b>	0,009	1,529	0,002	0,248	0,032	0,764	0,002	0,211	0,211	0,272	
			0.7	16,92	5,07	0,012	1,666	0,002	0,244	0,040	<b>0,778</b>	0,003	0,180	0,180	0,276	
			0.8	16,76	5,03	<b>0,014</b>	<b>1,935</b>	<b>0,002</b>	<b>0,257</b>	<b>0,048</b>	0,768	<b>0,003</b>	<b>0,238</b>	<b>0,238</b>	0,278	*
		0.9	17,68	5,15	0,010	1,608	0,002	0,255	0,035	0,767	0,002	0,204	0,204	<b>0,281</b>		
	7	0.6	17,58	5,09	0,008	1,444	0,002	0,249	0,028	0,765	0,002	0,195	0,195	0,276		
		0.7	17,72	5,18	0,008	1,649	0,002	<b>0,258</b>	0,032	0,764	0,002	<b>0,226</b>	<b>0,226</b>	<b>0,281</b>		
		0.8	17,94	<b>5,00</b>	<b>0,011</b>	<b>1,654</b>	<b>0,002</b>	0,251	<b>0,036</b>	0,777	<b>0,003</b>	0,221	0,221	0,274	+	
		0.9	<b>16,46</b>	5,05	0,009	1,463	0,002	0,241	0,030	<b>0,779</b>	0,002	0,180	0,180	0,271		
Medidas <i>fitness</i> :	3	0.6	18,00	5,13	0,011	1,790	0,002	0,261	0,038	0,759	0,003	<b>0,237</b>	<b>0,237</b>	0,283		
		0.7	<b>17,14</b>	5,09	0,012	1,664	0,002	0,248	0,042	<b>0,776</b>	0,003	0,193	0,193	0,277		
		0.8	21,54	5,25	0,009	1,704	0,002	<b>0,262</b>	0,033	0,768	0,002	0,220	0,220	<b>0,286</b>		
		0.9	18,56	<b>5,09</b>	<b>0,015</b>	<b>1,877</b>	<b>0,002</b>	0,251	<b>0,052</b>	0,770	<b>0,003</b>	0,210	0,210	0,281	+	
	FConf, FComp e Interés	5	0.6	18,58	<b>5,09</b>	0,013	1,698	<b>0,002</b>	<b>0,254</b>	0,042	0,765	<b>0,003</b>	<b>0,218</b>	<b>0,218</b>	0,280	
			0.7	<b>18,14</b>	5,11	<b>0,014</b>	<b>1,748</b>	0,002	0,249	<b>0,045</b>	0,773	0,003	0,197	0,197	0,280	+
			0.8	20,86	5,11	0,007	1,544	0,002	0,250	0,024	<b>0,785</b>	0,002	0,205	0,205	0,275	
		0.9	19,96	5,18	0,011	1,693	0,002	0,254	0,038	0,780	0,002	0,203	0,203	<b>0,283</b>		
	7	0.6	19,36	5,09	0,012	1,768	0,002	0,260	0,040	0,766	0,003	0,236	0,236	<b>0,281</b>		
		0.7	<b>16,20</b>	5,16	0,008	1,466	0,001	0,245	0,029	0,771	0,002	0,176	0,176	0,278		
		0.8	16,34	<b>5,00</b>	<b>0,014</b>	1,777	0,002	0,253	<b>0,046</b>	0,764	0,003	0,227	0,227	0,276		
		0.9	18,66	5,08	0,011	<b>1,844</b>	<b>0,002</b>	<b>0,264</b>	0,037	<b>0,774</b>	<b>0,003</b>	<b>0,249</b>	<b>0,249</b>	0,280	*	
Medidas <i>fitness</i> :	3	0.6	26,94	<b>4,49</b>	0,044	6,131	0,014	0,447	0,067	0,748	0,044	0,524	0,524	0,295		
		0.7	29,04	4,57	0,042	5,915	0,013	0,452	0,065	0,758	0,042	<b>0,537</b>	<b>0,537</b>	0,298		
		0.8	32,08	4,62	0,039	5,498	0,012	0,439	0,061	<b>0,765</b>	0,039	0,513	0,513	0,298		
		0.9	<b>24,78</b>	4,56	<b>0,045</b>	<b>6,158</b>	<b>0,014</b>	<b>0,452</b>	<b>0,068</b>	0,723	<b>0,044</b>	0,523	0,523	<b>0,300</b>	+	
	CConf, CComp e Interés	5	0.6	28,06	4,51	0,043	5,932	0,013	0,455	0,066	0,757	0,043	0,538	0,538	<b>0,297</b>	
			0.7	28,94	4,49	0,043	6,028	0,014	0,455	0,066	0,760	0,043	0,544	0,544	0,295	
			0.8	29,50	4,54	0,041	5,677	0,013	0,444	0,062	<b>0,769</b>	0,040	0,524	0,524	0,296	
		0.9	<b>24,40</b>	<b>4,38</b>	<b>0,049</b>	<b>6,515</b>	<b>0,015</b>	<b>0,466</b>	<b>0,073</b>	0,748	<b>0,048</b>	<b>0,545</b>	<b>0,545</b>	0,294	*	
	7	0.6	28,30	4,56	0,043	5,853	0,013	0,448	0,066	0,753	0,043	0,510	0,510	<b>0,298</b>		
		0.7	<b>26,46</b>	<b>4,39</b>	<b>0,046</b>	<b>6,322</b>	<b>0,014</b>	0,453	<b>0,069</b>	0,760	<b>0,046</b>	0,529	0,529	0,290	+	
		0.8	26,64	4,45	0,045	6,122	0,014	0,452	0,068	<b>0,768</b>	0,045	0,528	0,528	0,293		
		0.9	28,24	4,54	0,043	5,962	0,013	<b>0,455</b>	0,067	0,758	0,043	<b>0,535</b>	<b>0,535</b>	0,297		

Variables	Continuas	Ejemplos	Clases
6	0	1728	4

Tabla A.31 Resumen de la experimentación de SDIGA para Car con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	4,04	3,89	0,136	<b>33,046</b>	0,045	0,350	<b>0,706</b>	0,971	0,068	0,405	0,405	
		0.7	4,06	3,96	0,127	31,907	0,042	<b>0,357</b>	0,680	0,953	0,063	<b>0,424</b>	<b>0,424</b>	
		0.8	<b>4,02</b>	3,89	0,134	32,861	0,044	0,352	0,698	0,967	0,067	0,409	0,409	
		0.9	<b>4,02</b>	<b>3,88</b>	<b>0,139</b>	32,325	<b>0,045</b>	0,346	0,697	<b>0,975</b>	<b>0,069</b>	0,397	0,397	+
FConf y Comp	5	0.6	<b>4,04</b>	<b>3,88</b>	<b>0,137</b>	<b>33,018</b>	<b>0,045</b>	0,353	<b>0,703</b>	0,972	0,068	0,413	0,413	*
		0.7	4,06	3,95	0,125	31,434	0,042	0,355	0,666	0,950	0,062	<b>0,420</b>	<b>0,420</b>	
		0.8	4,06	3,98	0,121	31,765	0,040	0,352	0,675	0,941	0,060	0,416	0,416	
		0.9	<b>4,04</b>	3,90	0,136	32,694	0,045	<b>0,355</b>	0,698	<b>0,973</b>	<b>0,068</b>	0,414	0,414	
	7	0.6	4,02	3,87	0,138	33,208	0,045	0,351	0,705	0,974	0,068	0,397	0,397	
		0.7	4,06	3,94	0,125	32,824	0,043	<b>0,357</b>	0,683	0,954	0,063	<b>0,418</b>	<b>0,418</b>	
		0.8	4,06	3,93	0,131	31,968	0,043	0,345	0,687	0,961	0,065	0,396	0,396	
		0.9	<b>4,00</b>	<b>3,85</b>	<b>0,141</b>	<b>33,338</b>	<b>0,046</b>	0,349	<b>0,711</b>	<b>0,979</b>	<b>0,070</b>	0,393	0,393	+
Medidas fitness:	3	0.6	4,10	3,90	0,138	32,573	0,045	0,351	0,697	0,975	0,068	0,404	0,404	
		0.7	4,02	<b>3,85</b>	<b>0,139</b>	<b>32,961</b>	<b>0,045</b>	0,350	<b>0,707</b>	<b>0,975</b>	<b>0,069</b>	0,401	0,401	+
		0.8	4,22	4,04	0,118	31,850	0,040	<b>0,363</b>	0,662	0,943	0,059	<b>0,431</b>	<b>0,431</b>	
		0.9	<b>4,00</b>	3,90	0,132	32,702	0,044	0,351	0,695	0,963	0,066	0,404	0,404	
Fconf y Fcomp	5	0.6	4,04	3,92	0,128	32,800	0,043	<b>0,358</b>	0,694	0,956	0,064	<b>0,418</b>	<b>0,418</b>	
		0.7	4,02	3,99	0,118	31,207	0,040	0,351	0,659	0,939	0,059	0,410	0,410	
		0.8	4,12	3,92	0,129	32,533	0,043	0,352	0,687	<b>0,961</b>	0,065	0,405	0,405	
		0.9	<b>4,00</b>	<b>3,89</b>	<b>0,131</b>	<b>33,372</b>	<b>0,044</b>	0,353	<b>0,705</b>	0,960	<b>0,065</b>	0,414	0,414	+
	7	0.6	4,06	3,92	0,131	32,428	0,043	0,350	0,693	0,961	0,065	0,406	0,406	
		0.7	4,02	3,87	<b>0,136</b>	<b>33,690</b>	<b>0,045</b>	0,351	<b>0,714</b>	<b>0,970</b>	<b>0,067</b>	0,400	0,400	*
		0.8	4,06	3,90	0,134	32,833	0,044	<b>0,353</b>	0,694	0,969	0,067	<b>0,408</b>	<b>0,408</b>	
		0.9	<b>4,00</b>	<b>3,87</b>	0,135	32,915	0,044	0,347	0,700	0,969	0,067	0,396	0,396	
Medidas fitness:	3	0.6	8,62	2,64	0,111	14,224	0,034	0,553	0,163	0,874	0,111	0,671	0,671	
		0.7	8,56	2,61	0,114	14,646	0,035	0,556	0,168	0,868	0,114	0,666	0,666	
		0.8	<b>8,36</b>	<b>2,53</b>	<b>0,115</b>	<b>14,863</b>	<b>0,035</b>	<b>0,567</b>	<b>0,170</b>	0,871	<b>0,115</b>	0,666	0,666	+
		0.9	8,94	2,65	0,112	14,463	0,034	0,564	0,167	<b>0,897</b>	0,112	<b>0,675</b>	<b>0,675</b>	
CConf y CComp	5	0.6	8,88	2,72	0,111	14,461	0,034	0,558	0,167	0,862	0,111	0,666	0,666	
		0.7	8,84	2,64	0,111	14,388	0,034	0,557	0,165	0,874	0,111	0,672	0,672	
		0.8	8,74	2,66	0,113	14,614	0,035	<b>0,565</b>	0,168	0,856	0,113	<b>0,683</b>	<b>0,683</b>	
		0.9	<b>8,48</b>	<b>2,51</b>	<b>0,116</b>	<b>14,723</b>	<b>0,035</b>	0,548	<b>0,170</b>	<b>0,882</b>	<b>0,115</b>	0,651	0,651	+
	7	0.6	8,78	2,68	0,112	14,462	0,034	0,569	0,167	<b>0,893</b>	0,112	0,684	0,684	
		0.7	<b>8,50</b>	2,64	<b>0,115</b>	<b>15,014</b>	<b>0,035</b>	0,559	<b>0,171</b>	0,857	<b>0,115</b>	0,670	0,670	*
		0.8	8,58	<b>2,53</b>	0,114	14,610	0,035	0,551	0,169	0,892	0,114	0,652	0,652	
		0.9	8,80	2,70	0,113	14,785	0,035	<b>0,577</b>	0,169	0,858	0,113	<b>0,693</b>	<b>0,693</b>	

Variables	Continuas	Ejemplos	Clases
6	0	1728	4

Tabla A.32 Resumen de la experimentación de SDIGA para Glass con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int
Medidas fitness:	3	0.6	9,18	4,57	0,066	1,475	0,011	0,196	0,444	<b>0,240</b>	0,032	0,317	0,165	<b>0,103</b>	
		0.7	8,86	4,57	0,068	1,569	0,011	0,197	0,461	0,233	0,034	0,336	0,180	0,103	
		0.8	8,36	4,58	0,060	1,638	0,012	0,199	0,473	0,211	0,033	0,349	0,189	0,100	
		0.9	<b>7,28</b>	<b>4,46</b>	<b>0,078</b>	<b>1,796</b>	<b>0,013</b>	<b>0,202</b>	<b>0,532</b>	0,212	<b>0,038</b>	<b>0,363</b>	<b>0,197</b>	0,100	+
	5	0.6	10,82	3,75	0,083	1,584	0,005	0,179	0,229	0,184	0,021	0,200	0,117	0,029	
		0.7	10,84	<b>3,68</b>	0,081	1,654	0,005	0,181	0,255	0,191	0,023	0,208	0,124	0,028	
		0.8	10,82	3,71	<b>0,088</b>	1,492	0,004	0,176	0,225	<b>0,193</b>	0,020	0,182	0,108	<b>0,029</b>	
		0.9	<b>9,90</b>	3,70	0,082	<b>1,740</b>	<b>0,007</b>	<b>0,185</b>	<b>0,282</b>	0,192	<b>0,024</b>	<b>0,253</b>	<b>0,152</b>	0,029	+
	7	0.6	10,12	3,19	0,108	2,186	0,009	0,188	0,271	0,367	0,036	0,245	0,167	0,010	
		0.7	9,86	3,23	0,101	<b>2,342</b>	0,010	0,188	0,278	0,336	0,033	0,247	0,180	0,010	
		0.8	9,48	<b>3,18</b>	0,113	2,165	0,010	0,189	0,282	<b>0,376</b>	0,038	0,250	0,179	0,012	
		0.9	<b>8,84</b>	3,27	<b>0,116</b>	2,241	<b>0,010</b>	<b>0,191</b>	<b>0,308</b>	0,349	<b>0,039</b>	<b>0,268</b>	<b>0,182</b>	<b>0,018</b>	*
<hr/>															
		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int
Medidas fitness:	3	0.6	8,14	3,03	0,196	1,937	0,011	0,181	0,369	0,398	0,050	0,272	0,183	0,124	
		0.7	7,82	<b>3,02</b>	<b>0,216</b>	<b>1,998</b>	<b>0,013</b>	0,187	<b>0,396</b>	<b>0,460</b>	<b>0,059</b>	0,269	<b>0,205</b>	0,122	+
		0.8	8,06	3,13	0,201	1,814	0,012	<b>0,187</b>	0,385	0,431	0,054	<b>0,282</b>	0,192	0,128	
		0.9	<b>7,78</b>	3,12	0,201	1,807	0,011	0,183	0,360	0,381	0,050	0,268	0,186	<b>0,131</b>	
	5	0.6	<b>8,68</b>	<b>3,04</b>	<b>0,239</b>	<b>2,488</b>	<b>0,014</b>	0,190	<b>0,400</b>	0,517	<b>0,062</b>	0,266	<b>0,199</b>	0,064	+
		0.7	9,20	3,22	0,189	2,050	0,012	0,187	0,329	0,446	0,050	0,246	0,173	0,054	
		0.8	9,60	3,08	0,216	2,093	0,013	<b>0,191</b>	0,358	<b>0,523</b>	0,059	<b>0,269</b>	0,185	<b>0,064</b>	
		0.9	9,08	3,11	0,200	2,107	0,012	0,185	0,330	0,435	0,050	0,242	0,177	0,060	
	7	0.6	7,82	2,88	0,252	2,575	0,016	0,195	0,434	0,548	0,072	0,269	0,227	0,045	
		0.7	7,86	2,83	0,271	2,647	0,017	0,195	0,453	<b>0,613</b>	0,079	0,262	0,221	0,052	
		0.8	7,34	<b>2,73</b>	0,293	<b>2,798</b>	0,017	<b>0,195</b>	<b>0,487</b>	0,607	<b>0,083</b>	<b>0,298</b>	0,241	0,061	*
		0.9	<b>7,24</b>	2,74	<b>0,297</b>	2,724	<b>0,018</b>	0,195	0,480	0,611	0,082	0,281	<b>0,243</b>	<b>0,063</b>	
<hr/>															
		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int
Medidas fitness:	3	0.6	7,28	1,97	0,034	1,375	0,006	<b>0,099</b>	<b>0,201</b>	0,736	<b>0,012</b>	0,189	0,137	<b>0,055</b>	*
		0.7	<b>7,04</b>	<b>1,86</b>	<b>0,035</b>	<b>1,384</b>	0,006	0,088	0,181	0,771	0,010	0,166	0,128	0,053	
		0.8	7,22	1,88	0,026	1,272	<b>0,007</b>	0,094	0,186	<b>0,781</b>	0,011	<b>0,194</b>	<b>0,139</b>	0,052	
		0.9	7,30	1,90	0,029	1,345	0,007	0,095	0,173	0,754	0,012	0,187	0,136	0,054	
	5	0.6	8,40	1,77	0,018	0,795	<b>0,004</b>	<b>0,089</b>	<b>0,091</b>	0,764	0,007	0,162	0,104	0,037	
		0.7	8,08	1,70	0,019	<b>0,855</b>	0,003	0,081	0,083	<b>0,824</b>	0,006	0,152	0,102	0,032	
		0.8	<b>7,90</b>	1,71	0,019	0,769	0,004	0,083	0,090	0,781	<b>0,007</b>	<b>0,166</b>	<b>0,105</b>	<b>0,039</b>	+
		0.9	8,20	<b>1,66</b>	<b>0,021</b>	0,760	0,003	0,080	0,087	0,790	0,007	0,154	0,097	0,034	
	7	0.6	<b>7,56</b>	<b>1,59</b>	0,011	0,687	0,004	0,074	0,082	0,743	0,006	0,171	0,080	0,024	
		0.7	7,62	1,64	0,012	0,762	0,005	0,080	0,079	0,741	0,006	0,163	0,097	<b>0,026</b>	
		0.8	7,88	1,67	<b>0,013</b>	<b>0,796</b>	0,004	0,080	0,090	0,761	0,006	<b>0,173</b>	0,096	0,026	
		0.9	8,00	1,64	0,013	0,781	<b>0,005</b>	<b>0,082</b>	<b>0,090</b>	<b>0,788</b>	<b>0,007</b>	0,170	<b>0,102</b>	0,023	+

