

UNIVERSIDAD DE GRANADA



*Scatter Search para el Registrado de Imágenes 3D:
Aplicación en Antropología Forense*

MEMORIA QUE PRESENTA

José Santamaría López

PARA OPTAR AL GRADO DE DOCTOR

Octubre de 2006

DIRECTORES

Óscar Cordon García

Sergio Damas Arroyo

Departamento de Lenguajes y Sistemas Informáticos

Editor: Editorial de la Universidad de Granada
Autor: José Santamaría López
D.L.: Gr. 2305 - 2005
ISBN: 84-338-4161-0

La memoria titulada «*Scatter Search para el Registrado de Imágenes 3D: Aplicación en Antropología Forense*», que presenta D. José Santamaría López para optar al grado de doctor ha sido realizada dentro del programa de doctorado «*Métodos y Técnicas Avanzadas de Desarrollo de Software*» del Departamento de Lenguajes y Sistemas Informáticos de la Universidad de Granada bajo la dirección de los Doctores D. Óscar Córdón García y D. Sergio Damas Arroyo.

Granada, Octubre de 2006

El Doctorando

Los Directores

Fdo: José Santamaría López Fdo: Óscar Córdón García y Sergio Damas Arroyo

Agradecimientos

Quisiera empezar agradeciendo a mis directores, compañeros y amigos Oscar y Sergio la confianza depositada en mí para realizar junto a ellos este trabajo y, más aún, por su permanente dedicación en esta interminable pero breve, odiada pero anhelada, frustrante pero gratificante empresa.

Al Laboratorio de Antropología Física de la Universidad de Granada por dejar a nuestra disposición todos los medios técnicos y material de depósito, y muy especialmente a Inma y a Miguel, por la ayuda prestada en todo momento. También a Joseph Crisco del *Brown Medical School Hospital* de Rhode Island (EEUU) por el material médico proporcionado. Además, al grupo de investigación «*Soft Computing and Intelligent Information Systems*», en especial a Enrique, por su ayuda a comienzos de esta andadura.

A todos mis compañeros de doctorado con los que he compartido tertulias amenas y copiosas comidas: Agustín, Alfredo, Dani, Enrique, Kawthar y Zoraida. También a Alfredo, Luis, Raúl y Toribio, mis colegas de carrera y amigos.

A mi hermano Manolo y a mis padres, Manolo y Chari, para los que no encuentro suficientes palabras de agradecimiento por haber respetado mi decisión en todo momento y por su apoyo infinito a lo largo de mi vida.

Finalmente a Mari Ángeles, mi mejor amiga y mi novia. A ella tengo que agradecer su comprensión y paciencia, ya que una parte importante de las horas aquí invertidas se las debo a ella.

a mi familia

*... creo que para conseguir cosas en la vida
uno debe tener entusiasmo,
creer en lo que hace
y amarlo.*

Giuseppe Tringali. (Entrevista Kiss FM)

Índice

Planteamiento	1
1. Introducción	13
1.1. Procesamiento de imágenes	15
1.2. Registrado de imágenes	19
1.2.1. Imagen	27
1.2.2. Transformación de registrado	30
1.2.3. Métrica de similitud	34
1.2.4. Estrategia de búsqueda	37
1.3. Metaheurísticas	46
1.3.1. Computación evolutiva y procesamiento de imágenes	51
1.3.2. El algoritmo evolutivo scatter search	53
2. Registrado de imágenes en el espacio de correspondencias	57
2.1. Introducción	59
2.2. Antecedentes	60
2.2.1. Propuesta de <i>Zhang</i>	61
2.2.2. Propuesta de <i>Gold y otros</i>	62
2.2.3. Propuesta de <i>Luck y otros</i>	63
2.2.4. Propuesta de <i>Liu</i>	63
2.2.5. Propuesta de <i>Cordón y Damas</i>	66

2.3.	Detección de características en imágenes 3D	67
2.4.	Scatter Search para la búsqueda de correspondencias	68
2.4.1.	Esquema de codificación, información heurística y función objetivo	73
2.4.2.	Método de Generación de Soluciones Diversas	76
2.4.3.	Método de Actualización del Conjunto de Referencia	77
2.4.4.	Método de Generación de Subconjuntos	78
2.4.5.	Método de Combinación	78
2.4.6.	Método de Mejora	80
2.5.	Experimentación y análisis de resultados	83
2.5.1.	Diseño del experimento	84
2.5.2.	Análisis de resultados	91
3.	Registrado de imágenes en el espacio de la transformación	107
3.1.	Introducción	109
3.2.	Antecedentes	110
3.2.1.	Primeras aproximaciones evolutivas al problema de registrado de imágenes	110
3.2.2.	Propuesta de <i>Rouet y otros</i>	112
3.2.3.	Propuesta de <i>He y Narayana</i>	113
3.2.4.	Propuesta de <i>Cordón y otros</i>	113
3.3.	Scatter Search para la búsqueda de los parámetros de la transformación de registrado	114
3.3.1.	Esquema de codificación y función objetivo	116
3.3.2.	Método de Generación de Soluciones Diversas	117
3.3.3.	Método de Combinación	118
3.3.4.	Método de Mejora	118
3.4.	Experimentación y análisis de resultados	119
3.4.1.	Diseño del experimento	120
3.4.2.	Análisis de resultados	121

3.5. Comparativa resumen entre los dos enfoques de registrado	126
4. Aplicación en Antropología Forense	141
4.1. Introducción	143
4.2. Antropología Forense	144
4.3. Identificación Forense	145
4.4. El modelo digital	150
4.4.1. Introducción	150
4.4.2. Enfoques de reconstrucción	153
4.4.3. Métodos de prealineación	155
4.5. Aplicación de nuestras propuestas de registrado de imágenes a problemas de identificación forense	157
4.5.1. Cotejado de objetos forenses mediante la superposición de sus modelos tridimensionales	157
4.5.2. Obtención de modelos tridimensionales de objetos forenses mediante reconstrucción 3D	161
5. Comentarios finales	193
5.1. Resultados Finales y Conclusiones	195
5.2. Trabajos Futuros	199
Bibliografía	201

Índice de figuras

1.1. Imagen 2D de Lenna	17
1.2. A la izquierda, escáner (láser) 3D. A continuación, un mapa de rango, su correspondiente superficie/malla 3D y una instantánea (fotografía) de la escena tomada por una cámara CCD, respectivamente	17
1.3. Imagen volumétrica (3D). A la izquierda, combinación de vista sagital, axial y coronal de imágenes de resonancia magnética (MRI). A la derecha, la imagen anterior «voxelada» (imagen 3D) .	18
1.4. Imagen de ultrasonidos (US) en cuatro dimensiones (3D+T) mostrando la monitorización del ritmo cardíaco	18
1.5. Evolución de la producción científica en RI en los últimos años . .	21
1.6. Ejemplo de RI en fotogrametría: de izquierda a derecha, dos imágenes de satélite y la imagen resultante tras el proceso de registrado	22
1.7. Detección automático de marcas (esquinas) en la imagen. Las marcas de color rojo son primitivas que cuentan con su homólogo en la otra imagen, en azul las que no disponen de tal correspondencia correcta	23
1.8. De izquierda a derecha y de arriba abajo: fijación de un marco estereostático sobre el cráneo del paciente y localización del mismo sobre la plataforma del escáner. En la siguiente fila, dos imágenes CT y MRI en las que se muestran las marcas dejadas por dicho marco	24
1.9. Esquema general de un sistema de RI	25
1.10. Detector robusto de características para imágenes 2D con y sin ruido	29

1.11. Transformaciones 2D (de izquierda a derecha): objeto original; transformación rígida; similitud uniforme; similitud no uniforme y cizalla	33
1.12. Cubo y transformación de perspectiva del mismo	34
1.13. Cualquier movimiento rígido del plano imagen (en este caso de π_1 a π_2) que mantenga fijo el centro óptico O induce una transformación proyectiva entre los planos π_1 y π_2	35
1.14. GCP: imágenes escena (parte superior derecha) y modelo (parte inferior izquierda) encerradas en una doble estructura bidimensional de indexación. Para algunas celdas se muestra el vector de distancia asociado, $r_{C_j P'}$	38
1.15. Gráficas que representan parte del espacio de búsqueda en un problema de RI. En ellas se consideran dos de los parámetros de una rotación 3D (rotación en el eje X e Y) y el valor de información mutua asociado	39
1.16. Solución al problema de RI desde el enfoque de la búsqueda de las correspondencias	42
1.17. Solución al problema de RI desde el enfoque de la búsqueda de los parámetros de la transformación de registrado	45
1.18. Evolución de la aplicación de las metaheurísticas al RI en los últimos años. La información mostrada se ha obtenido a partir de la ecuación de búsqueda «(evolut* OR random* OR stochastic* OR *heuristic* OR annealing OR genetic OR swarm OR tabu) AND image AND (registration OR alignment)»	51
1.19. Esquema general de Scatter Search	55
2.1. Algoritmo RPM. Nótese cómo se resuelve alternativamente el problema de la correspondencia entre puntos y la estimación de los parámetros de registrado	64
2.2. Restricciones de colinealidad y proximidad. Con el mismo error de registrado e_i , el punto y_i'' es una asignación preferida al punto y_i' , ambos más próximos a x_i , ya que $d_i'' < d_i'$ y $\theta_i'' < \theta_i'$. Por tanto, x_i es más próximo al rayo que pasa a través de y_i'' que al rayo que pasa por y_i' , donde d_i'' y d_i' son las distancias desde el punto x_i a los rayos que pasan por y_i'' y y_i' , y θ_i'' y θ_i' son los ángulos entre el vector descrito por el punto x_i y los correspondientes a los puntos y_i'' y y_i' , respectivamente	65

2.3. Características diferenciales de superficies [Thirion, 96]	69
2.4. Superelipsoide sin polos y líneas de cresta extraídas del mismo . .	69
2.5. Diagrama de flujo general del algoritmo SS	70
2.6. Detalles de la implementación del esquema de representación basad- o en permutación para la correspondencia de puntos	74
2.7. Imagen I_1 . a) Imagen MRI original con sus tres vistas (axial, sag- ital, y coronal). Se pueden identificar de forma clara diferentes órganos (cráneo, cerebro, ojos, etc.). b) Isosuperficie correspondi- ente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante	86
2.8. Imagen I_2 . a) Imagen MRI original con 1 % de ruido gaussiano. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante .	86
2.9. Imagen I_3 . a) Imagen MRI original con 1 % de ruido gaussiano. Se marca mediante un círculo sobre la imagen la localización de la lesión de tipo esclerosis múltiple. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante	87
2.10. Imagen I_4 . a) Imagen MRI original con 5 % de ruido gaussiano. Se marca mediante un círculo sobre la imagen la localización de la lesión de tipo esclerosis múltiple. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante	87
2.11. Valor promedio del error de registrado con diferentes configura- ciones de pesos para los índices WC de F . Un balance apropiado para ambos índices repercute en la obtención de mejores resultados	97
2.12. De izquierda a derecha, la primera fila corresponde a los gráficos 3D con la superposición obtenida en cuatro de las dieciséis in- stancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada algorit- mo de RI (de arriba a abajo: SS_m , ILS , $ICP + SA$ e $I - ICP$)	105
3.1. Pseudocódigo del algoritmo SS para el RI en el espacio de los pará- metros de f	115

- 3.2. De izquierda a derecha, la primera fila corresponde a los gráficos 3D mostrando la superposición obtenida en cuatro de las dieciséis instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada algoritmo de RI (de arriba a abajo: SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real}) 127
- 3.3. Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), se promedia el valor medio de ECM (μ) de cada método en los cuatro escenarios de problema de registrado (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) 128
- 3.4. Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada uno de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$), se promedia el valor medio de ECM (μ) de cada método en las cuatro transformaciones de registrado a estimar (T_1 , T_2 , T_3 y T_4) 129
- 3.5. Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada método, en primer lugar, se promedia el valor medio de ECM (μ) de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), y después se obtiene el promedio de los cuatro valores anteriores 130
- 3.6. Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), se promedia el valor medio de ECM (μ) de cada método en los cuatro escenarios de problema de registrado (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) 131
- 3.7. Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada uno de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$), se promedia el valor medio de ECM (μ) de cada método en las cuatro transformaciones de registrado a estimar (T_1 , T_2 , T_3 y T_4) 136

3.8. Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada método, en primer lugar, se promedia el valor medio de ECM (μ) de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), y después se obtiene el promedio de los cuatro valores anteriores 137

3.9. Gráfica de líneas que muestra el rendimiento promedio de SS_m frente a SS_p para cada una de los cuatro escenarios. Para cada uno de los dos métodos, se realiza el promedio del valor medio de ECM (μ) de las transformaciones T_1 , T_2 , T_3 y T_4 en cada escenario I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$ 138

3.10. De izquierda a derecha, la primera fila corresponde a los gráficos 3D mostrando la superposición obtenida en cuatro de las dieciséis instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada una de nuestras propuestas de RI basadas en SS (de arriba a abajo: SS_m y SS_p) 139

4.1. De izquierda a derecha: marcas antropométricas en rojo sobre una imagen que simula la parte lateral de una cabeza humana; fotografía de un cráneo con la misma orientación que la cabeza de la imagen anterior (se marcan en rojo diferentes regiones antropométricas del cráneo); comparación de ambas imágenes mediante su superposición. El resultado de la identificación es negativo al no encontrarse una correspondencia adecuada entre ambos conjuntos de puntos 148

4.2. Principales puntos antropométricos del rostro (vistas frontal y lateral) 149

4.3. Personal del Laboratorio de Antropología Física de la Universidad de Granada trabajando con un escáner de rango 151

4.4. Ejemplo de adquisición y registrado de dos imágenes de rango correspondientes al busto en escayola de una mujer 152

4.5. Número de publicaciones por año en RIR. Los datos de la gráfica de barras se han obtenido de diferentes fuentes electrónicas (ACM SIGGRAPH, ISI Web of Knowledge, CompuScience, IEE-Explore) mediante la consulta «*range AND image AND (registration OR alignment)*» 152

4.6. Enfoque de RIR en dos etapas	155
4.7. Imagen I_1 . a) Imagen CT original. b) Isosuperficie correspondiente a la primera exploración CT de la muñeca del paciente. c) Extracción de 575 puntos de líneas de cresta	159
4.8. Imagen I_2 . a) Imagen CT original. b) Isosuperficie correspondiente a la segunda exploración CT de la muñeca del paciente. c) Extracción de 412 puntos de líneas de cresta	159
4.9. Mejores estimaciones obtenidas en la instancia I_1 Vs. $T_1(I_2)$ por los diferentes métodos de RI. De izquierda a derecha y de arriba abajo: SS_m , $ICP + SA$, $I - ICP$, SS_p , GA_{He} y CHC_{Real}	163
4.10. De izquierda a derecha: modelo 3D en bruto resultante del escaneado del cráneo considerado; vista parcial sin artefactos y sin aplicar suavizado; la misma vista tras aplicar un filtro de suavizado sobre ésta	164
4.11. En color gris oscuro se muestra la región de solapamiento de imágenes adyacentes. El color gris claro indica la región que pertenece exclusivamente a cada vista. De izquierda a derecha aparecen dos orientaciones distintas de las imágenes adyacentes $0^\circ - 45^\circ$ y $45^\circ - 90^\circ$	165
4.12. De arriba abajo: vistas parciales del objeto obtenidas a 270, 315, 0, 45 y 90 grados. A la derecha de cada una se visualizan las líneas de cresta extraídas	167
4.13. Resultados obtenidos por $I - ICP$ al registrar tres repertorios diferentes de imágenes. Los dos primeros («pájaro» y «rana») proceden de escaneos cada 20° , disponibles en el <i>Signal Analysis and Machine Perception Laboratory</i> (SAMPL) de la Universidad de Ohio en EEUU. El tercero corresponde a las vistas 0° y 45° de nuestro repertorio	172
4.14. Mejores estimaciones obtenidas por $ICP + SA$ en los cuatro escenarios. De izquierda a derecha se muestran las instancias: I_{0° Vs. $T_4(I_{45^\circ})$, I_{0° Vs. $T_3(I_{315^\circ})$, I_{45° Vs. $T_4(I_{90^\circ})$, e I_{315° Vs. $T_3(I_{270^\circ})$ 174	
4.15. Cinco ejemplos de RIR extraídos de la Tabla 4.5 mostrando (de izquierda a derecha) por columnas ordenadas según valor creciente de ECM, el resultado obtenido tras realizar las etapas de prealineación y de refinamiento	180

4.16. Gráficos 3D mostrando, desde diferentes puntos de vista, el modelo 3D reconstruido por SS_p siguiendo el enfoque de RIR automático . 186

4.17. Mejores estimaciones obtenidas por SS_m en los cuatro escenarios del enfoque de RIR semiautomático. De izquierda a derecha se muestran las instancias: I_{0° Vs. $T_4(I_{45^\circ})$, I_{0° Vs. $T_2(I_{315^\circ})$, I_{45° Vs. $T_1(I_{90^\circ})$, e I_{315° Vs. $T_4(I_{270^\circ})$ 187

4.18. Rendimiento promedio según valor de ECM ofrecido por los diferentes métodos de RIR al afrontar el problema desde el enfoque semiautomático. Las gráficas de barras corresponden, en la parte superior, al rendimiento obtenido en la etapa de prealineación, y en la parte inferior, al obtenido en la etapa final de refinamiento, considerando en ambos casos cada uno de los cuatro escenarios de RIR 188

4.19. Rendimiento promedio según valor de ECM ofrecido por los diferentes métodos de RIR al afrontar el problema desde el enfoque automático. Las gráficas de barras corresponden, en la parte superior, al rendimiento obtenido en la etapa de prealineación, y en la parte inferior, al obtenido en la etapa final de refinamiento, considerando en ambos casos cada uno de los cuatro escenarios de RIR 189

4.20. Comparativa del rendimiento promedio según valor de ECM entre los dos enfoques de RIR (semiautomático y automático). Los datos que se muestran de cada método corresponden al promedio de los valores medios de ECM de los cuatro escenarios 190

Índice de tablas

2.1. Transformaciones de similitud consideradas	89
2.2. De arriba a abajo: clasificación en orden ascendente de complejidad de los escenarios considerados en el problema de RI	89
2.3. Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_2)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita	92
2.4. Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_3)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita	93
2.5. Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_4)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita	94
2.6. Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_2 Vs. $T_i(I_4)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita	95

- 2.7. Valores promedio correspondientes con cada combinación de pesos de la función objetivo en las dos variantes de SS_m 98
- 2.8. Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_2 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita 101
- 2.9. Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_3 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita 102
- 2.10. Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_4 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita 103
- 2.11. Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_2 e I_4 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita 104
- 3.1. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado 122

3.2. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_3)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_3)$ e I_1 Vs. $T_4(I_3)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado 123

3.3. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_4)$, I_1 Vs. $T_2(I_4)$, I_1 Vs. $T_3(I_4)$ e I_1 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado 124

3.4. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_2 Vs. $T_1(I_4)$, I_2 Vs. $T_2(I_4)$, I_2 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado 125

3.5. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias 132

- 3.6. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_3)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_3)$ e I_1 Vs. $T_4(I_3)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias 133
- 3.7. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_4)$, I_1 Vs. $T_2(I_4)$, I_1 Vs. $T_3(I_4)$ e I_1 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias 134
- 3.8. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_2 Vs. $T_1(I_4)$, I_2 Vs. $T_2(I_4)$, I_2 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias 135
- 4.1. Valores mínimo (m), máximo (M), medio (μ), y desviación típica (σ) del ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para los métodos que trabajan en el espacio de correspondencias (SS_m e $ICP + SA$) y los que lo hacen en el espacio de la transformación (SS_p , GA_{He} y CHC_{Real}). En negrita aparecen resaltados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ) 162

4.2. Tamaño de las imágenes del repertorio (en número de puntos), antes y después de la aplicación del método de detección de líneas de cresta 166

4.3. Instancias de RIR consideradas para cada escenario (I_{0° Vs. $T_i(I_{45^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, y I_{315° Vs. $T_i(I_{270^\circ})$) y transformación de registrado (T_1 , T_2 , T_3 , y T_4) 169

4.4. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las dieciséis instancias de RIR (empleando el repertorio de imágenes original) tras realizar 15 ejecuciones diferentes del método *ICP + SA*. En negrita aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ) para cada uno de los cuatro escenarios (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$, I_{315° Vs. $T_i(I_{270^\circ})$) 174

4.5. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{0° Vs. $T_1(I_{45^\circ})$, I_{0° Vs. $T_2(I_{45^\circ})$, I_{0° Vs. $T_3(I_{45^\circ})$ e I_{0° Vs. $T_4(I_{45^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 176

4.6. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{0° Vs. $T_1(I_{315^\circ})$, I_{0° Vs. $T_2(I_{315^\circ})$, I_{0° Vs. $T_3(I_{315^\circ})$ e I_{0° Vs. $T_4(I_{315^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 177

- 4.7. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{45° Vs. $T_1(I_{90^\circ})$, I_{45° Vs. $T_2(I_{90^\circ})$, I_{45° Vs. $T_3(I_{90^\circ})$ e I_{45° Vs. $T_4(I_{90^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 178
- 4.8. Valores mínimo (m), máximo (M), medio (μ), y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{315° Vs. $T_1(I_{270^\circ})$, I_{315° Vs. $T_2(I_{270^\circ})$, I_{315° Vs. $T_3(I_{270^\circ})$ e I_{315° Vs. $T_4(I_{270^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 179
- 4.9. Resumen de resultados de los escenarios de RIR (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$ e I_{315° Vs. $T_i(I_{270^\circ})$) con imágenes procesadas por un detector de líneas de cresta (enfoque de RIR semiautomático). Se indican el número de veces (dieciséis como máximo) en que cada método de RIR (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) consigue el mejor valor mínimo y medio de ECM, así como la eficacia de cada método en el proceso de reconstrucción 180
- 4.10. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{0° Vs. $T_1(I_{45^\circ})$, I_{0° Vs. $T_2(I_{45^\circ})$, I_{0° Vs. $T_3(I_{45^\circ})$ e I_{0° Vs. $T_4(I_{45^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15% del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 181

4.11. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{0° Vs. $T_1(I_{315^\circ})$, I_{0° Vs. $T_2(I_{315^\circ})$, I_{0° Vs. $T_3(I_{315^\circ})$ e I_{0° Vs. $T_4(I_{315^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 182

4.12. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{45° Vs. $T_1(I_{90^\circ})$, I_{45° Vs. $T_2(I_{90^\circ})$, I_{45° Vs. $T_3(I_{90^\circ})$ e I_{45° Vs. $T_4(I_{90^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 183

4.13. Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{315° Vs. $T_1(I_{270^\circ})$, I_{315° Vs. $T_2(I_{270^\circ})$, I_{315° Vs. $T_3(I_{270^\circ})$ e I_{315° Vs. $T_4(I_{270^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita 184

4.14. Resumen de resultados de los escenarios de RIR (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$ e I_{315° Vs. $T_i(I_{270^\circ})$) con imágenes muestreadas uniformemente a un 15 % del tamaño original (enfoque de RIR automático). Se indican el número de veces (dieciséis como máximo) en que cada método de RIR (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) consigue el mejor valor mínimo y medio de ECM, así como la eficacia de cada método en el proceso de reconstrucción 185

Planteamiento

A. Introducción

- ¡ *Qué extraña escena describes-dijo-y qué extraños prisioneros !*

- *Iguales que nosotros-dije-, porque en primer lugar ¿ crees que los que están así han visto otra cosa de sí mismos o de sus compañeros sino las sombras proyectadas por el fuego sobre la parte de la caverna que está frente a ellos ?*

El mito de la caverna Platón (427-347 a.c.)

La visión es la parte del sistema nervioso con la misión de procesar la información proveniente del *espectro electromagnético*¹, concretamente dentro del rango de la luz visible. La necesidad de ampliar nuestra limitada capacidad visual ha llevado a la comunidad científica a investigar en la construcción de complejos *sistemas de adquisición de imágenes* que operen en diferentes regiones del espectro para trasladar dicha información procesada a nuestro sistema de visión. El *procesamiento de imágenes* es la disciplina del campo de la *visión por computador* encargada del tratamiento y análisis de las imágenes haciendo uso de computadoras [Faugeras, 96, González, 02].

Como muestra de la importancia que el procesamiento de imágenes ha llegado a tener en nuestros días, desde el *New England Journal of Medicine* se ha seleccionado al procesamiento de imágenes médicas como una de las once innovaciones

¹Espectro electromagnético o conjunto de ondas electromagnéticas que van desde las de menor longitud de onda, como los rayos cósmicos, luz ultravioleta, luz visible y rayos infrarrojos, hasta las ondas de mayor longitud de onda, como son las ondas de radio. Ciertas especies animales tienen la capacidad de ver en zonas del espectro no visible por el ojo humano.

más importantes de los últimos mil años, lo que ahonda aún más en el destacado papel que corresponde a campos de investigación como los citados anteriormente, visión y gráficos por computador. Es en ambas disciplinas donde el *Registrado*² *de imágenes* [Brown, 92, Maintz, 96, Maintz, 98, Zitová, 03] destaca como uno de los temas de mayor calado entre la comunidad científica especializada desde hace varias décadas.

Grosso modo, la tarea de registrado consiste en la superposición de dos imágenes, haciéndolas corresponder por sus partes iguales o similares. En este sentido, y dependiendo de la naturaleza de las imágenes consideradas, el registrado puede dar como resultado la inclusión total o parcial de una imagen en la otra, o bien la composición de una imagen de mayor orden a modo de puzzle. Esto último es lo que en algunos ámbitos no familiarizados con el registrado se conoce como «*cosido de imágenes*». De entre las aplicaciones más destacadas en las que el registrado interviene, se encuentran las relacionadas con áreas tales como la medicina, la teledetección, la robótica o la antropología [Goshtasby, 05].

Las imágenes pueden obtenerse en condiciones tales como: empleando diferentes sensores o dispositivos, en diferentes instantes de tiempo, o una combinación de éstas. Tales circunstancias originan que las imágenes se encuentren en sistemas de referencia diferentes, sin más relación entre sí que la información que almacenan. En definitiva, el objetivo es obtener la transformación de registrado que consiga superponer/solapar las dos imágenes de la mejor forma posible. Los *métodos directos* (planteando un simple sistema de ecuaciones) proporcionan la solución al problema de registrado cuando se considera una transformación simple y se cuenta con las correspondencias correctas entre imágenes.

En aquellos casos en los que el modelo de transformación es complejo y/o no se puede asegurar un conjunto adecuado de correspondencias entre imágenes, el uso de métodos no lineales de resolución inmersos en un proceso iterativo de búsqueda u *optimización* se convierte en la estrategia adecuada para solucionar el problema de registrado de imágenes. Dicha estrategia de búsqueda se considera uno de los componentes cruciales dentro del sistema de registrado, el cual además estará constituido por una *métrica* o *función objetivo*, y la *transformación* de registrado que pretendemos conseguir. Independientemente del diseño particular considerado para un método de registrado dado, la solución proporcionada por éste será aquella transformación que relacione y superponga, bajo un mismo sistema de referencia, las imágenes consideradas.

²El término *registrado* no aparece como tal en el diccionario de la R.A.E. Algunos autores hispano hablantes emplean en ocasiones puntuales la voz «registro» (con una acepción no incluida en dicho diccionario). Hemos optado por este anglicismo por la profusión de su utilización dentro del área.

En la literatura de registrado, la mayor parte de métodos de registrado de imágenes hacen uso de técnicas de optimización local, realizando una búsqueda *monótona* descendente (o ascendente) según cierta función de coste (función objetivo). Por otro lado, una característica deseable para dicha función es que su expresión analítica sea fácilmente diferenciable, bien pudiéndose calcular la derivada de primer orden, o en el mejor de los casos, de segundo orden. Esta forma de operar es comúnmente conocida como el cálculo del *gradiente de función*. Si bien los métodos de registrado que hacen uso de este tipo de funciones están considerados como los más eficaces, eficientes y precisos, hay que tener en cuenta que en el problema de registrado no existe una única función capaz de operar en cualquier aplicación del mundo real. En tales casos, es necesario realizar nuevos diseños de función adaptados a las necesidades del nuevo entorno, encontrándose casos en los que no es posible hacer uso de una expresión analítica diferenciable. Además, dificultades tales como la consideración de imágenes con ruido y/o la existencia de una importante *desalineación* entre las imágenes puede dar al traste con el proceso de búsqueda, aunque estemos empleando funciones diferenciables. Por tanto, es bien sabido por parte de la comunidad científica que los métodos de registrado, de no satisfacerse un buen número de precondiciones, suelen quedar atrapados en óptimos locales. Frente a esto, es el usuario quien debería de intervenir para corregir (manualmente) este tipo de situaciones no deseadas.

Dado el carácter práctico de este tipo de problemas de optimización, se han desarrollado multitud de algoritmos con la intención de ofrecer una estrategia de búsqueda más eficaz y robusta. Dichos algoritmos pueden clasificarse como *exactos* o *aproximados* [Brassard, 97, Levitin, 02]. Los primeros garantizan encontrar una solución óptima para cada instancia de tamaño finito de un problema de optimización combinatoria llevando a cabo una búsqueda exhaustiva. No obstante, para muchos problemas \mathcal{NP} -duros, estos métodos precisan un tiempo exponencial en el caso peor. Incluso para casos del problema de tamaño reducido, dichos algoritmos tardarían un tiempo que estaría muy por encima de lo admisible en aplicaciones prácticas. Bajo este condicionante, los métodos aproximados adquieren una mayor atención. En estos métodos sacrificamos la garantía de encontrar soluciones óptimas a cambio de obtener soluciones de calidad aceptable en un intervalo de tiempo mucho más reducido. Además, este tipo de técnicas son más flexibles al no exigir el manejo de funciones derivables, lo cual favorece el diseño de esquemas genéricos de resolución.

Recientemente, ha surgido una nueva familia de algoritmos aproximados basada en la extensión de métodos heurísticos básicos mediante su inclusión en un proceso iterativo de búsqueda que aumente sus capacidades exploratorias. A este grupo de algoritmos aproximados avanzados se les denomina *metaheurísticas*

[Glover, 03a]. El objetivo de este tipo de algoritmos heurísticos es encontrar un estado u objeto matemático discreto bajo cierta representación, tal como una cadena de bits o una permutación, que minimice/maximice cierta *función objetivo*, la cual actúa a modo de «caja negra». El conjunto de posibles estados que pueden ser evaluados por dicha función se conoce como *espacio de búsqueda*. Este tipo de métodos permiten combinar etapas de descenso con otras de ascenso (guiadas por la función objetivo) con la intención de proporcionar estrategias de búsqueda robustas capaces de escapar de óptimos locales. Las clasificaciones que se pueden hacer de las metaheurísticas son variadas según diversos criterios. La cardinalidad del conjunto de soluciones que intervienen en el proceso de búsqueda es uno de ellos, a partir del que se pueden realizar dos clasificaciones de estos métodos: las basadas en trayectorias (una única solución en el espacio de búsqueda) y las centradas en poblaciones (más de una solución). La *computación evolutiva* [Bäck, 97] se centra en proponer estrategias de esta segunda categoría, entre las que destacan los *algoritmos genéticos* [Michalewicz, 96] por su amplia difusión.

Independientemente de la categoría del método heurístico considerado, la estrategia de búsqueda empleada debiera ser diseñada de tal forma que se equilibraran la explotación de la experiencia acumulada a lo largo de la búsqueda (conocida como *intensificación o explotación*) y la exploración del espacio de búsqueda (conocida como *diversificación o exploración*). Este equilibrio es necesario por dos razones: identificar rápidamente regiones del espacio de búsqueda con soluciones de buena calidad y no malgastar demasiado tiempo en regiones del espacio que ya han sido exploradas previamente o que no proporcionen soluciones de calidad. Este tipo de métodos se han aplicado satisfactoriamente en diversos problemas entre los que se encuentran el problema de la asignación cuadrática, el viajante de comercio, el coloreo de grafos, la gestión de tráfico en redes de computadoras, etc.

La aplicación de este tipo de métodos heurísticos en diferentes problemas del área del procesamiento de imágenes ha aumentado significativamente en los últimos años entre la comunidad científica no afín al área de las metaheurísticas. Este hecho se refleja en las diferentes sesiones especiales que se han organizado hasta la fecha, tales como las celebradas en el *2005 IEEE Congress on Evolutionary Computation (CEC'05)* y en el *2006 FUZZY IEEE Conference (FUZZ-IEEE'06)*, tituladas «*Evolutionary Computer Vision*» y «*Soft Computing in Image Processing: Recent Advances*», respectivamente, así como la organización del *European Workshop on the application of Genetic and Evolutionary Computation to Image Analysis and Signal Processing (EvoIASP)* que se viene llevando a cabo desde 1999 con una periodicidad anual, junto a la publicación de un buen número de números especiales en revistas de reconocido prestigio, tales como *Journal of Advanced Signal Processing*, *Pattern Recognition Letters*, *Evolutionary Computation* e *Internatio-*

nal Journal of Approximate Reasoning, entre otras.