Variables	Continuas	Ejemplos	Clases
9	9	214	6

Tabla A.33 Resumen de la experimentación de SDIGA para Glass con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf
Medidas fitness:	3	0.6	7,90	<b>6,20</b>	0,048	2,014	0,013	0,203	0,517	0,175	0,032	0,342	0,259	
		0.7	7,70	6,23	0,050	1,987	0,013	0,205	0,533	0,182	0,033	0,338	0,260	
		0.8	7,50	6,24	0,052	<b>2,110</b>	0,014	0,206	0,549	<b>0,187</b>	0,034	0,354	0,262	
		0.9	<b>6,72</b>	6,44	<b>0,054</b>	2,109	<b>0,015</b>	<b>0,209</b>	<b>0,592</b>	0,182	<b>0,037</b>	<b>0,381</b>	<b>0,268</b>	*
FConf y Comp	5	0.6	9,22	6,74	0,028	1,415	0,008	0,192	0,346	<b>0,124</b>	0,019	0,319	0,181	
		0.7	8,72	6,83	0,027	1,436	<b>0,008</b>	<b>0,192</b>	<b>0,357</b>	0,116	<b>0,019</b>	<b>0,326</b>	0,181	+
		0.8	8,52	6,71	0,024	1,413	0,007	0,190	0,339	0,107	0,018	0,310	0,169	
		0.9	<b>8,06</b>	<b>6,66</b>	<b>0,028</b>	<b>1,497</b>	0,008	0,191	0,354	0,107	0,019	0,317	<b>0,183</b>	
	7	0.6	9,48	6,91	<b>0,032</b>	<b>1,574</b>	<b>0,006</b>	<b>0,187</b>	<b>0,322</b>	<b>0,117</b>	<b>0,018</b>	<b>0,309</b>	<b>0,176</b>	+
		0.7	8,70	6,95	0,031	1,455	0,004	0,182	0,304	0,092	0,017	0,287	0,129	
		0.8	8,84	<b>6,91</b>	0,029	1,386	0,006	0,185	0,306	0,102	0,017	0,296	0,141	
		0.9	<b>8,36</b>	7,00	0,027	1,372	0,005	0,185	0,284	0,096	0,017	0,287	0,148	
Medidas fitness:	3	0.6	6,78	2,67	0,308	2,470	0,020	0,198	0,534	0,743	0,100	0,300	0,262	
		0.7	6,76	<b>2,63</b>	<b>0,330</b>	2,470	0,020	0,195	0,555	<b>0,774</b>	0,104	0,301	0,256	
		0.8	6,88	2,67	0,304	2,427	0,019	0,191	0,524	0,742	0,097	0,303	0,250	
		0.9	<b>6,74</b>	2,70	0,321	<b>2,667</b>	<b>0,022</b>	<b>0,206</b>	<b>0,560</b>	0,764	<b>0,105</b>	<b>0,307</b>	<b>0,285</b>	*
Fconf y Fcomp	5	0.6	10,24	3,52	<b>0,147</b>	<b>2,184</b>	0,011	0,191	<b>0,300</b>	0,523	0,049	0,256	0,200	
		0.7	10,56	3,53	0,139	2,003	0,012	<b>0,196</b>	0,294	0,506	0,049	0,258	0,202	
		0.8	10,02	<b>3,50</b>	0,146	2,105	<b>0,012</b>	0,196	0,293	<b>0,542</b>	<b>0,052</b>	<b>0,270</b>	<b>0,232</b>	+
		0.9	<b>9,64</b>	3,56	0,122	1,951	0,011	0,189	0,258	0,436	0,043	0,248	0,206	
	7	0.6	13,10	4,71	0,054	1,573	0,005	0,180	0,232	0,254	0,020	0,192	0,113	
		0.7	13,66	4,51	0,073	<b>2,047</b>	0,007	0,183	<b>0,247</b>	0,350	0,027	<b>0,227</b>	0,138	+
		0.8	14,36	4,56	0,052	1,422	0,007	0,183	0,235	0,268	0,022	0,212	0,136	
		0.9	<b>12,14</b>	<b>4,33</b>	<b>0,094</b>	1,861	<b>0,010</b>	<b>0,190</b>	0,243	<b>0,411</b>	<b>0,036</b>	0,216	<b>0,172</b>	
Medidas fitness:	3	0.6	6,96	2,18	0,040	1,842	<b>0,011</b>	0,103	0,268	0,775	<b>0,017</b>	0,206	0,175	
		0.7	<b>6,72</b>	2,16	0,039	1,778	0,011	0,104	0,261	<b>0,804</b>	0,015	0,193	0,174	
		0.8	7,12	2,19	<b>0,043</b>	<b>1,855</b>	0,010	<b>0,105</b>	<b>0,287</b>	0,801	0,017	<b>0,211</b>	<b>0,177</b>	+
		0.9	6,94	<b>2,11</b>	0,039	1,717	0,010	0,101	0,255	0,788	0,016	0,197	0,172	
CConf y CComp	5	0.6	<b>11,64</b>	3,79	<b>0,067</b>	2,502	0,009	0,157	<b>0,323</b>	0,549	<b>0,018</b>	0,214	0,189	
		0.7	12,02	3,81	0,059	2,492	0,009	0,158	0,300	0,565	0,017	0,218	0,181	
		0.8	12,48	3,77	0,063	<b>2,594</b>	<b>0,011</b>	<b>0,161</b>	0,319	0,581	0,018	<b>0,223</b>	<b>0,189</b>	*
		0.9	11,86	<b>3,66</b>	0,064	2,475	0,008	0,151	0,307	<b>0,591</b>	0,017	0,212	0,169	
	7	0.6	<b>19,70</b>	<b>4,68</b>	0,058	<b>2,392</b>	<b>0,006</b>	0,178	0,304	<b>0,399</b>	0,020	0,266	0,183	
		0.7	21,84	4,77	0,059	2,373	0,005	0,179	<b>0,323</b>	0,386	0,022	0,283	0,177	
		0.8	20,90	4,70	0,061	2,285	0,004	0,176	0,297	0,360	0,020	0,264	0,170	
		0.9	21,42	4,76	<b>0,062</b>	2,292	0,005	<b>0,182</b>	0,322	0,395	<b>0,022</b>	<b>0,287</b>	<b>0,187</b>	+

Variables	Continuas	Ejemplos	Clases
9	9	214	6

Tabla A.34 Resumen de la experimentación de SDIGA para Wine con reglas no DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf	Int	
Medidas fitness:	3	0.6	6,00	4,43	0,077	3,036	0,051	0,482	0,608	0,426	0,086	0,776	0,542	0,238		
		0.7	6,02	4,29	0,081	3,210	0,054	0,495	0,633	<b>0,448</b>	0,091	0,789	0,602	0,238		
		0.8	6,20	4,34	0,071	2,831	0,047	0,472	0,597	0,408	0,082	0,767	0,517	<b>0,243</b>		
		0.9	<b>5,12</b>	<b>4,24</b>	<b>0,088</b>	<b>3,486</b>	<b>0,058</b>	<b>0,502</b>	<b>0,677</b>	0,395	<b>0,097</b>	<b>0,803</b>	<b>0,607</b>	0,232	*	
	FConf, Comp e Interés	5	0.6	7,14	3,71	0,057	1,948	0,032	0,436	0,386	0,338	0,060	0,705	0,419	0,110	
			0.7	7,18	<b>3,61</b>	0,059	2,052	0,032	0,436	0,396	<b>0,354</b>	0,061	0,707	0,423	0,108	
			0.8	6,84	3,67	<b>0,059</b>	2,050	0,034	0,441	0,379	0,337	0,061	0,704	0,430	<b>0,111</b>	
			0.9	<b>6,16</b>	3,63	0,058	<b>2,111</b>	<b>0,035</b>	<b>0,447</b>	<b>0,397</b>	0,316	<b>0,064</b>	<b>0,727</b>	<b>0,458</b>	0,109	+
		7	0.6	7,34	3,07	0,066	1,822	0,024	0,412	0,349	<b>0,337</b>	0,055	0,662	0,364	0,031	
			0.7	8,12	3,12	0,059	1,689	0,024	0,410	0,326	0,335	0,052	0,649	0,340	<b>0,034</b>	
			0.8	7,08	3,11	0,067	1,956	0,029	0,425	0,363	0,333	0,057	0,651	0,407	0,032	
			0.9	<b>5,18</b>	<b>2,92</b>	<b>0,079</b>	<b>2,215</b>	<b>0,033</b>	<b>0,437</b>	<b>0,398</b>	0,272	<b>0,065</b>	<b>0,697</b>	<b>0,430</b>	0,027	+
Medidas fitness:		3	0.6	3,46	2,49	0,168	4,038	0,041	<b>0,366</b>	<b>0,631</b>	0,619	0,099	<b>0,518</b>	0,434	<b>0,170</b>	
			0.7	3,44	2,37	<b>0,174</b>	<b>4,343</b>	<b>0,041</b>	0,365	0,630	0,621	<b>0,099</b>	0,516	<b>0,451</b>	0,160	*
			0.8	<b>3,20</b>	<b>2,25</b>	0,172	3,967	0,035	0,330	0,613	<b>0,644</b>	0,094	0,469	0,406	0,148	
			0.9	<b>3,20</b>	2,26	0,169	4,048	0,032	0,331	0,602	0,612	0,090	0,471	0,395	0,153	
	FConf, FComp e Interés	5	0.6	4,06	2,25	0,058	2,538	0,041	0,308	0,330	0,760	0,058	0,464	0,341	0,053	
			0.7	3,96	2,25	<b>0,067</b>	<b>2,834</b>	<b>0,044</b>	<b>0,328</b>	<b>0,363</b>	0,730	<b>0,063</b>	<b>0,494</b>	<b>0,388</b>	<b>0,056</b>	+
			0.8	4,10	2,17	0,065	2,729	0,043	0,317	0,359	<b>0,775</b>	0,062	0,478	0,376	0,055	
			0.9	<b>3,46</b>	<b>1,95</b>	0,059	2,535	0,040	0,281	0,318	0,757	0,057	0,390	0,338	0,042	
		7	0.6	4,06	1,91	<b>0,029</b>	<b>1,169</b>	<b>0,017</b>	0,206	<b>0,170</b>	0,731	<b>0,026</b>	0,305	<b>0,237</b>	0,013	+
			0.7	3,96	2,05	0,026	1,053	0,017	<b>0,223</b>	0,163	0,685	0,025	<b>0,345</b>	0,234	<b>0,017</b>	
			0.8	3,84	1,79	0,024	0,975	0,015	0,183	0,148	<b>0,776</b>	0,022	0,272	0,202	0,011	
			0.9	<b>3,46</b>	<b>1,74</b>	0,023	0,876	0,013	0,168	0,119	0,760	0,019	0,209	0,176	0,012	
Medidas fitness:		3	0.6	8,16	3,10	0,112	3,309	0,055	0,464	0,629	0,671	0,103	0,663	0,611	<b>0,231</b>	
			0.7	8,74	3,01	0,115	<b>3,599</b>	<b>0,059</b>	<b>0,475</b>	<b>0,661</b>	0,688	<b>0,108</b>	<b>0,673</b>	<b>0,635</b>	0,227	*
			0.8	8,48	3,08	0,107	3,298	0,054	0,461	0,614	<b>0,722</b>	0,101	0,669	0,596	0,231	
			0.9	<b>8,02</b>	<b>2,98</b>	<b>0,117</b>	3,423	0,055	0,467	0,628	0,683	0,105	0,654	0,624	0,231	
	CConf, CComp e Interés	5	0.6	12,26	<b>2,90</b>	<b>0,088</b>	<b>2,984</b>	<b>0,045</b>	<b>0,471</b>	<b>0,479</b>	0,626	<b>0,078</b>	<b>0,736</b>	<b>0,560</b>	0,120	+
			0.7	13,34	3,01	0,082	2,710	0,040	0,457	0,437	0,640	0,072	0,678	0,509	<b>0,125</b>	
			0.8	<b>12,12</b>	2,90	0,084	2,859	0,044	0,470	0,454	0,619	0,076	0,713	0,555	0,123	
			0.9	13,88	2,98	0,084	2,798	0,042	0,462	0,441	<b>0,660</b>	0,074	0,686	0,527	0,123	
		7	0.6	12,48	2,63	0,076	2,375	0,037	0,450	0,340	<b>0,601</b>	0,064	0,660	0,519	<b>0,044</b>	
			0.7	11,80	2,63	<b>0,081</b>	<b>2,566</b>	<b>0,041</b>	<b>0,459</b>	<b>0,358</b>	0,599	<b>0,068</b>	0,674	<b>0,552</b>	0,042	+
			0.8	13,04	2,67	0,073	2,368	0,038	0,450	0,340	0,600	0,064	<b>0,678</b>	0,512	0,043	
			0.9	<b>11,66</b>	<b>2,62</b>	0,076	2,426	0,038	0,454	0,345	0,581	0,065	0,665	0,523	0,042	

Variables	Continuas	Ejemplos	Clases
13	13	178	3

Tabla A.35 Resumen de la experimentación de SDIGA para Wine con reglas DNF

		Nº Et	CNFMin	NReg	NVar	Cob	Rel	Atip	Prec	Comp	CComp	FComp	FConf	CConf		
Medidas fitness:	3	0.6	5,58	5,48	0,075	2,964	0,050	0,481	0,645	0,397	0,083	0,766	0,527			
		0.7	5,54	5,36	0,077	3,016	0,051	0,484	0,652	<b>0,405</b>	0,084	0,781	0,538			
		0.8	5,32	5,38	0,081	3,175	0,053	0,489	0,663	0,400	0,086	0,769	0,538			
		0.9	<b>5,08</b>	<b>5,29</b>	<b>0,084</b>	<b>3,299</b>	<b>0,056</b>	<b>0,495</b>	<b>0,697</b>	0,393	<b>0,090</b>	<b>0,814</b>	<b>0,560</b>	*		
	FConf y Comp	5	0.6	5,44	6,71	0,056	2,156	0,035	0,449	0,578	0,273	0,064	0,822	0,481		
			0.7	5,50	6,75	0,052	1,991	0,032	0,445	0,556	0,263	0,061	0,825	0,477		
			0.8	<b>5,30</b>	6,89	0,053	2,025	0,033	0,448	0,579	0,255	0,064	0,809	0,484		
			0.9	<b>5,30</b>	<b>6,69</b>	<b>0,059</b>	<b>2,252</b>	<b>0,037</b>	<b>0,459</b>	<b>0,607</b>	<b>0,283</b>	<b>0,067</b>	<b>0,875</b>	<b>0,529</b>	+	
		7	0.6	5,50	<b>6,83</b>	0,053	1,917	0,030	0,434	0,516	<b>0,243</b>	0,054	0,763	0,431		
			0.7	5,14	6,86	<b>0,053</b>	1,887	0,029	0,437	0,506	0,224	0,054	0,766	<b>0,463</b>		
			0.8	5,14	6,91	0,051	<b>1,933</b>	<b>0,031</b>	<b>0,437</b>	0,528	0,227	<b>0,056</b>	<b>0,797</b>	0,442	+	
			0.9	<b>4,90</b>	7,13	0,051	1,880	0,029	0,436	<b>0,539</b>	0,215	0,054	0,760	0,451		
Medidas fitness:	3	0.6	3,12	1,55	0,093	3,199	0,054	<b>0,243</b>	0,366	0,939	0,071	0,322	<b>0,322</b>			
		0.7	3,04	<b>1,46</b>	0,095	<b>3,250</b>	<b>0,055</b>	0,236	0,358	<b>0,952</b>	0,072	0,307	0,313			
		0.8	<b>3,02</b>	1,53	<b>0,097</b>	3,246	0,055	0,241	<b>0,376</b>	0,926	<b>0,073</b>	<b>0,324</b>	0,302	+		
		0.9	<b>3,02</b>	1,48	0,093	3,231	0,054	0,237	0,361	0,939	0,071	0,312	0,312			
	Fconf y Fcomp	5	0.6	3,80	2,48	0,158	5,338	0,094	0,466	0,602	0,864	0,115	0,645	0,624		
			0.7	3,92	2,61	0,166	5,695	0,101	0,490	0,628	0,860	0,123	<b>0,669</b>	0,651		
			0.8	3,52	2,44	0,170	5,610	0,101	0,459	0,619	<b>0,899</b>	0,120	0,618	0,616		
			0.9	<b>3,34</b>	<b>2,40</b>	<b>0,183</b>	<b>6,109</b>	<b>0,110</b>	<b>0,494</b>	<b>0,662</b>	<b>0,862</b>	<b>0,131</b>	0,661	<b>0,672</b>	*	
		7	0.6	4,58	3,11	0,149	4,256	0,075	0,438	0,540	<b>0,828</b>	0,098	0,618	0,539		
			0.7	4,74	3,24	0,152	4,192	0,074	0,451	0,541	0,800	0,100	0,623	0,560		
			0.8	4,42	3,03	0,163	4,450	0,079	0,452	0,576	0,823	0,106	<b>0,641</b>	0,578		
			0.9	<b>3,56</b>	<b>2,74</b>	<b>0,169</b>	<b>4,888</b>	<b>0,087</b>	<b>0,458</b>	<b>0,585</b>	0,785	<b>0,112</b>	0,627	<b>0,610</b>	+	
Medidas fitness:	3	0.6	13,56	3,92	0,145	4,085	0,066	<b>0,516</b>	<b>0,823</b>	0,805	<b>0,123</b>	<b>0,662</b>	0,672			
		0.7	13,32	<b>3,85</b>	0,141	4,136	0,065	0,511	0,808	0,817	0,121	0,643	0,671			
		0.8	13,26	3,94	<b>0,148</b>	4,093	0,065	0,510	0,821	0,807	0,123	0,647	0,671			
		0.9	<b>12,78</b>	3,87	0,147	<b>4,265</b>	<b>0,068</b>	0,515	0,814	<b>0,825</b>	0,123	0,656	<b>0,675</b>	*		
	CConf y CComp	5	0.6	<b>14,78</b>	<b>4,86</b>	<b>0,120</b>	<b>3,225</b>	<b>0,050</b>	<b>0,481</b>	<b>0,633</b>	<b>0,790</b>	<b>0,090</b>	<b>0,655</b>	<b>0,596</b>	+	
			0.7	15,16	4,98	0,110	2,996	0,046	0,474	0,614	0,755	0,084	0,645	0,584		
			0.8	15,36	4,90	0,117	3,029	0,047	0,476	0,614	0,769	0,086	0,640	0,594		
			0.9	15,52	4,95	0,113	3,053	0,046	0,473	0,612	0,769	0,085	0,627	0,579		
		7	0.6	15,82	5,41	0,100	2,529	0,034	0,436	0,533	0,702	0,067	0,592	0,491		
			0.7	15,06	<b>5,34</b>	0,100	2,560	0,037	0,446	0,535	0,722	0,070	<b>0,618</b>	0,506		
			0.8	14,90	5,41	0,098	2,529	0,036	0,442	0,537	0,692	0,068	0,599	0,497		
			0.9	<b>14,70</b>	5,36	<b>0,106</b>	<b>2,652</b>	<b>0,039</b>	<b>0,453</b>	<b>0,550</b>	<b>0,723</b>	<b>0,072</b>	0,601	<b>0,528</b>	+	

Variables	Continuas	Ejemplos	Clases
13	13	178	3

Para el algoritmo MESDIF, las siguientes tablas muestran resultados para las medidas de calidad incluidas en la función fitness y para el resto de medidas de calidad consideradas en la bibliografía especializada. El contenido de las tablas es el siguiente:

- N° Et: Número de etiquetas utilizadas para las variables continuas.
- CElite: Tamaño para el conjunto elite.
- NReg: Número medio de reglas obtenidas.
- NVar: Número medio de variables por regla.
- Cob: Cobertura.
- Rel: Relevancia.
- Atip: Atipicidad.
- Prec: Precisión
- Comp: Completitud, medida sobre el número de ejemplos de la clase.
- FConf: Confianza difusa.

En estas tablas, un asterisco (\*) indica los mejores resultados de cada combinación de medidas de calidad, y un signo más (+) indica los mejores resultados para cada valor del número de variables.

Tabla A.36 Resumen de la experimentación del algoritmo MESIF sobre el dataset Australian con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3	3	<b>6,00</b>	<b>3,89</b>	<b>0,322</b>	<b>6,648</b>	<b>0,064</b>	<b>0,715</b>	0,537	0,797	+
		4	8,00	4,27	0,253	5,906	0,052	0,702	0,557	0,811	
		5	10,00	4,40	0,247	5,871	0,053	0,706	0,572	0,810	
		10	19,98	4,65	0,201	5,665	0,049	0,715	<b>0,588</b>	<b>0,829</b>	
	5	3	<b>6,00</b>	<b>3,28</b>	<b>0,372</b>	7,346	0,053	0,702	0,534	0,772	
		4	8,00	3,45	0,326	7,130	0,054	0,699	0,553	0,784	
		5	10,00	3,52	0,311	<b>7,594</b>	<b>0,060</b>	<b>0,714</b>	<b>0,577</b>	0,807	+
		10	20,00	3,96	0,247	6,706	0,054	0,710	0,540	<b>0,833</b>	
	7	3	<b>6,00</b>	<b>3,22</b>	<b>0,370</b>	<b>9,825</b>	<b>0,078</b>	0,745	0,558	0,820	*
		4	8,00	3,31	0,290	7,155	0,060	0,727	0,546	0,819	
		5	10,00	3,44	0,297	8,902	0,070	0,744	<b>0,565</b>	0,831	
		10	20,00	3,82	0,268	9,018	0,072	<b>0,760</b>	0,561	<b>0,860</b>	
DNF	3	3	<b>6,00</b>	<b>3,11</b>	<b>0,365</b>	5,771	0,048	0,658	0,590	0,709	
		4	7,94	3,47	0,322	6,085	0,051	0,692	0,581	0,767	
		5	9,94	3,58	0,290	<b>6,477</b>	<b>0,054</b>	0,701	0,598	0,785	
		10	19,12	4,12	0,241	6,161	0,049	<b>0,715</b>	<b>0,621</b>	<b>0,807</b>	+
	5	3	<b>6,00</b>	<b>3,26</b>	<b>0,375</b>	4,801	0,042	0,649	0,598	0,704	
		4	7,98	3,35	0,349	5,912	0,052	0,677	0,592	0,743	
		5	9,94	3,55	0,335	<b>6,866</b>	<b>0,057</b>	0,698	0,608	0,771	
		10	19,14	3,99	0,286	6,637	0,057	<b>0,719</b>	<b>0,611</b>	<b>0,794</b>	+
	7	3	<b>6,00</b>	<b>3,16</b>	<b>0,382</b>	5,390	0,051	0,656	0,592	0,689	
		4	7,96	3,37	0,375	<b>7,105</b>	<b>0,061</b>	0,697	<b>0,609</b>	0,750	*
		5	9,90	3,50	0,318	6,383	0,055	0,700	0,608	0,750	
		10	18,84	4,00	0,272	6,838	0,057	<b>0,723</b>	0,591	<b>0,800</b>	

Variables	Continuas	Ejemplos	Clases
14	6	600	2

Tabla A.37 Resumen de la experimentación de MESDIF para Breast-w con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>5,62</b>	<b>2,18</b>	0,464	15,261	0,093	0,815	0,648	0,866
		4	7,02	2,26	0,481	16,690	0,097	0,812	0,660	0,859
		5	8,42	2,32	0,487	17,057	0,100	0,819	0,668	0,864
		10	11,90	2,42	<b>0,508</b>	<b>19,409</b>	<b>0,116</b>	<b>0,857</b>	<b>0,710</b>	<b>0,896</b>
	5	3	<b>5,68</b>	<b>2,19</b>	0,466	14,868	0,090	0,806	0,641	0,859
		4	6,88	2,28	0,478	16,750	0,098	0,820	0,659	0,865
		5	8,42	2,33	0,489	17,047	0,100	0,820	0,672	0,865
		10	11,82	2,42	<b>0,500</b>	<b>19,594</b>	<b>0,118</b>	<b>0,862</b>	<b>0,706</b>	<b>0,901</b>
	7	3	<b>5,68</b>	<b>2,18</b>	0,468	14,989	0,092	0,814	0,647	0,864
		4	7,04	2,26	0,475	16,594	0,096	0,815	0,657	0,862
		5	8,36	2,34	0,488	16,797	0,100	0,817	0,668	0,862
		10	11,54	2,42	<b>0,500</b>	<b>19,733</b>	<b>0,120</b>	<b>0,865</b>	<b>0,709</b>	<b>0,905</b>
DNF	3	3	<b>5,98</b>	3,13	0,471	9,298	0,064	0,723	0,612	0,761
		4	7,88	<b>3,06</b>	0,464	13,242	0,090	0,787	0,668	0,838
		5	9,90	3,19	0,462	14,344	0,097	0,796	0,681	0,835
		10	18,90	3,38	<b>0,485</b>	<b>16,987</b>	<b>0,116</b>	<b>0,832</b>	<b>0,746</b>	<b>0,870</b>
	5	3	<b>6,00</b>	<b>3,09</b>	0,466	9,794	0,067	0,733	0,613	0,769
		4	7,96	3,10	0,458	12,656	0,088	0,777	0,660	0,812
		5	9,92	3,21	0,457	14,727	0,101	0,802	0,685	0,837
		10	18,84	3,41	<b>0,477</b>	<b>16,480</b>	<b>0,114</b>	<b>0,824</b>	<b>0,732</b>	<b>0,862</b>
	7	3	<b>6,00</b>	3,17	0,456	9,190	0,062	0,714	0,593	0,726
		4	7,96	<b>3,09</b>	0,478	11,795	0,080	0,760	0,657	0,795
		5	9,92	3,16	0,467	14,288	0,098	0,798	0,692	0,843
		10	18,60	3,35	<b>0,483</b>	<b>16,364</b>	<b>0,114</b>	<b>0,829</b>	<b>0,741</b>	<b>0,866</b>

Variables	Continuas	Ejemplos	Clases
9	0	699	2

Tabla A.38 Resumen de la experimentación de MESDIF para Bridges con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>3,53</b>	<b>0,196</b>	0,613	0,007	0,575	<b>0,450</b>	0,530
		4	8,00	3,78	0,180	0,610	0,012	0,587	0,436	0,544
		5	9,98	3,75	0,192	<b>0,627</b>	0,014	0,596	0,437	0,548
		10	19,50	3,89	0,195	0,578	<b>0,017</b>	<b>0,611</b>	0,438	<b>0,575</b> *
	5	3	<b>6,00</b>	3,07	<b>0,242</b>	<b>0,750</b>	0,013	0,561	<b>0,362</b>	0,509
		4	8,00	<b>2,99</b>	0,223	0,639	0,010	0,563	0,339	0,491
		5	9,96	3,01	0,215	0,645	<b>0,015</b>	<b>0,577</b>	0,353	<b>0,529</b> +
		10	17,92	3,31	0,194	0,613	0,012	0,562	0,338	0,513
	7	3	<b>6,00</b>	3,41	0,188	<b>0,566</b>	<b>0,020</b>	0,626	<b>0,384</b>	<b>0,576</b>
		4	8,00	<b>3,39</b>	<b>0,214</b>	0,536	0,018	<b>0,629</b>	0,346	0,532 +
		5	9,70	3,47	0,209	0,544	0,017	0,624	0,342	0,526
		10	16,56	3,47	0,202	0,499	0,014	0,591	0,325	0,466
DNF	3	3	<b>5,98</b>	<b>3,37</b>	<b>0,326</b>	0,716	0,018	0,579	<b>0,578</b>	0,524
		4	7,86	3,77	0,289	0,715	0,021	0,604	0,572	0,564
		5	9,22	3,84	0,307	0,674	0,017	0,603	0,560	0,559
		10	15,88	3,99	0,307	<b>0,748</b>	<b>0,025</b>	<b>0,645</b>	0,547	<b>0,624</b> *
	5	3	<b>5,98</b>	<b>3,23</b>	<b>0,329</b>	0,660	0,015	0,564	<b>0,608</b>	0,549
		4	7,88	3,42	0,304	<b>0,797</b>	<b>0,024</b>	0,584	0,584	0,566 +
		5	9,40	3,53	0,287	0,637	0,017	0,578	0,524	0,538
		10	16,46	4,02	0,252	0,712	0,017	<b>0,593</b>	0,529	<b>0,567</b>
	7	3	<b>6,00</b>	<b>3,30</b>	<b>0,372</b>	0,578	0,009	0,564	0,541	0,504
		4	7,86	3,43	0,356	<b>0,665</b>	0,015	0,579	0,553	0,529
		5	9,74	3,53	0,346	0,649	0,013	0,588	0,578	0,546
		10	17,20	3,79	0,336	0,653	<b>0,016</b>	<b>0,605</b>	<b>0,579</b>	<b>0,567</b> +

Variables	Continuas	Ejemplos	Clases
7	3	102	2

Tabla A.39 Resumen de la experimentación de MESDIF para Diabetes con reglas de ambos tipos.

	N° Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>3,19</b>	<b>0,163</b>	1,613	0,011	0,565	0,513	0,549
		4	8,00	3,37	0,133	2,273	0,012	0,590	<b>0,540</b>	0,616
		5	10,00	3,45	0,142	2,406	0,017	0,611	0,540	0,632
		10	20,00	4,07	0,121	<b>2,514</b>	<b>0,018</b>	<b>0,630</b>	0,533	<b>0,697</b> *
	5	3	<b>6,00</b>	<b>2,71</b>	<b>0,219</b>	1,531	0,009	0,531	0,452	0,522
		4	8,00	2,85	0,190	1,944	0,013	0,580	<b>0,453</b>	0,614
		5	10,00	2,94	0,166	<b>2,029</b>	<b>0,014</b>	0,591	0,437	0,624
		10	20,00	3,18	0,142	2,024	0,012	<b>0,598</b>	0,416	<b>0,680</b> +
	7	3	<b>6,00</b>	<b>2,39</b>	<b>0,168</b>	<b>2,297</b>	<b>0,011</b>	0,575	<b>0,380</b>	0,514
		4	8,00	2,67	0,146	1,985	0,009	0,566	0,363	0,551
		5	10,00	2,68	0,152	2,056	0,010	0,569	0,369	0,563
		10	19,98	2,92	0,127	2,080	0,009	<b>0,584</b>	0,327	<b>0,635</b> +
DNF	3	3	<b>5,94</b>	<b>3,12</b>	<b>0,205</b>	2,466	0,022	0,591	0,571	0,610
		4	7,96	3,18	0,181	3,049	0,024	0,614	0,561	0,649
		5	9,86	3,37	0,172	<b>3,263</b>	<b>0,027</b>	0,633	<b>0,577</b>	0,662 *
		10	18,74	4,10	0,130	2,901	0,023	<b>0,634</b>	0,529	<b>0,693</b>
	5	3	<b>6,00</b>	<b>3,26</b>	<b>0,290</b>	1,309	0,013	0,542	0,562	0,566
		4	8,00	3,33	0,252	1,815	0,019	0,579	<b>0,569</b>	0,597
		5	10,00	3,32	0,229	2,221	0,019	0,592	0,545	0,616
		10	19,92	3,93	0,164	<b>2,248</b>	<b>0,019</b>	<b>0,605</b>	0,522	<b>0,656</b> +
	7	3	<b>6,00</b>	<b>3,12</b>	<b>0,314</b>	1,479	0,014	0,557	0,555	0,558
		4	7,98	3,24	0,293	1,665	0,015	0,565	<b>0,556</b>	0,559
		5	9,92	3,47	0,248	1,599	0,014	0,567	0,534	0,574
		10	19,78	3,94	0,201	<b>1,910</b>	<b>0,015</b>	<b>0,586</b>	0,528	<b>0,627</b> +

Variabes	Continuas	Ejemplos	Clases
8	8	768	2

Tabla A.40 Resumen de la experimentación de MESDIF para Echo con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>3,42</b>	<b>0,254</b>	0,658	0,018	0,551	<b>0,514</b>	0,567
		4	8,00	3,62	0,209	0,676	0,017	0,540	0,489	0,567
		5	10,00	3,51	0,204	0,656	0,016	0,539	0,480	<b>0,587</b>
		10	19,94	3,70	0,186	<b>0,755</b>	<b>0,019</b>	<b>0,556</b>	0,476	0,582 *
	5	3	<b>6,00</b>	<b>3,13</b>	0,168	0,928	0,012	0,534	0,372	0,572
		4	8,00	3,22	<b>0,187</b>	<b>0,938</b>	0,016	0,545	<b>0,387</b>	0,593
		5	10,00	3,29	0,160	0,913	0,017	0,553	0,362	<b>0,598</b>
		10	19,74	3,30	0,164	0,877	<b>0,017</b>	<b>0,555</b>	0,355	0,591 +
	7	3	<b>6,00</b>	<b>2,77</b>	<b>0,271</b>	0,880	0,023	<b>0,568</b>	<b>0,395</b>	0,522
		4	8,00	2,79	0,227	0,844	<b>0,023</b>	0,566	0,370	<b>0,549</b>
		5	10,00	2,78	0,223	<b>0,956</b>	0,021	0,560	0,352	0,540 +
		10	19,74	2,89	0,178	0,914	0,017	0,548	0,296	0,510
DNF	3	3	<b>6,00</b>	<b>3,29</b>	<b>0,265</b>	0,821	0,020	0,557	0,590	0,551
		4	7,94	3,36	0,264	0,815	0,024	0,573	<b>0,608</b>	0,590
		5	9,80	3,56	0,246	<b>1,009</b>	<b>0,030</b>	<b>0,589</b>	0,585	<b>0,615</b> *
		10	17,96	3,95	0,190	0,851	0,024	0,568	0,526	0,586
	5	3	<b>6,00</b>	<b>3,18</b>	<b>0,326</b>	0,693	0,015	0,546	0,561	0,543
		4	7,98	3,49	0,305	0,803	0,023	0,561	0,547	0,583
		5	9,98	3,62	0,283	0,918	<b>0,028</b>	<b>0,583</b>	<b>0,570</b>	<b>0,628</b> +
		10	19,04	4,11	0,244	<b>0,986</b>	0,026	0,575	0,535	0,595
	7	3	<b>6,00</b>	<b>3,30</b>	<b>0,359</b>	0,614	0,017	0,539	0,559	0,517
		4	7,98	3,38	0,316	0,779	0,019	0,549	0,557	0,530
		5	10,00	3,47	0,311	<b>0,871</b>	0,018	0,550	<b>0,579</b>	0,548 +
		10	19,38	3,93	0,255	0,845	<b>0,020</b>	<b>0,559</b>	0,528	<b>0,566</b>