En esta memoria nos planteamos avanzar en el desarrollo de nuevos métodos de registrado de imágenes tridimensionales basados en el uso de metaheurísticas. Perseguimos obtener métodos de registrado que sean a la vez eficaces y eficientes en la resolución de problemas reales de registrado de imágenes médicas. Para ello abordaremos dos de los enfoques de resolución comúnmente usados en la literatura de registrado: **i)** planteando el problema desde la búsqueda de las mejores correspondencias entre las características más sobresalientes de las imágenes a partir de las cuales calcular la transformación de registrado (*resolución en el espacio de correspondencias o del matching*), o bien, **ii)** desde el estudio directo del espacio donde toman valores los parámetros que definen dicha transformación (*resolución en el espacio de la transformación*). En los últimos años, han surgido un conjunto de propuestas de registrado basadas en ambos enfoques e inspiradas en técnicas metaheurísticas, mostrando resultados exitosos en instancias con cierto grado de complejidad, difíciles de resolver por los métodos clásicos de registrado. Este doble enfoque de resolución ya fue abordado por el Dr. Sergio Damas en su trabajo de tesis doctoral [Damas, 03], donde se propusieron varios métodos de registrado, entre los que destacan por su buen rendimiento uno basado en la metaheurística *Iterative Local Search* (ILS) [Cordón, 06a] y otro en el algoritmo evolutivo *CHC* [Cordón, 06d], cada uno de ellos diseñado para operar, respectivamente, en el primero y en el segundo de los enfoques anteriores.

Por tanto, esta memoria toma como base y punto de partida la línea de trabajo iniciada por el Dr. Damas, tratando de afrontar nuevos y más complejos problemas con nuevos diseños de métodos más eficaces y eficientes (en tiempo asumible para la aplicación a la que van orientados), siempre en la línea de conseguir métodos automáticos de registrado. Además, debido al éxito y profusión que está teniendo el empleo de estas técnicas heurísticas en el área del registrado de imágenes, hemos adoptado la metodología propuesta por el algoritmo *Scatter Search* (búsqueda dispersa) [Laguna, 03] como esquema base para el diseño de dos nuevas propuestas de registrado, cada una de ellas con un diseño particular para cada uno de los dos enfoques anteriores de registrado. De forma breve, *Scatter Search* es una metaheurística poblacional con un *diseño modular* de sus componentes que, a diferencia de otras técnicas como los algoritmos genéticos [Michalewicz, 96], considera la evolución de un *conjunto reducido* (del orden de varias decenas inferior) de soluciones élite, siendo su objetivo fundamental el proponer diseños de mecanismos *sistemáticos* (frente a los puramente aleatorios) de búsqueda y construcción de soluciones. El diseño de estos mecanismos se apoya en el empleo de información específica del problema. Hemos considerado incluir varias contribuciones recientes para validar el rendimiento de nuestras propuestas, además de los

métodos con mejor rendimiento que se presentan en [Damas, 03].

Por último, pretendemos concluir nuestro trabajo aplicando nuestras nuevas propuestas de registrado al campo de la Antropología Forense, concretamente para automatizar ciertas tareas del proceso de *identificación forense* de seres humanos [Iscan, 81a, Iscan, 81b]. En este nuevo entorno de aplicación trataremos con imágenes de naturaleza muy diferente a las empleadas en otros entornos médicos, las denominadas *imágenes de rango*. De esta forma, afrontaremos un entorno de aplicación completamente distinto con un grado de complejidad notoriamente superior debido a las múltiples consideraciones que afectan a la resolución de este nuevo problema.

B. Objetivos

La principal limitación de los métodos clásicos de registrado de imágenes es su bajo rendimiento tratando con instancias complejas, así como la necesidad en muchos casos de la asistencia manual del usuario. Nuestro principal objetivo se centra en hacer uso de técnicas metaheurísticas como una alternativa de optimización más eficaz y robusta con la intención de conseguir métodos de registrado de imágenes casi completamente automáticos, que proporcionen soluciones de alta calidad en un tiempo de ejecución lo más reducido posible. Este objetivo principal se divide en varios que mostramos a continuación:

- *Diseñar nuevas técnicas de registrado de imágenes basadas en nuevos modelos de computación evolutiva.* El hecho de no tratar de forma adecuada la convergencia a óptimos locales deja en entredicho el rendimiento de muchas de las contribuciones que se presentan como métodos de registrado totalmente automáticos. Por este motivo, nuestra intención es hacer uso de las metaheurísticas como estrategia de búsqueda global intentando dar solución a este tipo de inconvenientes y conseguir métodos de registrado eficaces y eficientes.

Puesto que las metaheurísticas más utilizadas en la resolución del problema de registrado han sido los algoritmos evolutivos, en la presente memoria pretendemos abordar el problema haciendo uso de *Scatter Search*. El principal objetivo de esta técnica de optimización es proponer diseños de mecanismos *sistemáticos* de búsqueda y construcción de soluciones permitiendo hacer uso de información específica de nuestro problema de registrado, favoreciendo la búsqueda de soluciones de mayor calidad. Además, *Scatter Search* es una técnica con un *diseño modular* de sus componentes, lo que la convierte

en una estrategia que facilita su adaptación a las características de problemas muy diversos, haciendo más asequibles las tareas de análisis, diseño e implementación. Por último, la consideración de un *conjunto reducido* de soluciones élite, del orden de varias decenas menor al considerado en otros esquemas evolutivos (como los algoritmos genéticos), da lugar a que Scatter Search sea una técnica más eficiente, aspecto de gran interés para nuestro problema, ya que la evaluación de soluciones suele ser costosa.

- *Formular el problema de registrado estudiando conjuntamente la puesta en correspondencia o matching y la búsqueda de parámetros de la transformación de registrado.* Teniendo como base que la solución final del problema consiste en los valores apropiados para los parámetros que determinan la transformación de registrado, hay al menos dos enfoques que pueden considerarse para resolverlo, cada uno de los cuales trabaja en un espacio de búsqueda diferente: la *correspondencia o matching* de primitivas y la *aproximación de los valores de la transformación de registrado*. Por tanto, nuestra intención es diseñar distintas variantes de métodos de registrado basados en Scatter Search que permitan afrontar el problema trabajando en los dos espacios de búsqueda, para esclarecer las ventajas e inconvenientes de cada enfoque.
- *Relajar consideraciones sobre la función objetivo.* El uso de gran parte de métodos clásicos de registrado está sujeto a la consideración de una función cuya expresión analítica sea derivable, algo con lo que no siempre se puede contar. Bansiéndonos en la flexibilidad que proporcionan las metaheurísticas en este sentido, y con la intención de proporcionar métodos de registrado cuya aplicación sea lo más genérica posible, en nuestras propuestas de estrategias de búsqueda pretendemos relajar esta restricción y hacer uso de funciones comúnmente empleadas en los métodos de la literatura.
- *Afrontar problemas de registrado de imágenes médicas tridimensionales.* En esta memoria se pretende abordar el problema de registrado considerando imágenes 3D, por tratarse de un entorno de mayor complejidad (con mayor dimensionalidad que las imágenes 2D) y con un mayor interés en campos de aplicación como la medicina. Además, se contempla el manejo de escenarios con distinto grado de complejidad según se consideren imágenes con ruido, oclusión entre imágenes y grado de desalineación entre las imágenes a registrar. Con estas consideraciones, pretendemos confirmar la hipótesis de partida en la que afirmamos que los métodos de registrado que usan técnicas metaheurísticas presentan, en mayor o menor grado, un mejor rendimiento tratando con este tipo de instancias. Además, nuestra intención es hacer uso

de un enfoque de registrado basado en características con el objetivo de, por un lado, evitar en la medida de lo posible la problemática del enfoque basado en intensidades y, por otro, proponer métodos de registrado eficientes al contar con un conjunto reducido de información. En este sentido, pretendemos emplear la información derivada de la curvatura del contorno del objeto, que se ha mostrado como un potente descriptor de la forma.

- *Análizar el rendimiento de nuestras propuestas frente a un conjunto de métodos de referencia propuestos en la literatura especializada.* Con la intención de evaluar el rendimiento de nuestras propuestas, describiremos y emplearemos algunos de los métodos de registrado más relevantes y recientes en el área contra los que comparar. Consideraremos tanto contribuciones que hagan uso de técnicas metaheurísticas como otras referidas a métodos clásicos de la literatura. Este conjunto de métodos se seleccionará tanto para el enfoque de resolución en el espacio de correspondencias como en la aproximación de la transformación de registrado.
- *Aplicar nuestras propuestas de registrado de imágenes en Antropología Forense.* Por último, pretendemos concluir nuestro trabajo aplicando todo lo planteado anteriormente en el campo de la Antropología Forense con el propósito de ofrecer herramientas capaces de automatizar ciertas tareas del proceso de *identificación forense* de seres humanos [Iscan, 81a, Iscan, 81b], como son el *cotejo de pares de restos* y la *obtención de modelos 3D* a partir de imágenes obtenidas por escáneres de rango. En este último caso, trataremos con imágenes de naturaleza singular, como son las *imágenes de rango*, para llevar a cabo un proceso de *reconstrucción 3D* ([Bernardini, 02]) con el que obtener una versión digital del objeto real escaneado, por ejemplo la obtención del modelo 3D de los restos óseos de una persona.

C. Estructura

Para alcanzar los objetivos planteados, la presente memoria está organizada en los siguientes capítulos:

En el Capítulo 1 introducimos las bases teóricas del problema de registrado de imágenes y los elementos que constituyen el marco de trabajo de los métodos que tratan de abordar la resolución de este problema, así como de todo lo relacionado con esta materia que será de gran ayuda para el desarrollo del resto de capítulos de esta memoria.

El Capítulo 2 está dedicado a presentar un nuevo método de registrado que emplea un diseño específico del algoritmo evolutivo Scatter Search para resolver el problema desde el enfoque de la búsqueda de correspondencias. Además, se presentan un conjunto de experimentos destinados a evaluar el rendimiento de nuestra propuesta de registrado frente a otras dentro de la literatura especializada.

En el Capítulo 3 se describe nuestra segunda propuesta en la que también se considera el algoritmo Scatter Search para diseñar una estrategia específica con la que abordar el problema de registrado de imágenes desde el enfoque de los parámetros de la transformación. Al igual que en el capítulo anterior, se presentan una serie de experimentos orientados a evaluar la eficiencia y la efectividad de esta propuesta frente a otras del estado del arte de la literatura de registrado. El capítulo finaliza con una puesta en común de los resultados obtenidos con ambos enfoques de resolución del problema de registrado.

El Capítulo 4 aborda la aplicación de los métodos propuestos en los capítulos 2 y 3 en dos problemas del campo de la Antropología Forense: i) el cotejo de pares de restos; y ii) la obtención de modelos 3D. En este capítulo se presentan los diferentes diseños experimentales considerados para evaluar nuestras propuestas de registrado comparando los resultados con los obtenidos por otras técnicas de la literatura.

Por último, se resumen los resultados obtenidos en la memoria, las conclusiones y los trabajos futuros a plantear. Se incluyen, por tanto, los comportamientos más relevantes deducidos a partir de la experimentación llevada a cabo en cada capítulo, así como la introducción de posibles líneas abiertas para el desarrollo de nuevos trabajos dentro del ámbito del registrado de imágenes mediante técnicas basadas en metaheurísticas.

Capítulo 1

Introducción

1.1. Procesamiento de imágenes

La vista es nuestro sentido más desarrollado y complejo [Escalera, 01], cifrando su importancia en el setenta y cinco por ciento de la información procesada por el cerebro. Por tanto, no es extraño que las imágenes jueguen un papel crucial dentro de la percepción humana. A diferencia del ser humano, cuya visión se encuentra limitada a la conocida como *banda visual* del *espectro electromagnético*, los instrumentos o *sistemas de adquisición* de imágenes cubren casi completamente dicho espectro, desde las ondas gamma a las de radio. De hecho, pueden operar sobre imágenes generadas por fuentes que no pueden ser captadas por nuestro sistema de visión, entre ellas: imágenes de ultrasonidos, de microscopía electrónica, o de resonancia magnética. Por ello, el *procesamiento de imágenes* digitales es una tarea clave en multitud de aplicaciones de muy diversa índole:

- Telecomunicaciones: teledetección vía satélite.
- Medicina: diagnóstico y tratamiento de enfermedades.
- Robótica: sistemas de navegación.
- Identificación: sistemas de reconocimiento de huellas dactilares, de caras, matrículas de vehículos, etc.
- Tráfico: control viario.
- Control de calidad: inspección y verificación de motores, cristales, soldaduras, circuitos impresos, madera, alimentos, etc.
- Seguridad: vigilancia de edificios, detección de explosivos, etc.

Una imagen digital (2D), puede definirse [González, 02] como una función bidimensional $I(x,y)$, donde x e y son coordenadas espaciales, mientras que la amplitud de I en cualquier par de coordenadas (x,y) se denomina *intensidad* o *nivel de gris* de la imagen en ese punto. Cuando tanto las coordenadas como la amplitud I son magnitudes discretas y finitas, la imagen se dice *digital*. Es importante destacar que una imagen digital se compone de un número finito de *primitivas elementales*, llamadas *píxeles* o *vóxeles* para imágenes 2D ó 3D respectivamente. No debe confundirse el tipo anterior de primitivas con las denominadas *primitivas geométricas*¹ (término empleado en el área del registrado de imágenes [Besl, 92]) ya que estas últimas no son capturadas en la escena, sino generadas mediante software, bien mediante herramientas CAD² o por métodos de procesamiento de imágenes. Para evitar confusiones en lo sucesivo, emplearemos el término «primitiva» para cualquiera de las dos acepciones anteriores y aumentaremos este conjunto para cualquier tipo de elemento a partir del cual se genere una imagen. Además de poseer una ubicación espacial dentro de la imagen (de dominio discreto o continuo según se esté tratando), las primitivas pueden llevar asociado un vector de atributos, también denominado *vector de características*, en el que se recoge información de muy diversa naturaleza como puede ser la textura, curvatura, etc.

Existen diferentes tipos de imágenes atendiendo a la dimensión del espacio que ocupan:

- **Imágenes 2D:** son las resultantes de realizar la proyección de la luz irradiada por la escena sobre el plano discreto del dispositivo (malla 2D). Las *cámaras CCD* son los dispositivos de adquisición de este tipo de imágenes, con el *píxel* como primitiva elemental. La Figura 1.1 muestra un ejemplo típico con la fotografía de *Lenna* (o *Lena*)³.
- **Imágenes 3D:** según el tipo de sistema de adquisición empleado podemos encontrar las siguientes variantes:
 - **Imágenes de rango,** obtenidas mediante un *escáner 3D* o por medio de cámaras CCD (dos como mínimo). Grosso modo, una imagen de rango,

¹Formas geométricas consideradas primitivas por su básica constitución en las partes que la conforman, ya estemos tratando imágenes 2D ó 3D. Ejemplos de éstas pueden ser puntos, líneas, triángulos, círculos, etc.

²Diseño asistido por computador.

³Para los curiosos: esta imagen, ámpliamente usada en las publicaciones de procesamiento de imágenes, corresponde a un recorte de portada de la revista *Playboy* del año 1972 (www.lenna.org). En 1988, Lena Soderberg fue entrevistada en una publicación sueca sobre computación donde se mostraba agradecida por la utilidad que había tenido su fotografía en la comunidad científica.



Figura 1.1: Imagen 2D de Lenna

también llamada *mapa de rango*, se asemeja a una imagen 2D, con la particularidad de que cada «píxel» almacena un valor de profundidad (distancia del dispositivo a la superficie de la escena escaneada) en lugar de un nivel de intensidad lumínica (Figura 1.2). Además, si el dispositivo lo permite, éste puede recoger información adicional como atributos de color y textura presentes en la superficie de la escena.




Figura 1.2: A la izquierda, escáner (láser) 3D. A continuación, un mapa de rango, su correspondiente superficie/malla 3D y una instantánea (fotografía) de la escena tomada por una cámara CCD, respectivamente

- Imágenes *volumétricas*, que generalmente son las obtenidas por sistemas de adquisición de imagen médica. Existen distintas modalidades de dispositivos, cada uno de los cuales proporciona información de diferente naturaleza cuya combinación resulta de gran ayuda para el experto. Este tipo de sensores captan la escena irradiada en una estructura volumétrica a modo de apilado de una serie de «rebanadas»

(en inglés, *slices*) de imágenes bidimensionales, con el *vóxel* como primitiva elemental (Figura 1.3). Los sistemas de resonancia nuclear son un claro ejemplo como dispositivo de adquisición de estas imágenes volumétricas, entre ellas: *resonancia magnética* (MRI), *tomografía por computador* (CT), *tomografía axial por computador* (CTA), *tomografía por emisión de positrones* (PET), *tomografía por emisión de fotón único* (SPECT), *angiografía por sustracción digital* (DSA) y *ultrasonidos* (US).




Figura 1.3: Imagen volumétrica (3D). A la izquierda, combinación de vista sagital, axial y coronal de imágenes de resonancia magnética (MRI). A la derecha, la imagen anterior «voxelada» (imagen 3D)

- Imágenes 2D+T/3D+T, en las que se añade una tercera/cuarta dimensión referente al instante en el que son adquiridas las imágenes. Éstas son ampliamente utilizadas en aplicaciones médicas como por ejemplo en la monitorización del ritmo cardíaco (Figura 1.4).




Figura 1.4: Imagen de ultrasonidos (US) en cuatro dimensiones (3D+T) mostrando la monitorización del ritmo cardíaco

Por otro lado, no existe un acuerdo generalizado entre los autores para delimitar las fronteras entre el procesamiento de imágenes y otras áreas de conocimiento relacionadas, como el análisis de imágenes o la visión por computador, en lo que parece ser todo un continuo. No obstante, un paradigma útil es considerar tres procesamientos diferenciados dentro de este continuo: de bajo, de medio y de alto nivel:

- El *procesamiento de nivel bajo* incluye las operaciones primitivas como el preprocesamiento para reducir el ruido o aumentar el contraste. En este caso, tanto las entradas como las salidas son imágenes.
- En el *procesamiento de nivel medio* se incluyen tareas como la segmentación (división de una imagen en regiones u objetos); la descripción de dichos objetos con el fin de que sean adecuados para su posterior procesamiento por ordenador; y la clasificación (reconocimiento) de objetos individuales. El procesamiento de medio nivel se caracteriza por el hecho de que sus entradas generalmente son imágenes mientras que sus salidas suelen ser atributos extraídos de dichas imágenes (como fronteras, contornos o la identidad de objetos individuales).
- El *procesamiento de nivel alto* implica «dar sentido» a un conjunto de objetos reconocidos, como en análisis de imágenes y, al final del continuo al que antes hacíamos referencia, desarrollar las funciones cognitivas asociadas habitualmente con la visión.

Según este análisis global de los problemas relacionados con el procesamiento de imágenes, podríamos ubicar el registrado de imágenes digitales dentro del procesamiento de medio nivel, dado que, según veremos a continuación, como entrada al problema encontramos imágenes que deben ser procesadas con el fin de determinar un atributo, la función de transformación (*mapping*) que las relaciona.

1.2. Registrado de imágenes

En el campo de la medicina, concretamente en radioterapia, *Calvin R. Maurer* [Maurer, 93] define el registrado de imágenes (RI) como «*la tarea encargada de determinar la correspondencia uno-a-uno entre primitivas en un sistema de coordenadas y primitivas en un sistema de referencia diferente, de tal forma que dichos emparejamientos correspondan a una misma región de la anatomía escaneada*». El RI adquiere la categoría de problema debido a la *inexistencia de la correspondencia verdadera* entre dos imágenes que pertenecen a una misma escena. De forma

resumida, la tarea de RI está presente en los siguientes problemas/entornos prácticos:

- Integrar información procedente de diferentes dispositivos.
- Encontrar cambios en imágenes adquiridas en momentos o condiciones diferentes.
- Inferir información tridimensional a partir de imágenes en las que tanto el objeto/sujeto como el dispositivo pueden moverse.
- Identificar objetos empleando enfoques basados en modelos.

En la actualidad, diseñar métodos de RI eficaces, eficientes y completamente automáticos es un tema de investigación de gran interés en campos como la visión y los gráficos por computador, abordando un amplio conjunto de problemas reales. Por ejemplo, en aplicaciones médicas dando apoyo en el diagnóstico de enfermedades y posterior planificación del tratamiento quirúrgico [Goshtasby, 05], también en la industria (manufacturado de piezas) y en arqueología (reconstrucción digital de restos arqueológicos) [Bernardini, 02, Allen, 03]. Con la intención de mostrar el interés científico actual sobre RI, hemos consultado en cuatro bibliotecas digitales (accesibles vía web) el volumen total de publicaciones que versan sobre este tema, considerando como medios de difusión tanto actas de congresos como los artículos en revistas incluidas en los índices del *JCR*⁴. La gráfica de la Figura 1.5 muestra el creciente interés en la comunidad científica abordando el problema de RI. Los datos con los que se ha generado la citada gráfica se han obtenido consultando diferentes fuentes electrónicas (ACM SIGGRAPH, ISI Web of Knowledge, CompuScience e IEEEExplore) con la ecuación de búsqueda «*image AND (registration OR alignment)*» entre los años 1981 y 2005.

Independientemente de la aplicación particular considerada, el RI tiene como misión fundamental la de *superponer/solapar* imágenes adquiridas en diferentes condiciones: con diferentes mecanismos de captura (sensores, dispositivos, etc.), en diferentes instantes de tiempo, o una combinación de ambos. El factor relevante a tener en cuenta es el hecho de que cada imagen se encuentra en un sistema de referencia diferente, luego su superposición es el resultado de «modificar» el sistema de referencia (posición y orientación de las imágenes) de una de ellas para situarla en el sistema de coordenadas de la otra. Dicho cambio de coordenadas se realiza mediante lo que se conoce como *transformación de registrado*. La Figura 1.6 muestra un ejemplo de RI para imágenes vía satélite, en el que se puede

⁴Journal Citation Reports.




Figura 1.5: Evolución de la producción científica en RI en los últimos años

observar como un RI correcto consigue superponer regiones de ambas imágenes pertenecientes a la misma zona de la escena fotografiada, facilitando, a su vez, una mejor interpretación del contenido de las mismas.

Durante el procesamiento de imágenes médicas el problema de RI puede agravarse aún más bajo la confluencia de factores tales como:

- El sujeto escaneado se mueve (transformación global). De forma inevitable, el paciente cambia de posición a lo largo de sesiones periódicas de escaneado (efectuadas en diferentes intervalos de tiempo). Incluso realizando varios escaneados en un mismo instante, la elevada resolución del dispositivo puede llegar a captar movimientos del sujeto.
- De igual forma, ciertas zonas sufren ligeros desplazamientos (transformación local) y/o deformaciones (transformación elástica), como las orejas, párpados, labios, etc.
- Se emplean distintos dispositivos para escanear una misma zona anatómica (multimodalidad). Como consecuencia, la información contenida en las diferentes imágenes es distinta, con el añadido de que la fusión de las mismas (dos o más imágenes) proporciona información de gran importancia para el experto.




Figura 1.6: Ejemplo de RI en fotogrametría: de izquierda a derecha, dos imágenes de satélite y la imagen resultante tras el proceso de registrado

El problema de RI puede paliarse en cierta medida gracias al empleo de *dispositivos de calibración*⁵, también conocidos como *sistemas de posicionamiento*, pudiendo ser de tipo magnético, óptico, mecánico o acústico [Detmer, 94, Leotta, 97, Callieri, 04]. Este tipo de sensores proporcionan una transformación próxima a la óptima (debe tenerse en cuenta el error introducido por el propio dispositivo) que hace coincidir de la mejor forma posible ambos sistemas de referencia. Por otro lado, esta forma de operar es poco flexible, debido a que el usuario de estos artefactos debe estar bien formado para hacer un uso correcto de ellos, así como de tener que seguir un patrón fijo de escaneado (forma de realizar la adquisición de las imágenes) previamente diseñado y asegurarse de que la escena no sufra movimientos incontrolados.

El problema de RI se puede abordar en primera instancia desde una perspectiva de resolución *lineal* haciendo uso de métodos directos, como el planteamiento de sistemas ecuaciones a partir de un conjunto de correspondencias entre primitivas de pares de imágenes. Las Figuras 1.7 y 1.8 muestran dos ejemplos de RI tratados desde esta perspectiva. En el primer ejemplo, las primitivas a emparejar se corresponden con «marcas» obtenidas con algún método de procesamiento de la imagen, en este caso, con un detector de bordes o esquinas. El segundo ejemplo corresponde a un escenario habitual en el procesamiento de imagen médica. Previo

⁵El proceso de calibración es la tarea encargada de determinar la geometría interna y las características ópticas del dispositivo de captación (parámetros intrínsecos), así como la orientación y posición 3D del dispositivo con respecto al sistema de coordenadas del mundo (parámetros extrínsecos) en el que está el objeto capturado.

anestesiado del paciente, se fija sobre su cráneo un *marco estereostático* (técnica invasiva) provisto de una serie de cánulas estratégicamente localizadas que contienen una sustancia que sirve para dejar una marca impresa en la imagen.




Figura 1.7: Detección automático de marcas (esquinas) en la imagen. Las marcas de color rojo son primitivas que cuentan con su homólogo en la otra imagen, en azul las que no disponen de tal correspondencia correcta

Los métodos directos sólo son válidos cuando el objeto escaneado/fotografiado sufre una transformación de tipo rígido o afín (Sección 1.2.2). De esta forma, aplicaciones en las que no se busca un registrado de este tipo, y/o se trata con imágenes con ruido y/o oclusión (lo que impide obtener conjuntos adecuados de primitivas) no es viable hacer uso de este tipo de métodos directos. En este caso, el RI se convierte en un problema de naturaleza *no lineal*⁶ cuya solución debe abordarse mediante *métodos iterativos de optimización*.

El RI está presente en multitud de aplicaciones de muy diversa naturaleza, lo que hace imposible proporcionar un método de RI universal. Aun así, generalmente se define un marco común de trabajo en el que un sistema de RI se constituye de un conjunto de componentes implicados en un proceso iterativo de optimización:

⁶ En ocasiones, los términos «lineal» y «no lineal» son empleados de forma poco acertada cuando se quiere dar a entender que un cálculo es «fácil» y «duro», respectivamente. Aunque este uso es inapropiado, existe cierta relación con algunos problemas que pueden ser reducidos a un conjunto de ecuaciones lineales, *métodos directos*, cuya solución es más sencilla que aquellos en las que no es posible dicha reducción.




Figura 1.8: De izquierda a derecha y de arriba abajo: fijación de un marco estereotáxico sobre el cráneo del paciente y localización del mismo sobre la plataforma del escáner. En la siguiente fila, dos imágenes CT y MRI en las que se muestran las marcas dejadas por dicho marco

- Dos imágenes, denominadas *escena* (o imagen móvil), $I_e = \{\vec{p}_1, \vec{p}_2, \dots, \vec{p}_{Ne}\}$, y *modelo* (o imagen fija), $I_m = \{\vec{q}_1, \vec{q}_2, \dots, \vec{q}_{Nm}\}$, donde \vec{p}_i y \vec{q}_j son primitivas de la imagen escena y de la imagen modelo, ambas en sus respectivos sistemas de referencia.
- Una *transformación de registrado*, f , o función paramétrica

$$f: \mathbb{R}^n \longrightarrow \mathbb{R}^n \quad (1.1)$$

que relaciona las nuevas coordenadas (coordenadas transformadas) de I_e , $f(I_e)$, con las de I_m . La elección del tipo de transformación dependerá de factores tales como la naturaleza de los objetos/sujetos escaneados y los sistemas de adquisición empleados [Zitová, 03].

- Una *métrica de similitud*, F , que mide el grado de solapamiento entre las imágenes, según

$$F(I_e, I_m; f) = |f(I_e) - I_m| \quad (1.2)$$

- Una *estrategia de búsqueda* (u optimizador) cuya misión es la de encontrar aquella solución f^* que optimice F

$$f^* = \arg \min/\max_f F(I_e, I_m; f) \quad t.q. \quad f^*(I_e) = I_m \quad (1.3)$$

En la práctica, en pocas ocasiones se cumple la expresión $f^*(I_e) = I_m$, ya que las imágenes suelen estar corrompidas por ruido y demás afecciones producidas por el error introducido por el sistema de medición del dispositivo.

Independientemente del diseño particular que se haya realizado para cierto método de RI, la solución o resultado final de éste será una transformación de registrado f^* cuyos valores de parámetros minimicen (o maximicen) la expresión 1.3. La Figura 1.9 describe el esquema general de un sistema de RI.

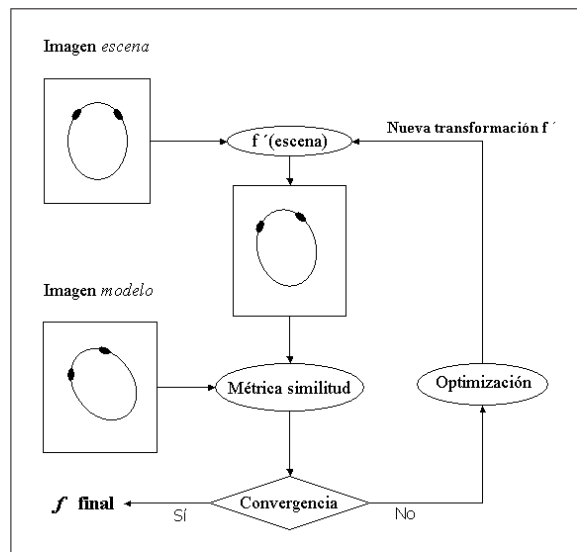


Figura 1.9: Esquema general de un sistema de RI

Desde hace décadas, se viene invirtiendo gran esfuerzo en proporcionar métodos de RI completamente automáticos. Además, hay un interés creciente en la

propuesta de enfoques que hagan uso de esquemas de optimización. Como ejemplo, el proyecto «*Retrospective Image Registration Evaluation (RIRE)*» con el Dr. Fitzpatrick de la Universidad de Vanderbilt (Tennessee, EEUU) como investigador principal, ha servido para comparar un gran número de métodos de RI multimodal (Sección 1.2.1) [West, 96]. La forma de evaluar estos métodos se basa en comparar el resultado proporcionado por ellos frente a la solución correcta conocida a priori (*ground-truth*). El RI correcto se calcula previamente a partir de imágenes en las que se han insertado una serie de marcas artificiales (por ejemplo, con marcos estereostáticos), las cuales se eliminan antes de dejar disponibles las imágenes para ser usadas por los investigadores en sus nuevas propuestas de RI. Las conclusiones de este proyecto indican que la gran mayoría de métodos propuestos proporcionan resultados satisfactorios la mayor parte de las veces. Sin embargo, para evitar aceptar posibles *falsos positivos*⁷, los resultados obtenidos deben ser validados por el usuario mediante inspección visual.

A día de hoy no existe un método de RI capaz de operar de forma eficaz, eficiente y completamente automática en cualquier aplicación. En los trabajos [Brown, 92, Zitová, 03] se encuentra una extensa revisión en cuanto a métodos de RI se refiere, clasificados atendiendo al diseño particular de cada uno de los componentes que constituyen un método de RI. Otros autores [Van den Elsen, 93] consideran un criterio adicional de clasificación de estos métodos, según se trate de sistemas:

- *Interactivos*: el usuario trata de superponer el par de imágenes probando, de forma reiterada, múltiples valores de parámetros de f . En general, esta es una aproximación considerada en aplicaciones donde la dimensionalidad de f es reducida (ocho a lo sumo) y donde el usuario tiene una idea aproximada a priori del resultado que se obtiene después de aplicarse. Además, dentro de esta categoría se encuentran aquellas herramientas que permiten seleccionar puntos característicos en ambas imágenes y hacerlos corresponder para que, en la mayoría de los casos, un método directo se encargue de estimar f . De forma similar, es necesario realizar este proceso tantas veces como sea necesario para conseguir unos resultados aceptables. En este caso, tres correspondencias serían suficientes para superponer dos imágenes, sin embargo, para conseguir resultados aceptables hay que considerar un número mayor,

⁷Un diseño acertado de métrica de similitud debería asegurar la correlación entre el valor de F y el grado solapamiento entre las imágenes. En RI, se considera falso positivo a aquellas soluciones (transformación) donde un mínimo/máximo de F no se corresponde con un caso correcto de solapamiento, por ejemplo, el hecho de no controlar de forma adecuada el escalado de la imagen puede originar situaciones de este tipo.

lo que supone un aumento en la complejidad de la tarea que debe realizar el usuario.

- *Semiautomáticos*: este enfoque reduce en gran medida el grado de interacción software-usuario. Por ejemplo, ciertos métodos necesitan de una etapa de procesamiento de imágenes previa al RI en la que se generan dos imágenes de características diferentes a las imágenes originales. A continuación, el método de RI se encarga, de forma automática, de superponer el par de imágenes generadas en el paso anterior. En general, este tipo de métodos de procesamiento previo de la imagen requieren de la experiencia del usuario, además de convertirse en una tarea laboriosa en la mayoría de los casos.
- *Automáticos*: estos sistemas trabajan directamente con las imágenes originales. Inicialmente, el usuario debe seleccionar el par de imágenes y fijar ciertos parámetros, después, el propio sistema realizará el registrado de las imágenes. Esta aproximación al problema de RI es de gran interés en la comunidad por prescindir de etapas previas de procesamiento de la imagen.

A continuación pasamos a describir los componentes de un sistema de RI.

1.2.1. Imagen

En primer lugar, los métodos de RI pueden clasificarse según el tipo de escena u objeto escaneado/fotografiado. Las imágenes pueden provenir de un único o diferentes (pero similares) objetos/sujetos, tratándose de métodos de RI *intrasujeto* o *intersujeto*, respectivamente.