Variables	Continuas	Ejemplos	Clases
6	5	131	2

Tabla A.41 Resumen de la experimentación de MESDIF para German con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>3,17</b>	<b>0,241</b>	1,226	0,013	0,555	0,551	0,490
		4	8,00	3,35	0,210	1,768	0,016	0,588	0,537	0,560
		5	10,00	3,55	0,204	2,115	0,018	0,602	<b>0,557</b>	0,582
		10	20,00	4,30	0,176	<b>2,810</b>	<b>0,022</b>	<b>0,648</b>	0,517	<b>0,637</b> +
	5	3	<b>6,00</b>	<b>2,91</b>	<b>0,401</b>	0,837	0,008	0,536	0,511	0,493
		4	8,00	2,91	0,386	1,508	0,017	0,562	<b>0,529</b>	0,565
		5	10,00	3,06	0,364	1,496	0,014	0,559	0,525	0,568
		10	20,00	3,70	0,267	<b>2,333</b>	<b>0,018</b>	<b>0,596</b>	0,479	<b>0,617</b> +
	7	3	<b>6,00</b>	2,95	<b>0,447</b>	0,938	0,014	0,546	<b>0,521</b>	0,511
		4	8,00	<b>2,88</b>	0,390	1,766	0,019	0,575	0,502	0,581
		5	10,00	3,02	0,365	2,145	0,020	0,582	0,498	0,579
		10	20,00	3,49	0,328	<b>2,675</b>	<b>0,024</b>	<b>0,605</b>	0,471	<b>0,612</b> *
DNF	3	3	<b>5,98</b>	<b>3,29</b>	0,343	1,439	0,016	0,564	<b>0,541</b>	0,497
		4	7,98	3,35	<b>0,346</b>	1,599	0,018	0,575	0,533	0,534
		5	10,00	3,59	0,291	1,859	0,020	0,594	0,521	0,566
		10	19,78	4,03	0,246	<b>2,860</b>	<b>0,026</b>	<b>0,636</b>	0,506	<b>0,632</b> *
	5	3	<b>6,00</b>	<b>3,20</b>	<b>0,409</b>	0,974	0,011	0,542	0,541	0,506
		4	7,98	3,27	0,407	1,323	0,015	0,554	<b>0,546</b>	0,523
		5	9,98	3,38	0,386	1,449	0,018	0,566	0,533	0,543
		10	19,90	4,04	0,347	<b>2,139</b>	<b>0,023</b>	<b>0,600</b>	0,543	<b>0,608</b> +
	7	3	<b>6,00</b>	<b>3,20</b>	0,420	0,840	0,008	0,530	0,519	0,468
		4	8,00	3,35	<b>0,435</b>	1,243	0,015	0,552	<b>0,545</b>	0,510
		5	10,00	3,35	0,401	1,848	0,020	0,570	0,531	0,553
		10	19,86	3,94	0,374	<b>2,104</b>	<b>0,022</b>	<b>0,594</b>	0,542	<b>0,595</b> +

Variables	Continuas	Ejemplos	Clases
20	7	1000	2

Tabla A.42 Resumen de la experimentación de MESDIF para Heart para reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
	3	<b>6,00</b>	3,42	0,281	1,655	0,033	0,607	0,561	0,649	
	4	8,00	<b>3,24</b>	<b>0,297</b>	2,329	0,047	0,647	0,594	0,702	
	5	10,00	3,28	0,283	2,547	0,051	0,660	<b>0,598</b>	0,716	
	10	20,00	3,58	0,242	<b>3,068</b>	<b>0,058</b>	<b>0,698</b>	0,584	<b>0,775</b>	*
No DNF	3	<b>6,00</b>	<b>2,86</b>	<b>0,246</b>	1,879	0,040	0,611	0,451	0,692	
	4	8,00	3,08	0,223	1,964	0,040	0,624	0,456	0,700	
	5	10,00	3,12	0,219	2,192	0,041	0,627	0,459	0,732	
	10	19,94	3,14	0,224	<b>2,549</b>	<b>0,051</b>	<b>0,660</b>	<b>0,467</b>	<b>0,774</b>	+
7	3	<b>6,00</b>	<b>2,83</b>	<b>0,300</b>	<b>3,192</b>	<b>0,067</b>	<b>0,673</b>	<b>0,478</b>	0,762	+
	4	8,00	2,98	0,274	2,642	0,058	0,646	0,459	0,734	
	5	10,00	3,01	0,283	2,884	0,063	0,663	0,472	<b>0,769</b>	
	10	19,78	3,20	0,267	2,864	0,062	0,662	0,454	0,757	
3	3	<b>6,00</b>	<b>3,53</b>	<b>0,310</b>	1,980	0,052	0,632	0,584	0,651	
	4	7,98	3,67	0,288	2,442	0,057	0,664	0,593	0,710	
	5	9,94	3,55	0,297	2,880	<b>0,065</b>	0,677	0,610	0,720	
	10	19,84	3,94	0,250	<b>3,117</b>	0,062	<b>0,696</b>	<b>0,625</b>	<b>0,774</b>	*
DNF	3	<b>6,00</b>	<b>3,23</b>	<b>0,369</b>	1,497	0,039	0,603	0,585	0,591	
	4	8,00	3,33	0,327	2,109	0,049	0,635	0,585	0,683	
	5	9,96	3,52	0,334	1,952	0,047	0,630	<b>0,591</b>	0,685	
	10	19,94	3,85	0,277	<b>2,354</b>	<b>0,053</b>	<b>0,660</b>	0,579	<b>0,743</b>	+
7	3	<b>6,00</b>	<b>3,28</b>	<b>0,401</b>	1,313	0,034	0,589	0,577	0,601	
	4	7,98	3,37	0,369	1,783	0,041	0,618	0,581	0,669	
	5	9,96	3,44	0,375	2,118	0,048	0,634	<b>0,592</b>	0,670	
	10	19,94	3,96	0,314	<b>2,480</b>	<b>0,053</b>	<b>0,666</b>	0,590	<b>0,736</b>	+

Variables	Continuas	Ejemplos	Clases
13	7	270	2

Tabla A.43 Resumen de la experimentación de MESDIF para Hepatitis con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>5,36</b>	0,272	1,140	0,021	0,624	0,603	0,660
		4	8,00	5,47	<b>0,307</b>	1,007	0,019	0,629	0,619	0,647
		5	10,00	5,60	0,300	1,101	0,021	0,625	0,632	0,658
		10	19,98	5,98	0,278	<b>1,143</b>	<b>0,026</b>	<b>0,635</b>	<b>0,645</b>	<b>0,714</b> +
	5	3	<b>6,00</b>	<b>3,48</b>	<b>0,419</b>	<b>1,283</b>	<b>0,032</b>	0,586	0,606	0,579
		4	8,00	3,67	0,415	0,988	0,025	0,572	0,608	0,557
		5	10,00	3,98	0,409	1,195	0,030	0,589	<b>0,620</b>	0,595 +
		10	19,94	4,68	0,297	1,017	0,022	<b>0,594</b>	0,571	<b>0,619</b>
	7	3	<b>6,00</b>	<b>3,37</b>	<b>0,521</b>	1,226	0,042	0,603	0,641	0,601
		4	8,00	3,56	0,467	1,250	0,036	0,599	0,614	0,605
		5	10,00	3,74	0,463	1,271	0,042	0,607	<b>0,645</b>	0,619
		10	19,82	4,31	0,381	<b>1,340</b>	<b>0,043</b>	<b>0,626</b>	0,640	<b>0,659</b> *
DNF	3	3	<b>5,98</b>	<b>3,65</b>	<b>0,260</b>	0,995	0,025	0,587	0,564	0,575
		4	7,96	3,77	0,257	1,263	0,031	0,621	0,592	0,664
		5	9,90	4,22	0,255	1,194	0,029	0,612	0,599	0,646
		10	18,58	4,62	0,255	<b>1,353</b>	<b>0,033</b>	<b>0,633</b>	<b>0,606</b>	<b>0,675</b> *
	5	3	<b>5,98</b>	<b>3,56</b>	<b>0,327</b>	0,775	0,016	0,568	0,584	0,540
		4	8,00	3,90	0,294	0,953	0,022	0,587	0,592	0,587
		5	9,92	3,98	0,294	1,156	<b>0,029</b>	0,612	0,592	0,631
		10	19,36	4,55	0,266	<b>1,164</b>	0,028	<b>0,622</b>	<b>0,592</b>	<b>0,644</b> +
	7	3	<b>6,00</b>	<b>3,42</b>	0,348	0,908	0,026	0,591	0,580	0,571
		4	8,00	3,63	0,327	0,997	0,026	0,587	0,588	0,578
		5	9,94	3,75	<b>0,354</b>	1,195	0,027	0,599	0,595	0,598
		10	19,52	4,59	0,318	<b>1,281</b>	<b>0,031</b>	<b>0,613</b>	<b>0,621</b>	<b>0,625</b> +

Variabes	Continuas	Ejemplos	Clases
19	6	155	2

Tabla A.44 Resumen de la experimentación de MESDIF para Hypothyroid con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3	3	<b>6,00</b>	<b>7,14</b>	<b>0,321</b>	5,439	<b>0,009</b>	0,695	0,580	0,646	
		4	8,00	7,74	0,257	6,940	0,008	0,744	0,608	0,687	
		5	10,00	8,29	0,224	7,854	0,008	0,765	0,636	0,708	
		10	20,00	8,76	0,161	<b>8,396</b>	0,008	<b>0,776</b>	<b>0,652</b>	<b>0,711</b>	+
	5	3	<b>6,00</b>	<b>6,73</b>	<b>0,320</b>	10,774	0,016	0,725	0,657	0,648	
		4	8,00	7,53	0,307	12,331	<b>0,016</b>	0,782	<b>0,667</b>	0,733	
		5	10,00	7,66	0,293	12,052	0,015	0,783	0,640	0,730	
		10	20,00	7,94	0,261	<b>13,749</b>	0,015	<b>0,805</b>	0,639	<b>0,751</b>	+
	7	3	<b>6,00</b>	<b>6,18</b>	0,278	14,606	0,013	0,800	0,607	0,704	
		4	8,00	6,65	0,260	14,001	0,013	0,802	0,612	0,735	
		5	9,96	6,57	0,269	12,621	0,012	0,802	0,611	0,776	
		10	19,98	7,26	<b>0,291</b>	<b>14,722</b>	<b>0,015</b>	<b>0,809</b>	<b>0,632</b>	<b>0,808</b>	*
DNF	3	3	<b>5,90</b>	<b>3,69</b>	<b>0,269</b>	5,816	0,009	0,631	0,578	0,586	
		4	7,72	3,87	0,250	5,977	0,009	0,639	0,593	0,598	
		5	8,96	4,05	0,229	<b>7,107</b>	<b>0,011</b>	0,647	0,590	0,600	
		10	11,90	4,18	0,219	6,555	0,010	<b>0,666</b>	<b>0,593</b>	<b>0,628</b>	+
	5	3	<b>5,74</b>	<b>3,48</b>	<b>0,332</b>	8,832	0,012	0,672	0,685	0,618	
		4	7,44	3,59	0,308	11,667	0,014	0,719	0,687	0,658	
		5	8,82	3,94	0,295	9,657	0,013	0,707	0,650	0,645	
		10	12,06	3,89	0,297	<b>12,072</b>	<b>0,015</b>	<b>0,752</b>	<b>0,689</b>	<b>0,695</b>	+
	7	3	<b>5,76</b>	<b>3,29</b>	0,360	11,334	0,014	0,684	0,739	0,623	
		4	7,36	3,37	0,350	<b>14,845</b>	<b>0,016</b>	<b>0,741</b>	<b>0,756</b>	0,659	*
		5	8,66	3,58	<b>0,361</b>	12,689	0,015	0,720	0,738	0,656	
		10	13,16	3,97	0,348	12,828	0,016	0,740	0,739	<b>0,661</b>	

Variables	Continuas	Ejemplos	Clases
25	7	3163	2

Tabla A.45 Resumen de la experimentación de MESDIF para Ionosphere con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>4,69</b>	<b>0,370</b>	2,892	0,046	0,615	0,596	0,704
		4	8,00	4,83	0,343	3,231	0,048	0,639	0,607	<b>0,741</b>
		5	10,00	5,26	0,331	2,984	0,045	0,628	0,629	0,719
		10	19,74	5,26	0,295	<b>3,809</b>	<b>0,056</b>	<b>0,675</b>	<b>0,638</b>	0,734 *
	5	3	<b>6,00</b>	<b>3,16</b>	<b>0,448</b>	2,168	0,037	0,604	<b>0,625</b>	0,683
		4	8,00	3,32	0,392	2,528	0,044	0,638	0,613	0,729
		5	10,00	3,51	0,347	2,466	0,043	0,643	0,586	0,735
		10	19,90	3,96	0,283	<b>3,623</b>	<b>0,051</b>	<b>0,679</b>	0,566	<b>0,778</b> +
	7	3	<b>5,98</b>	<b>3,03</b>	<b>0,431</b>	2,316	0,037	0,620	<b>0,595</b>	0,712
		4	8,00	3,19	0,386	2,759	<b>0,048</b>	0,647	0,588	0,739
		5	10,00	3,25	0,344	2,967	0,047	0,658	0,570	0,748
		10	19,56	3,52	0,253	<b>3,279</b>	0,046	<b>0,687</b>	0,495	<b>0,797</b> +
DNF	3	3	<b>5,98</b>	<b>3,94</b>	<b>0,337</b>	2,577	0,038	0,613	0,609	0,682
		4	7,88	4,28	0,296	2,657	0,038	0,618	0,620	0,714
		5	9,68	4,45	0,275	2,862	0,040	0,634	0,615	0,712
		10	16,52	5,42	0,242	<b>3,116</b>	<b>0,043</b>	<b>0,659</b>	<b>0,638</b>	<b>0,785</b> +
	5	3	<b>5,98</b>	<b>3,56</b>	<b>0,358</b>	2,020	0,035	0,611	0,602	0,673
		4	7,80	3,69	0,331	2,420	0,041	0,630	0,626	0,702
		5	9,62	3,98	0,294	2,591	0,041	0,637	0,603	0,697
		10	18,06	4,71	0,246	<b>3,003</b>	<b>0,047</b>	<b>0,677</b>	<b>0,640</b>	<b>0,768</b> +
	7	3	<b>5,98</b>	<b>3,53</b>	<b>0,377</b>	1,965	0,031	0,603	0,604	0,685
		4	7,98	3,77	0,323	1,913	0,034	0,607	0,610	0,676
		5	9,90	3,95	0,328	2,418	0,042	0,634	0,620	0,706
		10	19,28	4,67	0,275	<b>3,065</b>	<b>0,046</b>	<b>0,656</b>	<b>0,656</b>	<b>0,756</b> *

Variables	Continuas	Ejemplos	Clases
34	34	351	2

Tabla A.46 Resumen de la experimentación de MESDIF para Iris con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
	3		<b>8,96</b>	<b>3,46</b>	<b>0,120</b>	<b>3,350</b>	<b>0,071</b>	<b>0,482</b>	<b>0,653</b>	0,835	+
	4	11,88	3,62	0,092	2,565	0,054	0,448	0,584	0,834		
	5	14,72	3,74	0,076	2,140	0,045	0,430	0,551	0,846		
	10	23,66	3,90	0,052	1,489	0,031	0,404	0,534	<b>0,890</b>		
No DNF	3		<b>8,50</b>	<b>2,47</b>	<b>0,217</b>	<b>6,452</b>	<b>0,134</b>	<b>0,622</b>	<b>0,846</b>	<b>0,929</b>	*
	4	9,50	2,50	0,208	6,229	0,129	0,613	0,844	0,916		
	5	9,90	2,51	0,204	6,125	0,126	0,608	0,837	0,915		
	10	10,02	2,51	0,205	6,146	0,127	0,609	0,837	0,915		
	3	5,54	<b>2,35</b>	<b>0,144</b>	<b>4,669</b>	<b>0,095</b>	<b>0,585</b>	<b>0,888</b>	0,989	+	
	4	5,52	2,35	0,144	4,635	0,094	0,583	0,887	0,986		
	5	5,44	2,36	0,142	4,650	0,094	0,584	0,888	0,989		
	10	<b>5,30</b>	2,37	0,139	4,586	0,093	0,582	0,885	<b>0,991</b>		
	3		<b>5,26</b>	<b>3,00</b>	<b>0,203</b>	<b>5,440</b>	<b>0,115</b>	<b>0,565</b>	<b>0,787</b>	0,817	+
	4	6,34	3,10	0,176	4,646	0,099	0,535	0,739	0,782		
	5	6,82	3,15	0,163	4,444	0,095	0,528	0,730	0,813		
	10	8,42	3,26	0,136	3,781	0,080	0,502	0,693	<b>0,822</b>		
DNF	3		<b>5,66</b>	2,57	0,195	5,664	0,118	0,585	0,787	0,869	
	4	5,96	<b>2,57</b>	<b>0,201</b>	<b>5,886</b>	<b>0,122</b>	0,595	<b>0,801</b>	0,882	*	
	5	6,10	2,57	0,198	5,877	0,122	0,597	0,800	0,884		
	10	6,64	2,69	0,189	5,803	0,120	<b>0,598</b>	0,800	<b>0,901</b>		
	3		<b>7,58</b>	<b>2,63</b>	<b>0,240</b>	4,858	0,102	0,550	0,829	0,805	
	4	8,82	2,71	0,236	5,265	0,110	0,570	0,838	0,823		
	5	9,78	2,83	0,209	4,932	0,103	0,564	0,826	0,837		
	10	11,30	3,04	0,216	<b>5,407</b>	<b>0,113</b>	<b>0,589</b>	<b>0,863</b>	<b>0,859</b>	+	

Variables	Continuas	Ejemplos	Clases
4	4	150	3

Tabla A.47 Resumen de la experimentación de MESDIF para Tic-Tac-Toe con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3		3	<b>6,00</b>	3,14	<b>0,210</b>	<b>5,005</b>	<b>0,042</b>	0,711	<b>0,304</b>	0,747 *
			4	7,98	<b>3,02</b>	0,189	4,869	0,038	<b>0,716</b>	0,274	<b>0,768</b>
			5	9,70	3,05	0,177	4,507	0,035	0,703	0,257	0,744
			10	14,62	3,04	0,172	4,173	0,031	0,691	0,244	0,735
	5	3	<b>6,00</b>	3,16	<b>0,210</b>	<b>5,009</b>	<b>0,042</b>	0,711	<b>0,303</b>	0,743 +	
		4	7,94	3,02	0,187	4,975	0,038	<b>0,717</b>	0,273	<b>0,768</b>	
		5	9,54	3,06	0,176	4,554	0,035	0,703	0,255	0,746	
		10	14,90	<b>3,02</b>	0,177	4,093	0,031	0,687	0,248	0,730	
	7	3	<b>6,00</b>	3,18	<b>0,209</b>	4,883	<b>0,041</b>	0,710	<b>0,299</b>	0,751	
		4	7,96	<b>3,01</b>	0,186	<b>4,987</b>	0,039	<b>0,723</b>	0,273	<b>0,777</b> +	
		5	9,72	3,04	0,177	4,607	0,034	0,704	0,254	0,753	
		10	15,04	3,03	0,172	4,195	0,031	0,688	0,243	0,731	
DNF	3		3	<b>6,00</b>	3,19	0,322	3,660	0,032	0,642	0,393	0,669
			4	7,72	3,14	0,308	<b>4,929</b>	<b>0,045</b>	<b>0,683</b>	0,406	<b>0,721</b> *
			5	9,40	<b>3,02</b>	0,336	4,122	0,038	0,651	0,418	0,672
			10	18,06	3,04	<b>0,373</b>	4,318	0,037	0,638	<b>0,453</b>	0,652
	5	3	<b>5,96</b>	3,20	0,322	3,704	0,032	0,635	0,391	0,640	
		4	7,76	3,14	0,319	3,968	0,037	<b>0,654</b>	0,399	<b>0,679</b>	
		5	9,60	3,02	0,342	4,167	<b>0,039</b>	0,650	0,425	0,666	
		10	17,54	<b>3,01</b>	<b>0,375</b>	<b>4,330</b>	0,037	0,637	<b>0,458</b>	0,655 +	
	7	3	<b>5,98</b>	3,13	0,333	3,712	0,033	0,645	0,404	0,666	
		4	7,74	3,05	0,326	4,566	0,042	<b>0,668</b>	0,416	<b>0,695</b>	
		5	9,68	<b>2,98</b>	0,344	<b>4,631</b>	<b>0,042</b>	0,664	0,436	0,687 +	
		10	17,88	3,06	<b>0,366</b>	4,235	0,037	0,647	<b>0,446</b>	0,665	

Variabes	Continuas	Ejemplos	Clases
9	0	958	2

Tabla A.48 Resumen de la experimentación de MESDIF para Vote con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>6,00</b>	<b>3,33</b>	0,422	18,924	0,181	0,904	0,800	0,953
		4	7,86	3,44	0,429	<b>19,937</b>	<b>0,187</b>	<b>0,910</b>	0,827	<b>0,957</b> *
		5	9,20	3,48	<b>0,432</b>	19,189	0,182	0,898	0,826	0,945
		10	15,00	3,70	0,421	18,771	0,178	0,882	<b>0,831</b>	0,929
	5	3	<b>6,00</b>	<b>3,34</b>	0,422	18,625	0,180	0,901	0,798	0,951
		4	7,92	3,44	0,430	<b>19,685</b>	<b>0,185</b>	<b>0,908</b>	0,823	<b>0,955</b> +
		5	9,22	3,50	<b>0,433</b>	19,342	0,183	0,899	<b>0,830</b>	0,946
		10	14,86	3,69	0,421	18,652	0,178	0,880	0,830	0,927
	7	3	<b>6,00</b>	<b>3,30</b>	0,419	18,754	0,180	0,904	0,797	0,954
		4	7,86	3,45	0,428	<b>19,541</b>	<b>0,185</b>	<b>0,907</b>	0,820	<b>0,954</b> +
		5	9,28	3,49	<b>0,436</b>	19,129	0,182	0,897	0,829	0,943
		10	14,98	3,74	0,421	18,774	0,178	0,882	<b>0,831</b>	0,929
DNF	3	3	<b>5,68</b>	3,16	0,413	14,481	0,149	0,838	0,725	0,871
		4	7,04	<b>3,15</b>	<b>0,416</b>	15,584	0,157	0,853	0,758	0,896
		5	8,60	3,28	0,401	15,748	0,156	0,859	0,744	0,900
		10	13,84	3,47	0,394	<b>17,819</b>	<b>0,168</b>	<b>0,875</b>	<b>0,781</b>	<b>0,927</b> +
	5	3	<b>5,68</b>	3,19	0,406	14,451	0,147	0,840	0,717	0,874
		4	7,24	<b>3,18</b>	0,403	15,518	0,155	0,854	0,738	0,892
		5	8,48	3,20	<b>0,407</b>	16,586	0,161	0,861	0,759	0,903
		10	13,40	3,45	0,395	<b>17,968</b>	<b>0,170</b>	<b>0,876</b>	<b>0,788</b>	<b>0,927</b> *
	7	3	<b>5,68</b>	<b>3,15</b>	<b>0,408</b>	14,563	0,149	0,838	0,721	0,869
		4	7,06	3,25	0,404	16,066	0,157	0,858	0,744	0,902
		5	8,54	3,26	0,399	16,469	0,160	0,868	0,751	0,915 +
		10	13,72	3,45	0,394	<b>17,315</b>	<b>0,167</b>	<b>0,870</b>	<b>0,775</b>	<b>0,916</b>

Variables	Continuas	Ejemplos	Clases
9	0	958	2

Tabla A.49 Resumen de la experimentación de MESDIF para Balance con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf
No DNF	3	3	<b>9,00</b>	3,11	0,177	3,171	0,020	0,427	<b>0,353</b>	0,548
		4	11,92	3,02	0,173	3,325	0,021	0,425	0,338	0,535
		5	14,92	<b>2,97</b>	<b>0,178</b>	3,408	0,022	0,429	0,337	0,539
		10	28,10	3,08	0,163	<b>3,516</b>	<b>0,022</b>	<b>0,442</b>	0,318	<b>0,557</b> *
	5	3	<b>8,72</b>	3,05	0,074	2,746	0,012	0,398	0,086	0,329
		4	10,84	3,06	0,076	2,984	0,014	0,410	0,092	0,358
		5	12,62	2,97	0,087	<b>3,409</b>	0,015	<b>0,410</b>	0,099	0,374
		10	16,22	<b>2,91</b>	<b>0,090</b>	3,338	<b>0,016</b>	0,409	<b>0,103</b>	<b>0,391</b> +
	7	3	<b>8,76</b>	3,05	0,068	2,686	0,013	0,408	0,089	0,338
		4	11,16	3,01	0,078	3,001	0,015	<b>0,416</b>	<b>0,099</b>	<b>0,367</b>
		5	12,66	<b>2,99</b>	<b>0,079</b>	<b>3,036</b>	<b>0,015</b>	0,413	0,098	0,354 +
		10	18,00	3,09	0,077	2,918	0,013	0,400	0,091	0,348
DNF	3	3	<b>9,00</b>	<b>3,01</b>	<b>0,312</b>	4,625	0,038	0,454	<b>0,505</b>	0,529
		4	11,82	3,10	0,295	4,649	0,036	0,456	0,489	0,530
		5	14,92	3,17	0,287	4,869	0,037	0,466	0,488	0,541
		10	28,44	3,44	0,254	<b>5,912</b>	<b>0,042</b>	<b>0,500</b>	0,470	<b>0,566</b> *
	5	3	<b>9,00</b>	2,91	<b>0,396</b>	3,598	0,032	0,434	<b>0,438</b>	0,472
		4	11,94	<b>2,85</b>	0,377	4,227	0,033	0,446	0,415	0,481
		5	14,98	2,88	0,376	4,759	0,042	0,461	0,434	0,491
		10	28,62	3,17	0,363	<b>5,613</b>	<b>0,046</b>	<b>0,479</b>	0,431	<b>0,521</b> +
	7	3	<b>9,00</b>	3,02	<b>0,433</b>	2,406	0,015	0,404	<b>0,567</b>	0,446
		4	11,98	<b>3,01</b>	0,394	3,157	0,021	0,425	0,556	0,468
		5	15,00	3,04	0,384	3,750	0,028	0,440	0,549	0,477
		10	29,18	3,37	0,336	<b>4,406</b>	<b>0,033</b>	<b>0,460</b>	0,522	<b>0,504</b> +

Variabes	Continuas	Ejemplos	Clases
4	4	625	3

Tabla A.50 Resumen de la experimentación de MESDIF para Car con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3	3	<b>10,40</b>	<b>3,34</b>	<b>0,160</b>	<b>13,515</b>	<b>0,026</b>	<b>0,339</b>	<b>0,355</b>	0,312	+
		4	13,36	3,48	0,128	12,086	0,022	0,331	0,303	0,321	
		5	16,40	3,53	0,119	11,463	0,020	0,329	0,295	0,315	
		10	27,28	3,64	0,101	10,257	0,017	0,324	0,269	<b>0,327</b>	
	5	3	<b>10,34</b>	<b>3,36</b>	<b>0,160</b>	<b>13,330</b>	<b>0,025</b>	<b>0,332</b>	<b>0,353</b>	0,310	+
		4	13,30	3,47	0,128	11,813	0,021	0,326	0,304	0,307	
		5	16,40	3,55	0,117	11,538	0,020	0,331	0,292	0,318	
		10	27,80	3,62	0,104	10,608	0,018	0,329	0,274	<b>0,329</b>	
	7	3	<b>10,46</b>	<b>3,34</b>	<b>0,163</b>	<b>13,511</b>	<b>0,026</b>	<b>0,340</b>	<b>0,353</b>	0,308	*
		4	13,34	3,47	0,129	12,284	0,022	0,332	0,314	0,317	
		5	16,28	3,54	0,118	11,253	0,020	0,326	0,284	0,306	
		10	27,86	3,62	0,102	10,283	0,017	0,323	0,268	<b>0,323</b>	
DNF	3	3	<b>11,30</b>	<b>3,55</b>	<b>0,296</b>	18,145	0,037	0,417	<b>0,621</b>	0,443	
		4	15,12	3,70	0,269	18,975	0,038	0,440	0,568	0,475	
		5	17,10	3,87	0,254	20,633	<b>0,039</b>	0,462	0,566	0,507	
		10	26,74	4,29	0,208	<b>21,326</b>	0,038	<b>0,483</b>	0,498	<b>0,544</b>	+
	5	3	<b>11,28</b>	<b>3,59</b>	<b>0,288</b>	18,657	0,038	0,417	<b>0,612</b>	0,446	
		4	14,72	3,67	0,277	19,118	0,038	0,451	0,572	0,482	
		5	17,62	3,90	0,253	19,571	0,037	0,443	0,548	0,473	
		10	25,68	4,34	0,211	<b>22,238</b>	<b>0,039</b>	<b>0,495</b>	0,509	<b>0,568</b>	*
	7	3	<b>11,30</b>	<b>3,50</b>	<b>0,304</b>	17,444	0,035	0,413	<b>0,615</b>	0,440	
		4	14,96	3,68	0,273	19,613	<b>0,039</b>	0,445	0,573	0,477	
		5	17,68	3,89	0,254	19,415	0,038	0,456	0,552	0,503	
		10	25,88	4,31	0,213	<b>21,892</b>	0,039	<b>0,491</b>	0,511	<b>0,566</b>	+

Variables	Continuas	Ejemplos	Clases
6	0	1728	4

Tabla A.51 Resumen de la experimentación de MESDIF para Glass con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3	3	<b>18,00</b>	<b>5,58</b>	<b>0,083</b>	<b>1,515</b>	0,005	0,182	<b>0,353</b>	0,227	+
		4	24,00	5,92	0,072	1,323	0,005	0,183	0,328	0,227	
		5	29,96	5,98	0,066	1,303	0,005	0,184	0,343	0,253	
		10	59,84	6,22	0,045	1,137	<b>0,006</b>	<b>0,185</b>	0,304	<b>0,290</b>	
	5	3	<b>18,00</b>	<b>4,68</b>	<b>0,118</b>	<b>1,644</b>	<b>0,005</b>	0,181	<b>0,311</b>	<b>0,233</b>	+
		4	24,00	4,90	0,102	1,420	0,005	<b>0,181</b>	0,300	0,221	
		5	30,00	5,10	0,091	1,360	0,004	0,181	0,283	0,215	
		10	59,50	5,30	0,071	1,227	0,003	0,178	0,258	0,206	
	7	3	<b>18,00</b>	<b>4,09</b>	<b>0,132</b>	<b>1,821</b>	<b>0,006</b>	<b>0,186</b>	<b>0,265</b>	0,173	*
		4	23,98	4,33	0,117	1,797	0,006	0,186	0,239	0,166	
		5	29,90	4,39	0,107	1,647	0,005	0,182	0,226	<b>0,178</b>	
		10	57,66	4,72	0,088	1,425	0,003	0,177	0,193	0,173	
DNF	3	3	<b>15,78</b>	<b>3,99</b>	<b>0,154</b>	<b>3,573</b>	0,016	0,200	<b>0,565</b>	0,289	
		4	19,22	4,30	0,129	3,555	0,017	0,204	0,547	0,327	*
		5	22,48	4,52	0,115	3,184	<b>0,017</b>	<b>0,209</b>	0,511	0,331	
		10	31,28	4,90	0,083	2,630	0,015	0,205	0,454	<b>0,347</b>	
	5	3	<b>17,26</b>	<b>4,24</b>	<b>0,164</b>	3,063	0,015	0,203	0,495	0,297	
		4	21,64	4,39	0,148	<b>3,289</b>	<b>0,016</b>	<b>0,207</b>	<b>0,512</b>	0,326	+
		5	25,44	4,60	0,119	2,820	0,013	0,204	0,462	0,306	
		10	37,16	5,39	0,081	2,425	0,011	0,202	0,431	<b>0,330</b>	
	7	3	<b>17,26</b>	<b>4,09</b>	<b>0,182</b>	<b>3,204</b>	0,012	0,199	0,453	0,260	+
		4	22,32	4,48	0,163	3,059	<b>0,013</b>	<b>0,202</b>	<b>0,466</b>	0,267	
		5	26,32	4,56	0,155	2,856	0,011	0,199	0,455	<b>0,283</b>	
		10	39,72	5,40	0,105	2,398	0,010	0,201	0,404	0,282	

Variables	Continuas	Ejemplos	Clases
9	9	214	6

Tabla A.52 Resumen de la experimentación de MESDIF para Wine con reglas de ambos tipos.