Por otro lado, la dimensionalidad se considera un criterio alternativo de clasificación [Maintz, 96, Maintz, 98], dando lugar a las siguientes posibles configuraciones de registrado:

- 2D/2D
- 2D/3D
- 3D/2D
- 3D/3D

Atendiendo al modo de adquisición de las imágenes, los métodos de RI pueden clasificarse según hayan sido obtenidas por el mismo, o diferentes dispositivos, RI

monomodal o *multimodal* respectivamente [Maintz, 96, Viola, 97, Maintz, 98]. La Figura 1.8 muestra un ejemplo de RI multimodal.

Por último, la naturaleza de las imágenes permite establecer una clasificación de los métodos de RI en función del tipo de información considerada:

- *Métodos extrínsecos*: en ellos, se introducen objetos marcadores al margen de los que aparecen en la propia imagen. Estos objetos artificiales están diseñados para ser detectados fácilmente y de forma precisa. Precisamente, para no mermar tal precisión, los marcadores deben ser ubicados en zonas representativas del objeto de estudio, de ahí el carácter *invasivo* de este tipo de métodos. Ejemplos de aplicación haciendo uso de estas marcas son el comentado anteriormente empleando marcos estereostáticos (Figura 1.8) o la reconstrucción digital de edificaciones históricas [Akca, 03]. En este caso, se habla de un RI *prospectivo*.
- *Métodos intrínsecos*: en los que se emplea exclusivamente el contenido de las imágenes. A diferencia del anterior, esta forma de operar se conoce como RI *retrospectivo*. A pesar de ser una alternativa menos eficaz, cuenta con la ventaja de ser menos dependiente de la intervención manual e invasiva de usuarios altamente cualificados. Este enfoque es el origen de una línea de investigación que cuenta con un gran número de contribuciones [West, 96], siendo en la que se centra la presente memoria.

A su vez, los métodos de RI intrínsecos pueden subclasificarse en las dos siguientes categorías, comúnmente tratadas en la literatura de RI [Zitová, 03]:

- basados en *intensidades*
- basados en *características*

Los primeros operan directamente con la imagen original (tratando con las primitivas elementales como el píxel o vóxel). En los segundos se trabaja con un conjunto reducido de *características* relevantes en las imágenes, y extraídas previo al RI por un método de procesamiento de la imagen (por ejemplo, los métodos de *segmentación* de imágenes o los métodos de detección de contornos).

A pesar de que los métodos de RI basados en intensidades consiguen resultados más precisos por tratar con la totalidad de la imagen, su rendimiento empeora cuando se dan inconvenientes como los cambios en la iluminación y ciertas condiciones radiométricas en la escena. Además, si las imágenes son deformadas por transformaciones complejas (modelos no lineales de transformación, ver Sección 1.2.2),

la *ventana rectangular*, destinada a establecer correspondencias entre imágenes, no cubrirá las mismas zonas en ambas imágenes. Por otro lado, en los casos en los que la ventana se encuentre sobre regiones de imagen con valor de intensidad uniforme (valor suavizado de nivel de grises), es decir, carente de rasgos visuales relevantes, se establecerán correspondencias incorrectas entre regiones similares de ambas imágenes con una mayor probabilidad.

Con la intención de tratar los problemas planteados en el enfoque anterior, los métodos basados en características se centran en hacer uso únicamente de aquellas características o rasgos relevantes en la imagen.

Un detector de características que se precie de ser fiable, debe permitir comparar, de forma apropiada, conjuntos de características según cierto criterio de invarianza y precisión, es decir, debe ser robusto ante cambios en la geometría de las imágenes, condiciones radiométricas, cambios de intensidad lumínica y ruido [Zitová, 03]. La Figura 1.10 muestra un ejemplo de detección robusta de primitivas en imágenes desenfocadas y con ruido.

Existe una amplia variedad de características que pueden extraerse de la imagen:




Figura 1.10: Detector robusto de características para imágenes 2D con y sin ruido

- *Regiones* [Flusser, 94], por ejemplo, las imágenes de satélite albergan em-

balses de agua, lagos o urbes. Las regiones se representan a menudo a través de sus centros de gravedad.

- *Líneas*, representando segmentos en general o contornos de objetos [Maintz, 96, Maintz, 98], por ejemplo, estructuras anatómicas en aplicaciones de imagen médica. La correspondencia entre segmentos de línea se expresa normalmente mediante pares de terminaciones de línea o usando puntos intermedios.
- *Puntos*, principalmente para aquellos métodos que manejan intersecciones de líneas, detección de discontinuidades locales en cuanto a curvatura [Manjunath, 96] y esquinas [Rohr, 01].

Se debe destacar el amplio uso de los detectores de esquinas como puntos característicos en imágenes [Olague, 05], debido principalmente a su naturaleza invariante en cuanto a la geometría y al hecho de que son bien percibidos por un observador humano. En el trabajo de tesis doctoral del Dr. Damas [Damas, 03] se realiza una revisión detallada de los principales métodos de detección de características. Es de especial interés el uso de detectores 3D, en concreto, el Dr. Damas emplea un método de este tipo para extraer un conjunto de características denominadas *líneas de cresta* en imágenes médicas (MRI, CT, etc.). Recientemente se ha publicado una variante del método anterior ([Monga, 92, Thirion, 96]) para imágenes 3D de mallas de triángulos [Yoshizawa, 05].

Por último, es habitual encontrar métodos de RI que llevan a cabo la sinergia de ambos enfoques (intensidades y características). En una primera etapa, el método realiza un registrado basado en características, cuyo resultado se refina mediante una etapa final basada en intensidades [Chalermwat, 99].

1.2.2. Transformación de registrado

Los algoritmos de registrado también pueden clasificarse de acuerdo al modelo de transformación (o mapeado) $f \in \mathbb{R}^n$ considerado. La primera categoría incluye a las transformaciones de tipo *lineal* como el resultado, en la mayoría de los casos, de la combiación de una rotación, una traslación y un escalado (uniforme o no uniforme). Las transformaciones afines también estarían dentro de esta categoría. Por otro lado, las *no rígidas* o *elásticas* corresponden a la segunda categoría de transformaciones [Goshtasby, 03]. Mientras las primeras operan de forma global sobre la imagen, las segundas son capaces de modelar deformaciones locales, es decir, permiten transformar regiones concretas de la imagen.

Es una práctica común llevar a cabo un RI *multinivel*. En aplicaciones médicas, es habitual, en primera instancia, realizar un registrado rígido (rotación y traslación) de la cabeza del paciente al completo (estructura ósea, tejidos blandos, etc.), y posteriormente realizar un segundo RI no rígido para aquellas estructuras que sufren un tipo de deformación de mayor complejidad a la primera, el cerebro por ejemplo.

A continuación pasamos a describir algunos modelos de transformación lineal por ser de gran interés en capítulos posteriores de esta memoria. Las transformaciones del grupo lineal general vienen dadas por las siguientes ecuaciones:

$$\mathbf{X} = \mathcal{A} \cdot \mathbf{Y} + \mathbf{Z}$$

donde \mathbf{X} , \mathbf{Y} y \mathbf{Z} representan vectores n -dimensionales y \mathcal{A} una matriz $n \times n$.

Las matrices \mathcal{A} del grupo lineal general pueden escribirse como producto de matrices con la condición de que cada una de ellas represente una transformación pura de rotación, simetría o deformación de escala en cada eje.

En el caso 2D y 3D, subgrupos de interés son:

- *Rotaciones:* $\mathbf{X} = \mathcal{A} \cdot \mathbf{Y}$ con $\det|\mathcal{A}| = 1$ y $A = A^T$. Preserva escala, ángulos y orientación. La forma de la matriz \mathcal{A} (matriz de giro o rotación) en el caso 2D para un ángulo de rotación ϕ es:

$$\begin{pmatrix} \cos \phi & -\sin \phi \\ \sin \phi & \cos \phi \end{pmatrix} \quad (1.4)$$

Mientras que en el caso 3D, viene dada por:

$$\begin{pmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{pmatrix} \quad (1.5)$$

donde r_{ij} se define como:

$$r_{il} = r_{ij}^{(1)} r_{jk}^{(2)} r_{kl}^{(3)},$$

$$r^{(1)} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \alpha & -\sin \alpha \\ 0 & \sin \alpha & \cos \alpha \end{pmatrix},$$

$$r^{(2)} = \begin{pmatrix} \cos\beta & 0 & \sin\beta \\ 0 & 1 & 0 \\ -\sin\beta & 0 & \cos\beta \end{pmatrix},$$

$$r^{(3)} = \begin{pmatrix} \cos\gamma & -\sin\gamma & 0 \\ \sin\gamma & \cos\gamma & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

siendo (α, β, γ) los ángulos de rotación según los ejes de coordenadas (X, Y, Z) respectivamente.⁸

- *Isometrías o transformaciones rígidas:* $\mathbf{X} = \mathcal{A} \cdot \mathbf{Y} + \mathbf{Z}$ con \mathcal{A} de la forma que se indica en la Ecuación 1.4 o 1.5 (en función de si trabajamos en dos o en tres dimensiones, respectivamente) y \mathbf{Z} un vector que recoge los parámetros de la traslación: $\mathbf{Z} = (t_1, t_2)$ en el caso 2D y $\mathbf{Z} = (t_1, t_2, t_3)$ en el caso 3D.
- *Similitudes:* $\mathbf{X} = \mathcal{A} \cdot \mathbf{Y} + \mathbf{Z}$ con \mathcal{A} de la forma que se indica más abajo. Este grupo preserva todas las razones entre distancias y por tanto los ángulos. Si el cambio que se produce en la dimensión de los segmentos es el mismo en todas direcciones, estaremos ante una similitud *uniforme* de parámetro s (conocido como *factor de escala*, o simplemente, *escala* o *escalado*), cuya matriz para el caso 2D viene dada por:

$$\begin{pmatrix} s * \cos\phi & -\sin\phi \\ \sin\phi & s * \cos\phi \end{pmatrix}$$

mientras que si el cambio en la dimensión de los segmentos difiere según el eje, nos encontraremos ante una similitud *no uniforme* de parámetros (s_1, s_2) :

$$\begin{pmatrix} s_1 * \cos\phi & -\sin\phi \\ \sin\phi & s_2 * \cos\phi \end{pmatrix}$$

- *Cizalla:* en este caso se mantendrá invariante el paralelismo, esto es: dos líneas paralelas antes de la cizalla lo seguirán siendo tras aplicarla. Esta matriz sufre una deformación que equivale a la que presenta una figura elástica por una fuerza paralela a su base, pero con la base fija.

⁸Existen diversas formas de representar una rotación tridimensional: tres ángulos de Euler, matrices de rotación, cuaternión, eje+ángulo, etc.

$$\begin{pmatrix} 1 & \tan\theta \\ 0 & 1 \end{pmatrix}$$

Para una visión global de las diferentes transformaciones introducidas hasta el momento, en la Figura 1.11 mostramos un cuadrado y diversas transformaciones bidimensionales ejercidas sobre el mismo: rotación, similitud uniforme, similitud no uniforme y cizalla.




Figura 1.11: Transformaciones 2D (de izquierda a derecha): objeto original; transformación rígida; similitud uniforme; similitud no uniforme y cizalla

- *Transformación de perspectiva:* esta transformación aplica escenas 3D en escenas 2D. Tiene como objeto estudiar la distorsión que ocurre cuando se proyecta una escena 3D a través de un sistema óptico ideal. Además, este tipo de transformación se caracteriza por hacer aparecer más pequeño lo más lejano a la cámara. Si se conocen las coordenadas de los objetos en la escena, digamos (x_0, y_0, z_0) , entonces los correspondientes puntos en la imagen (x_i, y_i) están dados por:

$$x_i = \frac{-fx_0}{z_0 - f}, \quad y_i = \frac{-fy_0}{z_0 - f} \quad (1.6)$$

siendo f el centro de las lentes del sistema óptico. Cuando el sistema está enfocado para objetos lejanos, f es la distancia focal de las lentes. En la Figura 1.12 podemos apreciar como en la transformación de perspectiva (a la derecha) los objetos más lejanos a la cámara (en este caso una de las caras del cubo) aparecen más pequeños.




Figura 1.12: Cubo y transformación de perspectiva del mismo

- *Transformación proyectiva*: en el caso especial de que la escena esté compuesta de un objeto plano inclinado frente al plano imagen, se necesita una transformación proyectiva para aplicar el plano de la escena en el plano de la imagen a una escala dada. Las ecuaciones de una transformación proyectiva son:

$$x_i = \frac{a_{11}x_p + a_{12}y_p + a_{13}}{a_{31}x_p + a_{32}y_p + a_{33}} \quad (1.7)$$

$$y_i = \frac{a_{21}x_p + a_{22}y_p + a_{23}}{a_{31}x_p + a_{32}y_p + a_{33}} \quad (1.8)$$

siendo las a_i constantes que dependen de las ecuaciones de la escena y del plano imagen. En la Figura 1.13 observamos cómo un movimiento rígido del plano imagen que no altere el centro óptico induce una transformación proyectiva.

1.2.3. Métrica de similitud

Una de las componentes más importantes de cualquier método de RI es la métrica de similitud, F . Esta componente se encuentra íntimamente relacionada con la naturaleza de la imagen considerada. La misión de esta métrica es valorar cómo de solapadas se encuentran las imágenes o, en otro sentido, la expresión 1.2 indica «cómo» de diferentes son las imágenes modelo y escena para cierta transformación f . En el caso de instancias de RI con imágenes escena y modelo autocontenidas (es




Figura 1.13: Cualquier movimiento rígido del plano imagen (en este caso de π_1 a π_2) que mantenga fijo el centro óptico O induce una transformación proyectiva entre los planos π_1 y π_2

decir, que sólo se diferencian en cuanto a la posición que ocupan en el espacio), se cumple que $F(I_e, I_m; f^*) = 0$, siendo f^* la solución óptima.

Los métodos de RI pueden clasificarse también en función del tipo de métrica de similitud considerada o, más concretamente, en función del tipo particular de primitiva de imagen considerada para calcular el valor de similitud:

- Atributos de la imagen: tratan principalmente con primitivas elementales haciendo uso del valor de nivel de grises de la imagen. Como ejemplo tenemos los basados en la *suma del cuadrado de las diferencias* [Barnea, 72], en la *correlación cruzada de coeficientes* [Svedlow, 76] o de *fase* [De Castro, 87]), y en la *información mutua* [Viola, 97], entre otros.
- Geometría de la imagen: en este caso, las coordenadas de las primitivas son la fuente principal para evaluar la métrica [Allen, 03, Audette, 00, Chao, 05, Muratore, 02].

Los métodos de RI que hacen uso del segundo tipo de métricas también se conocen como *métodos basados en la superficie*, siendo uno de los primeros enfoques de RI desarrollados para aplicaciones médicas [West, 99]. La forma de proceder de dichos métodos consiste en generar la superficie de la región de interés (mediante la segmentación y la generación de la isosuperficie) a partir de la

cual realizar el RI. Desde hace una década, los enfoques que consideran métricas basadas en los atributos de la imagen cuentan con una mayor difusión en la comunidad, debido principalmente a que este tipo de métodos no llevan a cabo tareas previas de procesamiento de la imagen [Viola, 97]. Sin embargo, este tipo de métricas precisan de *operadores de interpolación* de la imagen para solucionar el problema que ocasiona la aplicación de f sobre la imagen escena y transformar coordenadas discretas de primitiva en coordenadas del espacio continuo (ver ecuación 1.1) [Pluim, 00]. Otra limitación a tener en cuenta es que en ellas no se hace uso de información de la geometría del objeto.

Por otro lado, a pesar de la mayor profusión de estas últimas, aún se siguen proponiendo nuevos métodos basados en la segunda categoría de métricas con resultados competitivos [Cao, 03, Stewart, 03], siendo también ampliamente consideradas en otras aplicaciones como la reconstrucción 3D de modelos digitales de objetos reales [Bernardini, 02].

El coste computacional de la métrica de similitud puede ser elevado en aplicaciones donde el volumen de información de las imágenes es considerable, como por ejemplo en imagen médica. En particular, el término de mayor coste en la evaluación de F corresponde al cálculo de correspondencias de primitivas entre imágenes. De este modo, los métodos de RI suelen hacer uso de *estructuras de indexación* con el fin de mejorar la eficiencia de dicho cálculo. Esta estructura se construye al comienzo del método de RI y se consulta (en tiempo constante o logarítmico, por ejemplo) cada vez que sea necesario evaluar una solución. A continuación se repasan algunas de las estructuras más empleadas en la literatura especializada de RI:

- **Kd-tree:** en [Zhang, 94] se propone por primera vez el uso de esta clase de estructura para un problema de RI. La estructura en árbol construida es una generalización de un método de bisección en una dimensión para k dimensiones. Para imágenes 3D ($k = 3$), dicho árbol se construye realizando sucesivos cortes del espacio en dos paralelepípedos rectangulares (generalizados) de tal forma que haya un número de primitivas aproximadamente igual en cada lado del plano de corte. De esta forma, el proceso de corte continúa con los dos hijos (derecho e izquierdo), pero ahora la orientación del plano de corte se cambia (*plano* – xy , *plano* – xz , *plano* – yz , y así sucesivamente). El proceso de división finaliza cuando se consigue un paralelepípedo rectangular con sólo una primitiva, que corresponde con un nodo hoja en el árbol. Una estructura *kd-tree* puede construirse en un tiempo $O(N \cdot \log N)$ con $O(N)$ en cuanto a espacio de almacenamiento, siendo N el número de primitivas en la imagen. Desafortunadamente, en el peor de los casos es necesario

un tiempo de búsqueda en el árbol de $O(N^{2/3})$. El desarrollo de estos órdenes puede consultarse en [Preparata, 86] (pág. 77).

- **Mapa de distancias:** también denominadas como *grids espaciales*, ya que realizan una división rectangular del espacio de la imagen en un conjunto de celdas o vóxels de tamaño δ^2 o δ^3 según la dimensión de la imagen considerada (2D ó 3D). Para el caso de imágenes 3D, un mapa de distancias corresponde con un cubo que encierra la superficie de un objeto. Cada celda alberga un vector $\vec{p} \in \mathbb{R}^3$ con origen en el centro de la celda y destino la primitiva de la imagen modelo más cercana al centro de la celda. De esta forma, cada vez que sea necesario obtener el valor de distancia de cierta primitiva transformada de la imagen escena a la imagen modelo, bastará con acceder a la celda en la que «cae» dicha primitiva para recuperar el vector \vec{p} asociado, todo esto en un tiempo de búsqueda $O(1)$. En [Yamany, 99], se propone una estructura de este tipo para imágenes 3D, llamada *Grid Closest Point (GCP)*, con la diferencia de que, en este caso, se construye un primer volumen de tamaño $L \times W \times H$ que encierra ambas imágenes, escena y modelo (ver Figura 1.14). En dicha figura, $r_{C_j P'}$ corresponde al vector distancia con origen en la celda C_j y destino en la primitiva más cercana de la imagen modelo, P' . Adicionalmente, con la intención de reducir el error introducido por la discretización de este tipo de estructuras, se construye un segundo cubo con el doble de tamaño ($2L \times 2W \times 2H$) que alberga sólo a la imagen modelo. De esta forma, el uso de la estructura *GCP* permite llevar a cabo un registrado inicial de menor calidad y un proceso de refinamiento de éste en las últimas etapas del RI.

1.2.4. Estrategia de búsqueda

En las secciones anteriores hemos comentado las características que convierten el RI en un problema de naturaleza no lineal. De este modo, es claro el hecho de que su resolución se puede afrontar desde una perspectiva de búsqueda u optimización de la solución óptima, es decir, de la transformación de registrado que mejor registre las imágenes consideradas.

El problema de optimización de RI puede caracterizarse de la siguiente forma: Dada una función F que opera sobre cierto dominio discreto (finito) D de soluciones, también llamado *espacio de búsqueda*, encontrar una solución $x^* \in D$ que satisfaga la expresión

$$F(x^*) \leq F(x), \forall x \in D \quad (1.9)$$




Figura 1.14: GCP: imágenes escena (parte superior derecha) y modelo (parte inferior izquierda) encerradas en una doble estructura bidimensional de indexación. Para algunas celdas se muestra el vector de distancia asociado, $r_{C_j P'}$

siendo x^* la solución óptima u óptimo global. Generalmente, aunque no de forma necesaria, se considera que F es una función continua y derivable. Por ejemplo, si F se puede modelar con una simple función cuadrática, la posibilidad de calcular sus derivadas parciales, conocido como cálculo del *gradiente de la función*, resulta de gran ayuda en la decisión del siguiente paso (solución) en el proceso de optimización. En estos casos, el número de iteraciones necesarias para alcanzar la solución óptima es reducido.

En general, la estrategia de búsqueda debe enfrentarse con los siguientes escollos:

1. En cada evaluación de F se aplica una transformación de registrado sobre la imagen escena y se calculan correspondencias entre la escena transformada y el modelo. Al contar con imágenes con un gran volumen de información, el coste computacional de estas dos operaciones puede ser elevado en tiempo y espacio. Este coste se incrementa para los casos en los que se deben calcular las derivadas parciales de F , ya sean de primer o de segundo orden.
2. La complejidad del problema aumenta según sea el modelo de transforma-

ción considerado. Por ejemplo, mientras una transformación rígida 3D está constituida por seis parámetros, la dimensionalidad de una transformación afín es de doce, aumentando considerablemente el tamaño del espacio de búsqueda.

- Debido a las diferencias existentes entre la topología del espacio de búsqueda y el de la función objetivo, se genera un espacio fuertemente multidimensional con múltiples *óptimos locales* [He, 02, Chow, 04]. Este factor afecta de forma drástica en la convergencia de la estrategia de búsqueda. La Figura 1.15 muestra un ejemplo de lo comentado extraído de [He, 02], trabajo en el que se propone un método de RI empleando información mutua como métrica de similitud.

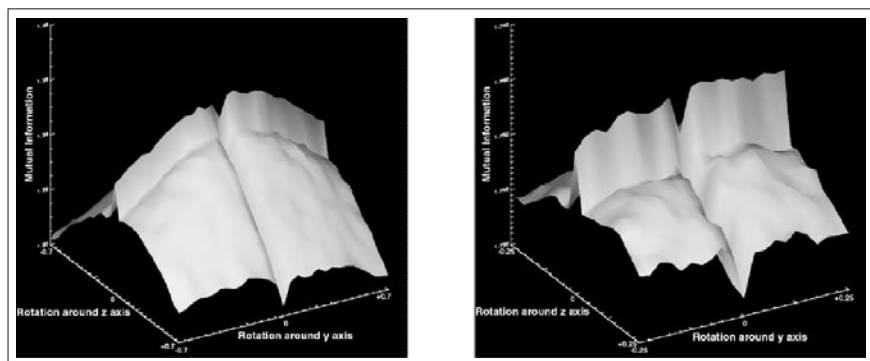


Figura 1.15: Gráficas que representan parte del espacio de búsqueda en un problema de RI. En ellas se consideran dos de los parámetros de una rotación 3D (rotación en el eje X e Y) y el valor de información mutua asociado

- El hecho de que en la gran mayoría de aplicaciones se trate con imágenes que presentan ruido y oclusión supone un serio inconveniente para aquellos métodos de RI que cuentan con funciones derivables, ya que en estos casos se suelen generar estimaciones erróneas de sus derivadas parciales, lo que desplaza la búsqueda a zonas poco prometedoras. Este inconveniente suele aliviarse suavizando la topología del espacio de búsqueda introduciendo algún término adicional en la descripción de F que modele la naturaleza particular de las imágenes consideradas (en el caso de ser posible), o bien aplicando filtros de mejora y realzado de las imágenes.

Analizando el listado anterior, el tercer ítem obliga en principio a llevar a

cabo una búsqueda exhaustiva de la solución óptima. A los métodos de optimización que implementan esta forma de operar se les conoce como algoritmos *exactos* [Brassard, 97, Levitin, 02]. Por otro lado, si consideramos los dos primeros escollos, es evidente que este tipo de técnicas son impracticables para dar solución al problema de RI de forma eficaz y eficiente al mismo tiempo. En definitiva, es necesario establecer una solución de compromiso entre aceptar un óptimo local y llevar a cabo una búsqueda exhaustiva.

En estos casos, con la intención de proporcionar soluciones próximas al óptimo en un tiempo admisible, se suele hacer uso de técnicas *heurísticas* de optimización, implementadas por los llamados algoritmos *aproximados* [Brassard, 97, Levitin, 02]. Dentro de los métodos aproximados básicos se suele distinguir entre los *constructivos* y los de *búsqueda local*. Los primeros generan soluciones partiendo de cero mediante la inclusión secuencial de componentes en una solución parcial inicialmente vacía hasta completar una solución factible al problema. Los métodos constructivos suelen ser más rápidos, aunque a menudo proporcionan soluciones de peor calidad respecto de las de los algoritmos de búsqueda local. Por contra, estos últimos parten de una solución ya construída y, de forma iterativa, aplican una serie de «modificaciones» de carácter local (de ahí su nombre) sobre dicha solución con el propósito de mejorarla progresivamente en base a un mejor valor de función objetivo. Este procedimiento heurístico se cataloga como «miope» en base a la escasa información que emplea para desarrollar su proceso de búsqueda, viéndose reducida su capacidad explorativa a medida que aumenta el tamaño del problema. El *ascenso de colinas* (denominado *hill climbing* en la literatura especializada) es un método heurístico que combina los anteriores enfoques aproximados. Estos métodos comienzan desde una solución y aplican una búsqueda local con la intención de encontrar una mejor solución. Si se encuentra una solución mejor, la búsqueda se mueve hasta dicha posición y se vuelve a aplicar la búsqueda local sobre ésta. El método termina cuando la búsqueda local no es capaz de encontrar una solución mejor a la actual. El principal inconveniente de estos métodos es que son incapaces de escapar de óptimos locales.

Durante años, el concepto de procedimiento heurístico (aún prevaleciente a día de hoy) fue idear una regla de ojeado ingeniosa o una regla iterativa que finalizara tan pronto no se encuentre una solución mejor a la actual. Dichas heurísticas iterativas se refieren a menudo a métodos descendentes, métodos ascendentes, o métodos de búsqueda local (hoy en día, la búsqueda local no se encuentra limitada a un concepto estrictamente local en ocasiones). Por consiguiente, el surgimiento de métodos apartados de estos diseños clásicos constituye un importante avance dentro del campo de la optimización. En los últimos años, ha surgido una nueva familia de algoritmos aproximados basada en la extensión de métodos heurísticos

básicos mediante su inclusión en un proceso iterativo que aumente sus capacidades exploratorias. A este grupo de algoritmos aproximados avanzados se le denomina *metaheurísticas* [Glover, 03a]. Como veremos más adelante, las metaheurísticas proporcionan una metodología de diseño flexible, entre otros motivos, debido a la no exigencia de usar una función diferenciable, hecho de especial importancia para el diseño de métodos de RI lo más generales posible.

Por otro lado, los métodos de RI pueden clasificarse según el espacio de búsqueda D sobre el que trabaje la estrategia de búsqueda considerada. En la literatura existen dos enfoques principales:

- *Búsqueda en el espacio de correspondencias*: el espacio de búsqueda está constituido por soluciones ($x \in D$) cuya representación está determinada por un conjunto de correspondencias de primitivas entre imágenes, cualquiera que sea el criterio considerado para establecer dichas correspondencias. Como se puede observar, en este caso una solución x no se corresponde directamente con lo que entendemos por solución al problema de RI, es decir, una transformación de registrado f , sino que los parámetros de la misma se derivan posteriormente a partir de las correspondencias codificadas en x mediante métodos numéricos, como la estimación por mínimos cuadrados.
- *Búsqueda en el espacio de los parámetros*: en este caso, una solución $x \in D$ está representada por un vector de parámetros, que coinciden con los parámetros de la transformación de registrado ($x = f$). Este enfoque permite aproximar soluciones de cualquier modelo de transformación paramétrica.

Por último, y con la intención de acelerar el RI, es una práctica habitual escalonar el proceso de búsqueda comenzando con imágenes de baja resolución y terminar con el grueso de éstas. A esta técnica se le conoce como *multiresolución* o *piramidal*, en la que se pasa de un RI «tosco» a un RI «fino» (en inglés, *coarse-to-fine*) [Chalermwat, 99, Maes, 99].

Las siguientes subsecciones describen los dos enfoques de RI mencionados e introducen algunas de las propuestas más destacadas para cada uno de ellos.

1.2.4.1. Búsqueda en el espacio de correspondencias

Esta estrategia de búsqueda, también conocida como *point matching*, tiene por objetivo, en primer lugar, obtener un conjunto de correspondencias (x) de primitivas entre ambas imágenes, entendiendo por correspondencia el emparejamiento directo entre dos primitivas, cada una de ellas perteneciente a cada ima-

gen. El paso siguiente consiste en calcular la transformación de registrado, f , implícita en el conjunto de correspondencias, haciendo uso de métodos numéricos (ver Figura 1.16), como los habituales estimadores por *mínimos cuadrados* [Arun, 87, Faugeras, 96, Horn, 87]. Este tipo de estimadores han sido ampliamente usados debido a sus interesantes y especiales propiedades, ya que sólo precisan de descriptores estadísticos tales como la media, la varianza y la covarianza para operar [Luenberger, 97]. A pesar de que estos métodos tienen la ventaja de poder realizar el cálculo de la transformación de registrado con al menos tres correspondencias, en la práctica, las imágenes se corrompen en el proceso de adquisición, por lo que para conseguir estimaciones más precisas, es necesario contar con un conjunto de observaciones más amplio [Horn, 87].




Figura 1.16: Solución al problema de RI desde el enfoque de la búsqueda de las correspondencias

En la teoría clásica de estimación, la noción de observación aberrante (outlier) es, en cierta medida, vaga. Estos valores muestrales —en nuestro caso, primitivas— pueden entenderse como observaciones erróneas (ruidosas), las cuales se encuentran bien diferencias del grueso de las observaciones. Por tanto, este tipo de primitivas deben tratarse con especial atención. Además, asumimos que dichas observaciones aberrantes no sólo no aportan ningún tipo de información de importancia en la estimación de f , sino que además alteran su correcta estimación. Este es el principal problema de los estimadores por mínimos cuadrados.

Se asume que, para que un estimador basado en mínimos cuadrados opere de forma correcta, las observaciones erróneas deben estar distribuidas de forma normal o ligéramente desviadas de dicha normalidad. En la literatura relacionada, podemos encontrar algunas propuestas de trabajos como extensiones mejoradas a estos métodos basadas en el análisis de los valores residuales de $L2$ norm (mínimos cuadrados) para identificar observaciones erróneas [El Hakim, 84, Förstner, 85]. Puesto que dichas observaciones presentan una distribución desconocida, esta clase de estimadores no pueden garantizar la inferencia de la transformación correcta,

por lo que será más apropiado la consideración de un estimador robusto. Concretamente, los *M-estimadores* [Huber, 81], bien conocidos en la literatura, son ampliamente utilizados por su robustez.

Todos los métodos anteriores trabajan desde el establecimiento explícito de correspondencias. Así, la fase de correspondencia se convierte en una etapa fundamental en la que, dependiendo de lo apropiado del criterio adoptado para construir los emparejamientos entre primitivas, el resultado obtenido por el estimador de la transformación se verá influenciado proporcionalmente con respecto a la calidad de las correspondencias establecidas. Cuanto mejor sea la correspondencia entre ambas imágenes, más próxima será la estimación de la transformación de registrado al valor óptimo.

Para problemas de RI que consideren imágenes con pocas primitivas a corresponder, un método de búsqueda exhaustiva puede dar con la solución al problema en un tiempo razonable. Sin embargo, son pocas las aplicaciones en las que estas condiciones de partida sean tan favorables. Normalmente nos encontramos con instancias de tamaño considerable en las que una búsqueda exhaustiva sería computacionalmente intratable, convirtiéndose así el RI en un problema considerado *NP duro*⁹.

A pesar del coste computacional necesario, este enfoque obtiene registros precisos si se cuenta con conjuntos adecuados de primitivas y mecanismos robustos para su correspondencia. En la literatura de RI, el método clásico por excelencia propuesto para el enfoque de correspondencias se conoce con el nombre de *Iterative Closest Point (ICP)* [Besl, 92], originalmente propuesto para el registrado de pares de imágenes de rango. A continuación, se hace una breve descripción del método:

- Se cuenta con: una imagen escena I_e formada por un conjunto de puntos 3D $\vec{p}_i \in I_e$ de tamaño N_e , y una imagen modelo I_m de tamaño N_m constituida por primitivas geométricas $\vec{q}_i \in I_m$, tales como puntos, líneas, triángulos, etc.
- Se considera una transformación rígida representada de la forma:

$$\vec{q} = [q_1, q_2, q_3, q_4, t_1, t_2, t_3]^t$$

donde los primeros cuatro parámetros corresponden con los cuatro componentes de un cuaternion [Horn, 87], que determinan una rotación 3D, y los tres últimos parámetros almacenan una traslación.

⁹Para una revisión de los conceptos de problemas \mathcal{P} , \mathcal{NP} , \mathcal{NP} -completos y \mathcal{NP} -duros nos remitimos a [Brassard, 97, Garey, 79].

El procedimiento de RI se inicia estableciendo $I_{e_0} = I_e$, la transformación inicial de registrado a $\vec{q}_0 = [1, 0, 0, 0, 0, 0, 0]^t$, y $k = 0$. Los cuatro pasos siguientes se aplican de forma reiterada hasta converger, según una función o métrica (F) basada en el *Error Cuadrático Medio (ECM)*, hasta un umbral de tolerancia $\tau > 0$:

1. Establecer correspondencias ($x_k \in D$) entre I_{e_k} e I_m , empleando como criterio de emparejamiento de pares de primitivas la regla del *vecino más cercano*
2. Calcular la transformación de registrado: $f_k = \varphi(x_k, I_e, I_m)$
3. Aplicar f_k sobre la imagen escena: $I_{e_{k+1}} = f_k(I_e)$
4. Terminar si el cambio en valor del ECM es inferior a τ . En otro caso, incrementar k y volver a 1

Se puede observar cómo el proceso de búsqueda de ICP no está guiado por F (ECM), sino por el criterio considerado para establecer las correspondencias. En particular, la propuesta original de ICP considera la regla del *vecino más cercano* como criterio para esta tarea (es decir, cada primitiva transformada de la imagen escena se asocia con la primitiva más cercana de la imagen modelo, de acuerdo a la distancia Euclídea). Luego queda claro el comportamiento local de este tipo de técnicas, además del hecho de que el resultado de la iteración $k + 1$ depende de lo obtenido en la iteración k . Por tanto, en este caso F sólo interviene como criterio de parada, considerando que el algoritmo ha convergido cuando la reducción del error (ECM) en dos iteraciones consecutivas es inferior a cierto umbral determinado por el usuario (τ), el cual puede ser de ayuda para graduar el grado de monotonía del proceso de búsqueda y tratar de evitar caer en óptimos locales.

Sin embargo, la propuesta original de ICP adolece de los siguientes inconvenientes importantes:

- Una de las dos imágenes (generalmente la imagen escena) debe estar contenida en la otra.
- Es necesario tener una idea del grado de desalineación entre las imágenes, o bien que éste no sea importante.
- No puede tratar con conjuntos de primitivas cuya dispersión no siga una distribución normal.

Desde su propuesta en 1992, han aparecido múltiples variantes de este método con la intención de dotarlo de una mayor robustez [Zhang, 94, Masuda, 95,

Feldmar, 96, Gold, 96, Luck, 00, Rusinkiewicz, 01, Sharp, 02, Liu, 04], así como de otras alternativas a este esquema clásico propuestas desde el campo de las meta-heurísticas [Brunnström, 96, Cordon, 06a].

1.2.4.2. Búsqueda en el espacio de parámetros de la transformación

A diferencia del anterior, este segundo enfoque implica realizar la búsqueda directamente en el espacio de parámetros de la transformación de registrado ($D \leftrightarrow f$). Por tanto, una solución $x \in D$ se representada mediante un vector de parámetros con la misma dimensión que el número de parámetros del modelo de transformación considerado.

De esta forma, la estrategia de búsqueda genera directamente vectores candidatos con valores dentro del dominio especificado para cada parámetro de f , es decir, posibles soluciones al problema de RI (ver Figura 1.17). Además, como segunda diferencia importante con los métodos basados en matching, el proceso de búsqueda sí está guiado por el valor de función F , considerando el problema de RI como un procedimiento de optimización de parámetros centrado en la búsqueda de los mejores valores de f que optimicen F .




Figura 1.17: Solución al problema de RI desde el enfoque de la búsqueda de los parámetros de la transformación de registrado

En la literatura de RI nos encontramos con dos categorías distintas de métodos que siguen este segundo enfoque:

- Métodos de estimación del gradiente de F : *Gradiente-conjugado*, *Levenberg-Marquardt*, *Quasi-Newton*, etc.
- Métodos no basados en la estimación del gradiente de F : *Powell*, *Simplex*, *Solis&Wets*, etc.

Sin embargos, ambas categorías de métodos de optimización proporcionan estrategias de búsqueda de tipo local. En [Maes, 99] se encuentra una completa comparativa de estas técnicas aplicadas al RI en medicina.

Resulta importante destacar el hecho de que el orden de magnitud establecido en el escalado de los parámetros de f es crucial para los métodos de RI que tratan con este enfoque de optimización. Cambios unitarios en los parámetros de f tienen una repercusión desigual en el cambio de orientación y desplazamiento de la imagen transformada. Por ejemplo, considerando un cambio de escala de un grado en la rotación y de un milímetro en la traslación de forma proporcional, los puntos más alejados del centro de rotación se verán más afectados por esta transformación que el resto. Esta diferencia de comportamiento se presenta como valles prolongados en el espacio de búsqueda de f , lo que afecta en gran medida a cualquiera de las dos categorías anteriores de estrategias de búsqueda [He, 02]. Al igual que para los métodos basados en matching, los métodos de RI que operan en este espacio de búsqueda encuentran serios problemas tratando con casos de problemas en los que la desalineación entre las imágenes es importante.

1.3. Metaheurísticas

En secciones anteriores se expusieron los diferentes escollos e inconvenientes a los que deben sobreponerse los métodos clásicos de RI. El comportamiento local de este tipo de métodos obliga a comenzar el proceso de búsqueda desde soluciones próximas al óptimo global (lo cual no siempre es posible). En caso contrario, la búsqueda tiene una alta probabilidad de quedar atrapada en óptimos locales.

Adoptar estrategias de búsqueda global que aumenten las capacidades explorativas se convierte en la mejor alternativa para dar solución a los inconvenientes anteriores. Sin embargo, este cambio de estrategia obligaría a realizar la exploración de la totalidad del espacio de búsqueda para encontrar la solución óptima en el caso de realizar una búsqueda exhaustiva y seguiría siendo intratable en la mayoría de los casos aunque se emplearan algoritmos exactos que seleccionaran las partes del espacio más prometedoras, como la *Programación Dinámica*, el *Backtracking* o el *Branch and Bound*, debido a la gran dimensión del espacio de búsqueda.

A modo de ejemplo, en imagen médica, la colocación cuidadosa del paciente puede reducir la posibilidad de encontrar un mal registrado en los rangos $+/- 10$ mm. y $+/- 10$ grados para la traslación y rotación, respectivamente. Para llevar a cabo una búsqueda exhaustiva dentro del espacio de búsqueda asociado con

una transformación rígida 3D (tres parámetros para la rotación y otros tres para la traslación), es necesario explorar 20^6 coordenadas, realizando la evaluación de F para cada una de ellas, cuando se trabaja con el enfoque de búsqueda en el espacio de parámetros. Por otro lado, si no es posible garantizar una colocación adecuada del paciente, hecho bastante habitual en entornos clínicos, la incertidumbre en cada parámetro de f puede ser del orden de dos o tres veces superior a la planteada en el anterior caso favorable, aumentando así el número de coordenadas a buscar en un factor de entre 2^6 y 3^6 , respectivamente. En particular, la evaluación de una métrica basada en la superficie del objeto (imágenes 3D) habitualmente debe: transformar (como poco) 500 puntos de la imagen escena; calcular para cada punto transformado su correspondiente más cercano en la imagen modelo; y calcular el cuadrado de las diferencias para cada correspondencia. Una implementación eficiente de la función objetivo puede suponer la ejecución de aproximadamente 50000 instrucciones en un tiempo aproximado de 100ms para cada evaluación de F . Por tanto, realizar una exploración exhaustiva mediante métodos exactos resultará impracticable si el tiempo de respuesta es un factor importante a satisfacer.

Ambos inconvenientes (óptimos locales y tiempo de convergencia) convierten al RI en un problema difícil de tratar dentro de los conocidos como \mathcal{NP} -duros, los cuales precisan de un tiempo exponencial en el caso peor. Por tanto, incluso para instancias del problema de tamaño reducido, los algoritmos exactos tardarían un tiempo que estaría muy por encima de lo admisible en aplicaciones prácticas.

Como hemos comentado anteriormente, en los últimos años, ha surgido una nueva familia de algoritmos aproximados basada en la extensión de métodos heurísticos básicos mediante su inclusión en un proceso iterativo que aumente sus capacidades exploratorias, cuya premisa es proporcionar soluciones aceptables (próximas al óptimo) para tiempos de convergencia razonables. A este grupo de algoritmos aproximados avanzados se le denomina *metaheurísticas* (término acuñado en 1986 por Fred Glover) [Glover, 03a].

En esta familia incluiríamos, entre otros, algoritmos como ¹⁰ la *Computación Evolutiva* (CE) [Bäck, 97] con su variante más conocida: los *Algoritmos Genéticos* (AG) [Holland, 75, Michalewicz, 96], la *Optimización basada en Colonias de Hormigas* (OCH) [Dorigo, 04], la *Búsqueda Local Reiterada* («*Iterated Local Search*») (ILS) [Lourenço, 03], el *Enfriamiento* (para algunos autores, Templado o Recocido) *Simulado* (ES) [Aarts, 89], la *Búsqueda Tabú* (BT) [Glover, 97], la *Búsqueda dispersa* («*Scatter Search*») (SS) [Laguna, 03] y los *Métodos Multi-Arranque* (MMA) [Martí, 03], los *Procedimientos de Búsqueda Adaptativa Aleato-*

¹⁰ Véase que en algunos casos hemos mantenido los acrónimos en inglés (ILS, SS, GRASP y VNS) por ser más habituales que los correspondientes en español.

riamente Voraces («*Greedy Randomized Adaptive Search Procedures*») (GRASP) [Feo, 95], la *Búsqueda de Vecindario Variable* («*Variable Neighbourhood Search*») (VNS) [Mladenović, 97], o los *Algoritmos de Estimación de Distribuciones* («*Estimation of Distribution Algorithms*») (EDAs) [Lozano, 06].

Hasta el momento, no hay una definición comúnmente aceptada para el término metaheurística. No obstante, podemos señalar las propiedades fundamentales que se recogen en las definiciones aportadas hasta el momento:

- Las metaheurísticas son estrategias que «guían» el proceso de búsqueda.
- El objetivo es explorar eficientemente el espacio de búsqueda para encontrar soluciones próximas al óptimo.
- Las técnicas que conforman los algoritmos metaheurísticos van desde la búsqueda local simple a procedimientos complejos de aprendizaje.
- Los algoritmos metaheurísticos son aproximados y no determinísticos.
- Incorporan mecanismos que tratan de evitar quedar atrapados en áreas concretas del espacio de búsqueda.
- Los conceptos básicos de las metaheurísticas permiten una descripción a nivel abstracto.
- Las metaheurísticas no son específicas de un problema concreto.
- Las metaheurísticas no exigen que la función objetivo sea derivable.
- Las metaheurísticas hacen uso de conocimiento específico del dominio del problema y/o de la experiencia (memoria) para sesgar la búsqueda.

En resumen, las metaheurísticas son conceptos de alto nivel para explorar espacios de búsqueda mediante diversas estrategias. Dichas estrategias deberían seleccionarse de forma que se equilibrara la explotación de la experiencia de búsqueda acumulada (conocida como *intensificación o explotación*) y la exploración del espacio de búsqueda (conocida como *diversificación o exploración*). Este equilibrio es necesario por dos razones: identificar rápidamente regiones del espacio de búsqueda con soluciones de buena calidad y no malgastar demasiado tiempo en regiones del espacio que ya han sido exploradas previamente o que no proporcionen soluciones de calidad.

La estructura de estas estrategias depende en gran medida de la filosofía de la metaheurística en cuestión. Algunas de estas filosofías pueden verse como extensiones «inteligentes» de los algoritmos de búsqueda local. El objetivo de este tipo de metaheurísticas es escapar de mínimos locales, explorar el espacio de búsqueda y desplazarse para encontrar un óptimo local mejor. Este es el caso, por ejemplo, de los MMA, la BT, la ILS, la VNS, el GRASP y el ES.

Otra filosofía diferente es la de algoritmos como la OCH, los EDAs y la CE, que incorporan un componente de aprendizaje en el sentido de que implícita o explícitamente tratan de aprender correlaciones entre variables de decisión para identificar áreas de alta calidad del espacio de búsqueda. Este tipo de metaheurísticas lleva a cabo, en cierto sentido, un muestreo sesgado del espacio de búsqueda. Así, en CE, esto se consigue mediante una recombinación de las soluciones, mientras que en la OCH y en los EDAs, mediante el muestreo del espacio de búsqueda en cada iteración de acuerdo a una distribución de probabilidad.

Hay diversas formas de clasificar los algoritmos metaheurísticos atendiendo a las características que seleccionemos para diferenciarlos entre sí. A continuación resumimos algunos de estos criterios de clasificación [Blum, 03]:

- **Inspirados vs. no inspirados en la naturaleza.** Quizás la forma más intuitiva de clasificar las metaheurísticas es preguntarse por el origen del algoritmo en cuestión. Hay algoritmos inspirados en procesos de la naturaleza (como los AGs o los algoritmos de OCH) y otros no inspirados en aquélla (como la BT o la ILS). No obstante, debemos indicar que no es el mejor criterio de clasificación por diversos motivos: por un lado, día a día proliferan los métodos híbridos que serían difíciles de encuadrar en alguna de estas categorías y, por otro, en ocasiones es complicado conocer el origen del algoritmo.
- **Basados en población vs. búsqueda en un único punto.** Otro criterio para la clasificación de las metaheurísticas es la forma en que llevan a cabo la búsqueda. La pregunta es: «¿en cada instante de tiempo, se centran en el estudio de una población o en un individuo en particular?» Los primeros se caracterizan por llevar a cabo procesos de búsqueda que describen la evolución de un conjunto de puntos dentro del espacio de búsqueda; mientras que los segundos describen una trayectoria concreta dentro del mencionado espacio.
- **Función objetivo dinámica vs. estática.** ¿Cómo podemos hacer uso de la función objetivo? Algunos algoritmos la mantienen inalterada en la representación del problema y durante la búsqueda. Otros, sin embargo, se inclinan por intentar escapar de mínimos locales modificando el formato de la

búsqueda. Así, mientras se busca, la función objetivo se altera al objeto de incorporar información recogida durante el proceso de búsqueda.

- **Una sola vs. varias estructuras de vecindario.** La mayoría de los algoritmos metaheurísticos trabajan con una sola estructura de vecindario. En otras palabras: la hipersuperficie de ajuste no cambia durante el desarrollo del algoritmo. No obstante, hay algunas metaheurísticas (como la VNS) que usan un conjunto de estructuras de vecindario que les proporciona la posibilidad de diversificar la búsqueda y enfrentarse al problema del salto entre diferentes hipersuperficies de ajuste.
- **Métodos con vs. sin memoria.** Un aspecto muy importante de las metaheurísticas es el uso que hacen de la historia de la búsqueda, es decir, el empleo o no de memoria. Los algoritmos sin memoria llevan a cabo un proceso de Markov [Taylor, 94], puesto que la información que precisan se limita al estado actual del proceso de búsqueda. Hay diferentes formas de usar la memoria. Habitualmente, se distingue entre memoria a corto o a largo plazo. La primera, suele controlar los movimientos dados, soluciones visitadas o, en general, decisiones tomadas recientemente. En cambio, la memoria a largo plazo suele manejar un conjunto de parámetros e índices que sintetizan la búsqueda realizada desde el comienzo de la ejecución del algoritmo. El uso de memoria se reconoce hoy en día como uno de los elementos cruciales que determina la potencia de una metaheurística. Un ejemplo de metaheurística que combina ambos modelos de memoria de una forma muy eficaz es la BT.

En los últimos años, estas técnicas heurísticas de optimización han tenido un gran calado entre los investigadores del campo de RI, como así se demuestra en las numerosas contribuciones que sobre este tema podemos encontrar (ver Figura 1.18), en especial aquéllas en las que se ha hecho uso de metaheurísticas con un esquema de búsqueda evolutivo [Fitzpatrick, 84, Mandava, 89, Brunnström, 96, Tsang, 97, Simunic, 98, Matsopoulos, 99, Yamany, 99, Chow, 01, He, 02, Guiliang, 03, Chow, 04, Wachowiak, 04, Silva, 05, Silva, 06, Lomonosov, 06]. Por otro lado, podemos encontrar un conjunto menos amplio de contribuciones que emplean esquemas basados en metaheurísticas no evolutivas [Luck, 00, Wachowiak, 01, Maglogiannis, 04]. Por último, debemos destacar el trabajo realizado por el Dr. Damas en su memoria de tesis doctoral [Damas, 03], punto de partida para el desarrollo de esta memoria, en la que se confirma el éxito de la aplicación de las metaheurísticas al problema de RI. En concreto, se propone un primer método RI en el que se hace uso de la metaheurística no

evolutiva ILS como esquema de búsqueda de correspondencias [Cordón, 06a] y una segunda propuesta en la que se hace uso del algoritmo evolutivo CHC para resolver el problema de RI desde el enfoque de la búsqueda de los parámetros de la transformación [Cordón, 06d].




Figura 1.18: Evolución de la aplicación de las metaheurísticas al RI en los últimos años. La información mostrada se ha obtenido a partir de la ecuación de búsqueda «*(evolut* OR random* OR stochastic* OR *heuristic* OR annealing OR genetic OR swarm OR tabu) AND image AND (registration OR alignment)*»

A continuación se describen los aspectos más representativos de la computación evolutiva y su sinergia con el procesamiento de imágenes.

1.3.1. Computación evolutiva y procesamiento de imágenes

Como hemos mencionado en la sección anterior, hay metaheurísticas que siguen otra filosofía distinta a lo que podemos considerar como extensiones «inteligentes» de los algoritmos clásicos de búsqueda local. En este sentido, la CE [Bäck, 97] trata de aprender implícita o explícitamente correlaciones entre variables de decisión para identificar áreas de calidad en el espacio de búsqueda. Más concretamente, la CE usa modelos computacionales de procesos evolutivos como

elementos centrales para el diseño e implementación de sistemas de resolución de problemas. Dentro de este marco general, se han propuesto una gran variedad de modelos evolutivos a los que se conoce como algoritmos evolutivos (AEs). A grandes rasgos, el modo de trabajo de este tipo de algoritmos se basa en mantener una población de soluciones al problema, aplicar cambios aleatorios sobre las mismas e incorporar un mecanismo de selección para determinar cuáles se mantendrán en generaciones sucesivas y cuáles se eliminarán de la lista de soluciones.

Los AGs son quizás los AEs más conocidos. Los AGs son algoritmos de búsqueda de propósito general que emplean principios inspirados en la genética de poblaciones naturales para evolucionar soluciones a problemas. Así, combinan la supervivencia del más apto entre cadenas binarias (esquema de representación original [Holland, 75]) con información inicial estructurada completamente al azar, que va cambiando. En cada generación se crea un nuevo conjunto de criaturas o individuos artificiales (población de cromosomas) usando bits o grupos de bits de las soluciones con más aptitud de la generación anterior según el valor de una función objetivo, o más concretamente, *función de fitness*. Cada combinación nueva que se forma se prueba como solución, es decir, se comprueba si su valor de fitness se ajusta mejor que el resto como solución al problema. Con respecto a la aleatoriedad, podemos decir que los AGs no siguen un camino completamente al azar, ya que explotan eficientemente la información histórica para especular sobre nuevos puntos de búsqueda. Los AGs se analizan en profundidad en diversos libros como [Goldberg, 89, Michalewicz, 96] habiéndose demostrado en la teoría y en la práctica que proporcionan una búsqueda robusta en espacios complejos, ofreciendo por tanto una aproximación válida a problemas que requieren búsquedas eficientes y eficaces.

La aplicabilidad general de los AEs permite utilizar la CE para solucionar problemas de forma eficaz y robusta en una gran cantidad de aplicaciones prácticas dentro del procesamiento de imágenes ([CEC, EuroGP, GECCO, PPSN]). De entre tales campos, la visión por computador y la comprensión de imágenes (VCCI) representan algunos de los más desafiantes por la complejidad de las tareas que se están resolviendo, centradas en diseñar computadoras con capacidades de comprensión similares a las del ser humano para permitirles percibir el entorno, comprender la información adquirida, identificar patrones, emprender acciones apropiadas y aprender de la experiencia para mejorar futuras actuaciones ([CVPR, EC-CV, ICCV, ICPR]).

En breve, aplicaciones reales de la VCCI incluirán sistemas automáticos de navegación en robots y vehículos, de inspección, de control de calidad, de vigilancia, por mencionar sólo unos pocos. Para conseguir estas tareas de alto nivel, deben

resolverse otros problemas de más bajo nivel, tales como la extracción de características, el modelado 3D y la clasificación de objetos. Estas tareas del mundo real requieren ser robustas y flexibles para optimizar su rendimiento en diversos escenarios presentes en cada aplicación. La VCCI está ganando importancia dentro del amplio número de campos de aplicación de los AEs, gracias a la capacidad de estos últimos para explorar dominios de búsqueda de gran dimensión de forma efectiva. Un beneficio importante de estudiar los AEs dentro del marco de trabajo computacional de la VCCI es madurar las capacidades del procesamiento de la información de sistemas artificiales basados en problemas desafiantes del mundo real.

Por tanto, el empleo de AEs en tareas de la VCCI del mundo real necesita del conocimiento relacionado con el dominio de la aplicación y con la abstracción del dominio del problema en términos de estructuras evolutivas por medio de la selección de representaciones apropiadas. Por tanto, un diseño útil y eficaz de un sistema evolutivo necesita responder a preguntas como qué pretende ser evolucionado (selección de una representación apropiada) y cuáles son los mecanismos por los cuales la evolución tiene lugar (selección de una función objetivo). La solución adaptada mediante AEs debe entonces compararse con aquellas técnicas empujadas en los sistemas de visión actuales para posiblemente sustituir estas últimas o diseñar un modelo híbrido entre ambas. Este enfoque de diseño de sistemas de visión parece ser aceptado como una técnica estandar en la investigación de la visión por computador.

1.3.2. El algoritmo evolutivo scatter search

Scatter Search (SS) es una variante de AE empleado en la resolución de un gran número de problemas de optimización. Sus principios fundamentales se propusieron a comienzos de la década de los setenta [Glover, 77], estando basados en estrategias de combinación de reglas de decisión, especialmente en problemas de secuenciación.

En [Glover, 98] se propone una versión más específica del método en la que se recogen y simplifican muchas de las ideas expuestas en trabajos anteriores, a partir de la cual numerosos investigadores comenzaron a aplicar la SS en la resolución de problemas de optimización, obteniendo resultados de gran calidad. Recientemente, Laguna y Martí sacaron a la luz el primer libro monográfico dedicado al método [Laguna, 03], asentando sus bases así como sus estrategias y extensiones más notables.

Del mismo modo que los AGs, la SS mantiene un conjunto de soluciones centrándose en la combinaciones de éstas. A diferencia de los primeros, la SS no se

fundamenta en operar de forma aleatoria sobre un conjunto relativamente grande de soluciones, sino más bien llevar a cabo elecciones *sistemáticas* y estratégicas sobre un conjunto relativamente pequeño (del orden de diez veces inferior), llamado *Conjunto de Referencia* (*Reference Set*), notado *RefSet*. Este conjunto mantiene las «buenas»¹¹ soluciones encontradas durante el proceso de búsqueda. Otro aspecto importante de la SS es su interés en aprovecharse de información particular del problema con la intención de proponer estrategias de búsqueda capaces de conseguir soluciones de mayor calidad en menor tiempo. A continuación se muestran las componentes o métodos que constituyen la SS:

Método de Generación de Soluciones Diversas. Genera un conjunto P de soluciones diversas de tamaño $Psize$ (aproximadamente $Psize = 100$ soluciones).

Método de Actualización del Conjunto de Referencia. A partir del anterior conjunto P , se construye el Conjunto de Referencia *RefSet* de tamaño b (aproximadamente $b = 10$ soluciones) atendiendo a criterios de calidad y diversidad de soluciones:

- *Creación.* *RefSet* se inicializa con las b_1 (por ejemplo, $b_1 = b/2$) mejores soluciones de P (según valor de la función objetivo). Las $b_2 = b - b_1$ soluciones restantes se extraen de P por el criterio de *máxima distancia* con las ya incluidas en *RefSet*. En tal caso, será necesario definir previamente una función de distancia (métrica de distancia) para el problema considerado.
- *Actualización.* Las soluciones fruto de las combinaciones pueden entrar en el *RefSet* y reemplazar a algunas de las existentes (en el caso de mejorarlas). De este modo, el *RefSet* mantiene un tamaño b constante e inmerso en un proceso evolutivo de mejora. En implementaciones sencillas suele adoptarse la actualización del *RefSet* únicamente por calidad, pudiéndose realizar también según un criterio adicional por diversidad.

Método de Generación de Subconjuntos. Este método considera diversos criterios basados en la calidad y diversidad de las soluciones para construir subconjuntos de dos ó más soluciones a partir de las actualmente contenidas en el *RefSet*.

¹¹Es importante destacar que el significado de «buena» no se restringe a la calidad de la solución, sino que también se considera la diversidad que ésta aporta al conjunto de referencia.

Método de Combinación. La SS se centra en combinar todas las soluciones de cada subconjunto construido por el método anterior. La solución o soluciones que se obtienen de esta combinación pueden introducirse inmediatamente en el *RefSet* (*actualización dinámica*) o ser almacenadas temporalmente en una lista hasta terminar de realizar todas las combinaciones para después ver qué soluciones de dicha lista entran en el *RefSet* (*actualización estática*).

Método de Mejora. En general, se trata de un método de búsqueda local de refinamiento de soluciones, empleado tanto en las soluciones de P como en las generadas por el método de combinación antes de ser consideradas candidatas potenciales a ser insertadas en el *RefSet*.

La Figura 1.19 muestra la forma de operar de la SS. En [Laguna, 03] se proponen diferentes alternativas de diseño y estrategias avanzadas al esquema básico descrito.

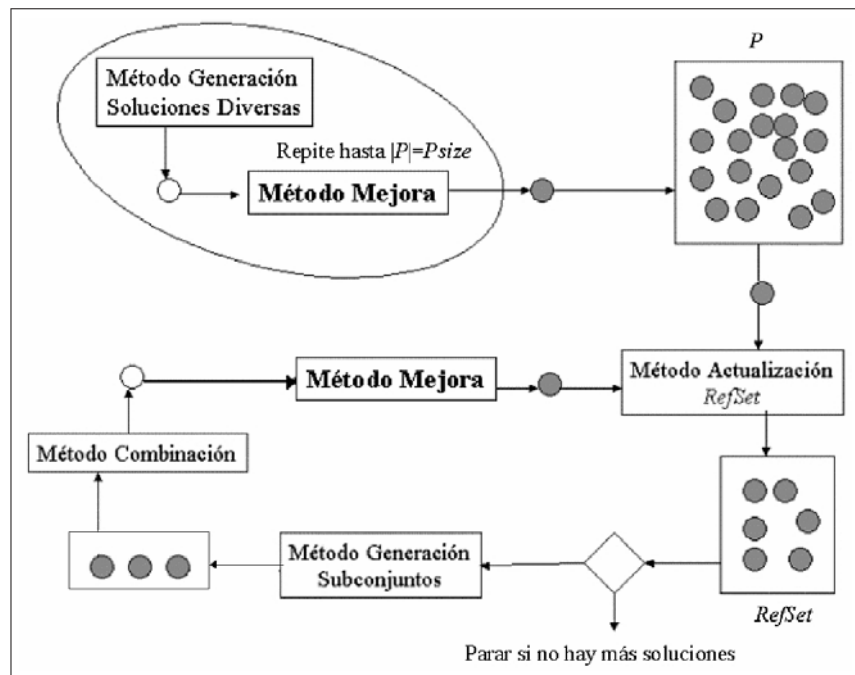


Figura 1.19: Esquema general de Scatter Search

Conclusiones

En este capítulo hemos introducido las bases teóricas del problema de RI y los elementos que constituyen el marco de trabajo de los métodos que tratan de abordar la resolución de este problema, así como de todo lo relacionado con esta materia que nos servirá para el desarrollo del resto de capítulos de esta memoria.

A continuación, en el siguiente capítulo abordaremos el problema de RI desde el enfoque de búsqueda de las correspondencias, en el que presentaremos el diseño de un nuevo método de RI basado en SS trabajando en este enfoque. Para validar el rendimiento de esta nueva propuesta diseñaremos una serie de instancias de RI de alta complejidad, comparando los resultados obtenidos con los de otros métodos de RI de la literatura especializada.

Capítulo 2

Registrado de imágenes en el espacio de correspondencias

2.1. Introducción

Como ya hemos comentado en el capítulo anterior, los métodos clásicos de RI son la alternativa más eficiente y eficaz cuando las condiciones del entorno de aplicación lo permiten. Sin embargo, la solución al problema de RI se convierte en una meta difícil de conseguir en gran medida debido a la confluencia de una serie de factores que limitan la aplicación de este tipo de métodos, que como sabemos hacen uso de técnicas de optimización esencialmente de naturaleza local.

En este capítulo pretendemos abordar el problema de RI desde el enfoque de búsqueda de correspondencias por ser uno de los más tratados en la literatura de RI debido a la amplia difusión que ha tenido en la comunidad el esquema de optimización del algoritmo ICP ([Besl, 92, Zhang, 94, Masuda, 95, Feldmar, 96, Gold, 96, Luck, 00, Rusinkiewicz, 01, Sharp, 02, Liu, 04]). Además, debemos señalar que para solucionar las limitaciones que posee el esquema de búsqueda anterior, en los últimos años se han propuesto una serie de métodos de RI que incorporan estrategias de búsqueda basadas en metaheurísticas [Brunnström, 96, Cordon, 06a].

En él describiremos nuestra propuesta de método de RI para la que hemos considerado el algoritmo evolutivo (AE) *Scatter Search* (SS) [Laguna, 03] tanto por haberse considerado con éxito en múltiples aplicaciones como por las interesantes características que proporciona a nivel de diseño, como por ejemplo la potenciación en el uso de información específica del problema (aspecto atractivo para enfoques de RI basados en características). Debido al éxito obtenido por la propuesta de RI basada en ILS [Damas, 03, Cordon, 06a], hemos decidido incluir algunos de sus elementos en nuestro diseño de SS: la representación de la solución, el enfoque basado en características (líneas de cresta en imágenes 3D) y la función objetivo. Para validarla, llevaremos a cabo una serie de experimentos considerando instan-

cias de RI de gran complejidad, empleando para ello un repertorio de imágenes médicas 3D obtenidas del repositorio público *BrainWeb*, muy utilizado en la literatura especializada.

Así, en la Sección 2.2 se introducen los aspectos más relevantes del proceso de optimización seguido por los métodos de RI de la literatura clásica y se describen algunas de las contribuciones más relevantes tratando esta perspectiva del problema RI. A continuación, en la Sección 2.3 se introduce el método de detección de características considerado para la extracción de información relevante en imágenes 3D. Después, la Sección 2.4 se dedica a presentar el diseño considerado para cada una de las componentes de SS abordando el problema de RI desde el enfoque de características. Por último, la Sección 2.5 se destina a presentar el diseño experimental considerado para la evaluación de nuestra propuesta de RI frente a otras de la literatura especializada. Finalmente, se incluye una sección de conclusiones del capítulo.

2.2. Antecedentes

El conocido método clásico de RI propuesto por Besl y McKay [Besl, 92], ICP, se basa en la búsqueda de las correspondencias que conduzcan a la obtención de la transformación de registrado que consiga solapar de forma óptima el par de imágenes considerado. Puede consultarse la Sección 1.2.4 para recordar la estructura algorítmica del método y la notación empleada.

Además de las limitaciones de las que adolece esta familia de métodos (ver Sección 1.2.4), debemos resaltar el problema de convergencia que presentan al enfrentarse con dichas limitaciones, el cual se debe al criterio considerado para establecer las correspondencias entre primitivas de la imagen: «Cada primitiva de la imagen escena $P_k = f_{k-1}(P_0)$ se hace corresponder con su homólogo más cercano (según distancia Euclídea) en la imagen modelo X ». Conviene recordar la notación P_0 y P_k . Mientras la primera corresponde a la imagen escena original (no transformada), la segunda (P_k) es el resultado de transformar dicha imagen con la transformación de registrado (f_{k-1}) estimada en la iteración anterior ($k-1$). A lo anterior hay que añadir el carácter monótono como estrategia de búsqueda local. Por tanto, se puede concluir que, para problemas donde el grado de desalineación entre las imágenes es importante y en los que no se tiene un conocimiento aproximado de la transformación de registrado óptima a priori, el criterio de correspondencia basado en la regla del *vecino más cercano* no asegura la convergencia correcta del método.

Son numerosas las contribuciones desde las que se han propuesto ex-

tensiones al método original con resultados satisfactorios aunque no definitivos [Zhang, 94, Masuda, 95, Feldmar, 96, Gold, 96, Luck, 00, Rusinkiewicz, 01, Sharp, 02, Liu, 04]. Además, desde el campo de las metaheurísticas se ha contribuido con otras tantas propuestas de RI [Brunnström, 96, Cordón, 06a]. A continuación, realizamos una breve descripción de algunas de estas propuestas.

2.2.1. Propuesta de Zhang

La propuesta fundamental del algoritmo [Zhang, 94] consiste en realizar un estudio de la distribución de las distancias para enfrentarse a puntos aberrantes, oclusiones, etc. A partir de la correspondencia establecida, nuevamente se usa una técnica de mínimos cuadrados para estimar los parámetros del movimiento rígido 3D.