	Nº Et	CElite	NReg	NVar	Cob	Rel	Atip	Prec	Comp	FConf	
No DNF	3	3	<b>9,00</b>	<b>5,52</b>	<b>0,071</b>	<b>2,446</b>	<b>0,042</b>	<b>0,456</b>	<b>0,683</b>	0,897	+
		4	12,00	5,56	0,062	2,120	0,037	0,445	0,677	0,897	
		5	14,98	5,70	0,060	2,044	0,035	0,444	0,677	0,899	
		10	29,78	6,04	0,050	1,683	0,030	0,433	0,651	<b>0,919</b>	
	5	3	<b>9,00</b>	<b>2,99</b>	<b>0,146</b>	<b>2,715</b>	<b>0,035</b>	0,435	<b>0,602</b>	<b>0,749</b>	*
		4	12,00	3,25	0,121	2,497	0,033	0,434	0,552	0,732	
		5	14,92	3,24	0,116	2,596	0,033	<b>0,436</b>	0,548	0,715	
		10	28,26	3,44	0,093	2,283	0,031	0,433	0,497	0,709	
	7	3	<b>9,00</b>	<b>2,63</b>	<b>0,095</b>	2,356	0,033	<b>0,440</b>	<b>0,459</b>	0,710	
		4	11,96	2,76	0,089	<b>2,425</b>	<b>0,033</b>	0,439	0,437	0,739	
		5	14,48	2,79	0,085	2,389	0,031	0,433	0,442	0,726	
		10	21,90	2,73	0,091	2,420	0,032	0,435	0,451	<b>0,753</b>	+
DNF	3	3	<b>8,26</b>	<b>3,85</b>	<b>0,162</b>	<b>4,222</b>	<b>0,075</b>	<b>0,530</b>	0,747	0,786	*
		4	10,26	3,96	0,145	3,878	0,068	0,522	0,758	0,824	
		5	11,88	4,21	0,134	3,883	0,068	0,527	<b>0,774</b>	0,849	
		10	15,90	4,82	0,108	3,431	0,060	0,515	0,754	<b>0,884</b>	
	5	3	<b>8,88</b>	3,73	<b>0,197</b>	3,656	<b>0,064</b>	0,500	0,700	0,746	
		4	11,46	<b>3,71</b>	0,181	<b>3,736</b>	0,062	0,505	<b>0,708</b>	0,760	+
		5	13,88	4,04	0,163	3,661	0,063	<b>0,509</b>	0,703	0,794	
		10	20,30	4,43	0,129	3,164	0,055	0,498	0,684	<b>0,819</b>	
	7	3	<b>8,92</b>	<b>3,92</b>	<b>0,195</b>	2,586	0,045	0,455	0,633	0,663	
		4	11,60	4,08	0,175	2,666	<b>0,047</b>	0,462	<b>0,640</b>	0,673	
		5	14,00	4,06	0,162	<b>2,769</b>	0,044	0,457	0,633	0,708	+
		10	22,88	4,61	0,123	2,634	0,044	<b>0,470</b>	0,637	<b>0,757</b>	

Variables	Continuas	Ejemplos	Clases
13	13	178	3

## Apéndice C. El algoritmo CN2-SD

---

CN2-SD es un algoritmo de descubrimiento de subgrupos obtenido mediante la modificación del algoritmo estándar de aprendizaje de reglas de clasificación, CN2, a descubrimiento de subgrupos. El enfoque propuesto realiza descubrimiento de subgrupos mediante las siguientes modificaciones a CN2: (a) reemplazando la heurística de búsqueda basada en precisión con una nueva heurística de precisión relativa ponderada que tiene en cuenta la generalidad y la precisión de la regla, (b) incorporando pesos a los ejemplos al algoritmo de cobertura, (c) incorporando pesos a los ejemplos en la heurística de búsqueda de precisión relativa ponderada, y (d) utilizando clasificación probabilística basada en la distribución de clases de los ejemplos cubiertos por reglas individuales, tanto para el caso de conjuntos de reglas desordenados como para listas de decisión ordenadas.

A continuación describimos las principales modificaciones realizadas al algoritmo CN2, haciéndolo adecuado para descubrimiento de subgrupos: la implementación del algoritmo de cobertura ponderada, y la incorporación de los pesos en los ejemplos en la heurística de precisión relativa ponderada.

### 1) Algoritmo de cobertura ponderada

Uno de los problemas de los algoritmos de aprendizaje de reglas, como CN2 y RIPPER, cuando se utilizan para la tarea de descubrimiento de subgrupos es la utilización del algoritmo de cobertura para la construcción de los conjuntos de reglas, porque solo las primeras reglas inducidas pueden ser interesantes como descripciones de subgrupos con suficiente cobertura y relevancia. En las siguientes iteraciones del algoritmo de cobertura, las reglas se inducen desde un subconjunto de ejemplos sesgado, es decir, subconjuntos que solo incluyen los ejemplos positivos que aún no están cubiertos por las reglas previamente inducidas, lo que sesga de forma inadecuada el proceso de descubrimiento de subgrupos.

Para evitar este problema, CN2-SD propone la utilización de un algoritmo de cobertura ponderado [GL02], en el que las reglas inducidas posteriormente también representan subgrupos de la población interesantes y suficientemente grandes. El algoritmo de cobertura ponderado modifica el algoritmo clásico de cobertura de forma que los ejemplos positivos cubiertos no se eliminan del conjunto de entrenamiento. En lugar de eso, en cada iteración el algoritmo almacena una cuenta con cada ejemplo para indicar cuantas reglas han cubierto a un ejemplo hasta ahora. Los pesos asociados a estas cuentas de ejemplos se tienen en cuenta para calcular la atipicidad (WRAcc). El peso inicial de todos los ejemplos  $E^s$  es 1,  $w(E^s, 0) = 1$ , lo que significa que el ejemplo aún no ha sido cubierto por ninguna regla. Cada vez que una regla cubre a un ejemplo, se disminuye el peso del ejemplo, de

forma que los ejemplos de la clase objetivo no cubiertos cuyos pesos no se han decrementado tienen más opciones de ser cubiertos en las siguientes iteraciones del algoritmo.

Es necesario especificar el esquema de pesos a utilizar, es decir, cuanto se decrementará el peso de cada ejemplo cada vez que sea cubierto por una regla. CN2-SD puede utilizar dos esquemas de pesos:

- *Pesos multiplicativos*, en los que los pesos decrecen de forma multiplicativa. Dado un parámetro  $0 < \gamma < 1$ , un ejemplo  $E^s$  cubierto por  $i$  reglas tendrá un peso  $\gamma^i$ . Cuando  $\gamma = 1$ , el algoritmo siempre encuentra la misma regla una y otra vez, mientras que si  $\gamma = 0$  el algoritmo se comporta exactamente igual que con el algoritmo estándar CN2.
- *Pesos aditivos*, en el que un ejemplo cubierto por  $i$  reglas tendrá un peso  $1/(i+1)$ . En la primera iteración todos los ejemplos de la clase objetivo tendrán un peso de 1, mientras que en las siguientes iteraciones el peso de cada ejemplo es inversamente proporcional al número de reglas previamente inducidas que lo cubren.

## 2) Heurística WRAcc modificada con pesos en los ejemplos

El algoritmo CN2-SD utiliza como heurística de búsqueda la precisión relativa ponderada modificada para manejar pesos en los ejemplos. Esto aporta la forma de considerar diferentes partes del espacio de ejemplos en cada iteración del algoritmo de cobertura ponderado.

En el cálculo de WRAcc, todas las probabilidades se calculan mediante frecuencias relativas. El peso de un ejemplo mide lo importante que es cubrir un ejemplo en la siguiente iteración. La medida WRAcc modificada se define entonces como:

$$WRAcc(Cond \rightarrow Class) = \frac{n'(Cond)}{N'} \cdot \left( \frac{n'(Class.Cond)}{n'(Cond)} - \frac{n'(Class)}{N'} \right) \quad (A.1)$$

En esta ecuación,  $N'$  es la suma de pesos de todos los ejemplos,  $n'(Cond)$  es la suma de los pesos de todos los ejemplos cubierto, y  $n'(Class.Cond)$  es la suma de los pesos de todos los ejemplos correctamente cubiertos.

Para añadir una regla al conjunto de reglas generadas, se elige la regla del espacio de búsqueda con mayor valor de la medida WRAcc que aún no esté en el conjunto de reglas producidas.



## Apéndice D. Descripción de las variables del problema de extracción de conocimiento en certámenes feriales

La Tabla A.53 muestra las características de las variables recogidas para el problema de extracción de conocimiento en certámenes feriales con datos recogidos en la Bienal de Máquina-Herramienta celebrada en Bilbao en marzo de 2002, y han sido estudiados en el Departamento de Organización y Marketing de la Universidad de Mondragón. Se indica el número de la variable, su tipo, nombre y valores que puede tomar cada variable.

*Tabla A.53 Descripción de las variables del conjunto de datos de Marketing*

VAR	TIPO	NOMBRE	VALORES
-	Nom	Eficiencia del stand	1. Eficacia baja 2. Eficacia media 3. Eficacia alta
0	Nom	Zona geográfica en la que se sitúa la empresa	1. Zona Norte 2. Zona Centro 3. Zona Levante 4. Zona Sur
1	Nom	Número de Empleados de la empresa	1. Más de 500 2. 251-500 3. 101-250 4. 51-100 5. 11-50 6. 10 ó menos
2	Nom	Volumen de ventas anual de la empresa	1. Más de 5000 millones 2. 1000-4999 3. 500-999 4. 250-499 5. 100-249 6. 50-99
3	Nom	Nivel de concentración de las ventas	1. Concentración alta 2. Concentración baja
4	Nom	Sector al que pertenece el expositor	1. Máquina por arranque 2. Máquina por deformación 3. Electricidad 4. Accesorios 5. Herramientas 6. Medida y control 7. CAD-CAM 8. Accesorios
5	Nom	Antigüedad como expositor en la feria de bilbao	1. más de 20 años 2. 15-20 años 3. 10-15 años 4. 5-10 años 5. 2-5 años 6. primera vez

VAR	TIPO	NOMBRE	VALORES
6	Nom	Utilidad proporcionada por la publicidad	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
7	Nom	Utilidad proporcionada por las ferias	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
8	Nom	Utilidad proporcionada por los vendedores	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
9	Nom	Utilidad proporcionada por el Telemarketing	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
10	Nom	Utilidad proporcionada por el mailing	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
11	Nom	Utilidad proporcionada por internet	1. Ninguna utilidad 2. Utilidad media 3. Bastante utilidad 4. Mucha utilidad
12	Nom	Número de ferias en las que se participa anualmente como expositor	1. Más de 15 2. 11-15 3. 6-10 4. 2-5 5. una 6. Solo en la BIEMH
13	Nom	Utilización de asesoría para preparar la participación en la feria	1. Si 2. No
14	Nom	Existencia de objetivos para la BIEMH por escrito	1. Si 2. No
15	Nom	Importancia concedida a la introducción de nuevos productos	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
16	Nom	Satisfacción alcanzada en la introducción de nuevos productos	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
17	Nom	Importancia concedida a la obtención de pedidos	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
18	Nom	Satisfacción alcanzada en la consecución de pedidos	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho

VAR	TIPO	NOMBRE	VALORES
19	Nom	Importancia concedida a la consecución de nuevos contactos	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
20	Nom	Satisfacción alcanzada en la consecución de nuevos contactos	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
21	Nom	Importancia concedida a la relación mantenida con clientes actuales	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
22	Nom	Satisfacción alcanzada en la relación mantenida con clientes actuales	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
23	Nom	Importancia concedida a la mejora de la imagen de la empresa	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
24	Nom	Satisfacción alcanzada en la mejora de la imagen	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
25	Nom	Importancia concedida a la obtención de información	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
26	Nom	Satisfacción alcanzada en la obtención de información	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
27	Nom	Importancia concedida a la consecución de nuevos distribuidores	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
28	Nom	Satisfacción alcanzada en la consecución de nuevos distribuidores	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
29	Nom	Importancia concedida a las relaciones públicas	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante

VAR	TIPO	NOMBRE	VALORES
30	Nom	Satisfacción alcanzada en las relaciones públicas	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
31	Nom	Realización de promoción previa a la feria	1. Si 2. No
32	Nom	Listados a quienes informar de la presencia en la feria	1. Si 2. No
33	Nom	Destinatarios de la campaña de promoción	1. Clientes actuales y potenciales 2. Sólo actuales 3. Sólo potenciales
34	Nom	Destinatarios de la promoción para los que han hecho una promoción dirigida a todos sus clientes	1. Discriminación 2. Indiscriminado
35	Nom	Destinatarios para aquellos que sólo se han dirigido a sus propios clientes	1. Discriminación 2. Indiscriminado
36	Nom	Destinatarios para aquellos que sólo se han dirigido a potenciales clientes	1. Discriminación 2. Indiscriminado
37	Nom	Seguimiento de la campaña de promoción previa	1. Si 2. No
38	Num	Tamaño del stand en metros cuadrados	Valores entre 0 y 1000
39	Nom	Tipo de stand contratado	1. Modular 2. Diseño
40	Nom	Existencia de un despacho cerrado para reunirse con clientes en el stand	1. Si 2. No
41	Nom	Satisfacción global alcanzada en la feria	1. Nada satisfecho 2. Poco satisfecho 3. Satisfacción media 4. Bastante satisfecho 5. Muy satisfecho
42	Num	Valoración de las condiciones de registro	Valores entre 0-10
43	Num	Valoración servicios de montaje y desmontaje	Valores entre 0-10
44	Num	Valoración de la ubicación del stand	Valores entre 0-10
45	Num	Valoración información sobre el visitante	Valores entre 0-10
46	Num	Valoración calidad de los visitantes	Valores entre 0-10
47	Num	Valoración de la organización en general	Valores entre 0-10
48	Nom	Importancia concedida a las operaciones realizadas en la propia feria	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
49	Nom	Importancia concedida a las operaciones realizadas después de la feria	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
50	Nom	Importancia concedida Al número de contactos nuevos realizados	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
51	Nom	Importancia concedida al número de contactos realizados con clientes actuales	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante

VAR	TIPO	NOMBRE	VALORES
52	Nom	Importancia concedida a la calidad de los contactos realizados	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
53	Nom	Importancia concedida al número de visitantes en el stand	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
54	Nom	Importancia concedida al número de visitantes que han solicitado más información	1. Nada importante 2. Poco importante 3. Importancia media 4. Bastante importante 5. Muy importante
55	Nom	Modalidad de seguimiento de contactos después de la feria	1. a todos los contactos 2. Sólo a los de calidad
56	Nom	Uso de carta de agradecimiento	1. No se utiliza 2. A todos 3. Sólo a los de calidad
57	Nom	Realización de llamadas telefónicas	1. No se utiliza 2. A todos 3. Sólo a los de calidad
58	Nom	Envío de folletos de agradecimiento	1. No se utiliza 2. A todos 3. Sólo a los de calidad
59	Nom	Seguimiento del contacto hasta la resolución del mismo	1. No se utiliza 2. A todos 3. Sólo a los de calidad
60	Nom	Contacto telefónico a través de telemarketing	1. No se utiliza 2. A todos 3. Sólo a los de calidad
61	Nom	Cualificación del contacto	1. No se utiliza 2. A todos 3. Sólo a los de calidad
62	Nom	Modalidad de stand	1. Columna 2. Corner 3. Final 4. Bloque
63	Nom	Demostraciones de maquinaria en el stand	1. Si 2. No
64	Nom	Tipo de demostraciones de maquinaria	1. Funcionamiento permanente 2. Funcionamiento esporádico 3. Exhibición de maquinaria
65	Nom	Demostraciones de productos en el stand	1. Si 2. No
66	Nom	Tipo de demostraciones de producto	1. Exhibición de productos 2. Exhibición en movimiento
67	Nom	Demostraciones realizadas en el stand	1. Sólo de maquinaria 2. Maquinaria y productos 3. Sólo productos 4. Ni maquinaria ni productos
68	Nom	Existencia de la figura del director ferial en la empresa	1. Si 2. No
69	Nom	Existencia de obsequios en el stand	1. Si 2. No

VAR	TIPO	NOMBRE	VALORES
70	Nom	Discriminación en el ofrecimiento de obsequios	1. Si 2. No
71	Nom	Presencia de novedades en el stand	1. Auténtica novedad 2. Perfeccionamiento producto 3. Exhibición de catálogo 4. Otros
72	Nom	Envío de cartas personalizadas	0. No 1. Si
73	Nom	Invitaciones a través de comerciales	0. No 1. Si
74	Nom	Invitaciones a través de mailing	0. No 1. Si
75	Nom	Publicidad en revistas del sector	0. No 1. Si
76	Nom	Exhibición en otras ferias	0. No 1. Si
77	Nom	Publicidad en el catálogo de expositores	0. No 1. Si
78	Nom	Referencia en página web	0. No 1. Si
79	Nom	Aparición en TV o radio	0. No 1. Si
80	Nom	Publicidad estática en feria	0. No 1. Si
81	Nom	Mención en la publicidad habitual de la empresa	0. No 1. Si
82	Nom	Artículos en revistas del sector	0. No 1. Si
83	Nom	Oferta de pequeños obsequios antes de la feria	0. No 1. Si
84	Nom	Encartes en revistas del sector	0. No 1. Si
85	Nom	Publirreportajes	0. No 1. Si
86	Nom	Trípticos con motivo de la feria	0. No 1. Si
87	Nom	Pegatinas ofrecidas por la propia feria	0. No 1. Si
88	Nom	Fotografías en el stand	0. No 1. Si
89	Nom	Elementos audiovisuales en el stand	0. No 1. Si
90	Nom	Uso de color en el stand	0. No 1. Si
91	Nom	Uso de rótulo standard	0. No 1. Si
92	Nom	Uso de rótulo elaborado	0. No 1. Si
93	Nom	Uso de palabras gancho	0. No 1. Si
94	Nom	Uso de displays	0. No 1. Si
95	Nom	Uso de banderas señalizadoras	0. No 1. Si
96	Nom	Existencia de puerta de acceso	0. No 1. Si