Más concretamente, la actualización de las correspondencias que se propone realizar en cada paso consiste en emplear una técnica robusta de manera que se descarten algunos de los emparejamientos establecidos hasta el momento analizando las estadísticas de las distancias. La idea es que la distancia entre cada pareja de puntos establecida razonablemente no debería ser muy diferente (de no ser así ese emparejamiento podría no ser correcto). Para ello, en cada iteración se propone actualizar un parámetro de distancia máxima D_{max}^l permitida entre los emparejamientos en función de la distribución de distancias existente entre los puntos más cercanos en dicho ciclo del algoritmo, esto es, en función de su media y desviación típica (μ, σ) .

La nueva estructura del algoritmo ICP es:

1. Calcular la correspondencia implícita entre los puntos de la escena y el modelo aplicando la regla de asignación del punto más próximo: $Y_k = \mathcal{C}(P_k, X)$.
2. Obtener un subconjunto de emparejamientos $Y'_k \subseteq Y_k$ con aquellos puntos de Y_k que verifiquen una restricción de distancia máxima D_{max}^l con su correspondiente punto de X :

$$\forall y_k \in Y_k, y_k \in Y'_k \iff \exists x_{CP} \in X : d(y_k, x_{CP}) \leq D_{max}^l, \\ d(y_k, x_{CP}) \leq d(y_k, x_i), \forall x_i = \{1, \dots, N_x\}$$

siendo $d(x_i, x_j)$ la distancia Euclídea entre los puntos (x_i, x_j) .

3. Actualizar el valor del umbral de distancia máxima D_{max}^I analizando la distribución de distancias (μ, σ) en (Y'_k, X_k) .
4. Calcular la transformación de registrado por mínimos cuadrados: $f_k(P_0, Y'_k)$.
5. Aplicar la transformación estimada: $P_{k+1} = f_k(P_0)$.
6. Terminar la iteración si el cambio en el ECM es inferior al umbral τ fijado.

2.2.2. Propuesta de Gold y otros

El método denominado *Robust Point Matching* (RPM) fue propuesto por Gold y otros [Gold, 96] y posteriormente aplicado en diversos trabajos [Rangarajan, 97], [Rangarajan, 99]. Se parte de una serie de puntos característicos de cada una de las imágenes: $X_i, i = 1, 2, \dots, N_1$ e $Y_j, j = 1, 2, \dots, N_2$, donde N_1 y N_2 son el número de puntos de los conjuntos X e Y , respectivamente, y se intenta minimizar la siguiente función objetivo:

$$\min_{M, \theta, t, s} E(M, \theta, t, s) = \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} M_{ij} \|X_i - t - s \cdot R(\theta) Y_j\|^2$$

$$+ \frac{\gamma}{2} \cdot (\log s)^2 - \alpha \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} M_{ij}$$

$$\text{sueto a: } \begin{cases} \sum_{i=1}^{N_1+1} M_{ij} = 1, & \forall j \in \{1, \dots, N_2\} \\ \sum_{j=1}^{N_2+1} M_{ij} = 1, & \forall i \in \{1, \dots, N_1\} \\ M_{ij} \in \{0, 1\} \end{cases}$$

Se trata de un problema de optimización en el que los parámetros de la transformación (el ángulo de rotación θ , la traslación t y el parámetro de escala uniforme s) pueden obtenerse por minimización. Además, se formula un problema de optimización desde el punto de vista de las correspondencias entre los puntos (dada por la matriz de emparejamientos M_{ij}).

La principal dificultad del problema reside en abordar conjuntamente la resolución de los parámetros espaciales y de las correspondencias, teniendo en cuenta las naturalezas aparentemente dispares de ambos problemas (uno de optimización numérica en un espacio continuo, el otro de optimización combinatoria). Como

solución, los autores transforman el problema mixto en un problema de optimización no lineal, que resulta en un algoritmo en dos etapas que alterna entre la resolución de los parámetros y las correspondencias, según el pseudocódigo de la Figura 2.1.

Una de las aportaciones más interesantes de este método es la formulación del problema de registrado considerando tanto la puesta en correspondencia como la estimación de parámetros.

2.2.3. Propuesta de Luck y otros

El método presentado en [Luck, 00] propone una estrategia híbrida de RI propuesta por las siguiente dos etapas:

1. Se aplica un algoritmo basado en el esquema de ICP en el que se hace uso de una regla de rechazo de falsas correspondencias. Dicha regla se basa en el descarte de aquellos emparejamientos que superan un cierto umbral de distancia calculado al comienzo del algoritmo.
2. Un algoritmo de enfriamiento simulado [Aarts, 89] trata de optimizar la solución obtenida en la etapa anterior siguiendo el enfoque de RI de los parámetros de la transformación, estableciéndose además un espacio de búsqueda reducido para la aplicación de este algoritmo.

En la evaluación del método, los autores consideran un máximo de dos iteraciones de las dos etapas anteriores. Se puede observar cómo el diseño del método trata de solucionar el problema del estancamiento en óptimos locales ayudando al proceso de búsqueda local con la aplicación de una estrategia de escape bien conocida en el campo de las metaheurísticas.

2.2.4. Propuesta de Liu

En [Liu, 04], el autor mantiene el esquema algorítmico de ICP y centra su interés en la propuesta de un método con una regla de rechazo de falsas correspondencias en base a los criterios de *colinealidad* y *proximidad* entre las primitivas emparejadas. Esta regla se basa en la satisfacción de las dos restricciones siguientes:

- *Restricción de colinealidad*: para cada posible correspondencia $\{\vec{x}_i, \vec{y}_i\}$, los puntos \vec{x}_i , \vec{y}_i y el centro óptico O deben aproximarse a ser colineales (ver

Algoritmo RPM (*Robust Point Matching*)**Inicialización** θ, t a cero, s a uno, β a β_0 y M_{ij} a $1 + \varepsilon_{ij}$ **Inicio A** Repetir A hasta $\beta \geq \beta_f$ **Inicio B** Repetir B hasta que M converja o N^o de iteraciones $> I_0$ **Inicio C**Para todo $i \in \{1, \dots, N_1\}$ and $j \in \{1, \dots, N_2\}$

$$Q_{ij} \leftarrow -\|X_i - t - sR(\theta)Y_j\|^2 + \alpha$$

$$M_{ij} \leftarrow \exp(\beta Q_{ij})$$

Inicio D Repetir D hasta que M converja o N^o de iteraciones $> I_1$ Actualizar M normalizando las filas

(excepto la fila de valores aberrantes):

$$M_{ij} \leftarrow \frac{M_{ij}}{\sum_{j=1}^{N_2+1} M_{ij}}, i \in \{1, \dots, N_1\}, j \in \{1, \dots, N_2 + 1\}$$

Actualizar M normalizando las columnas

(excepto la columna de valores aberrantes):

$$M_{ij} \leftarrow \frac{M_{ij}}{\sum_{j=1}^{N_1+1} M_{ij}}, i \in \{1, \dots, N_1 + 1\}, j \in \{1, \dots, N_2\}$$

Fin D**Fin C****Inicio E**Actualizar θ usando una solución analíticaActualizar t usando una solución analíticaActualizar s usando el método de Newton**Fin E****Fin B**

$$\beta \leftarrow \beta_r \beta$$

Fin A

Figura 2.1: Algoritmo RPM. Nótese cómo se resuelve alternativamente el problema de la correspondencia entre puntos y la estimación de los parámetros de registrado

Figura 2.2). Esta restricción viene expresada por la siguiente expresión:

$$d_i = \sqrt{\left| d^2(\vec{x}_i, \vec{y}_i) - \frac{(\vec{y}_i^T \vec{x}_i)^2}{\vec{y}_i^T \vec{y}_i} \right|}.$$

- *Restricción de proximidad*: la distancia entre los puntos \vec{x}_i y \vec{y}_i debe ser mínima, según se expresa en la siguiente ecuación:

$$e_i = \|\vec{x}_i - \vec{y}_i\|.$$




Figura 2.2: Restricciones de colinealidad y proximidad. Con el mismo error de registrado e_i , el punto y_i'' es una asignación preferida al punto y_i' , ambos más próximos a x_i , ya que $d_i'' < d_i'$ y $\theta_i'' < \theta_i'$. Por tanto, x_i es más próximo al rayo que pasa a través de y_i'' que al rayo que pasa por y_i' , donde d_i'' y d_i' son las distancias desde el punto x_i a los rayos que pasan por y_i'' y y_i' , y θ_i'' y θ_i' son los ángulos entre el vector descrito por el punto x_i y los correspondientes a los puntos y_i'' y y_i' , respectivamente

A partir de lo anterior, se calculan las medias, μ_d y μ_e , y desviaciones típicas, σ_d y σ_e , de d_i y e_i , respectivamente, tomando cada asignación establecida en la fase de matching. Finalmente, la regla propuesta establece que si $|d_i - \mu_d| \leq k\sigma_d$ y $|e_i - \mu_e| \leq k\sigma_e$, la asignación de puntos $\{x_i, y_i\}$ se considera válida y se mantiene. En caso contrario, dicha correspondencia se descarta para el cálculo de la transformación de registrado. Como aportación novedosa del método, se aplica una

pequeña perturbación aleatoria sobre la solución en curso. Dicha perturbación se realiza previamente a la finalización de la ejecución del algoritmo. Según demuestran los resultados presentados en la experimentación del método, la aplicación de la perturbación no supone una mejora global del método, dejando el autor total libertad para su consideración.

2.2.5. Propuesta de *Cordón y Damas*

Este método de RI [Cordón, 06a] hace uso de la metaheurística ILS [Lourenço, 03] como estrategia de búsqueda global, abordando el problema de RI desde una perspectiva de optimización combinatoria de las correspondencias en base a la minimización de cierta función objetivo. Es decir, a diferencia de las propuestas anteriores, en este caso el proceso de búsqueda tiene el «control total» sobre las correspondencias, pudiéndose diseñar diferentes criterios para el establecimiento de las mismas y explorando el proceso de búsqueda en base a la calidad de las soluciones. De forma similar, en [Brunnström, 96] se propone un método de RI empleando un AG como estrategia de búsqueda de las mejores correspondencias.

En primer lugar, la propuesta de Cordón y Damas se centra en un enfoque de RI basado en características, para lo cual se hace uso de un método de detección de características en imágenes médicas 3D. En concreto, se extrae un conjunto de líneas de cresta (ver Sección 2.3), así como se diseña un esquema de codificación de las soluciones específico para el enfoque de las correspondencias basado en permutaciones. Las soluciones codificadas de esta forma son evaluadas por una función objetivo cuyo diseño trata de minimizar de forma conjunta el Error Cuadrático Medio (ECM) y el error cuadrático del matching de las correspondencias, medido este último en base a información de curvatura de las primitivas emparejadas (ver Sección 2.4.1). Por otro lado, la solución de partida del algoritmo se construye de forma completamente aleatoria y la etapa de perturbación de la solución consiste en barajar, de forma aleatoria, una porción de la permutación. Por último, como algoritmo de optimización local se implementó una estrategia de búsqueda del primer mejor que emplea el operador de movimiento de intercambio.

Hemos de decir que, si bien esta propuesta obtenía resultados satisfactorios, la necesidad de afrontar problemas de RI de diferente naturaleza que contaran con una mayor complejidad, buscando obtener soluciones de mayor calidad, es lo que nos ha llevado a estudiar la propuesta de un nuevo método de RI (descrito con todo detalle en secciones posteriores), basándonos para ello en el AE Scatter Search.

2.3. Detección de características en imágenes 3D

Siguiendo el enfoque de RI basado en características considerado con gran éxito en [Damas, 03, Cordón, 06a], en el que se realiza la extracción de información relevante en imágenes 3D como son las denominadas *líneas de cresta*, nuestra intención es aprovechar dicha información para el diseño de nuestra propuesta de RI basada en SS. A continuación pasamos a describir el proceso de extracción considerado en [Damas, 03].

El objetivo de este proceso es hallar aquellas primitivas, en este caso nos referimos a puntos 3D, que sinteticen información de la estructura de la forma que procesamos. Nuestro objeto 3D estará delimitado por una superficie y, en este caso, la curvatura en un punto tendrá como referencia dicha superficie. Más formalmente:

Definamos la superficie de *iso-intensidad* de una imagen 3D, a la que a partir de ahora llamaremos *isosuperficie*: Para cualquier función continua $f(x, y, z)$ de \mathbb{R}^3 , cualquier valor I de \mathbb{R} (conocido como *iso-valor*) define una superficie continua, que no interseca consigo misma y sin agujeros, denominada *superficie de iso-intensidad de f* . Una forma de definir sin ambigüedad la isosuperficie es hacerlo considerando la superficie que separa las regiones del espacio donde la intensidad de f es mayor o igual a I de aquellas regiones cuyo valor de intensidad es estrictamente menor que I . Que esa isosuperficie delimite o no el objeto de nuestro estudio es otro problema.

No obstante, las técnicas de obtención de la isosuperficie se usan directamente con el fin de segmentar objetos de forma habitual en determinados entornos, como cuando se trabaja con ciertas imágenes médicas. Es el caso de la extracción de los huesos en imágenes CT. En otras aplicaciones, es preciso emplear estas técnicas como fase final del proceso de extracción de la superficie, con el fin de garantizar que las superficies reconstruidas serán continuas, no intersecarán consigo mismas y no contendrán ningún agujero. Precisamente, gracias a estas propiedades topológicas, las técnicas basadas en las isosuperficies son uno de los métodos más empleados para la segmentación de imágenes 3D.

Como formalizaremos a continuación, la curvatura en una superficie depende de la dirección en la que nos dirijamos (este detalle no tiene sentido en el caso de curvas lineales, pues sólo nos podemos mover a lo largo de la curva). Euler demostró que en cada punto de una superficie existen dos direcciones en las que la curvatura alcanza su máximo y su mínimo, y que estas direcciones son perpendiculares entre sí. Podemos visualizar la curvatura de una superficie estudiando un cilindro. Si nos movemos a lo largo del cilindro (sobre la generatriz) la curvatura es cero y si nos movemos en dirección perpendicular a la generatriz (recorriendo

una circunferencia) la curvatura será máxima.

Estudiemos ahora algunas propiedades de las superficies de \mathcal{C}^2 , esto es, dos veces diferenciables (ver Figura 2.3). En cada punto P de tales superficies, hay un número infinito de curvaturas, pero para cada dirección \vec{t} del plano tangente en P , hay una única curvatura $k_{\vec{t}}$. Hay dos direcciones privilegiadas de la superficie, conocidas como *direcciones principales* (\vec{t}_1 y \vec{t}_2), que corresponden a los dos valores extremos de la curvatura: k_1 y k_2 (excepto para los puntos umbilicales, para los que la curvatura es la misma en todas direcciones). Las dos curvaturas y direcciones principales bastan para determinar cualquier otro valor de curvatura en P . Una de estas dos curvaturas principales, llamada *maximal*, es máxima en valor absoluto (supongamos que es k_1). Al producto de las curvaturas principales se le denomina curvatura gaussiana K y a su semisuma, curvatura media S . Estos valores diferenciales, $\vec{t}_1, \vec{t}_2, k_1, k_2, K$ y S , pueden usarse de muy diversas formas para caracterizar localmente la superficie. Asimismo, podemos añadir el *criterio de extremalidad* e , tal y como lo definen Monga y otros en [Monga, 92], que equivale a la derivada direccional de la curvatura maximal en la correspondiente dirección (\vec{t}_1 , según nuestra notación). De hecho, el mismo criterio de extremalidad puede definirse para la otra dirección principal. Por tanto, tendríamos dos «extremalidades» e_1 y e_2 . La ubicación sucesiva de los cruces por cero del criterio de extremalidad define unas líneas que se denominaron líneas de sierra (*ridge lines*) en [Monga, 92] y, más comúnmente, *líneas de cresta* [Thirion, 96]. Por tanto, además de la ubicación espacial, toda primitiva (punto 3D) que forme parte de cierta línea de cresta tendrá asignada un vector de atributos, en este caso bidimensional, con la información de curvatura asociada a ésta, es decir, los valores de los parámetros k_1 y k_2 . Esta información será de especial importancia para el diseño de nuestra propuesta basada en SS.

A modo de ejemplo, en la parte izquierda de la Figura 2.4 mostramos una superficie generada artificialmente, concretamente se trata de la malla de un superelipsoide sin polos. A la derecha, se representan las diferentes líneas de cresta detectadas en distintos colores para poder ser distinguidas con facilidad.

2.4. Scatter Search para la búsqueda de correspondencias

El AE SS fue introducido por primera vez en 1997 por Fred Glover como una heurística para programación entera [Glover, 77]. SS orienta sus exploraciones de forma sistemática y de forma relativa a un conjunto de puntos de referencia, compuesto normalmente por una serie de buenas soluciones obtenidas mediante un esfuerzo previo de resolución del problema. El esquema básico inicial de SS

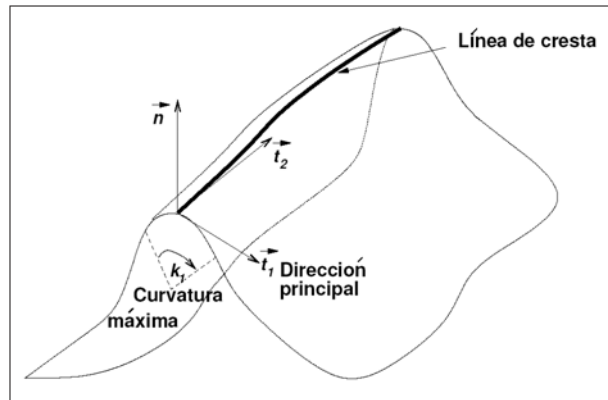


Figura 2.3: Características diferenciales de superficies [Thirion, 96]




Figura 2.4: Superelipsoide sin polos y líneas de cresta extraídas del mismo

[Glover, 98] ha servido de base para la mayoría de implementaciones hechas hasta la fecha. La metodología de SS es muy flexible, ya que cada una de sus componentes puede implementarse de múltiples formas y con diferentes grados de sofisticación. A continuación, proporcionamos su esquema básico sobre el que diseñaremos nuestra propuesta de RI. Para ello, nos centraremos en la conocida «*plantilla de los cinco métodos*» [Laguna, 03]. Las características avanzadas de SS se relacionan con la forma en la que se implementan estos cinco métodos, es decir, la sofisticación de esta metaheurística proviene de la implementación de los cinco métodos, en lugar de la decisión de incluir o excluir algunos de sus componentes como sucede en la búsqueda tabú u otras metaheurísticas. La Figura 2.5 muestra el diagrama de flujo general del algoritmo SS.

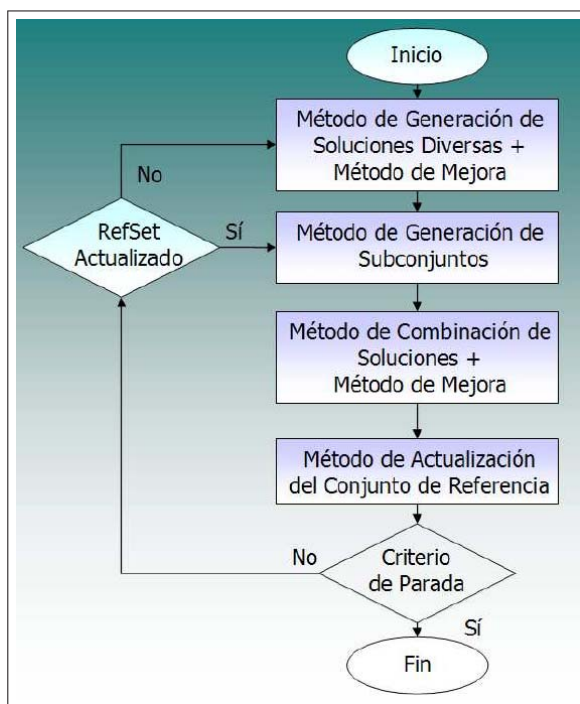


Figura 2.5: Diagrama de flujo general del algoritmo SS

El *Método de Generación de Soluciones Diversas* se usa para construir un amplio conjunto de soluciones diversas, P . El tamaño de P ($Psize$) es generalmente del orden de diez veces superior al del conjunto de referencia, $RefSet$. El conjunto

de referencia inicial (*Refset*), de tamaño b , se construye según el *Método de Actualización del Conjunto de Referencia*, el cual recoge las mejores soluciones (con respecto a su calidad) de P para componer *RefSet*. Alternativamente, se puede considerar la diversidad en lugar de la calidad o de forma adicional a la misma para su inicialización y actualización. Por ejemplo, el *Método de Actualización del Conjunto de Referencia* podría consistir en la selección de b soluciones distintas y con un alto grado de diversidad del conjunto P . Independientemente de las reglas empleadas para seleccionar las soluciones de referencia, las soluciones en *RefSet* se ordenan de acuerdo a su calidad, donde la mejor solución es la primera de la lista. Después, el proceso de búsqueda se inicia mediante la aplicación del *Método de Generación de Subconjuntos*, el cual, en su modo de funcionamiento más simple, implica la generación de todos los pares de soluciones de referencia. Dichos pares de soluciones se seleccionan uno a uno del *RefSet* y se aplica sobre ellos el *Método de Combinación* para generar una o más soluciones de prueba. Estas soluciones de prueba pueden estar sujetas a la aplicación del *Método de Mejora*. El *Método de Actualización del Conjunto de Referencia* se aplica una vez más para construir el nuevo *RefSet* con las mejores soluciones, según el valor de función objetivo, a partir del actual *RefSet* y del conjunto de soluciones de prueba generado (del nuevo, se pueden tomar en cuenta también criterios de diversidad en la actualización). El procedimiento básico finaliza después de estudiar todos los subconjuntos de soluciones y comprobar que no se acepta ninguna de las soluciones de prueba generadas (tras la aplicación o no del *Método de Mejora*) para actualizar *RefSet* bajo las reglas del *Método de Actualización del Conjunto de Referencia*.

El conjunto de referencia, *RefSet*, es una colección tanto de soluciones de calidad como soluciones diversas que se usan para generar nuevas soluciones por medio de la aplicación del *Método de Combinación*. Podemos usar un mecanismo simple que considera ambos tipos de soluciones para construir un conjunto de referencia inicial. El tamaño de *RefSet* se denota por $b = b_1 + b_2 = |\text{RefSet}|$. La construcción del conjunto de referencia inicial comienza con la selección de las b_1 mejores soluciones de P . Estas soluciones se añaden a *RefSet* y se eliminan de P . Para cada solución en $P - \text{RefSet}$, se calcula el mínimo de las distancias con las soluciones en *RefSet*. Luego, se selecciona la solución con el máximo de estas distancias mínimas. Esta solución se añade a *RefSet*, se elimina de P y se actualiza el mínimo de las distancias. El proceso de repite b_2 veces, donde $b_2 = b - b_1$. El conjunto de referencia resultante posee b_1 soluciones de calidad y b_2 soluciones diversas.

De los cinco métodos presentes en la metodología de SS, sólo cuatro de ellos son estrictamente necesarios. En general, el *Método de Mejora* sólo es necesario si se requieren resultados de alta calidad, aunque el procedimiento de SS puede

implementarse sin dicha componente. Por otro lado, los diseños de SS podrían incorporar la búsqueda tabú u otras metaheurísticas complejas como *Método de Mejora* (demandando por lo general más tiempo de ejecución).

Por tanto, la metodología de SS consta básicamente de cinco elementos (y sus estrategias asociadas). Tres de ellos, el *Método de Generación de Soluciones Diversas*, el *Método de Mejora* y el *Método de Combinación* son dependientes del problema y deben diseñarse de forma específica para el problema considerado (aunque es posible emplear procedimientos «genéricos», es más efectivo basar el diseño en las condiciones específicas de la configuración del problema). Los otros dos, el *Método de Actualización del Conjunto de Referencia* y el *Método de Generación de Subconjuntos* son independientes del contexto y generalmente poseen una implementación estándar.

Por otro lado, en la Sección 2.4.3 haremos uso de un diseño avanzado del conjunto de referencia orientado a la inducción de diversidad en el proceso de búsqueda. Esta estrategia se conoce como *diseño del RefSet en dos capas* ([Laguna, 03]) y se basa en el particionamiento del *RefSet* en dos secciones diferenciadas. La primera, *RefSet₁* (*RefSet* de calidad), está formado por b_1 soluciones de alta calidad, $\{S^1, \dots, S^{b_1}\}$, mientras que la segunda capa, *RefSet₂* (*RefSet* de diversidad), se compone de $b_2 = b - b_1$ soluciones diversas, $\{S^{b_1+1}, \dots, S^{b_2}\}$. Las soluciones en *RefSet₁* se ordenan según su valor de función objetivo y una nueva solución S reemplaza a la peor solución S^{b_1} si la calidad de la primera es mejor que la de esta última. *RefSet₂* se ordena de acuerdo con el valor de diversidad de las soluciones, de tal forma que una nueva solución S reemplaza la peor solución S^{b_2} si $div(S) > div(S^{b_2})$, donde el valor de diversidad div se calcula en nuestro caso empleando la distancia *DCP* definida en la Sección 2.4.3.

Así, en las subsecciones siguientes se describe el esquema de codificación y la función objetivo considerados, así como el diseño de los diferentes métodos de SS comentados anteriormente. Por un lado, los métodos independientes del contexto, el *Método de Generación de Subconjuntos* y el *Método de Actualización del Conjunto de Referencia* (siguiendo las directrices marcadas en [Laguna, 03]). Por otro, los tres métodos que requieren de un diseño específico para el problema de RI: el *Método de Generación de Soluciones Diversas*, el *Método de Mejora* y el *Método de Combinación*.

2.4.1. Esquema de codificación, información heurística y función objetivo

Esta técnica de RI considera la resolución del problema realizando la búsqueda en el espacio de correspondencias de primitivas de imagen dentro de un enfoque de RI basado en características. Por ello, es necesario definir un esquema de codificación para especificar la correspondencia entre primitivas de la imagen escena (I_e) e imagen modelo (I_m).

Como ya hemos dicho en la Sección 2.3, tras la aplicación del método de detección de características se obtiene un conjunto reducido de primitivas puntos 3D (sobre un total de millones de puntos), conocidos como puntos de *línea de cresta*, cuyos valores de curvatura, k_1 y k_2 , representan valores característicos y bien diferenciados en la isosuperficie del objeto escaneado. Por tanto, realizando este procesamiento previo de la imagen habremos reducido considerablemente nuestro espacio de búsqueda y obtenido información característica del problema a resolver para ayudar a nuestro método de búsqueda a encontrar soluciones de mayor calidad.

La correspondencia de puntos entre ambas imágenes se representa como una permutación $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_l)$ de tamaño $l = \max(n, m)$ (n y m son el número de puntos en I_e e I_m , respectivamente), la cual asocia los r puntos ($r = \min(n, m)$) del conjunto menor de puntos entre I_e y I_m con los primeros r puntos de la permutación, seleccionados de entre los del conjunto mayor. Sin pérdida de generalidad, y con la intención de simplificar la notación, hemos considerado que el número de puntos de I_m es mayor o igual al de I_e ($n \geq m$). Hemos implementado la permutación de tal forma que cada uno de los primeros r elementos (en nuestro caso $r = m$) de σ son puntos de I_m asociados con los m puntos de I_e . La Figura 2.6 ilustra los detalles de dicha implementación.

A partir de la correspondencia de puntos σ somos capaces de inferir (mediante métodos numéricos) los parámetros de la transformación f_σ implícita en dichas correspondencias. Para ello, hemos empleado la solución de [Horn, 87], basada en la resolución por mínimos cuadrados ¹ con la que estimar un tipo de transformación lineal, concretamente de similitud, comúnmente empleada para el registro de imágenes aéreas e imágenes vía satélite, imágenes de estructuras óseas, e imágenes multimodales de cerebros [Goshtasby, 05]. Dicha transformación de similitud está compuesta por una rotación $R = (\lambda, \langle \phi_x, \phi_y, \phi_z \rangle)$, una traslación $\vec{t} = (t_x, t_y, t_z)$, y un factor de escala uniforme s .

¹Para ajustarnos fielmente a lo propuesto en [Horn, 87], los centros de masas de ambas imágenes se calculan a partir de r primeros puntos de σ

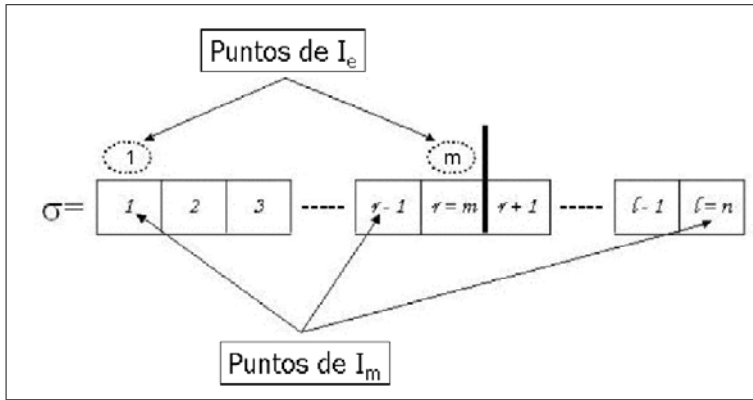


Figura 2.6: Detalles de la implementación del esquema de representación basado en permutación para la correspondencia de puntos

Una vez conocida la expresión de f_{σ} , es decir, los parámetros (R, \vec{t}, s) que definen la transformación de similitud, podemos estimar el error de registrado existente entre los puntos \vec{x}_i de la imagen escena y los puntos \vec{y}_i de la imagen modelo mediante la función g . Estimamos el error de registrado calculando la distancia Euclídea de cada punto transformado de I_e (empleando la anteriormente mencionada transformación f_{σ}) con su correspondencia en la imagen I_m según σ , tal y como se describe en la ecuación 2.1:

$$g(\sigma) = \frac{\sum_{i=1}^r \|f_{\sigma}(\vec{x}_i) - \vec{y}_{\sigma(i)}\|^2}{r}, \quad \text{donde } f_{\sigma}(\vec{x}_i) = sR(\vec{x}_i) + \vec{t} \quad (2.1)$$

Se puede observar cómo $g(\sigma)$ sólo calcula información a nivel de la geometría de las imágenes (puntos 3D). Algunos autores [Yamany, 99, Luck, 00, Robertson, 02] han propuesto varias aproximaciones metaheurísticas cuyo único objetivo es minimizar la expresión 2.1. Sin embargo, considerar solamente la evaluación de esta función objetivo genera ciertos problemas relacionados con la naturaleza de las imágenes estudiadas. Principalmente, los relativos a posibles simetrías de tipo global de los objetos presentes en las imágenes [Gagnon, 94, Weik, 97]. Generalmente, el anterior aspecto provoca que el método de registrado considerado quede atrapado en óptimos locales. Una buena explicación de tal comportamiento no deseado se encuentra en [Luck, 00], donde los autores emplean un método de *enfriamiento simulado* para solucionar este problema.

De esta forma, para superar estos problemas haremos uso de esta información dependiente (del contexto) del problema para el diseño de las diferentes componentes que especifican nuestra estrategia de búsqueda basada en SS. Una cualidad interesante de este tipo de información heurística es que los valores de curvatura representan una fuente invariante de información con respecto a la transformación de similitud f_σ que vamos a usar, es decir, para cada punto \vec{x} , se cumple que $k_1(\vec{x}) = k_1(f_\sigma(\vec{x}))$ y lo mismo para $k_2(\vec{x})$. Estos atributos característicos permanecen inalterados ante cualquier transformación de similitud f_σ .

Por tanto, dada la correspondencia entre un punto \vec{x}_i de la imagen escena (I_e) y otro \vec{y}_j de la imagen modelo (I_m) (cada uno de ellos caracterizado por sus dos valores de curvatura), cuanto más próximos sean los valores de curvatura, mayor será la probabilidad de que la correspondencia entre ambos puntos sea correcta. De esta forma, introducimos la matriz de distancias $D = (d_{ij})_{n \times m}$, donde d_{ij} se corresponde con la distancia Euclídea calculada sobre los atributos de curvatura del i -ésimo punto de I_e y del j -ésimo punto de I_m . En términos matemáticos:

$$d_{ij} = \sqrt{(k_1(\vec{x}_i) - k_1(\vec{y}_j))^2 + (k_2(\vec{x}_i) - k_2(\vec{y}_j))^2}, \quad \forall \vec{x}_i \in I_e, \vec{y}_j \in I_m \quad (2.2)$$

Usaremos estas distancias entre valores de curvatura en dos de los componentes de SS, concretamente en el *Método de Generación de Soluciones Diversas* y el *Método de Mejora*. En el primero, dichas distancias se considerarán para una evaluación alternativa de soluciones, mientras que para el segundo servirán para restringir el tamaño del vecindario de una solución dada para realizar una búsqueda más eficaz y eficiente.

Por último, hemos mantenido la expresión de la función objetivo propuesta en [Cordón, 06a] para nuestro método de RI basado en SS. El valor de $F(\sigma)$ viene expresado de la forma siguiente:

$$F(\sigma) = \omega'_g \cdot g(\sigma) + \omega'_{m_{error}} \cdot m_{error}(\sigma), \quad \text{con } m_{error}(\sigma) = \sum_{i=1}^r d_{i\sigma(i)}^2 \quad (2.3)$$

donde la función de error $m_{error}(\sigma)$ mide la bondad de las correspondencias en σ empleando los atributos extra de información de curvatura asociados con cada punto. Los pesos ² ω'_g y $\omega'_{m_{error}}$ definen, de forma uniforme, la importancia relativa de

² Los pesos en la función objetivo se han normalizado previamente según $\omega'_g = \omega_g$ y $\omega'_{m_{error}} = \omega_{m_{error}} \cdot \left(\frac{m_{error}(\sigma_0)}{g(\sigma_0)}\right)$, donde $\omega_g, \omega_{m_{error}} \in [0, 1]$ ($\omega_g + \omega_{m_{error}} = 1$) y $m_{error}(\sigma_0)$ y $g(\sigma_0)$, son el error de correspondencia y el error de registrado de la solución inicial σ_0 , respectivamente.

cada término. Con tal función tendremos una métrica de similitud más apropiada para realizar una mejor búsqueda en el espacio de soluciones, evitando los inconvenientes de métodos de RI precedentes en los que generalmente sólo se considera el primer término de la expresión 2.3 (para $\omega_g = 1$ y $\omega_{m_{error}} = 0$). Por tanto, esta definición de la función $m_{error}(\sigma)$ es un caso específico basado expresamente en dos valores de curvatura. Dependiendo de la naturaleza de las imágenes y los atributos característicos extraídos de ellas, $m_{error}(\sigma)$ podría ser definida de múltiples formas.

2.4.2. Método de Generación de Soluciones Diversas

En lugar de partir de una solución generada aleatoriamente, como hace la ILS propuesta en [Cordón, 06a], se puede considerar la información heurística (curvatura) descrita en las secciones anteriores para establecer un criterio de preferencia de buenas asignaciones (correspondencias) entre puntos de las imágenes escena y modelo, lo que permite generar el conjunto inicial P de un modo más eficaz. Así pues, un punto \vec{x}_i de I_e tiene una mayor probabilidad de emparejarse con aquellos puntos \vec{y}_j ($1 \leq j \leq m$) de I_m con el mismo o similar valor de curvatura k_1 y k_2 , es decir, con un valor d_{ij} bajo.

En nuestro procedimiento SS podemos hacer uso de esta información con la idea de generar el conjunto inicial de soluciones diversas P , obteniendo así soluciones de calidad y, a su vez, con un alto grado de diversidad. De forma específica, fijar primero un orden de selección para los puntos $\vec{x}_i \in I_e$ y asignar después su correspondiente punto más cercano $\vec{y}_i \in I_m$ supondría una heurística voraz determinística equivalente a los métodos de RI basados en ICP. No así, en nuestro caso, pues introducimos aleatoriedad en ambos procesos, permitiendo que se tome cada decisión aleatoriamente entre los mejores candidatos. De esta forma, nuestro *Método de Generación de Soluciones Diversas* se comporta de forma similar a la fase de construcción de un algoritmo GRASP [Resende, 01]. El elemento más importante en este tipo de construcción es que la selección en cada paso debe guiarse por una función voraz que se adapta según las elecciones pseudo-aleatorias realizadas en los pasos anteriores.

Nuestro método comienza creando dos listas de candidatos de puntos aún no asignados (LC_m y LC_e) las cuales, al comienzo, están compuestas por todos los puntos de I_e e I_m (es decir, inicialmente $LC_m = I_e$ y $LC_e = I_e$). Para cada punto $\vec{x}_i \in LC_e$, calculamos su distancia potencial d_i con LC_m como el valor mínimo de las distancias de \vec{x}_i con todos los elementos de LC_m . Después, construimos la lista restringida de candidatos (LRC_e) con un porcentaje $\alpha \in [0, 1]$ de los elementos de

LC_e con menor valor d_i , y seleccionamos aleatoriamente un elemento \vec{x}_k de LRC_e para realizar una correspondencia. Para encontrar un punto apropiado en I_m para emparejarlo con \vec{x}_k , construimos la lista restringida de candidatos LRC_m con un porcentaje $\alpha \in [0, 1]$ de los elementos de LC_m cuyo valor de curvatura es próximo al de \vec{x}_k , es decir, aquellos elementos con menor distancia a \vec{x}_k . Por último, seleccionamos aleatoriamente un punto \vec{y}_k en LRC_m y lo emparejamos con \vec{x}_k . Posteriormente, actualizamos LC_e y LC_m ($LC_e = LC_e - \{\vec{x}_k\}$, $LC_m = LC_m - \{\vec{y}_k\}$) y realizamos una nueva iteración. El algoritmo termina cuando se asignan los $r = n$ puntos de I_e y los restantes $l - r$ elementos de la permutación se eligen aleatoriamente de entre los restantes de LC_m .

Repetimos la aplicación de este algoritmo constructivo pseudoaleatorio hasta que obtengamos un total de $Psize$ soluciones diferentes en P y aplicamos el *Método de Mejora* descrito en la Sección 2.4.6 a las soluciones generadas. Dado que dos soluciones diferentes pueden producir la misma solución mejorada, aplicamos el paso de construcción un número adicional de veces, en caso necesario, hasta obtener $Psize$ soluciones mejoradas y diferentes entre sí.

2.4.3. Método de Actualización del Conjunto de Referencia

Como se mencionó al comienzo de esta sección, el conjunto de referencia, $RefSet$, es una colección de b soluciones (puntos de referencia) utilizadas para generar nuevas soluciones. La construcción del conjunto de referencia de partida comienza con la selección de las $b_1 < b$ soluciones mejoradas de P con mayor calidad. Estas soluciones se añaden a $RefSet$ y se eliminan de P . Las restantes $b_2 = b - b_1$ soluciones de $RefSet$ se seleccionan de P teniendo en cuenta la diversidad. Para ello, necesitamos definir una métrica de distancia entre los vectores de soluciones, es decir, entre las permutaciones. En esta memoria consideramos la distancia entre dos permutaciones $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_l)$ y $\rho = (\rho_1, \rho_2, \dots, \rho_l)$ como el número de veces que σ_i difiere de ρ_i (para $1 \leq i \leq r$). Además, para favorecer la inclusión de soluciones de calidad, establecemos un sesgo sobre la medida de distancia y dividimos su valor entre la suma de las evaluaciones de ambas soluciones. Llamaremos a esta métrica *Distancia de Correspondencia de Puntos* (DCP) con la intención de diferenciarla de la distancia de curvatura de puntos d . Su definición en términos matemáticos es la siguiente:

$$DCP(\sigma, \rho) = \frac{\sum_{i=1}^r \min(1, |\sigma_i - \rho_i|)}{F(\sigma) + F(\rho)} \quad (2.4)$$

De este modo, el $RefSet_2$ se genera siguiendo el esquema «min-max» propuesto

en [Laguna, 03]. Para cada solución mejorada en $P - RefSet$ se calcula el mínimo de DCP, seleccionándose la solución con el máximo de esta distancia mínima. Esta solución se añade a $RefSet$ y se elimina de P , actualizando las distancias mínimas en $RefSet$. Este proceso se repite en b_2 ocasiones. Como resultado del procedimiento anterior, el conjunto de referencia obtenido posee b_1 soluciones de alta calidad y b_2 soluciones diversas.

Por otro lado, en cada iteración el *Método de Actualización del Conjunto de Referencia* actualiza el $RefSet$ siguiendo el esquema *estático* propuesto en [Laguna, 03]. Cada nueva solución generada después de los pasos de combinación y mejora se inserta en una lista de soluciones, $Lista$, ordenada según su valor de función objetivo, donde la solución con mejor valor es la primera en la lista. Las peores soluciones de $RefSet_1$ se reemplazarán con las correspondientes soluciones de $Lista$ (siempre que estas últimas mejoren a las primeras). A continuación, el resto de soluciones de $Lista$ (todas ellas con un valor de calidad inferior al de aquellas en $RefSet_1$) se consideran una a una para actualizar $RefSet_2$ en base al esquema «*min-max*» anterior hasta que no se encuentre una solución de $Lista$ cuyo valor de DCP sea mayor al de la solución con menor valor de DCP de $RefSet_2$.

2.4.4. Método de Generación de Subconjuntos

Como en nuestro caso el conjunto $RefSet$ está compuesto por una parte con soluciones de calidad y otra parte con soluciones diversas, el *Método de Generación de Subconjuntos* crea tres tipos diferentes de subconjuntos de soluciones a partir de dichas partes. Por un lado, con la intención de intensificar la búsqueda combinando soluciones de alta calidad, se crean todos los subconjuntos de soluciones con las $b_1 * (b_1 - 1)$ posibles parejas de soluciones en el subconjunto $RefSet$ de calidad ($RefSet_1$). Por otro lado, con el propósito de la diversificación, se considera la combinación de soluciones pertenecientes a aquellos subconjuntos creados con $b_2 * (b_2 - 1)$ parejas de soluciones del subconjunto $RefSet$ de diversidad ($RefSet_2$). En último lugar, se crea un tercer grupo de $b_1 * b_2$ subconjuntos de pares de soluciones emparejando cada solución $RefSet_1$ con cada solución en $RefSet_2$, obteniendo así nuevas soluciones combinadas con un balance entre ambos aspectos (diversificación/intensificación).

2.4.5. Método de Combinación

Hemos considerado dos métodos de combinación distintos, que tienen en común la generación de una única solución combinada a partir de un subconjunto

compuesto por un par de soluciones originales. El primero de estos métodos, llamado *Partially Mapped Crossover*, se basa en elementos aleatorios y es muy usado en el contexto de AGs. El segundo, llamado *Método del Voto*, se basa en elementos determinísticos y es bien conocido y empleado en el contexto de algoritmos de programación con memoria adaptativa. Compararemos el rendimiento de ambos operadores de combinación en una sección experimental posterior.

Partially Mapped Crossover Corresponde a una implementación del operador clásico de recombinación para representaciones basadas en el orden, llamado Partially Mapped Crossover (PMX) [Goldberg, 85]. Está diseñado para preservar la posición absoluta de algunos elementos en la primera solución. El método elige aleatoriamente dos puntos de cruce en una de las dos soluciones de referencia y copia la correspondiente porción de la permutación (la región contenida entre los puntos de cruce) en la nueva solución. El resto de elementos se copian en las posiciones en las que aparecen en la segunda solución de referencia. Si una posición ya está ocupada por un elemento copiado del primer padre, se copia el elemento proporcionado por el mapeo resultante de hacer corresponder los alelos (números) situados en las mismas posiciones en ambos cromosomas. Este proceso se repite hasta que el conflicto se resuelve. Con la intención de limitar la aleatoriedad del método y asegurarnos de la contribución de ambas soluciones referencia a la nueva solución combinada, generamos de forma aleatoria el primer punto de cruce pc_1 en $\{1, 0.5 * l\}$ (suponiendo que $0.5 * l < r$) y fijamos el segundo punto de cruce pc_2 en $pc_2 = pc_1 + 0.25 * l$.

Según se indica en [Cotta, 98], este operador es *respetuoso* ya que transmite un número relevante de características de las soluciones originales a la solución combinada. En términos genéticos, decimos que PMX transmite un *bloque de forma* (una clase de equivalencia inducida por las relaciones identificadas como relevantes). Los autores comparan ocho operadores genéticos de cruce en el contexto de problemas de secuenciación de tareas (basados en una representación de orden) y concluyen que PMX es el de mejor rendimiento en tales escenarios.

Método del Voto El método explora (de izquierda a derecha) ambas permutaciones (soluciones) de referencia y usa una regla de construcción en la que cada permutación de referencia vota por su primer elemento que aún no ha sido incluido en la permutación combinada (referido como el «elemento incipiente»). El voto determina qué elemento se va a insertar primero en la siguiente posición no asignada de la permutación. Se trata de una regla min-max en el sentido de que si se elige cualquier elemento distinto del elemento incipiente, se debe incrementar la

desviación entre las permutaciones de referencia y la permutación combinada. De forma similar, si el elemento incipiente se coloca más tarde en la permutación combinada en lugar de hacerlo en la siguiente posición disponible, esta desviación también debe incrementarse. Luego, la regla intenta minimizar la máxima desviación de la solución combinada desde la solución de referencia considerada, sujeta al hecho de que la otra solución de referencia «compite» por contribuir con sus elementos. Para el desempate se implementa un factor discriminador que proporciona mayor peso al voto de la permutación de referencia con calidad superior. Esta regla se emplea cuando más de un elemento recibe el mismo número de votos. Se selecciona el elemento con el mayor voto ponderado, donde el peso de un voto es directamente proporcional al valor de función objetivo de la correspondiente solución de referencia. Se pueden encontrar detalles adicionales sobre este método de combinación en [Campos, 01].

2.4.6. Método de Mejora

Como se ha comentado, se puede implementar un algoritmo de SS sin este componente, aunque su empleo permite obtener resultados de alta calidad. Por otro lado, Ugray y otros [Ugray, 05] demostraron que la aplicación exhaustiva del Método de Mejora sobre todas las soluciones obtenidas por cierto Método de Combinación no garantiza un mejor resultado. Así pues, para obtener un balance apropiado entre la cantidad de mejora de la solución como resultado del uso del *Método de Mejora* y el tiempo consumido por éste, hemos decidido ejecutar la búsqueda local sobre cada nueva solución que se genera en el *Método de Generación de Soluciones Diversas* y, por contra, no aplicarlo a cada nueva solución generada por el *Método de Combinación*, sino sólo sobre algunas de ellas (de este modo se reduce el coste computacional de la propuesta). Estudios previos han demostrado como una aplicación selectiva del optimizador local, con una selección aleatoria basada en una cierta probabilidad con un valor bajo, ha dado como resultado un buen rendimiento en diferentes algoritmos meméticos y, de forma específica, en algunas implementaciones de SS [Hart, 94, Lozano, 04, Herrera, 05]. En nuestro caso, esta decisión se toma de forma determinística, la solución resultado del *Método de Combinación* se optimiza sólo cuando su valor de evaluación F es mejor que el de al menos una de las dos soluciones originales que la generan.

De forma específica para nuestro diseño del *Método de Mejora*, hemos empleado el *intercambio* como operador de movimiento (o de vecino) y un esquema de búsqueda local del *primer mejor*. Definimos cierto movimiento como $mov(\sigma_i, \sigma_j)$, $i \in \{1, \dots, r = \min(n, m)\}$, $j \in \{1, \dots, l = \max(n, m)\}$, $i \neq j$, como el intercambio de σ_i y σ_j en la solución actual σ . Esta operación da como resultado la orde-

nación $\sigma' = (\sigma_1, \dots, \sigma_{i-1}, \sigma_j, \sigma_{i+1}, \dots, \sigma_{j-1}, \sigma_i, \sigma_{j+1}, \dots, \sigma_l)$ cuando $i < j$ (y de forma simétrica cuando $j < i$).

Por otro lado, para reducir el coste computacional del proceso de búsqueda local, se ha introducido un sesgo en la función objetivo mediante la anulación del segundo término de F , devolviendo como resultado el cálculo de g . Una vez finaliza la ejecución del método, la solución encontrada se evalúa con F . Además, una diferencia importante con otros problemas de optimización es que, por la singularidad del problema que estamos tratando, no podemos calcular de forma eficiente el valor de coste asociado con un movimiento de prueba. En otras palabras, para evaluar la calidad de un movimiento, necesitamos evaluar la solución completa σ' obtenida tras la aplicación del mismo y comparar su valor con aquel de la solución inicial σ ($\text{valor_de_movimiento} = g(\sigma) - g(\sigma')$). Se observa como una modificación en la solución (permutación σ) indica que se produce un pequeño cambio en las correspondencias entre los puntos de ambas imágenes (cambian dos de ellas), lo que implica una nueva estimación de la transformación f . Desafortunadamente, una modificación tan simple puede dar como resultado una transformación de registrado $f_{\sigma'}$ totalmente diferente. Por tanto, cambiarían todos los términos en la expresión $g(\sigma)$ y no habría forma de calcular $g(\sigma')$ sin estimar previamente la nueva transformación $f_{\sigma'}$.

Además de considerar la aplicación selectiva del método como medida de aceleración, se realiza una exploración eficiente del vecindario de cada solución σ , $N(\sigma)$, en base al poder discriminador de la información heurística del problema (de esta forma se evita tener que evaluar soluciones poco prometedoras). En concreto, una solución σ representa la correspondencia $(\vec{x}_i, \vec{y}_{\sigma(i)})$, para $i = 1, \dots, r$, y se espera entonces que, en una buena correspondencia, los puntos \vec{x}_i e $\vec{y}_{\sigma(i)}$ tendrán valores de curvatura similar. En términos matemáticos, $d_{i\sigma(i)}$ debería ser relativamente pequeño para $i = 1, \dots, r$. Debido a que la evaluación de cada movimiento es una operación relativamente costosa en tiempo, reduciremos el vecindario de una solución para incluir sólo movimientos prometedores. De forma específica, consideraremos el vecindario restringido de una solución σ , $N'(\sigma)$, como el conjunto de aquellos movimientos, $mov(\sigma_i, \sigma_j)$, en los que esta diferencia de curvatura se decrementa para σ_i o para σ_j :

$$N'(\sigma) = \{mov(\sigma_i, \sigma_j) / d_{j\sigma_i} \leq d_{i\sigma_i} \text{ o } d_{i\sigma_j} \leq d_{j\sigma_j}, 1 \leq i \leq k, 1 \leq j \leq l, i \neq j\} \quad (2.5)$$

Dada cierta solución σ y su transformación f_σ asociada, cada elemento σ_i contribuye en la evaluación de la solución total $g(\sigma)$ con δ_i , donde:

$$\delta_i = \|f_{\sigma}(\vec{x}_i) - \vec{y}_{\sigma_i}\|^2 \quad (2.6)$$

Esta medida muestra que los puntos no deben tratarse de la misma forma por un procedimiento que seleccione un índice para una búsqueda local (es decir, para intensificación de la búsqueda). Consideramos que δ es una medida de influencia y puede emplearse para guiar una búsqueda eficiente de $N'(\sigma)$. De forma específica, ordenamos los elementos de una solución según su valor δ y seleccionamos el elemento σ_{i^*} con el mayor valor de intercambio δ_i . Entonces exploramos $N'(\sigma)$ (en el orden dado por el valor de distancia de curvatura $d_{j\sigma(i^*)}$) a la búsqueda del primer elemento σ_j cuyo intercambio $mov(\sigma_{i^*}, \sigma_j)$ origina un valor de movimiento estrictamente positivo (es decir, un movimiento tal que $g(\sigma') < g(\sigma)$). Como se documenta en [Laguna, 99], la estrategia anterior no necesariamente selecciona la mejor solución disponible en el vecindario pero, después de varias iteraciones, puede conducir la búsqueda hacia una solución mejor que una estrategia voraz basada en la selección de la mejor solución en cada iteración. Si no encontramos ningún movimiento de mejora asociado con el elemento σ_{i^*} , saltamos al siguiente en la lista ordenada y operamos de la misma forma. El método de búsqueda local termina bien cuando $N'(\sigma)$ no contiene ningún movimiento de mejora o cuando se alcanza un número máximo de iteraciones.

Calcular el valor δ , ordenar los elementos y seleccionar el más influyente es computacionalmente costoso. Para acelerar el funcionamiento de nuestro operador de vecino, estos valores δ no se actualizan después de la aplicación de un movimiento en cada iteración de la búsqueda local sino que mantenemos el orden y seleccionamos el siguiente elemento en la lista para la siguiente iteración (y procedemos de la misma forma para una serie de iteraciones sucesivas). La noción de no actualizar valores clave (por ejemplo, valores de movimiento) tras cada iteración se basa en la *lista de candidatos elite* sugerida en [Glover, 97]. El diseño considera que no es absolutamente necesario actualizar el valor de los movimientos en una lista de candidatos después de que se haya completado una iteración (es decir, tras la aplicación del movimiento seleccionado) porque para la mayoría de estos valores de movimiento o bien los valores permanecen iguales o bien su mérito relativo permanece casi inalterado. La aplicación de esta estrategia es particularmente útil cuando la actualización de los valores de movimiento es computacionalmente costosa, como en nuestro caso. Después de k iteraciones de la búsqueda local, actualizamos los valores δ y calculamos el nuevo orden. El parámetro k refleja el punto de equilibrio entre precisión de información y esfuerzo computacional en la implementación, y se fija empíricamente.

2.5. Experimentación y análisis de resultados

Con la intención de estudiar el rendimiento de nuestra propuesta, en esta sección presentamos un número de experimentos diseñados para estimar varias transformaciones de registrado considerando un repertorio de imágenes médicas 3D. El reto más importante asociado con la presente experimentación se centra en que el objetivo del proceso de RI es registrar *dos imágenes diferentes de objetos similares*, en lugar de dos imágenes de un mismo objeto (como se hacía en la propuesta de la ILS para RI [Cordón, 06a]), con lo que se estaría tratando de resolver un posible escenario real en aplicaciones de RI para entornos médicos.

Para ello, haremos uso del repertorio de imágenes proveniente del repositorio *BrainWeb* [Collins, 98, Kwan, 99], ampliamente usado por la comunidad investigadora en RI [Rogelj, 02, Held, 04, Wachowiak, 04], y del que hemos seleccionado cuatro imágenes de resonancia magnética (MRI) que simulan la captación de objetos del mundo real, en concreto se trata de MRIs de cerebros humanos. En particular, tres de ellas presentan ruido, lesiones anatómicas y cierto grado de oclusión, lo que complica el registrado de las mismas. Haciendo uso de este conjunto de imágenes queremos resaltar la complejidad del problema que se va a abordar. La principal razón para elegir dicho simulador de imágenes es facilitar la comparación de nuestros resultados con los obtenidos por contribuciones previas, entre ellas la propuesta de RI basada en ILS desarrollada en nuestro grupo de investigación. Por otro lado, este repertorio de cuatro imágenes se empleará también como estándar de comparación para ajustar los parámetros relacionados con nuestra propuesta.

Esta configuración experimental es significativamente más compleja que la considerada en [Cordón, 06a]. Por supuesto, el registrado de objetos diferentes es mucho más complicado que el problema planteado con imágenes cuya diferencia más importante es la localización espacial y, a lo sumo, considerando instancias con ruido generado mediante funciones estándar, poco ajustadas a la fuente que en realidad lo origina.

Los resultados obtenidos por nuestro algoritmo SS_m para el problema de RI 3D basado en características se compararán con los de nuestra propuesta previa basada en el algoritmo ILS [Cordón, 06a], además de con los de otras técnicas clásicas en la literatura de RI descritas en secciones anteriores. En concreto, con la propuesta de Luck y otros [Luck, 00] y con la contribución de Liu [Liu, 04], notadas respectivamente como $ICP + SA$ e $I - ICP$ (ver Sección 2.2). Los dos métodos anteriores mantienen su forma original salvo para el cálculo de la transformación de registrado, ya que al considerar en este caso un modelo de transformación diferente (similitud), hemos adaptado el cálculo siguiendo las directrices presentadas

en [Horn, 87].

Por último, mostraremos los resultados obtenidos por el algoritmo voraz descrito en la Sección 2.4.2, como umbral inferior de calidad para nuestro procedimiento SS_m .

2.5.1. Diseño del experimento

Esta subsección describe la configuración experimental considerada para estimar varias transformaciones de registrado en el repertorio de imágenes médicas 3D mencionado. Se ha dividido en tres partes bien diferenciadas. En primer lugar, se presentan las imágenes usadas para diseñar los diferentes escenarios de RI. Después, se introducen las instancias del problema de RI que se van a resolver, mediante la descripción de los pares de imágenes a registrar en cada escenario y de las cuatro transformaciones de registrado aplicadas a cada una de ellas. Por último, indicaremos los valores de parámetros empleados en los diferentes algoritmos de RI que se han considerado.

2.5.1.1. Imágenes médicas 3D

Nuestros resultados corresponden con un número de problemas de registrado con cuatro imágenes MRI diferentes del mundo real. Estas imágenes se han conseguido de la base de datos pública *BrainWeb* de la Universidad de McGill.

Estableciendo los parámetros apropiados en el simulador de *BrainWeb*, hemos añadido diferentes niveles de ruido en tres de las cuatro imágenes consideradas en este repertorio. La razón es la simulación (mediante el modelado adecuado del ruido real en tal tipo de imágenes) de las condiciones de adquisición donde el dispositivo introduce cierta componente de ruido. Asimismo, no podemos descartar uno de los objetivos más importantes del RI: apoyar en la toma de decisiones críticas que conciernen a la terapéutica de la evolución de la lesión en un paciente. Para ello, hemos obtenido dos imágenes (de un total de cuatro) presentando una lesión del tipo de la esclerosis múltiple mediante el simulador de *BrainWeb*.

La influencia de estos dos factores (intensidad de ruido y presencia o ausencia de una lesión) nos permitirá diseñar un conjunto de experimentos con diferentes grados de complejidad, como veremos posteriormente en la Tabla 2.2. Debemos señalar que estas decisiones sobre la introducción de ruido y la consideración de una lesión están restringidas por las posibilidades proporcionadas en la base de datos *BrainWeb* donde sólo pueden realizarse algunas selecciones, es decir, esta-

mos limitados a añadir solamente ruido de tipo gaussiano a nuestras imágenes de prueba, aunque otros modelos de ruido podrían ser más apropiados cuando se trabaja con imágenes MRI. No obstante, como se indica en [Yetik, 06]: «*No es posible modelar el ruido mediante un modelo gaussiano aditivo cuando se emplean diferentes técnicas para adquirir imágenes. En ciertos casos, por ejemplo, en modalidades diferentes de imágenes médicas, las imágenes se relacionan mediante una función no lineal y no aleatoria. Por tanto, los resultados que obtenemos aquí son válidos para la misma modalidad donde el ruido gaussiano aditivo supone una presunción razonable.*» En nuestra contribución también se emplean imágenes con la misma modalidad, por lo que está justificado el único modelo de ruido permitido por el simulador de *BrainWeb* para las imágenes que proporciona.

Sobre todas estas imágenes se ha llevado a cabo un paso previo de procesamiento con la intención de obtener información dependiente del problema para guiar el proceso de RI, así como para reducir la ingente cantidad de datos que almacenan las instancias iniciales de estas imágenes. Así, extraemos de cada imagen original la isosuperficie del objeto de interés (en nuestro caso nos referimos a cerebros humanos) y seleccionamos los puntos de líneas de cresta con información de curvatura relevante (ver Sección 2.3).

La primera imagen (« I_1 », ver Figura 2.7) corresponde a una imagen MRI de una persona sana que se ha obtenido mediante un escáner ideal, es decir, no existe ni lesión ni ruido en dicho escenario. Se han seleccionado 583 puntos tras realizar tanto la extracción de la isosuperficie que identifica el cerebro como el estudio de los puntos de línea de cresta con información de curvatura relevante.

La imagen « I_2 » (ver Figura 2.8) corresponde a un escenario con bajo nivel de ruido (1 % de ruido gaussiano) y con una persona sana. Después de la extracción de la isosuperficie, se seleccionaron 393 puntos de líneas de cresta.

La tercera imagen (« I_3 », ver Figura 2.9) incluye una lesión de tipo esclerosis múltiple con el mismo nivel de ruido de I_2 . Como en las imágenes anteriores, extraemos un total de 348 puntos con información de curvatura relevante.

La imagen « I_4 » (Figura 2.10) corresponde a un paciente con esclerosis múltiple adquirida empleando un dispositivo defectuoso o de bajas prestaciones (se introduce un 5 % de ruido gaussiano). Sobre la isosuperficie se puede ver el efecto provocado por el nivel de ruido considerado (superficie abrupta en lugar de suavizada). Por último, se han identificado un total de 248 puntos con información de curvatura relevante.




Figura 2.7: Imagen I_1 . a) Imagen MRI original con sus tres vistas (axial, sagital, y coronal). Se pueden identificar de forma clara diferentes órganos (cráneo, cerebro, ojos, etc.). b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante




Figura 2.8: Imagen I_2 . a) Imagen MRI original con 1 % de ruido gaussiano. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante




Figura 2.9: Imagen I_3 . a) Imagen MRI original con 1 % de ruido gaussiano. Se marca mediante un círculo sobre la imagen la localización de la lesión de tipo esclerosis múltiple. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante




Figura 2.10: Imagen I_4 . a) Imagen MRI original con 5 % de ruido gaussiano. Se marca mediante un círculo sobre la imagen la localización de la lesión de tipo esclerosis múltiple. b) Isosuperficie correspondiente con el cerebro en la imagen MRI. c) Puntos de líneas de cresta con información de curvatura relevante

2.5.1.2. Problemas de RI considerados

Nuestros resultados corresponden a un número de instancias de problemas de RI para las diferentes imágenes 3D presentadas en la sección anterior, las cuales han sufrido las mismas cuatro transformaciones de similitud (notadas en la Tabla 2.1 como T_1 , T_2 , T_3 y T_4), que deben ser estimadas tras la aplicación de los diferentes algoritmos de RI considerados. Las transformaciones mostradas en la tabla se consideran transformaciones verdaderas (*ground-truth*) que nos permitirán cuantificar la eficacia y precisión de la solución de RI alcanzada por cada algoritmo. Así pues, conoceremos por adelantado la transformación de registrado óptima (es decir, la solución exacta a la instancia del problema) que relaciona y hace superponer en un mismo sistema de referencia el par de imágenes escena y modelo del repertorio considerado, permitiéndonos calcular el valor de función objetivo asociado con la solución óptima del problema en ambos repertorios de imágenes (ver Sección 2.5.2).

Tal y como se mencionó en la Sección 1.2.2, las transformaciones de similitud implican una rotación, una traslación y un escalado uniforme. Así, pueden representarse por ocho parámetros: uno para la magnitud de la rotación (λ), tres para el eje de rotación ($axis_x$, $axis_y$, $axis_z$), tres para el vector de traslación (t_x , t_y , t_z) y uno más para el factor de escala uniforme (s). Para conseguir una buena solución, cada algoritmo debe estimar valores precisos de estos ocho parámetros. Los valores de la Tabla 2.1 se han elegido dentro de los rangos apropiados de tal forma que se tengan que estimar transformaciones importantes, simulando escenarios de RI donde las imágenes presentan una desalineación considerable. De hecho, el ángulo de rotación más pequeño es de 115° . Igualmente, los valores de traslación son también elevados y el factor de escala se sitúa en el rango $[0.8, 1.2]$. De esta forma, estamos generando instancias complejas de problemas de RI.

Además, con la intención de tratar con un conjunto de instancias del problema con diferentes niveles de complejidad en el repertorio de imágenes MRI de cerebro (ver Tabla 2.2), consideraremos los siguientes escenarios (de menor a mayor dificultad): I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$. Por tanto, en este estudio experimental, cada algoritmo se enfrentará con dieciséis instancias del problema de RI, resultado de la combinación de los cuatro escenarios y las cuatro transformaciones diferentes T_i .

	T_1	T_2	T_3	T_4
λ	115.0	168.0	235.0	276.9
$axis_x$	-0.863868	0.676716	-0.303046	-0.872872
$axis_y$	0.259161	-0.290021	-0.808122	0.436436
$axis_z$	0.431934	0.676716	0.505076	-0.218218
t_x	-26.0	6.0	16.0	-12.0
t_y	15.5	5.5	-5.5	5.5
t_z	-4.6	-4.6	-4.6	-24.6
s	1.0	0.8	1.0	1.2

Tabla 2.1: Transformaciones de similitud consideradas

Problema de RI	Imagen escena		Imagen modelo	
	Lesión	Ruido	Lesión	Ruido
I_1 Vs. $T_i(I_2)$	No	No	No	1 %
I_1 Vs. $T_i(I_3)$	No	No	Sí	1 %
I_1 Vs. $T_i(I_4)$	No	No	Sí	5 %
I_2 Vs. $T_i(I_4)$	No	1 %	Sí	5 %

Tabla 2.2: De arriba a abajo: clasificación en orden ascendente de complejidad de los escenarios considerados en el problema de RI

2.5.1.3. Valores de parámetros

Antes de realizar la experimentación final, llevamos a cabo un estudio preliminar de los valores de parámetros más apropiados para los diferentes algoritmos de RI que se consideran en la posterior experimentación. Tanto la prueba preliminar como la experimentación posterior se han realizado en una plataforma con procesador Intel Pentium IV a 2.6 MHz. Todos los algoritmos se han implementado con el lenguaje de programación C++ y compilado para ser ejecutados sobre el sistema operativo GNU-Linux.

Para el algoritmo $I - ICP$, se ha fijado un máximo de 40 iteraciones para asegurar una correcta convergencia suponiendo condiciones de partida favorables. Se debe resaltar cómo los métodos de RI basados en ICP convergen de forma satisfactoria dentro de las diez primeras iteraciones del algoritmo [Rusinkiewicz, 01]. Desafortunadamente, en una gran cantidad de situaciones no es posible contar con información suficiente para proporcionar al algoritmo una solución de partida próxima al óptimo. Siguiendo las directrices de [Horn, 87], hemos elegido como solución de partida de $I - ICP$ una rotación arbitraria, una traslación dada por la sustracción de los centros de masas de la imagen escena y modelo, y un factor de escala uniforme estimado. Para el resto de parámetros asociados con el algoritmo se han fijado a los mismos valores empleados por el autor [Liu, 04].

Para el algoritmo híbrido ICP+SA, al igual que para $I - ICP$, se ha fijado un total de 40 iteraciones para la primera etapa de registro con $I - ICP$. El proceso de enfriamiento realiza 20 iteraciones y 50 movimientos de prueba como máximo por iteración, con un valor de temperatura inicial estimada con $T_0 = [\mu / \log_e(\phi)] \cdot C(S_0)$ (donde $C(S_0)$ es el coste de la solución inicial obtenida en la fase anterior con ICP). Sólo hemos considerado una iteración para el procedimiento ICP+SA.