<b>VAR</b>	<b>TIPO</b>	<b>NOMBRE</b>	<b>VALORES</b>	
97	Nom	Suelo enmoquetado	0.	No
			1.	Si
98	Nom	Señalización en altura	0.	No
			1.	Si
99	Nom	Existencia de columnas	0.	No
			1.	Si
100	Nom	Stand a distintas alturas	0.	No
			1.	Si
101	Nom	Presencia de azafatas	0.	No
			1.	Si
102	Nom	Servicio de barra en el stand	0.	No
			1.	Si
103	Nom	Comida/bebida en el stand	0.	No
			1.	Si



# Bibliografía

---

- [AC02] Au, W.H. and Chan, K.C.C. *An evolutionary approach for discovering changing patterns in historical data*. in *2002 SPIE 4730, Data Mining and Knowledge Discovery: Theory, Tools and Technology*. 2002.
- [AC98] Au, W.H. and Chan, K.C.C., *An effective algorithm for discovering fuzzy rules in relational databases*, in *IEEE International Conference on Fuzzy Systems (FUZZ IEEE '98)*. 1998: Anchorage, AK, USA. p. 1314-1319.
- [AC99] Au, W. and Chan, K.C.C., *FARM: A Data Mining System for Discovering Fuzzy Association Rules*, in *8th IEEE International Conference on Fuzzy Systems*. 1999: Seoul, South Korea. p. 1217-1222.
- [ADG+03] Alcalá, J., del Jesús, M.J., Garrell, J.M., Herrera, F., Hervás, C., and Sánchez, L., *Proyecto KEEL: Desarrollo de una Herramienta para el Análisis e Implementación de Algoritmos de Extracción de Conocimiento Evolutivos*, in *Tendencias de la Minería de Datos en España*. , Giraldes, J., Riquelme, J.C., and Aguilar, J.S., Editors. 2004. p. 413-423.
- [AIS93] Agrawal, R., Imielinski, T., and Swami, A.N. *Mining Association Rules between Sets of Items in Large Databases*. in *International Conference on Management of Data (ACM SIGMOD)*. 1993. Washington, D.C.: ACM Press.
- [ALF00] Araujo, D.L.A., Lopes, H.S., and Freitas, A.A., *Rule discovery with a parallel genetic algorithm*, in *Genetic and Evolutionary Computation Conference Workshop 2000 (GECCO2000)*. 2000: Las Vegas, USA. p. 89-94.
- [ALF99] Araujo, D.L.A., Lopes, H.S., and Freitas, A.A. *A parallel genetic algorithm for rule discovery in large databases*. in *IEEE Conference on Systems, Man and Cybernetics*. 1999.
- [AMS+96] Agrawal, R., Mannila, H., Srikant, R., Toivonen, H., and Verkamo, I., *Fast Discovery of Association Rules*, in *Advances in Knowledge Discovery and Data Mining*, Fayyad, U., et al., Editors. 1996, AAAI Press: Menlo Park, Calif. p. 307-328.
- [And02] Anderson, S., *Better measurement: Help exhibitors identify their return on objectives*, in *EXPO Magazine*. 2002. p. 21.
- [AP06] Atzmueller, M. and Puppe, F. *SD-Map - A Fast Algorithm for Exhaustive Subgroup Discovery*. in *10th European Conference on Principles and Practice of Knowledge Discovery in Databases (PKDD 2006)*. 2006: Springer.
- [APB04] Atzmueller, M., Puppe, F., and Buscher, H.-P. *Towards Knowledge-Intensive Subgroup Discovery*. in *Proc. LWA 2004 Workshop (FGML Track)*. 2004.

- [AS95] Agrawal, R. and Srikant, R., *Mining Sequential Patterns*, in *11th International Conference on Data Engineering*. 1995: Taipei, Taiwan. p. 3-14.
- [Bal96] Baldwin, J.F., *Knowledge from data using fuzzy methods*. Pattern Recognition Letters, 1996. **17**: p. 593-300.
- [BBM93] Beasley, D., Bull, D.R., and R.R., M., *A sequential niche technique for multimodal function optimization*. Evolutionary Computation, 1993. **1**: p. 101-125.
- [BC96] Berndt, D. and Clifford, J., *Finding Patterns in Time Series: A Dynamic Programming Approach*, in *In Advances in Knowledge Discovery and Data Mining*, Fayyad, U., et al., Editors. 1996, AAAI Press: Menlo Park, Calif. p. 229-248.
- [BD96] Brockwell, P.J. and Davis, R.A., *Introduction to time series and forecasting*. 1996, New York: Springer-Verlag.
- [BDG+06] Berlanga, F.J., del Jesus, M.J., González, P., Herrera, F., and Mesonero, M., *Multiobjective Evolutionary Induction of Subgroup Discovery Fuzzy Rules: A Case Study in Marketing*, in *6th Industrial Conference on Data Mining (ICDM 2006)*. 2006, Springer: Leipzig, Germany. p. 337-349.
- [BF99] Buckley, J.J. and Feuring, T., *Fuzzy and Neural: Interactions and Applications*. Studies in Fuzziness and Soft Computing. 1999, Heidelberg: Physica-Verlag.
- [BFM97] Bäck, T., Fogel, D., and Michalewicz, Z., *Handbook of Evolutionary Computation*. 1997, Oxford: Oxford University Press.
- [BFOS84] Breiman, L., Friedman, J.H., Olshen, R.A., and Stone, C.J., *Classification and Regression Trees*. 1984, Belmont, Calif.: Wadsworth.
- [BN93] Basseville, M. and Nikiforov, I.V., *Detection of Abrupt Changes: Theory and Application*. 1993, Englewood Cliffs, N.J.: Prentice Hall.
- [BPU99] Bosc, P., Pivert, O., and Ughetto, L., *Database mining for the discovery of extended functional dependencies*, in *International Conference of the North American Fuzzy Information Processing Society (NAFIPS 99)*. 1999: New York, USA. p. 580-584.
- [CC61] Charnes, A. and Cooper, W.W., *Management models and industrial applications of linear programming*. Vol. 1. 1961, New York: John Wiley.
- [CCW00] Chiang, D.A., Chow, L.R., and Wang, Y.F., *Mining time series data by a fuzzy linguistic summary system*. Fuzzy Sets and Systems, 2000. **112**: p. 419-432.
- [CDH98] Cordon, O., del Jesus, M.J., and Herrera, F., *Genetic Learning of Fuzzy Rule-based Classification Systems Co-operating with Fuzzy Reasoning Methods*. International Journal of Intelligent Systems 1998. **13**(10/11): p. 1025-1053.
- [CDHL99] Cordon, O., del Jesus, M.J., Herrera, F., and Lozano, M., *MOGUL: A Methodology to Obtain Genetic fuzzy rule-based systems Under the iterative*

- rule Learning approach*. International Journal of Intelligent Systems, 1999. **14**: p. 1123-1153.
- [CF02] Carvalho, D.R. and Freitas, A.A., *A genetic algorithm for discovering small-disjunct rules in data mining*. Applied Soft Computing, 2002. **2**: p. 75-88.
- [CN89] Clark, P. and Niblett, T., *The cn2 induction algorithm*. Machine Learning, 1989. **3**(4): p. 261-283.
- [Coe06] Coello, C.A., *Evolutionary Multiobjective Optimization: A Historical View of the Field*. IEEE Computational Intelligence Magazine, 2006. **1**(1): p. 28-36.
- [Coh95] Cohen, W.W. *Fast effective rule induction*. in *Twelfth International Conference on Machine Learning*. 1995: Morgan Kaufmann.
- [CVL02] Coello, C.A., Van Veldhuizen, D.A., and Lamont, G.B., *Evolutionary Algorithms for Solving Multi-Objective Problems*. 2002: Kluwer Academic Publishers.
- [CW02] Chen, G. and Wei, Q., *Fuzzy association rules and the extended mining algorithms*. Information Sciences, 2002. **147**: p. 201-228.
- [CH83] Chankong, V. and Haimes, Y., *Multi-objective Decision making Theory and Methodology*. 1983: Elsevier Science Publishing Co.
- [CHHM01] Cordon, O., Herrera, F., Hoffmann, F., and Magdalena, L., *Genetic fuzzy systems: evolutionary tuning and learning of fuzzy knowledge bases*. 2001: World Scientific.
- [CHT06] Chen, C.H., Hong, T.P., and Tseng, V.S., *A cluster-based fuzzy-genetic mining approach for association rules and membership functions*, in *IEEE International Conference on Fuzzy Systems*. 2006. p. 1411-1416.
- [DCP00] Dhar, V., Chou, D., and Provost, F., *Discovering interesting patterns for investment decision making with Glower-a Genetic Learner Overlaid With Entropy Reduction*. Data Mining and Knowledge Discovery, 2000. **4**: p. 251-280.
- [Deb01] Deb, K., *Multi-Objective Optimization using Evolutionary Algorithms*. 2001: John Wiley & Sons.
- [DGHM07] del Jesus, M.J., González, P., Herrera, F., and Mesonero, M., *Evolutionary Fuzzy Rule Induction Process for Subgroup Discovery: A Case Study in Marketing*. IEEE Transactions on Fuzzy Systems, 2007. **15**(4): p. 578-592.
- [Dom98] Domingos, P. *Occam's two razors: the sharp and the blunt*. in *Fourth International Conference on Knowledge Discovery and Data Mining (KDD '98)*. 1998.
- [DPAM02] Deb, K., Pratap, A., Agarwal, A., and Meyarivan, T., *A fast and elitist multiobjective genetic algorithm: NSGA-II*. IEEE Transactions on Evolutionary Computation, 2002. **6**(2): p. 182-197.
- [DSG93] De Jong, K.A., Spears, W.M., and Gordon, D.F., *Using genetic algorithms for concept learning*. Machine Learning, 1993. **13**: p. 161-188.

- [ES03] Eiben, A.E. and Smith, J.E., *Introduction to evolutionary computation*. 2003, Berlin: Springer Verlag.
- [FF93] Fonseca, C.M. and Fleming, P.J. *Genetic algorithms for multiobjective optimization: formulation, discussion and generalization*. in *Fifth International Conference on Genetic Algorithms (ICGA)*. 1993. San Mateo, CA.
- [FHS03] Ferri, C., Hernández-Orallo, J., and Salido, M., *Volume Under the ROC Surface for Multiclass Problems*, in *2003 European Conference on Machine Learning, ECML '03*, Springer Verlag. p. 108-120.
- [FL98] Freitas, A.A. and Lavington, S.H., *Mining very large databases with parallel processing*. 1998: Kluwer.
- [Fla03] Flate, M., *Online education and learning management systems. Global e-learning in a Scandinavian perspective*. 2003, Oslo: NKI Gorlaget.
- [FMMT96] Fukuda, T., Morimoto, Y., Morishita, S., and Tokuyama, T., *Mining optimized association rules for numeric attributes*, in *The ACM SIGACT-SIGMOD-SIGART Symposium on principles of database systems*. 1996. p. 182-191.
- [Fog88] Fogel, D.B., *An evolutionary approach to the travelling salesman problem*. Biological Cybernetics, 1988. **60**(2): p. 139-144.
- [FPS96] Fayyad, U.M., Piatetsky-Shapiro, G., and Smyth, P., *From Data Mining to Knowledge Discovery: An Overview*, in *Advances in Knowledge Discovery and Data Mining*, Fayyad, U., et al., Editors. 1996, AAAI Press. p. 1-30.
- [FPS96b] Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P., *The KDD process for extracting useful knowledge from volumes of data*. Communications of the ACM, 1996. **39**: p. 27-34.
- [FR95] Flockhart, I.W. and Radcliffe, N.J., *GA-MINER: Parallel data mining with hierarchical genetic algorithms*. 1995, University of Edimburgh, UK.
- [Fre02] Freitas, A.A., *Data Mining and Knowledge Discovery with Evolutionary Algorithms*. 2002: Springer.
- [Fre02] Freitas, A.A., *A Survey of Evolutionary Algorithms for Data Mining and Knowledge Discovery*, in *Advances in Evolutionary Computation*, Ghosh, A. and Tsutsi, S., Editors. 2002, Springer-Verlag. p. 819-845.
- [Fre99] Freitas, A.A., *On Rule Interestingness Measures*. Knowledge-Based Systems, 1999. **12**(5-6): p. 309-315.
- [FS99] Flach, P.A. and Savnik, I., *Database dependency discovery: a machine learning approach*. AI Communications 1999. **12**(3): p. 139-160.
- [FWS+98] Fu, A.W.-C., Wong, M.H., Sze, S.C., W.C., W., W.L., W., and Yu, W.K., *Finding fuzzy sets for the mining of fuzzy association rules for numerical attributes*, in *First International Symposium on Intelligente Data Engineering and Learning (IDEAL '98)*. 1998. p. 263-268.

- [GD93] Greene, D.P. and Smith, S.F., *Competition-based induction of decision models from examples*. Machine Learning, 1993. **13**: p. 229-257.
- [GL02] Gamberger, D. and Lavrac, N., *Expert-guided subgroup discovery: Methodology and application*. Journal Of Artificial Intelligence Research, 2002. **17**: p. 1-27.
- [GLK03] Gamberger, D., Lavrac, N., and Krstacic, G., *Active subgroup mining: a case study in coronary heart disease risk group detection*. Artificial Intelligence In Medicine, 2003. **28**(1): p. 27-57.
- [GLKK07] Gamberger, D., Lavrač, N., Krstajić, A., and Krstajić, G., *Clinical data analysis based on iterative subgroup discovery: Experiments in brain ischaemia data analysis*. Applied Intelligence, 2007. **27**(3): p. 205-217.
- [GLWS95] Gopalakrishna, S., Lilien, G.L., Williams, J.D., and Sequeira, I.K., *Do trade shows pay off*. Journal of Marketing, 1995. **59**: p. 75-83.
- [GMV96] Guyon, O., Matic, N., and Vapnik, N., *Discovering Informative Patterns and Data Cleaning*, in *Advances in Knowledge Discovery and Data Mining*, Fayyad, U., et al., Editors. 1996, AAAI Menlo Park, Calif. p. 181–204.
- [GN95] Giordana, A. and Neri, F., *Search-intensive concept induction*. Evolutionary Computation, 1995. **3**(4): p. 375-416.
- [Gol89] Goldberg, D.E., *Genetic algorithms in search, optimization and machine learning*. 1989: Addison-Wesley.
- [Gol96] Golden, R.M., *Mathematical Methods for Neural Network Analysis and Design*. 1996, Cambridge, MA: MIT Press.
- [GP99] González, A. and Pérez, R., *SLAVE: a genetic learning system based on an iterative approach*. IEEE Trans. Fuzzy Systems, 1999. **7**(2): p. 176-191.
- [Han81] Hand, D.J., *Discrimination and Classification*. 1981, Chichester, U.K: Wiley.
- [HAP89] Holte, R.C., Acker, L., and Porter, B., *Concept Learning and the Problem of Small Disjuncts*, in *Eleventh International Joint Conference on Artificial Intelligence*. 1989. p. 813-818.
- [HKC99] Hong, T.P., Kuo, C.S., and Chi, S.C., *A data mining algorithm for transaction data with quantitative values*. Intelligent Data Analysis, 1999. **3**(5): p. 363-376.
- [HL92] Hajela, P. and Lin, C.Y., *Genetic search strategies in multicriterion optimal design*. Structural Optimization, 1992. **4**: p. 99-107.
- [HN93] Horn, J. and Nafpliotis, N., *Multiobjective optimization using the niched pareto genetic algorithms (IlliGAL Report 93005)*. 1993, University of Illinois: Urbana, Champaign.
- [Hol75] Holland, J.H., *Adaptation in natural and artificial systems*. 1975: University of Michigan Press.

- [HPY00] Han, J., Pei, J., and Yin, Y. *Mining frequent patterns without candidate generation*. in *2000 ACM SIGMOD International Conference on Management of Data*. 2000: ACM Press.
- [HRF04] Hernández Orallo, J., Ramírez Quintana, M.J., and Ferri Ramírez, C., *Introducción a la minería de datos*. 2004: Editorial Pearson.
- [HS96] Hale, J. and Sheno, S., *Analyzing FD inference in relational databases*. *Data and Knowledge Engineering*, 1996. **18**: p. 167-183.
- [HT01] Hand, D. and Till, R., *A simple generalisation of the Area Under the ROC Curve for multiple class classification problems*. *Machine Learning*, 2001. **45**: p. 171-186.
- [Iji65] Ijiri, Y., *Management goals and accounting for control*. 1965, Amsterdam: North-Holland.
- [IM98] Ishibuchi, H. and Murata, T., *A multiobjective genetic local search algorithm and its application to flowshop scheduling*. *IEEE Trans. System, Man and Cybernetics*, 1998. **28**(3): p. 392-403.
- [INH04] Ishibuchi, H., Nakashima, T., and Hii, M., *Classification and Modelling with Linguistic Information Granules. Advanced Approaches to Linguistic Data Mining*. 2004: Springer-Verlag.
- [INN04] Ishibuchi, H., Nakashima, T., and Nii, M., *Classification and modeling with linguistic information granules*. 2004: Springer-Verlag.
- [INY01] Ishibuchi, H., Nakashima, T., and Yamamoto, T., *Fuzzy association rules for handling continuous attributes*, in *IEEE International Symposium on Industrial Electronics (ISIE 2001)*. 2001, IEEE: Pusan (South Korea). p. 118-121.
- [IY04] Ishibuchi, H. and T., Y., *Fuzzy rule selection by multi-objective genetic local search algorithms and rule evaluation measures in data mining*. *Fuzzy Sets and Systems* 2004. **141**(1): p. 59-88.
- [Jan93b] Janikow, C.Z., *A knowledge-intensive genetic algorithm for supervised learning*. *Machine Learning*, 1993. **13**: p. 189-228.
- [Jan98] Janikow, C.Z., *Fuzzy decision trees: issues and methods*. *IEEE Transactions on Systems, Man and Cybernetics*, 1998. **28**(1): p. 1-14.
- [JD88] Jain, A.K. and Dubes, R.C., *Algorithms for Clustering Data*. 1988, Englewood Cliffs, N.J.: Prentice-Hall.
- [JL01] Jovanoski, V. and Lavrac, N. *Classification Rule Learning with APRIORI-C*. in *Progress in Artificial Intelligence: Knowledge extraction, Multi-agent systems, Logic programming, and Constraint solving. X Portuguese Conference on Artificial Intelligence (EPIA'01)*. 2001. Porto, Portugal: Springer.
- [JSM97] Jang, J.R., Sun, C., and Mizutani, E., *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. 1997, Englewood Cliffs, NJ: Prentice-Hall.