Con respecto al método de RI basado en ILS desarrollado en nuestro grupo de investigación [Cordón, 06a], hemos mantenido los valores del parámetro a que controla el grado de perturbación de la permutación al valor establecido en la propuesta original, $a = 2$ (perturbación del 50 % de la permutación), y los valores de los pesos que determinan la importancia relativa de las funciones g y m_{error} en F (ver expresión 2.3 y Sección 2.4.1) a $\omega_g = 0.1$ y $\omega_{m_{error}} = 0.9$. El método de mejora de ILS se ha establecido al mismo número de iteraciones fijado para SS_m (80 iteraciones).

Nuestra propuesta SS_m maneja un conjunto inicial P compuesto por $Psize = 80$ soluciones diversas y un $RefSet$ con $b = b_1 + b_2 = 10$ soluciones, con $b_1 = 7$ en el subconjunto de Calidad ($RefSet_1$) y $b_2 = 3$ en el subconjunto de Diversidad ($RefSet_2$). El algoritmo de búsqueda local se ejecuta un máximo de 80 iteraciones

en cada aplicación del Método de Mejora, actualizando el vector de correspondencias δ cada $k = 10$ iteraciones de la búsqueda local (ver Sección 2.4.6). De esta forma, δ se actualizará siete veces durante cada aplicación de la búsqueda local.

Para los algoritmos ILS y SS_m , hemos establecido un tiempo máximo de CPU de 20 segundos en cada ejecución. Además, para los dos algoritmos anteriores y para el algoritmo $ICP + SA$ (método híbrido), hemos realizado un total de 15 ejecuciones (con semillas diferentes para el generador de números aleatorios) para cada una de las dieciséis instancias de problema con la intención de eludir el usual sesgo aleatorio de los algoritmos probabilísticos.

2.5.2. Análisis de resultados

Esta sección está dedicada a mostrar los resultados obtenidos en los experimentos. En beneficio de la claridad, la hemos dividido en dos partes distintas. En la primera subsección, se realiza un estudio experimental previo para analizar el rendimiento de las diferentes variantes de nuestra propuesta SS_m , donde se prueban los dos operadores de combinación implementados y varias configuraciones de pesos de la función objetivo (ver Sección 2.4.2). Los resultados de la heurística voraz se consideran como un umbral inferior de calidad para esta primera experimentación. Después, con la intención de medir el rendimiento de nuestra propuesta en la solución del problema cuando se consideran las imágenes MRI de cerebros humanos, SS_m se compara con el resto de técnicas del estado del arte en RI en el espacio de correspondencias, $I - ICP$ [Liu, 04], $ICP+SA$ [Luck, 00] y la contribución de RI basada en el algoritmo ILS [Cordón, 06a].

2.5.2.1. SS_m -PMX Versus SS_m -Voto

Para cada instancia del problema de RI (especificada por cierto escenario de RI y por una de las cuatro transformaciones), la comparación entre ambos métodos de combinación se realiza considerando cinco valores diferentes de los pesos de la función objetivo F . Cada una de estas variantes se denotan por WC_{x-y} , donde x e y corresponden a los coeficientes de ponderación ω_g y $\omega_{m_{error}}$ de la función objetivo (ver Sección 2.4.2). La pareja de pesos comprende valores en el rango $(\omega_g, \omega_{m_{error}}) = (0, 1)$, donde el proceso de búsqueda sólo está guiado por el uso de información dependiente (específica de la imagen) del problema (midiendo la calidad de la correspondencia de puntos mediante la información de curvatura y sin tener en cuenta el error de registrado g), hasta $(\omega_g, \omega_{m_{error}}) = (1, 0)$, donde la búsqueda solamente se guía por el error de registrado, como es la prác-

tica habitual. Se prueban también tres situaciones intermedias $((\omega_g, \omega_{merror}) = \{(0.2, 0.8), (0.5, 0.5), (0.8, 0.2)\})$, donde se establece un balance diferente entre ambos criterios de optimización.

Las Tablas 2.3 a 2.6 muestran una comparación detallada entre los métodos de combinación PMX y Voto para los cuatro escenarios mostrados en la Tabla 2.2. La estructura de cada tabla está organizada para albergar las cuatro instancias a resolver, es decir, cada una de las cuatro transformaciones consideradas (ver Tabla 2.1).

	T_1										
	Voraz	WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4072	911	2562	627	2558	479	2549	358	2430	401	2377
M	-	1982	3296	1136	2992	820	2841	2629	2629	2577	2577
μ	-	1283	2885	773	2782	567	2648	766	2543	2095	2497
σ	-	262	162	145	143	79	87	563	57	705	54

	T_2										
	Voraz	WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	2606	562	1639	368	1639	284	1631	252	1555	236	1521
M	-	1215	2109	638	1915	408	1818	1682	1682	1649	1649
μ	-	792	1863	484	1767	330	1690	680	1627	1433	1597
σ	-	168	120	75	88	35	55	573	36	422	34

	T_3										
	Voraz	WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4072	906	2562	584	2562	488	2549	407	2430	433	2377
M	-	1724	3296	1095	3296	941	2841	2629	2629	2577	2577
μ	-	1293	2911	762	2911	601	2650	1132	2545	2158	2495
σ	-	276	187	143	136	111	85	881	58	696	53

	T_4										
	Voraz	WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	5864	1313	3689	842	3689	668	3689	645	3499	623	3423
M	-	3281	4747	1519	4309	944	4747	3626	3786	3712	3712
μ	-	1991	4197	1069	3984	787	4197	970	3661	3052	3597
σ	-	596	267	159	199	73	267	721	82	1116	79

Tabla 2.3: Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_2)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita

Los resultados mostrados en cada celda de tabla corresponden al valor de g , la medida de evaluación final de la superposición obtenida entre ambas imágenes, para la estimación de registrado obtenida por cada uno de los dos métodos de com-

		T_1										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4072	911	2562	627	2558	479	2549	358	2430	401	2377	
M	-	1982	3296	1136	2992	820	2841	2629	2629	2577	2577	
μ	-	1283	2885	773	2782	567	2648	766	2543	2095	2497	
σ	-	262	162	145	143	79	87	563	57	705	54	

		T_2										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	2606	562	1639	368	1639	284	1631	252	1555	236	1521	
M	-	1215	2109	638	1915	408	1818	1682	1682	1649	1649	
μ	-	792	1863	484	1767	330	1690	680	1627	1433	1597	
σ	-	168	120	75	88	35	55	573	36	422	34	

		T_3										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4072	906	2562	584	2562	488	2549	407	2430	433	2377	
M	-	1724	3296	1095	3296	941	2841	2629	2629	2577	2577	
μ	-	1293	2911	762	2911	601	2650	1132	2545	2158	2495	
σ	-	276	187	143	136	111	85	881	58	696	53	

		T_4										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	5864	1313	3689	842	3689	668	3689	645	3499	623	3423	
M	-	3281	4747	1519	4309	944	4747	3626	3786	3712	3712	
μ	-	1991	4197	1069	3984	787	4197	970	3661	3052	3597	
σ	-	596	267	159	199	73	267	721	82	1116	79	

Tabla 2.4: Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_3)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita

		T_1										
		WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}		
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4471	885	2549	451	2378	327	2378	<u>282</u>	2378	692	2365	
M	-	1595	3230	1186	2893	970	2698	2657	2679	2591	2591	
μ	-	1213	2934	714	2613	<u>477</u>	2546	767	2513	2348	2467	
σ	-	176	169	224	145	175	108	739	90	446	61	

		T_2										
		WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}		
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	2861	573	1631	315	1522	214	1522	<u>186</u>	1522	477	1513	
M	-	1102	2067	671	1851	553	1727	1714	1714	1642	1642	
μ	-	739	1886	462	1668	<u>326</u>	1634	739	1609	1512	1578	
σ	-	177	106	136	96	119	72	633	58	278	37	

		T_3										
		WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}		
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	4471	847	2549	407	2378	293	2378	<u>283</u>	2378	387	2365	
M	-	1695	3230	1103	2893	907	2698	2679	2679	2566	2566	
μ	-	1153	2945	688	2605	<u>438</u>	2546	1088	2513	2214	2464	
σ	-	221	173	245	148	151	108	970	90	642	57	

		T_4										
		WC_{0-1}		$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}		
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m	6439	1134	3671	667	3425	450	3425	<u>399</u>	3425	439	3406	
M	-	2095	4660	1502	4166	1261	3923	3502	3857	3695	3695	
μ	-	1689	4232	937	3751	<u>687</u>	3679	866	3620	3179	3550	
σ	-	303	258	323	213	246	167	748	131	934	84	

Tabla 2.5: Errores de registrado obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_1 Vs. $T_i(I_4)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita

		T_1										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m		4374	934	2544	480	2480	463	2480	<u>328</u>	2475	2318	2318
M		-	1387	3217	872	3217	1002	2844	2670	2741	2598	2598
μ		-	1003	2927	628	2773	637	2677	738	2592	2504	2504
σ		-	164	156	141	180	166	93	755	85	62	62

		T_2										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m		2799	534	1671	308	1620	266	1620	<u>219</u>	1584	472	1484
M		-	969	2058	729	2058	542	1820	1754	1754	1662	1662
μ		-	630	1878	461	1809	338	1725	760	1669	1453	1606
σ		-	101	97	128	119	77	45	671	50	381	41

		T_3										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m		4374	755	2544	477	2480	387	2480	<u>331</u>	2475	391	2439
M		-	1423	3217	921	3217	825	2844	2673	2741	2598	2598
μ		-	1001	2927	649	2773	506	2677	1024	2595	2379	2512
σ		-	160	157	135	180	127	93	984	85	532	42

		T_4										
		WC_{0-1}			$WC_{0.2-0.8}$		$WC_{0.5-0.5}$		$WC_{0.8-0.2}$		WC_{1-0}	
		Voraz	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto	PMX	Voto
m		6299	1211	4081	681	3571	583	3571	<u>504</u>	3564	3339	3339
M		-	2280	4632	1816	4632	1134	4096	3806	3947	3741	3741
μ		-	1530	4251	973	4000	766	3871	1082	3725	3610	3610
σ		-	282	183	310	252	156	130	1080	122	94	94

Tabla 2.6: Errores de registro obtenidos por el algoritmo SS_m al considerar los operadores de combinación PMX y Voto y los cinco valores diferentes para los dos pesos de la función objetivo. La tabla se divide en cuatro subtablas, una por cada instancia del escenario I_2 Vs. $T_i(I_4)$ considerando imágenes 3D. Los valores mínimo y medio de g se muestran subrayados y en negrita

binación en las quince ejecuciones realizadas. Se muestran los valores mínimo, máximo, medio y desviación típica, notados, respectivamente, por m , M , μ y σ . Además, también se muestra el valor de error obtenido por el algoritmo voraz de referencia para cada una de las dieciséis instancias.

En primer lugar, se debe hacer una mención especial a la relación existente entre los diferentes niveles de complejidad de los cuatro escenarios y las estimaciones de registrado realizadas por cada algoritmo de RI, que queda recogida claramente en las Tablas 2.3 a 2.6. Vemos cómo, para aquellos escenarios de RI donde una de las dos imágenes involucradas corresponde con una situación con lesión (las últimas tres subtablas), los valores de g son considerablemente superiores.

Analizando los resultados (redondeados) que se muestran en las Tablas 2.3 a 2.6, podemos observar cómo el empleo del operador PMX produce mejores resultados en nuestro método de RI SS_m que los proporcionados por el operador de Votos y el algoritmo voraz. El algoritmo SS_m -PMX obtiene los mejores resultados mínimos y medios en cada una de las dieciséis instancias de RI. Por otro lado, como era de esperar, el algoritmo heurístico voraz obtiene el peor rendimiento.

La Figura 2.11 muestra los valores promedio mínimo y medio obtenidos por cada combinación de pesos en las dieciséis instancias de RI empleando PMX como *Método de Combinación*. Resulta destacable el hecho de que las combinaciones de pesos intermedios inciden en un mejor rendimiento para ambos índices de la función objetivo F . Por tanto, se obtienen peores resultados cuando sólo se considera uno de los dos términos de F , hecho que refuerza nuestra intención inicial de hacer uso de información adicional (en nuestro caso, información de curvatura) como un término extra que guíe de mejor forma el proceso de búsqueda.

Por otro lado, para una comparación profunda de las dos variantes de SS_m , analizamos también la frecuencia de aplicación del *Método de Mejora*. Teniendo en cuenta que cada nueva solución generada por combinación se considera para ser procesada por el algoritmo de búsqueda local en caso de que su calidad supere la de alguno de sus dos padres, hemos observado como para la variante de SS_m que usa el operador PMX, se optimizó el 32 % de las soluciones generadas (valor medio sobre las quince ejecuciones diseñadas y las dieciséis instancias) mediante el *Método de Mejora*, frente a un 16 % del operador del Voto. Este hecho prueba cómo el primer método presenta una serie de propiedades que favorecen la construcción de soluciones de mejor calidad e incrementa la oportunidad de mejorar aquellas nuevas soluciones empleando el *Método de Mejora*.

Con respecto a la influencia de los valores de pesos (WC_{x-y}) sobre el comportamiento de las dos variantes de SS_m , se puede ver que la combinación $WC_{0.5-0.5}$ nos permite obtener el mejor valor medio en trece de los dieciséis casos, mientras

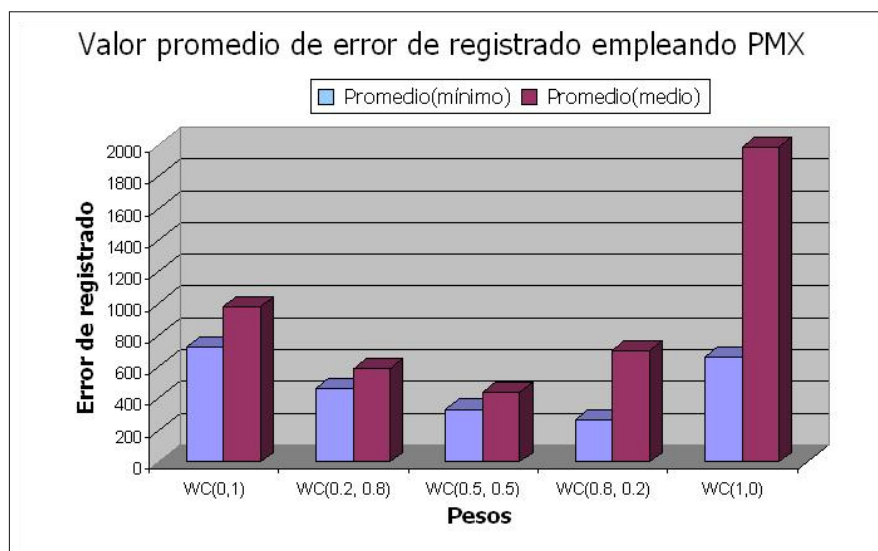


Figura 2.11: Valor promedio del error de registrado con diferentes configuraciones de pesos para los índices WC de F . Un balance apropiado para ambos índices repercute en la obtención de mejores resultados

que el mejor valor mínimo en doce de los dieciséis casos corresponde a $WC_{0.8-0.2}$. En vista de esto, parece que el dar la misma importancia a ambos criterios de la función objetivo nos permite obtener los resultados más robustos, frente al hecho de obtener el mejor rendimiento al reducir ligeramente la importancia del error de registrado para considerar más la información de curvatura de la imagen.

Con la pretensión de confirmar la hipótesis anterior, la Tabla 2.7 recoge los resultados promedio que se han obtenido por cada configuración de pesos WC_{x-y} para las dos variantes de SS_m . En vista de los datos que se muestran en dicha tabla, el mejor rendimiento para SS_m -Voto se obtiene con la combinación WC_{1-0} para los índices mínimo y medio (es decir, cuando la búsqueda está guiada sólo por la consideración del error de registrado y se descarta por completo el uso de la información heurística específica del problema). Además, se puede ver que cuanto mayor es el valor de ω_g y más bajo el de $\omega_{m_{error}}$, mejor es el valor de g . Sin embargo, las pequeñas diferencias existentes entre las distintas configuraciones de pesos junto con la baja precisión general de esta variante claramente nos hace concluir que este análisis no es muy significativo.

		\bar{m}	$\bar{\mu}$
SS_m -PMX	WC_{0-1}	725	980
	$WC_{0.2-0.8}$	465	586
	$WC_{0.5-0.5}$	334	440
	$WC_{0.8-0.2}$	267	701
	WC_{1-0}	665	1988
SS_m -Voto	WC_{0-1}	2525	2849
	$WC_{0.2-0.8}$	2438	2676
	$WC_{0.5-0.5}$	2428	2597
	$WC_{0.8-0.2}$	2393	2507
	WC_{1-0}	2344	2454

Tabla 2.7: Valores promedio correspondientes con cada combinación de pesos de la función objetivo en las dos variantes de SS_m

Por otro lado, centrando nuestra atención de forma específica en el método PMX (el cual proporciona los mejores resultados en todos los casos, lo que nos permite realizar un análisis más profundo), es fácil darse cuenta cómo para la combinación intermedia de pesos, los resultados son los más equilibrados en ambos índices. Es evidente que los peores resultados se obtienen cuando se considera

un único término en la función objetivo. Se deducen los peores valores medios cuando la información heurística no se considera, es decir, cuando se usa la combinación de pesos WC_{0-1} , mientras que se obtienen los peores valores mínimos cuando no se tiene en cuenta el término referente al error de registrado g (la combinación WC_{0-1}). De forma adicional, el segundo peor resultado en cada índice se obtiene mediante la otra combinación. Este comportamiento muestra cómo un buen balance entre ambos términos de la función objetivo permite conseguir una convergencia más apropiada. De esta forma, los resultados experimentales de la variante SS_m -PMX refuerzan nuestra intención inicial de hacer uso de información adicional (la información de curvatura, en nuestro caso) como un segundo término de la función objetivo para tener un proceso de búsqueda mejor guiado, mostrando cómo es necesario contar con un balance adecuado entre los dos criterios de error para obtener un comportamiento global robusto y unos resultados precisos.

2.5.2.2. Comparación entre SS_m y métodos previos de RI

En esta sección comparamos nuestra propuesta de SS_m (considerando el operador de combinación PMX y los valores de pesos $WC_{0.5-0.5}$) con ILS (la propuesta de RI desarrollada por miembros de nuestro grupo de investigación [Cordón, 06a]) y con dos algoritmos recientes del estado del arte en RI tratando con el enfoque de correspondencias de puntos: $I - ICP$ [Liu, 04] e $ICP + SA$ [Luck, 00]. Compararemos la calidad de la solución obtenida con estos tres métodos al resolver las dieciséis instancias del estudio. Como medida de comparación consideraremos el valor de *Error Cuadrático Medio* (ECM). El valor de ECM es más adecuado para comparar métodos de RI generales que el valor de g , ya que este último restringe su uso a aquellas aproximaciones basadas en permutación. Además, se trata de una métrica muy conocida y usada en la comunidad de RI basado en características [Besl, 92, Feldmar, 96, Yamany, 99]. Finalmente, el ECM se ha propuesto recientemente como una métrica estándar de rendimiento para prevenir posibles comparaciones injustas entre algoritmos de RI y motiva un análisis preciso estadísticamente [Robinson, 04].

La expresión del ECM, en el que cada punto transformado de la imagen escena se asigna con su correspondiente más cercano de la imagen modelo (sin considerar el que este último esté asignado con otro punto de la imagen escena), es la siguiente:

$$ECM = \frac{\sum_{i=1}^r \|f(\vec{x}_i) - \vec{y}_i\|^2}{r} \quad (2.7)$$

donde $f(\vec{x}_i)$ es la transformación espacial que sufre $\vec{x}_i \in I_e$ ($1 \leq i \leq r$) al aplicarle la transformación f estimada, \vec{y}_i es el punto de I_m más cercano a $f(\vec{x}_i)$, y r es el número de puntos de la imagen escena I_e .

Debemos tener en cuenta que al finalizar la ejecución de cualquier método de RI, la calidad del RI que se obtiene con la solución obtenida viene expresada según la ecuación 2.7, es decir, el valor de ECM. Se puede ver cómo F y ECM corresponden a expresiones de funciones con objetivos de evaluación diferentes. Sin embargo, en ciertas aplicaciones de RI, F y ECM podrían expresarse de la misma forma, por lo que no sería necesario realizar una segunda evaluación de la solución estimada por el método de RI para medir la calidad del RI.

Al igual que en los experimentos anteriores, proporcionamos el valor mínimo, el máximo, el promedio y la desviación típica del ECM para las quince ejecuciones independientes realizadas. Las Tablas 2.8 a 2.11 muestran los valores (redondeados) obtenidos por los cuatro algoritmos de RI para los experimentos con el repertorio de imágenes del *BrainWeb*, así como el valor de ECM de las soluciones óptimas (las correspondientes con el registrado de las dos imágenes consideradas mediante las transformaciones verdaderas recogidas en la Tabla 2.1), el cual aparece entre corchetes tras los dieciséis nombres de instancia. Se observa que cada número en esta tabla está redondeado.

Nuestra primera conclusión a la vista de los resultados recogidos en estas tablas es que se demuestra la relación entre los diferentes niveles de complejidad en las instancias de RI y los resultados obtenidos por cada algoritmo, de la misma forma que ocurría en las Tablas 2.3 a 2.6. Se puede observar cómo los valores de ECM obtenidos se alejan cada vez más del óptimo cuando se incrementa la complejidad del escenario de RI. Por otro lado, se puede ver cómo nuestra propuesta de RI SS_m consigue el mejor rendimiento medio en los dieciséis casos, así como el mejor valor de ECM mínimo en quince de los dieciséis casos.

Los pobres resultados de la contribución basada en ILS muestran que, a pesar de hacer uso de esta misma información heurística, nuestra propuesta de RI SS_m es capaz de hacer un mejor uso de la información dependiente del problema en un menor tiempo de ejecución. A pesar de ello, la propuesta basada en ILS consigue el mejor valor mínimo de ECM en una de las dieciséis instancias, siendo la segunda mejor propuesta de RI al contar con dieciséis mejores valores mínimos y ocho de dieciséis mejores valores medios, empatando en dos más, frente al tercer mejor algoritmo $ICP + SA$. Mientras tanto, el bajo valor de desviación típica muestra la robustez de nuestra propuesta SS_m , frente al elevado valor obtenido por la ILS. En particular, conseguimos uno de nuestros principales objetivos: diseñar un método de RI lo suficientemente competitivo en términos de eficacia y eficiencia trabajando

	$T_1[32]$				$T_2[21]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	344	247	97	<u>35</u>	131	131	61	<u>37</u>
M	-	344	752	40	-	131	482	50
μ	-	307	287	<u>37</u>	-	131	184	<u>43</u>
σ	-	38	186	2	-	0	119	4

I_1 V.s. $T_i(I_2)$

	$T_3[32]$				$T_4[47]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	894	457	96	<u>57</u>	632	283	181	<u>49</u>
M	-	711	751	67	-	611	1081	59
μ	-	559	288	<u>63</u>	-	465	413	<u>54</u>
σ	-	81	186	3	-	101	268	3

Tabla 2.8: Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_2 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita

en escenarios complejos de RI médico intrasujeto.

Para mostrar de forma clara el rendimiento real de cada técnica de RI cuando se abordan los problemas de RI con *BrainWeb* anteriormente introducidos, la Figura 2.12 recoge las inspecciones visuales del solapamiento conseguido por cada algoritmo de RI en cuatro de las dieciséis instancias consideradas, una por cada escenario de RI. Los gráficos 3D de la citada figura (concretamente, los gráficos de la fila segunda a la fila quinta) muestran la superposición de la imagen escena transformada con f estimada (f') y la imagen modelo. Obviamente, una mejor estimación de f obtiene un mayor solapamiento de las imágenes. Así, a partir de lo presentado en la citada figura, se puede ver cómo nuestra propuesta SS_m siempre obtiene el mejor registrado (ver las imágenes en la segunda fila). Podemos observar cómo la mejora de rendimiento con respecto al resto de algoritmos es mucho más destacada a medida que se incrementa el orden de complejidad del escenario de RI y que el enfoque basado en ILS es la única técnica de RI, aparte de la SS_m , que es capaz de proporcionar soluciones de calidad, aunque de forma poco robusta en comparación con nuestra propuesta de RI SS_m .

	$T_1[43]$				$T_2[30]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	518	305	106	<u>90</u>	330	237	69	<u>50</u>
M	-	432	837	132	-	297	549	66
μ	-	343	362	<u>112</u>	-	261	235	<u>57</u>
σ	-	32	121	2	-	18	136	4

I_1 Vs. $T_i(I_3)$

	$T_3[43]$				$T_4[62]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	438	279	98	<u>43</u>	478	336	143	<u>112</u>
M	-	389	853	235	-	429	1225	143
μ	-	347	357	<u>64</u>	-	382	520	<u>123</u>
σ	-	33	215	46	-	24	307	8

Tabla 2.9: Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_3 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita

	$T_1[46]$				$T_2[30]$			
	$I - ICP$	$ICP + SA$	ILS	SS_m	$I - ICP$	$ICP + SA$	ILS	SS_m
m	704	236	226	<u>149</u>	1493	314	137	<u>51</u>
M	-	466	889	269	-	388	561	167
μ	-	385	385	184	-	359	238	89
σ	-	61	167	33	-	22	110	41

I_1 Vs. $T_i(I_4)$

	$T_3[46]$				$T_4[67]$			
	$I - ICP$	$ICP + SA$	ILS	SS_m	$I - ICP$	$ICP + SA$	ILS	SS_m
m	951	312	215	<u>52</u>	416	342	307	95
M	-	433	873	227	-	413	1267	375
μ	-	381	381	82	-	367	553	154
σ	-	43	169	45	-	17	241	86

Tabla 2.10: Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_1 e I_4 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita

	$T_1[29]$				$T_2[18]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	237	230	<u>116</u>	128	341	142	78	<u>52</u>
M	-	237	971	298	-	341	626	188
μ	-	236	312	<u>193</u>	-	268	219	<u>75</u>
σ	-	2	236	62	-	71	153	41

I_2 Vs. $T_i(I_4)$

	$T_3[29]$				$T_4[45]$			
	$I-ICP$	$ICP+SA$	ILS	SS_m	$I-ICP$	$ICP+SA$	ILS	SS_m
m	609	399	108	<u>70</u>	1588	982	164	<u>105</u>
M	-	439	975	278	-	1533	1395	362
μ	-	407	338	<u>104</u>	-	1247	481	<u>150</u>
σ	-	10	238	67	-	209	339	78

Tabla 2.11: Valores de ECM obtenidos por los tres algoritmos de RI del estado del arte y nuestro método de RI SS_m considerando el escenario de problema de RI entre las imágenes I_2 e I_4 . La tabla se subdivide en cuatro subtablas para considerar las cuatro transformaciones que dan lugar a las diferentes instancias de RI a resolver. Los mejores valores de ECM mínimo y medio se muestran subrayados y en negrita

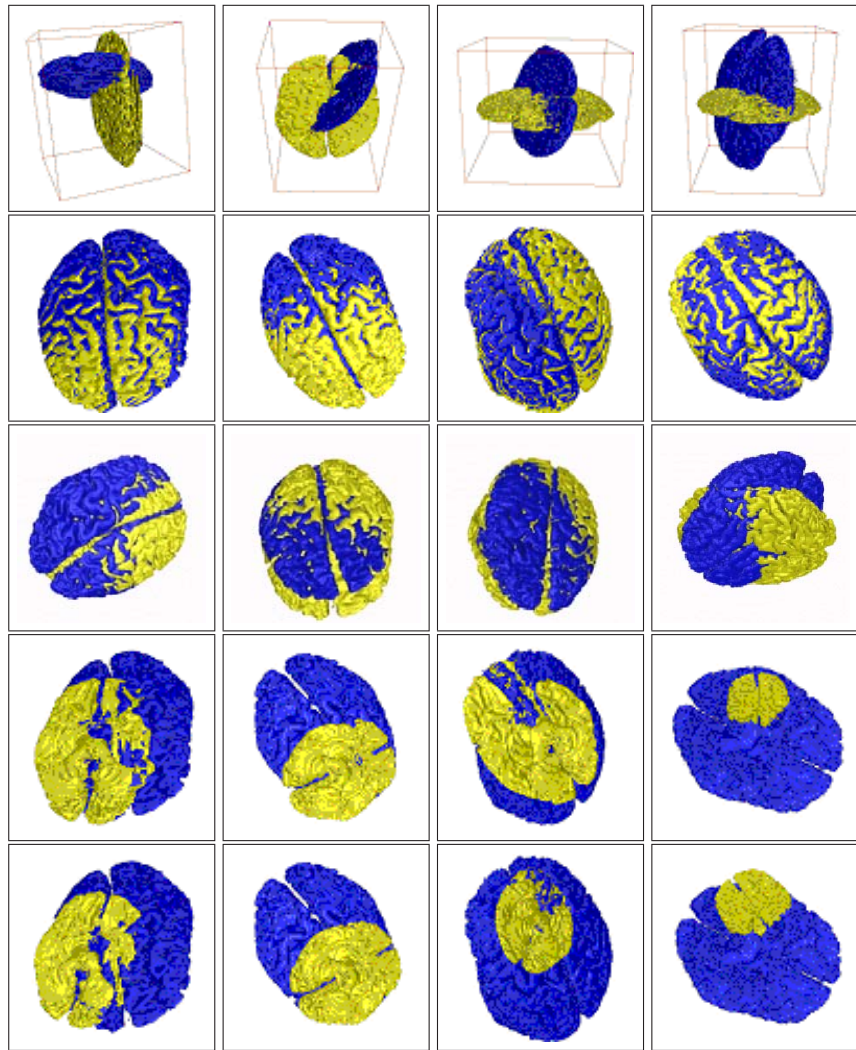


Figura 2.12: De izquierda a derecha, la primera fila corresponde a los gráficos 3D con la superposición obtenida en cuatro de las dieciséis instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada algoritmo de RI (de arriba a abajo: SS_m , ILS , $ICP + SA$ e $I - ICP$)

Conclusiones

En este capítulo hemos descrito el diseño de una nueva propuesta de RI que emplea el algoritmo SS para la búsqueda de soluciones de calidad en el espacio de las correspondencias. Se ha realizado un diseño específico para cada una de las componentes de SS, adaptado al enfoque de RI considerado. Para el análisis del rendimiento de nuestra propuesta, hemos configurado una amplia variedad de experimentos, para lo que hemos usado imágenes 3D del repositorio público *BrainWeb* que simulan resonancias magnéticas de cerebros humanos, de entre las que hemos seleccionado un repertorio donde se consideran situaciones con/sin ruido y otras con/sin lesión de esclerosis múltiple. El método desarrollado se ha comparado con otras propuestas de la literatura de RI, en especial con el método basado en el algoritmo ILS propuesto en la tesis doctoral del Dr. Damas [Damas, 03, Cordon, 06a], siendo nuestra propuesta la que ha mostrado unos resultados significativamente mejores al resto de métodos considerados.

En el siguiente capítulo abordaremos el problema de RI desde el enfoque de los parámetros de la transformación de registrado, presentando el diseño de un nuevo método de RI basado en SS para este enfoque. Los resultados obtenidos por esta propuesta se compararán con los conseguidos por otras propuestas de la literatura especializada en este enfoque, en especial la propuesta de CHC del Dr. Damas [Damas, 03]. Además, con ello pretendemos extraer una serie de conclusiones acerca de las características que nos pueden proporcionar ambas propuestas RI al tratar de resolver el problema de RI desde los dos enfoques considerados.

Capítulo 3

Registrado de imágenes en el espacio de la transformación

3.1. Introducción

Continuando con el trabajo desarrollado en el capítulo anterior, en el presente capítulo pretendemos profundizar en la mejora del rendimiento de nuestra primera propuesta basada en el emparejamiento de las correspondencias afrontando el problema de RI desde un enfoque distinto. En este caso consideraremos el enfoque de búsqueda de los valores apropiados para los parámetros de la transformación de registrado f . Por tanto, abordaremos el problema desde una perspectiva de optimización numérica, en concreto, de los parámetros de f , y no de optimización combinatoria como en el caso anterior.

Los algoritmos evolutivos (AEs) son las técnicas metaheurísticas de mayor aplicación como estrategia de optimización de la transformación de registrado, como así demuestra el volumen importante de contribuciones publicadas en las últimas décadas en la literatura especializada [Fitzpatrick, 84, Mandava, 89, Tsang, 97, Simunic, 98, Matsopoulos, 99, Yamany, 99, Rouet, 00, Chalermwat, 01, Chow, 01, He, 02, Cerdón, 06d]. Aunque estas propuestas evolutivas de métodos de RI tratan resolver los problemas asociados a los métodos clásicos que comentamos en el primer capítulo de esta memoria, aún presentan diferentes inconvenientes y limitaciones que analizaremos en la sección siguiente.

Tratando de resolver estos problemas, en este capítulo proponemos el uso del AE Scatter Search (SS) como estrategia de búsqueda de los mejores parámetros de la transformación de registrado. Gracias a la modularidad y fácil adaptabilidad con la que cuenta SS, nuestra propuesta de método de RI mantiene el esquema general desarrollado para la propuesta del capítulo anterior, rediseñando nuevas estrategias de búsqueda y construcción de soluciones para los componentes dependientes del problema tratado.