- [KC00] Knowles, J.D. and Corne, D., *Approximating the Nondominated Front Using the Pareto Archived Evolution Strategy*. *Evolutionary Computation*, 2000. **8**(2): p. 149-172.
- [Kee07] *KEEL*. 2007 [cited; Available from: <http://www.keel.es>].
- [KL06] Kavsek, B. and Lavrac, N., *APRIORI-SD: Adapting association rule learning to subgroup discovery*. *Applied Artificial Intelligence*, 2006(20): p. 543–583.
- [Klo02] Klösgen, W., *Subgroup Discovery*, in *Handbook of Data Mining and Knowledge Discovery*, Klösgen, W. and Zytkow, J., Editors. 2002, Oxford University Press: New York. p. 354-364.
- [Klo96] Klösgen, W., *Explora: A Multipattern and Multistrategy Discovery Assistant*, in *Advances in Knowledge Discovery and Data Mining*, Fayyad, U., et al., Editors. 1996, AAAI Press: Menlo Park, Calif. p. 249–271.
- [KM02] Klösgen, W.M., Michael. *Census Data Mining - An Application*. in *ECML/PKDD'02 Workshop on Mining Official Data 2002*. Helsinki
- [Kov04] Kovacs, T., *Strength or accuracy: credit assignment in learning classifier systems*. 2004: Springer-Verlag.
- [Koz92] Koza, J.R., *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. 1992: MIT Press.
- [Koz94] Koza, J.R., *Genetic Programming II: Automatic Discovery of Reusable Programs*. 1994, Cambridge, MA, USA: MIT Press.
- [Kun00] Kuncheva, L.I., *Fuzzy classifier design*. 2000, Berlin: Springer.
- [KY95] Klir, G. and Yuan, B., *Fuzzy Sets and Fuzzy Logic. Theory and Applications*. 1995: Prentice-Hall.
- [KZ02] Klösgen, W. and Zytkow, J., eds. *Handbook of Data Mining and Knowledge Discovery*. 2002, Oxford University Press: New York.
- [LCGF04] Lavrac, N., Cestnik, B., Gamberger, D., and Flach, P., *Decision support through subgroup discovery: Three case studies and the lessons learned*. *Machine Learning*, 2004. **57**(1-2): p. 115-143.
- [LFKT02] Lavrac, N., Flach, P.A., Kavsek, B., and Todorovski, L. *Adapting classification rule induction to subgroup discovery*. in *2002 IEEE International Conference on Data Mining (ICDM 2002)*. 2002. Maebashi City, Japan: IEEE Computer Society.
- [LFZ99] Lavrac, N., Flach, P., and Zupan, B., *Rule evaluation measures: A unifying view*, in *Inductive Logic Programming*. 1999. p. 174-185.
- [LHL05] Lee, Y.C., Hong, T.P., and Lin, W.Y., *Mining association rules with multiple minimum supports using maximum constraints* *International Journal of Approximate Reasoning*, 2005. **40**(1-2): p. 44-54.

- [LK97] Lee, D.H. and Kim, M.H., *Database summarization using fuzzy ISA hierarchies*. IEEE Transactions on Systems, Man and Cybernetics B, 1997. **27**: p. 68-78.
- [LKFT04] Lavrac, N., Kavsec, B., Flach, P., and Todorovski, L., *Subgroup discovery with CN2-SD*. Journal of Machine Learning Research, 2004. **5**: p. 153-188.
- [LPVP99] Lopes, C., Pacheco, M., Vellasco, M., and Passes, E., *Rule-evolver: An evolutionary approach for data mining*, in *7th International Workshop on New Directions in Rough Sets, Data Mining, and Granular-Soft Computing (RSFDGrC '99)*. 1999: Yamaguchi, Japan. p. 458-462.
- [LZF03] Lavrac, N., Zelezny, F., and Flach, P.A., *RSD: Relational subgroup discovery through first-order feature construction*, in *Inductive Logic Programming*. 2003. p. 149-165.
- [LL04] Lin, M.-Y. and Lee, S.-Y., *Interactive sequence discovery by incremental mining*. Information Sciences, 2004. **165**(3-4): p. 187-205.
- [MA75] Mamdani, E.H. and Assilian, S., *An experiment in linguistic synthesis with a fuzzy logic controller*. International Journal of Man Machine Studies, 1975. **7**: p. 1-13.
- [Maz99] Mazlack, L.J., *Softly focusing on data*, in *International Conference of the North American Fuzzy Information Processing Society (NAFIPS 99)*. 1999: New York, USA. p. 700-704.
- [McL92] McLachlan, G.J., *Discriminant analysis and statistical pattern recognition*. 1992, New York: John Wiley.
- [Mes04] Mesonero, M., *Hacia un modelo efectivo de planificación ferial basado en algoritmos genéticos*, in *Departamento de Organización y Marketing 2004*, Universidad de Mondragón: Mondragón.
- [Mic92] Michalewicz, Z., *Genetic algorithms + Data Structures = Evolution Programs*. 1992, Berlin: Springer-Verlag.
- [Mie99] Miettinen, K., *Nonlinear multiobjective optimization*. 1999, Boston: Kluwer.
- [Mil03a] Miller, S., *Saque el máximo provecho de las ferias*. 2003: Ediciones Urano.
- [Mit97] Mitchell, T.M., *Machine learning*. 1997: McGraw-Hill.
- [MMHL96] Michalski, R.S., Mozetic, I., Hong, J., and Lavrac, N. *The multi-purpose incremental learning system AQ15 and its testing application on three medical domains*. in *Fifth National Conference on Artificial Intelligence*. 1986: Morgan Kaufmann.
- [Moo07] Moodle. 2007 [cited; Available from: <http://moodle.org>].
- [MP96] Mitra, S. and Pal, S.K., *Fuzzy self organization, inferencing and rule generation*. IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans, 1996. **26**: p. 608-620.

- [MPM02] Mitra, S., Pal, S.K., and Mitra, P., *Data mining in soft computing framework: A survey*. IEEE Transactions on Neural Networks, 2002. **13**: p. 3-14.
- [MST94] Michie, D., Spiegelhalter, D.J., and Taylor, C.C., *Machine learning, neural and estatistical classification*. 1994: Ellis Horwood.
- [MVFN01] Mendes, R.R.F., Voznika, F.B., Freitas, A.A., and Nievola, J.C., *Discovering fuzzy classification rules with genetic programming and co-evolution*, in *Genetic and Evolutionary Computation Conference (GECCO-2001)*. 2001. p. 183-194.
- [NFL99] Noda, E., Freitas, A.A., and Lopes, H.S. *Discovering Interesting Prediction Rules with a Genetic Algorithm*. in *IEEE Congress on Evolutionary Computation (CEC 99)*. 1999. Washington, USA.
- [PDH97] Palm, R., Driankov, D., and Hellendoorn, H., *Model based fuzzy control*. 1997, Berlin: Springer-Verlag.
- [Pea88] Pearl, J., *Probabilistic reasoning in intelligent systems*. 1988, Palo Alto, CA, USA: Morgan Kaufmann.
- [Ped96a] Pedrycz, W., *Conditional fuzzy c-means*. Pattern Recognition Letters, 1996. **17**: p. 625-632.
- [Ped96b] Pedrycz, W., ed. *Fuzzy modelling: Paradigms and practice*. 1996, Kluwer Academic Press.
- [Ped98b] Pedrycz, W., *Fuzzy set technology in knowledge discovery*. Fuzzy Sets and Systems, 1998. **98**: p. 279-290.
- [PF01] Provost, F.J. and Fawcett, T., *Robust classification for imprecise environments*. Machine Learning, 2001. **42**(3): p. 203–231.
- [PF91] Piatetsky-Shapiro, P. and Frawley, W.J., eds. *Knowledge Discovery in Databases*. 1991, AAAI/MIT Press: Menlo Park, CA.
- [Pia91] Piatetsky-Shapiro, G., *Knowledge Discovery in Real Databases: A Report on the IJCAI-89 Workshop*. AI Magazine, 1991. **11**(5 ): p. 68-70.
- [PM94] Piatetsky-Shapiro, G. and Matheus, C. *The interestingness of deviation*. in *AAAI Workshop on Knowledge Discovery in Databases 1994*. Seattle, Washington, USA.
- [PS91] Syswerda, G. and Palmucci, J., *The application of genetic algorithms to resource scheduling*, in *Fouth International Conference on Genetic Algorithms*. 1991, Morgan-Kaufmann: San Mateo, CA. p. 502-508.
- [Qui87] Quinlan, J.R. *Generating Production Rules from Decision Trees*. in *International Joint Conference on Artificial Intelligence (IJCAI)*. 1987. Milan, Italy: Morgan Kaufmann.
- [RD97] Raedt, L.D. and Dehaspe, L., *Clausal discovery*. Machine Learning 1997. **26**: p. 99-146.

- [RER94] Ritzel, B.J., Eheart, J.W., and Ranjithan, S., *Using genetic algorithms to solve a multiple objective groundwater pollution containment problem*. Water Resources Research, 1994. **30**(5): p. 1589-1603.
- [RFP02] Romao, W., Freitas, A.A., and Pacheco, R.C.S. *A Genetic Algorithm for Discovering Interesting Fuzzy Prediction Rules: applications to science and technology data*. in *Genetic and Evolutionary Computation Conference (GECCO 2002)*. 2002.
- [RL99] Russell, S. and Lodwick, W., *Fuzzy clustering in data mining for telco database marketing campaigns*, in *18th International Conference of the North American Fuzzy Information Processing Society (NAFIPS 99)*. 1999: New York, USA. p. 720-726.
- [Sch05] Scholz, M., *Knowledge-Based Sampling for Subgroup Discovery*, in *Lecture Notes in Computer Science*, Morik, K., Boulicaut, J.-F., and Siebes, A., Editors. 2005, Springer-Verlag. p. 171-189.
- [Sch84] Schaffer, J.D., *Multiple Objective Optimization with Vector Evaluated Genetic Algorithms*. 1984, Vanderbilt University.
- [Sch85] Schaffer, J.D. *Multiple Objective Optimization with Vector Evaluated Genetic Algorithms*. in *First International Conference on Genetic Algorithms*. 1985: Lawrence Erlbaum.
- [Sch95] Schwefel, H.P., *Evolution and Optimum Seeding*. 1995: Wiley Inc.
- [SD95] Srinivas, N. and Deb, K., *Multiobjective optimization using nondominated sorting in genetic algorithms*. Evolutionary Computation, 1995. **2**: p. 221-248.
- [Sil86] Silverman, B.W., *Density estimation for statistics and data analysis*. 1986: Chapman and Hall.
- [SLN02] Sarker, R., Liang, K.H., and Newton, C., *A new multiobjective evolutionary algorithm*. European Journal of Operational Research, 2002. **140**: p. 12-23.
- [SNT85] Sawaragi, Y., Nakayama, H., and Tanino, T., *Theory of Multiobjective Optimization*. Mathematics in Science and Engineering. Vol. 176. 1985, Orlando, USA: Academic Press Inc.
- [ST95] Silberschatz, A. and Tuzhilin, A. *On Subjective Measures of Interestingness in Knowledge Discovery*. in *Proceedings of KDD-95: First International Conference on Knowledge Discovery and Data Mining*. 1995. Menlo Park, Calif: American Association for Artificial Intelligence.
- [TS85] Takagi, T. and Sugeno, M., *Fuzzy identification of systems and its application to modeling and control*. IEEE Transactions on Systems, Man, and Cybernetics, 1985. **15**: p. 116-132.
- [TSM85] Titterton, D.M., Smith, A.F.M., and Makov, U.E., *Statistical Analysis of Finite-Mixture Distributions*. 1985, Chichester, U.K.: Wiley. .
- [TT01] Tettamanzi, A. and Tomassini, M., *Soft Computing. Integrating Evolutionary, Neural and Fuzzy Systems*. 2001: Springer.

- [Tur98] Turksen, L.B., *Fuzzy data mining and expert system development*, in *IEEE International Conference on Systems, Man and Cybernetics*. 1998: San Diego, CA, USA. p. 2057-2061.
- [UCI94] Murphy, P.M. and Aha, D.W. *UCI repository of machine learning databases*. 1994 [cited; Available from: <http://www.ics.uci.edu/mllearn/MLRepository.html>].
- [WF05] Witten, I.H. and Frank, E., *Data Mining: Practical Machine Learning Tools and Techniques*. 2005: Morgan Kaufmann.
- [WH00] Weiss, G.M. and Hirsh, H., *A Quantitative Study of Small Disjuncts*, in *Seventeenth National Conference on Artificial Intelligence*. 2000: Austin, Texas.
- [Wi95] Wilson, S.W., *Classifier fitness based on accuracy*. *Evolutionary Computation*, 1995. **3**(2): p. 149-175.
- [WK91] Weiss, S.I. and Kulikowski, C., *Computer Systems That Learn: Classification and Prediction Methods from Statistics, Neural Networks, Machine Learning, and Expert Systems*. 1991, San Francisco, California: Morgan Kaufmann.
- [Wro97] Wrobel, S., *An algorithm for multi-relational discovery of subgroups*, in *Principles Of Data Mining And Knowledge Discovery*. 1997. p. 78-87.
- [Yag91] Yager, R.R., *On linguistic summaries of data*, in *Knowledge Discovery in Databases*, Frawley, W. and Piatetsky-Shapiro, G., Editors. 1991, AAAI/MIT Press: Menlo Park, CA. p. 347-363.
- [Yag96] Yager, R.R., *Database discovery using fuzzy sets*. *International Journal of Intelligent Systems*, 1996. **11**: p. 691-712.
- [YG94] Yang, X. and Gen, M., *Evolution program for bicriteria transportation problem*, in *16th International Conference on Computers and Industrial Engineering*. 1994: Ashikaga, Japan. p. 451-454.
- [Zad65] Zadeh, L.A., *Fuzzy sets*. *Information Control*, 1965. **8**: p. 338-353.
- [Zad75] Zadeh, L.A., *The concept of a linguistic variable and its applications to approximate reasoning, Parts I, II, III*. *Information Sciences*, 1975. **8-9**: p. 199-249, 301-357, 43-80.
- [Zad94] Zadeh, L.A., *Soft Computing and Fuzzy Logic*. *IEEE Software*, 1994. **11**(6): p. 48-56.
- [Zad97] Zadeh, L.A., *Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic*. *Fuzzy Sets and Systems*, 1997. **19**: p. 111-127.
- [Zah92] Zadeh, L.A., *Knowledge representation in fuzzy logic*, in *An Introduction to Fuzzy Logic Applications in Intelligent Systems*, Yager, R.R. and Zadeh, L.A., Editors. 1992, Kluwer: Boston. p. 1-25.
- [ZDT00] Zitzler, E., Deb, K., and Thiele, L., *Comparison of Multiobjective Evolutionary Algorithms: Empirical Results*. *Evolutionary Computation*, 2000. **8**(2): p. 173-195.

- [ZLT02] Zitzler, E., Laumanns, M., and L., T., *SPEA2: Improving the strength pareto evolutionary algorithm for multiobjective optimisation*, in *Evolutionary methods for design, optimisation and control*, Giannakoglou, K., et al., Editors. 2002, CIMNE. p. 95-100.
- [ZLZ04] Zhang, S., Lu, J., and Zhang, C., *A fuzzy logic based method to acquire user threshold of minimum-support for mining association rules*. Information Sciences 2004. **164**: p. 1-16.
- [ZTQ97] Zitzler, E., Thiele, L., and Quinlan, J., *Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach*. IEEE Transactions on Evolutionary Computation, 1997. **3**(4): p. 257-217.
- [Zur92] Zurada, J.M., *Introduction to Artificial Neural Systems*. 1992: West Publishing Company.
- [ZZ96] Zembowicz, R. and Zytkow, J., *From Contingency Tables to Various Forms of Knowledge in Databases*, in *Advances in Knowledge Discovery and Data Mining*, , Fayyad, U., et al., Editors. 1996, AAAI Press: Menlo Park, Calif. p. 329-351.