La estructura de este capítulo se divide en las siguientes secciones. En la Sec-

ción 3.2 se detallan los diferentes inconvenientes y limitaciones de las propuestas evolutivas de métodos de RI de mayor difusión en el estado del arte. Además, en la citada sección describimos algunas de las contribuciones más relevantes y recientes abordando esta perspectiva del problema RI. A continuación, en la Sección 3.3 detallamos tanto el esquema de codificación y la función objetivo como el diseño específico de las componentes de SS dependientes de la aplicación. En la Sección 3.4 se lleva a cabo la experimentación y el análisis de resultados obtenidos por nuestra propuesta en comparación con otros métodos de RI presentes en la literatura que trabajan con el enfoque de los parámetros de la transformación de registrado en los problemas de RI médicas considerados en el capítulo anterior. A continuación, la Sección 3.5 pretende analizar de forma conjunta el rendimiento obtenido por nuestras dos propuestas y el resto de métodos del estado del arte independientemente del esquema considerado: correspondencia de primitivas vs. optimización de parámetros de la transformación. Por último, se incluye una sección de conclusiones del capítulo.

3.2. Antecedentes

Esta sección está dedicada a presentar las primeras propuestas evolutivas de RI, detallando sus principales limitaciones al abordar el problema de RI. Además, en subsecciones posteriores describiremos algunas de las contribuciones más relevantes y recientes tratando el problema de RI desde esta perspectiva.

3.2.1. Primeras aproximaciones evolutivas al problema de registrado de imágenes

Prácticamente la totalidad de contribuciones de registrado que emplean AEs como esquema de optimización están basadas en el enfoque de RI de la búsqueda de los parámetros de la transformación (f). Dentro de esta familia de métodos, podemos encontrar soluciones de alta calidad con un diseño muy perfeccionado, así como enfoques en los que el AE no se construye de forma adecuada. A continuación pasamos a realizar una revisión analítica de los diferentes métodos evolutivos de RI propuestos en la literatura.

Los primeros intentos de resolver el registrado mediante técnicas de optimización global se encuentran a principios de los ochenta. El volumen de la información manejada así como el número de parámetros que se buscan prevenían de realizar una búsqueda exhaustiva de las soluciones. La primera aproximación basa-

da en un AG se propuso en 1984 para imágenes angiográficas 2D [Fitzpatrick, 84]. Desde esta contribución inicial, diversos autores han resuelto el problema mediante distintos enfoques pero aún encontramos importantes limitaciones en sus aproximaciones.

Como primera limitación se encuentra el uso de la codificación binaria para resolver un problema cuyas variables son inherentemente reales. Esto nos lleva a la situación de tener que equilibrar la magnitud de la transformación considerada y la precisión de la solución que se devuelve para un determinado número de bits en la codificación. Este tipo de situaciones sólo puede permitirse en entornos donde la precisión no es un requisito crítico o donde conozcamos a priori el rango de cambio de los parámetros que definen la transformación. Además, si intentamos obtener una solución más precisa aumentando el número de bits de la codificación, el tiempo de ejecución necesario para que el algoritmo alcance la convergencia aumentará también.

Por ejemplo, en 1989, *Mandava y otros* [Mandava, 89] usaron una estructura de 64 bits para representar una solución candidata al intentar encontrar los ocho parámetros de una transformación bilineal. *Tsang* [Tsang, 97] usaba cromosomas de 48 bits para codificar tres puntos de prueba como base de la estimación de una función de registrado afín 2D. En propuestas más recientes como la de *Yamany y otros* [Yamany, 99] y la de *Chalermwat y otros* [Chalermwat, 01], se sigue el mismo esquema de codificación binaria al enfrentarse con imágenes con transformaciones rígidas 3D y 2D respectivamente. Yamany y otros imponen un rango de $\pm 31^\circ$ sobre los ángulos de rotación y de ± 127 unidades en el desplazamiento al definir un cromosoma de 42 bits (ocho para cada parámetro de traslación y seis para cada ángulo de rotación). Por su parte, Chalermwat y otros usaban 12 bits para la codificación del parámetro de rotación 2D a fin de alcanzar un rango de búsqueda de $\pm 20.48^\circ$ (permitiendo así el uso de un factor de precisión para la discretización del intervalo continuo asociado al ángulo de rotación) y almacenaban en otros 10 bits cada uno de los dos parámetros de traslación (± 512 pixels).

Al margen del uso de la codificación binaria básica, el tipo de AG considerado es habitualmente el propuesto originalmente por Holland [Holland, 75], [Goldberg, 89]. Esto es, se usa una estrategia de selección basada en el mecanismo de asignación de probabilidad proporcional y en el muestreo estocástico con reemplazo (el conocido método de selección por ruleta), así como el operador clásico de cruce en un punto y la mutación simple por intercambio de un bit. De un lado, es bien sabido que la estrategia de selección mencionada causa una fuerte presión selectiva, teniendo por tanto un alto riesgo de convergencia prematura del algoritmo. De otro lado, también se ha demostrado que es difícil que el cruce en un único pun-

to proporcione descendientes útiles puesto que destruye los bloques constructores con mucha facilidad [Goldberg, 89].

Otro inconveniente importante de muchas contribuciones es que sólo manejan imágenes que han sufrido una transformación rígida [Simunic, 98, Chow, 01, He, 02]. Estas transformaciones pueden emplearse en un número limitado de aplicaciones prácticas pero éste no es el caso de muchas situaciones reales donde al menos sería deseable la posibilidad de incluir un factor de escala uniforme [Goshtasby, 05]. En el caso 2D, se han realizado diversas propuestas para considerar transformaciones bilineales o afines [Mandava, 89, Tsang, 97, Matsopoulos, 99], pero no así en 3D.

A continuación, realizamos un breve resumen de la descripción de algunas de las contribuciones más recientes y de mayor interés que solucionan en gran medida los inconvenientes planteados por los métodos anteriores.

3.2.2. Propuesta de Rouet y otros

En [Rouet, 00], los autores afrontan el registrado 3D MR-CT mediante un algoritmo con tres etapas. Primero, se determinan los parámetros de una transformación rígida mediante un AG con codificación real. A continuación, emplean otro AG para la correspondencia entre puntos que tratará de determinar una transformación trilineal global. Finalmente, proponen un análisis posterior de la población de salida del paso previo con el fin de alcanzar un ajuste más fino mediante un proceso de optimización local. Esta propuesta brinda una de las aproximaciones más completas al problema de registrado mediante AGs que hemos encontrado en la literatura. No obstante, identificamos algunos puntos débiles en la misma:

- Diversos estudios han demostrado que se precisa un equilibrio entre la tasa de diversidad y convergencia hacia la solución con el objetivo de alcanzar un buen comportamiento de cualquier AG (a fin de evitar quedar atrapados en mínimos locales). Aunque Rouet y otros usan el principio de *Latin squares*¹ para controlar la distribución de la población por el espacio de búsqueda, hay otras aproximaciones que pueden llevarse a cabo y que han demostrado una mayor eficacia. Las técnicas basadas en nichos [Deb, 89, Goldberg, 87, Goldberg, 89, Mahfoud, 95], o incluso algunos de los principios del algoritmo CHC [Eshelman, 91] son esquemas muy empleados en el área de la CE y parecen aproximaciones más apropiadas.

¹ Este procedimiento no es conocido en el área de la CE y sólo lo reconocemos como mecanismo inductor de diversidad por la explicación de los autores

- Además, el éxito del segundo paso del algoritmo depende de una definición precisa de la clase de curvatura en cada punto. Las medidas de curvatura requieren del cálculo de las derivadas de la curva o superficie que son operaciones complejas que pueden introducir errores de cálculo o, incluso peor, ser difíciles de obtener en el caso de superficies no estructuradas de cualquier forma.
- Por último, el uso de operadores simples (como el cruce uniforme) en un AG con codificación real no es la mejor opción, incluso si lo que pretendemos es mejorar la eficiencia de nuestro algoritmo [Herrera, 98].

3.2.3. Propuesta de He y Narayana

Esta contribución ([He, 02]) corresponde con una ligera mejora de la aproximación realizada por Yamany y otros [Yamany, 99], proponiendo un esquema de codificación real y haciendo uso de un operador de cruce aritmético y un operador de mutación uniforme dentro de un modelo generacional elitista que considera un mecanismo de reinicialización de la población. Esta propuesta se enfrenta a transformaciones rígidas siguiendo una técnica en dos pasos que realiza primero una estimación de parámetros preliminar mediante un AG con codificación real y después refina los resultados con un método de división en rectángulos desarrollando una búsqueda local. En la primera etapa, el rango de los parámetros se fijó a ± 20 vóxeles a lo largo de las direcciones x e y , y a ± 40 vóxeles en la dirección del eje z . No obstante, el ajuste de los parámetros entre ambas imágenes puede ser un punto débil cuando se trate de aplicar este método a entornos del mundo real, como veremos en las experimentaciones realizadas en este capítulo y el siguiente.

3.2.4. Propuesta de Cordón y otros

Miembros de nuestro grupo de investigación proponen en [Cordón, 06d] la solución al problema de RI haciendo uso de un AE avanzado como es el algoritmo CHC [Eshelman, 91]. En este trabajo se consideran imágenes MRI y la resolución del problema se enmarca en un enfoque basado en características, concretamente en líneas de cresta. El trabajo incluye el diseño de dos métodos distintos de RI basados en el algoritmo CHC. El primero de ellos emplea un esquema de representación binario y el operador de cruce *HUX* (siguiendo la propuesta original de CHC [Eshelman, 91]), mientras que el segundo considera un esquema real para la codificación de soluciones junto a diferentes operadores como el cruce *BLX* - α [Eshelman, 93]. En ambas propuestas se considera una transformación

de registrado diferente a las empleadas en las propuestas anteriores, como es la transformación de similitud, en la que se añade un parámetro adicional de escalado uniforme, necesario en ciertos escenarios tratando con imagen médica y otros como el RI aéreas y de satélite [Goshtasby, 05]. En este caso, se mantiene la misma función objetivo empleada en contribuciones previas modificandola ligeramente para tener en cuenta dicho factor de escala. Ambas propuestas se confrontaron con las anteriores en el RI MRI de cerebros obteniendo claramente un mejor rendimiento.

Por último, en línea con el trabajo desarrollado en esta memoria, hemos de decir que la propuesta presentada en esta sección obtenía buenos resultados. No obstante, la necesidad de afrontar diferentes problemas reales de RI con una mayor complejidad en un tiempo reducido, buscando obtener soluciones de mayor calidad, es lo que nos ha llevado a estudiar la propuesta de un nuevo método de RI empleando el AE SS, descrito de forma detallada en la sección siguiente.

3.3. Scatter Search para la búsqueda de los parámetros de la transformación de registrado

Según lo expuesto en el capítulo anterior, el hecho de que los mecanismos que componen la SS no estén restringidos a un simple diseño uniforme permite la exploración de nuevas estrategias que puedan resultar efectivas en una implementación particular, en nuestro caso, para el problema de RI. En la siguiente Figura 3.1 mostramos el pseudocódigo que describe el procedimiento algorítmico de nuestra propuesta de método de RI basado en SS para la optimización de los parámetros de la transformación de registrado.

Al igual que para la propuesta del capítulo anterior, hemos optado por incluir la componente opcional de búsqueda local con la intención de conseguir soluciones de alta calidad para intentar satisfacer de mejor forma los requisitos de nuestro problema. Además del cambio necesario en el *Método de Mejora* (notado como **MM** en la Figura 3.1), en la propuesta actual hemos considerado diseños particulares para los otros dos métodos dependientes de la aplicación, el *Método de Generación de Soluciones Diversas* (notado como **MGSD** en la Figura 3.1) y el *Método de Combinación* (notado como **MC** en la Figura 3.1). Por otro lado, hemos mantenido el diseño descrito en el capítulo anterior para los métodos independientes de la aplicación, es decir, el *Método de Generación de Subconjuntos* (notado como **MGS** en la Figura 3.1) y el *Método de Actualización del Conjunto de Rreferencia* (notado como **MACR** en la Figura 3.1), así como el uso del diseño avanzado del conjunto de referencia basado en un *modelo de dos capas*, además de emplear el

Algoritmo SS para el RI en el espacio de los parámetros de f :

$P \leftarrow \emptyset$

MIENTRAS ($|P| < PSize$) HACER

 Obtener una solución nueva x generada por el **MGSD**

 Mejorar x con el **MM** y generar x'

 SI ($x' \notin P$) ENTONCES $P \leftarrow P \cup \{x'\}$

Ordenar las soluciones en P según su valor de función objetivo (la mejor solución de P es aquella con el valor más alto de F ocupando la primera posición). Incluir las primeras b soluciones de P a $RefSet$

MIENTRAS (no se cumpla condición de parada) HACER

$NuevosElems \leftarrow Verdad$

$Lista \leftarrow \emptyset$

 MIENTRAS ($NuevosElems$) Y (no se cumpla condición de parada) HACER

 Generar $SubConj$ con el **MGS**

$NuevosElems \leftarrow Falso$

 MIENTRAS ($SubConj \neq \emptyset$) HACER

 Selecciona el siguiente subconjunto s de $SubConj$ y eliminarlo de $SubConj$

 Aplicar el **MC** sobre s para obtener una nueva solución x

 SI (el valor F de x es mejor que el de la solución mediana de $RefSet$) HACER

 Aplicar el **MM** a la solución x con una probabilidad de 0.0625 para obtener la solución x'

 SINO $x' \leftarrow x$

 Añadir x' a $Lista$

 Aplicar el **MACR** seleccionando las b mejores soluciones en $RefSet \cup Lista$

 SI ($RefSet$ tiene al menos una solución nueva) ENTONCES

$NuevosElems \leftarrow Verdad$

SI (no se cumple la condición de parada) ENTONCES

 Construir un nuevo conjunto P usando el **MGSD**

 Sustituir las $b - 1$ peores soluciones de $RefSet$ con las $b - 1$ mejores de P

Figura 3.1: Pseudocódigo del algoritmo SS para el RI en el espacio de los parámetros de f

mismo criterio de actualización *estático* del *RefSet*.

A continuación, describiremos tanto el esquema de codificación y la función objetivo como el diseño realizado para los tres métodos dependientes de la aplicación, es decir, el *Método de Generación de Soluciones diversas*, el *Método de Mejora* y el *Método de Combinación*.

3.3.1. Esquema de codificación y función objetivo

Al igual que en el capítulo anterior trabajaremos con una transformación de similitud 3D. Como esquema de codificación de soluciones hemos escogido representar la transformación de similitud mediante un vector de elementos reales, cada uno de los cuales codifica un parámetro del modelo de transformación considerado. De este modo, tenemos cuatro parámetros que codifican la rotación $R = (\alpha, Eje_X, Eje_Y, Eje_Z)$ (donde α y Eje_i , $i \in X, Y, Z$, definen respectivamente el ángulo y el eje para cierta rotación 3D), tres para la traslación $\vec{t} = (t_x, t_y, t_z)$ y uno para el factor de escalado uniforme s . Además, para una representación más apropiada de la rotación, hemos considerado una representación basada en *quaternions* en lugar de la basada en los tres parámetros de Euler con el propósito de solucionar el inconveniente que esta última tiene con el problema denominado *gimbal lock*².

Con objeto de mejorar el rendimiento del método evolutivo de RI, proponemos el diseño de una nueva función objetivo específica para nuestro problema de RI (notada como F). Trataremos con un problema de maximización muy similar a los manejados habitualmente en la literatura de RI con la salvedad de que, en nuestro caso, añadimos un segundo término que ayuda a conseguir una mejor estimación del parámetro de escalado de la transformación de similitud de un modo más sencillo. La expresión matemática de esta función objetivo es la siguiente:

$$F(f, I_e, I_m) = \omega_1 \cdot \left(\frac{1}{1 + \sum_{i=1}^N \|f(\vec{p}_i) - \vec{p}'_j\|^2} \right) + \omega_2 \cdot \left(\frac{1}{1 + |\rho_c^s - \rho^m|} \right) \quad (3.1)$$

donde I_e e I_m son las imágenes escena y modelo, f es la transformación codificada en la solución evaluada, \vec{p}_i es el i -ésimo punto 3D de la imagen escena y \vec{p}'_j es su

²Es un inconveniente originado por la representación de la rotación mediante los ángulos de Euler, la cual provoca la pérdida de un grado de libertad. Concretamente, este problema se produce cuando la rotación del segundo eje (generalmente, el eje Y) a 90 grados hace coincidir el primer y el último eje (los ejes X y Z), ocasionando resultados inesperados [Shoemake, 85].

homólogo más cercano en la imagen modelo, calculado mediante la estructura de indexación GCP (ver Sección 1.2.3), ω_1 y ω_2 ($\omega_1, \omega_2 \in [0, 1]$ y $\omega_1 + \omega_2 = 1$) son dos coeficientes que ponderan la importancia de cada término de F , ρ_c^s es el radio de la esfera que envuelve a la imagen escena transformada por la actual f , y ρ^m es el radio de la esfera que envuelve a la imagen modelo. Se debe observar como F toma su valor máximo en 1.0 para casos donde se obtiene un hipotético registrado perfecto.

Debemos señalar que el segundo término de F es necesario para estimar de forma apropiada los cambios de escala en imágenes. Nótese que si obviáramos este segundo término, al tratarse de una maximización, cuanto más próximo fuera s a cero, tanto más se evaluaría como mejor la solución propuesta³. De esta forma, con $s \simeq 0$ se lograría un «falso» máximo de F . Esto nos lleva a evitar que dicho factor sea nulo y que tengamos que definir un rango apropiado de valores para él (introduciendo el segundo término de F).

Finalmente, con el propósito de acelerar el proceso de construcción del GCP, hemos realizado una mejora sobre éste a través del uso de otra estructura de indexación basada en un Kd-tree ([Zhang, 94], ver Sección 1.2.3), que resulta ser mucho más eficiente que la propuesta original donde se emplea una estrategia de búsqueda exhaustiva. De esta forma, GCP logra realizar el cálculo del vecino más cercano en tiempo constante, salvo para aquellos puntos de la imagen escena que, tras aplicarles la transformación de registrado f , caen fuera de la rejilla que alberga a I_e e I_m . En estos casos, se obtiene un tiempo de respuesta de orden logarítmico al realizar la búsqueda en el Kd-tree, el cual se basa en una estructura de árbol binario.

3.3.2. Método de Generación de Soluciones Diversas

Este método hace uso de una aleatorización controlada según una memoria de frecuencias para generar el conjunto inicial de soluciones P , siguiendo las directrices de implementación descritas en [Glover, 03b]. Para ello, se divide el rango de cada variable (en nuestro caso, cada uno de los ocho parámetros de la transformación de similitud) en cuatro subrangos de igual tamaño. La solución se construye en dos pasos. En primer lugar, para cada parámetro seleccionamos de forma aleatoria uno de los cuatro subrangos, donde la probabilidad de selección es inversamente proporcional al número de veces que dicho subrango ha sido seleccionado durante el proceso de generación. Inicialmente, esta memoria de frecuencias se inicializa a

³Obviamente, un factor de escala $s = 0$ aplicado sobre cualquier imagen significaría la disminución uniforme de la imagen hasta alcanzar un 0% de su tamaño original, esto es, su «desaparición».

1 para cada parámetro y el número de veces que cierto subrango j se ha seleccionado para generar un valor para el parámetro i -ésimo de la solución se acumula en dicho contador (*contador_de_frecuencias(i,j)*). Posteriormente, se genera un valor dentro del subrango seleccionado de forma aleatoria.

3.3.3. Método de Combinación

Para este componente hemos usado los operadores de combinación *Combinación lineal múltiple* [Glover, 03b], *BLX- α* [Eshelman, 93] y *PBX- α* [Herrera, 05]. De entre los anteriores métodos, el BLX- α fue el que proporcionó mejores prestaciones en nuestra propuesta de RI basada en SS. BLX- α es un operador de cruce típico en AGs con codificación real. Este mecanismo de combinación obtiene una solución combinada, $x = (h_1, \dots, h_k, \dots, h_l)$ (donde $l = 8$ es el número de parámetros de la transformación de similitud y h_k el valor asociado con la variable k -ésima) de las dos soluciones padre $x^1 = (c_1^1, \dots, c_l^1)$ y $x^2 = (c_1^2, \dots, c_l^2)$ que componen el subconjunto s , generando uniformemente un valor aleatorio para cada variable h_k en el intervalo $[c_{min} - I \cdot \alpha, c_{max} + I \cdot \alpha]$, con $c_{max} = \max(c_k^1, c_k^2)$, $c_{min} = \min(c_k^1, c_k^2)$, e $I = c_{max} - c_{min}$. De este forma, el parámetro α permite establecer un balance entre exploración y explotación. Este operador de combinación ya fue incorporado con éxito a SS en [Lozano, 04].

3.3.4. Método de Mejora

Si bien es posible realizar un diseño de SS sin este método, hemos decidido incorporarlo con el objetivo de obtener soluciones de alta calidad. Así pues, para obtener un balance apropiado entre la cantidad de mejora de la solución y el tiempo consumido, hemos decidido ejecutar la búsqueda local sobre cada nueva solución generada por el *Método de Generación de Soluciones Diversas* y hacerlo de forma selectiva en el *Método de Combinación*, aplicándolo sólo sobre algunas de ellas con la intención de lograr una convergencia rápida a buenas soluciones. Para ello, hemos considerado como criterio de aplicación selectiva del optimizador local una selección aleatoria basada en una cierta probabilidad con un valor bajo, en concreto de $1/16 = 0.0625$. El uso de este valor de probabilidad se justifica en [Hart, 94] y se aplicó con éxito en [Lozano, 04, Herrera, 05].

En este caso, hemos considerado los algoritmos *Simplex* [Nelder, 65] y *Solis&Wets* [Solis, 81] para el *Método de Mejora*. Tras realizar una experimentación preliminar, escogimos este último para la mejora de soluciones generadas en el procedimiento de SS. El algoritmo de búsqueda local *Solis&Wets* es un proce-

dimiento aleatorio de ascenso de colinas (*hill-climber*) con un tamaño adaptativo del paso para generar soluciones vecinas. Cada ejecución comienza a partir de una solución inicial x . Se selecciona un valor de adaptación δ según una distribución normal cuya desviación típica viene dada por un parámetro ρ . El proceso de búsqueda se mueve hacia la mejor solución originada por el movimiento $x + \delta$ o el movimiento $x - \delta$, en caso de que sea mejor que la solución actual, y se cuenta el éxito conseguido. En otro caso, se contabiliza como fracaso. Tras conseguir varios movimientos con éxito en una misma dirección, se incrementa la variable ρ para aumentar el tamaño del paso entre movimientos. Por el contrario, tras varios movimientos fallidos en una misma dirección, se decrementa ρ con el propósito de centrar la búsqueda en una región más localizada del espacio de búsqueda.

3.4. Experimentación y análisis de resultados

Con la intención de estudiar el rendimiento de nuestra propuesta, en esta sección presentamos una serie de experimentos diseñados para estimar varias transformaciones de registro considerando un repertorio de imágenes médicas 3D. Al igual que hemos hecho en el capítulo anterior, el reto más importante asociado con la presente experimentación se centra en que el objetivo del proceso de RI es registrar *dos imágenes diferentes de objetos similares*, en lugar de dos imágenes de un mismo objeto, con lo que se está tratando resolver un escenario realista en aplicaciones de RI para entornos médicos.

Para ello, volvemos a hacer uso del repertorio de imágenes presentado en el capítulo anterior proveniente del almacén público *BrainWeb*. Haciendo un repaso de lo explicado en dicho capítulo, hemos seleccionado cuatro imágenes MRI de este repertorio simulando la captación de objetos del mundo real, en concreto se trata de imágenes MRI de cerebros humanos. En particular, tres de ellas presentan ruido, lesiones de esclerosis múltiple y cierto grado de oclusión.

Nuestra propuesta de algoritmo de optimización real basado en SS se comparará en primer lugar con la contribución previa [Cordón, 06d] realizada por investigadores de nuestro grupo de investigación en la que se desarrollan dos métodos de RI basados en el AE CHC tanto para codificación real como binaria, respectivamente, notados como CHC_{Real} y CHC_{Bin} . Además, hemos considerado otras técnicas evolutivas de RI que abordan el enfoque de los parámetros de la transformación f , como son los métodos GA_{Yamany} [Yamany, 99] y GA_{He} [He, 02], bien conocidos en el área y descritos en la Sección 3.2. Los dos algoritmos anteriores se mantienen en su forma original, con la salvedad de que, por tratar en nuestro caso con una transformación de mayor dimensionalidad como es la transformación

de similitud, ambos métodos se han adaptado con ligeros cambios para estimar el parámetro adicional de escalado uniforme (las dos propuestas originales sólo son capaces de tratar con transformaciones de tipo rígido, es decir, sólo consideran rotación y traslación). En concreto, el tamaño de la solución (vector de parámetros) se incrementa en una unidad para considerar este último parámetro y se incorpora la función objetivo diseñada en este capítulo (ver Sección 3.3.1).

3.4.1. Diseño del experimento

Esta subsección describe la configuración experimental con la que evaluaremos el rendimiento de nuestra propuesta de RI basada en SS que trabaja en el enfoque de los parámetros de la transformación.

En concreto, hacemos uso del repertorio de imágenes médicas 3D del capítulo anterior, así como de los cuatro escenarios de RI resultantes de la combinación de pares de estas imágenes (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$, e I_2 Vs. $T_i(I_4)$) y las mismas cuatro transformaciones ⁴ consideradas en dicho capítulo, abordando así un total de dieciséis instancias de problema de RI.

A continuación pasamos a describir el ajuste de los valores de los parámetros de nuestra propuesta de SS y del resto de algoritmos de RI considerados en esta sección experimental. Para ello, hemos realizado un estudio preliminar para determinar los valores de parámetros más apropiados para los diferentes algoritmos de RI que se consideran en la posterior experimentación. Tanto la prueba preliminar como la experimentación final se han realizado en una plataforma con procesador Intel Pentium IV a 2.6 MHz. Todos los algoritmos han sido implementados con el lenguaje de programación C++ y compilados para ser ejecutados en sistema operativo GNU-Linux.

Nuestra propuesta de RI basada en SS, notada como SS_p , crea el conjunto inicial P con $Psize = 30$ soluciones diversas y el $RefSet$ con un total de $b = b_1 + b_2 = 8$ soluciones donde $b_1 = 8$ (subconjunto de calidad $|RefSet_1| = 8$). En estudios de parámetros preliminares para nuestra propuesta de SS observamos cómo con $b_2 = 0$ (es decir, al no considerar el subconjunto de diversidad $RefSet_2$) obteníamos un mejor rendimiento global de nuestro método de RI. Esto se relaciona con el valor que hemos fijado para el parámetro α de BLX- α en el *Método de Combinación*, cuyo valor de 0.3 proporciona un nivel de diversidad comparable

⁴Nótese que al igual que en el Capítulo 2, conoceremos a priori el valor exacto de las transformaciones que relacionan cada par de imágenes al objeto de poder llevar a cabo una adecuada evaluación de cada uno de los métodos de RI que se han considerado.

al que aportaría el subconjunto de diversidad $RefSet_2$ en el bajo tiempo de ejecución que fijamos para el algoritmo. En último lugar, realizamos una aplicación selectiva del *Método de Mejora*, que se ejecuta un máximo de 80 iteraciones cada vez que se aplica.

Para los algoritmos CHC_{Real} , CHC_{Bin} , GA_{Yamany} y GA_{He} , el tamaño de la población de individuos es de 100 soluciones. Con respecto al número de bits asignados a cada gen (cada gen codifica un parámetro concreto del modelo de transformación de registrado) en los algoritmos GA_{Yamany} y CHC_{Bin} , con la intención de conseguir registrados precisos, hemos preferido considerar individuos de gran longitud debido a la amplitud de las transformaciones de registrado consideradas. Esto nos permite definir un cromosoma binario (solución al problema de RI) como una estructura de 80 bits de longitud: diez bits para cada uno de los ocho parámetros de la transformación de similitud. Por otro lado, el parámetro α del operador de cruce $BLX-\alpha$, empleado en los algoritmos GA_{He} y CHC_{Real} , se ha fijado a 0.5 con el propósito de propiciar un balance más apropiado en cuanto a la naturaleza explorativa/explotativa de sus respectivas estrategias de búsqueda. Por último, las probabilidades de cruce y mutación se han fijado a $P_c = 0.6$ y $P_m = 0.1$ en los algoritmos GA_{Yamany} y GA_{Bin} .

Para todos los algoritmos anteriores, hemos establecido un tiempo máximo de CPU de 20 segundos en cada ejecución, así como un total de 15 ejecuciones diferentes para cada uno de ellos (con semillas distintas para el generador de números aleatorios) en cada una de las dieciséis instancias de problema, con la intención de eludir el usual sesgo aleatorio introducido por los algoritmos probabilísticos de optimización.

3.4.2. Análisis de resultados

Como en la sección homóloga del Capítulo 2, todos los resultados estadísticos mostrados a continuación se basan en la medida del *Error Cuadrático Medio* (ECM), calculado según la expresión:

$$ECM = \frac{\sum_{i=1}^r \|f(\vec{x}_i) - \vec{y}_i\|^2}{r} \quad (3.2)$$

donde $f(\vec{x}_i)$ es la transformación espacial que sufre $\vec{x}_i \in I_e$ ($1 \leq i \leq r$) al aplicarle la transformación f estimada, \vec{y}_i es el punto de I_m más cercano a $f(\vec{x}_i)$ y r es el número de puntos de la imagen escena I_e .

En las Tablas 3.1 a 3.4 presentamos el rendimiento ofrecido por nuestra pro-

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	32	32	<u>32</u>	0	21	21	<u>21</u>	0
GA_{Yamany}	34	114	60	32	25	74	53	16
GA_{He}	33	43	38	3	21	50	27	9
CHC_{Bin}	32	113	51	27	21	74	29	15
CHC_{Real}	32	32	<u>32</u>	0	21	49	30	13

I_1 Vs. $T_i(I_2)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	32	32	<u>32</u>	0	47	47	<u>47</u>	0
GA_{Yamany}	37	122	65	31	49	152	79	42
GA_{He}	32	42	35	2	47	115	55	17
CHC_{Bin}	32	77	37	12	47	221	66	44
CHC_{Real}	32	32	<u>32</u>	0	47	47	<u>47</u>	0

Tabla 3.1: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado

puesta de RI basada en SS y el resto de métodos de RI del estado del arte. Cada una de las cuatro tablas muestra los resultados (redondeados) obtenidos por dichos métodos para los correspondientes escenarios de problema de RI recogidos en la sección anterior: I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$, e I_2 Vs. $T_i(I_4)$. A su vez, cada tabla se divide en cuatro subtablas, una para cada transformación de registrado: T_1 , T_2 , T_3 , y T_4 . Así pues, los resultados mostrados corresponden a un total de dieciséis instancias diferentes de problema de RI a resolver y quince ejecuciones distintas para cada uno de los cinco métodos considerados, es decir, estamos tratando con valores estadísticos obtenidos de mil doscientas ejecuciones en total.

A la vista de los datos resumidos en las Tablas 3.1 a 3.4, observamos cómo nuestra propuesta basada en SS ofrece los mejores resultados en cuanto a valores mínimos y medios de ECM. Concretamente, SS_p alcanza el mejor valor en quince

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	65	66	<u>65</u>	0	41	42	<u>41</u>	0
GA_{Yamany}	67	150	81	26	46	119	64	23
GA_{He}	65	77	71	4	42	48	44	2
CHC_{Bin}	65	207	76	35	41	94	55	21
CHC_{Real}	65	66	66	0	41	85	44	11

I_1 Vs. $T_i(I_3)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	64	65	<u>64</u>	0	93	94	<u>93</u>	0
GA_{Yamany}	79	167	108	33	93	209	123	38
GA_{He}	67	83	71	4	94	200	113	34
CHC_{Bin}	64	134	75	23	93	113	99	9
CHC_{Real}	64	64	<u>64</u>	0	93	191	100	25

Tabla 3.2: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_3)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_3)$ e I_1 Vs. $T_4(I_3)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	48	48	<u>48</u>	0	31	31	<u>31</u>	0
GA_{Yamany}	48	129	58	23	33	80	48	18
GA_{He}	50	68	55	5	31	67	36	8
CHC_{Bin}	48	123	74	31	31	78	48	18
CHC_{Real}	48	49	<u>48</u>	0	31	65	35	11

I_1 Vs. $T_i(I_4)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	48	48	<u>48</u>	0	69	70	<u>70</u>	0
GA_{Yamany}	61	135	83	24	73	171	88	33
GA_{He}	49	67	54	5	71	84	75	4
CHC_{Bin}	48	101	52	13	69	72	<u>70</u>	1
CHC_{Real}	48	48	<u>48</u>	0	70	70	<u>70</u>	0

Tabla 3.3: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_4)$, I_1 Vs. $T_2(I_4)$, I_1 Vs. $T_3(I_4)$ e I_1 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	29	29	<u>29</u>	0	18	18	18	0
GA_{Yamany}	33	101	54	31	27	71	41	15
GA_{He}	29	33	30	1	18	49	21	7
CHC_{Bin}	28	96	45	25	18	68	28	15
CHC_{Real}	29	75	32	12	18	48	30	14

I_2 Vs. $T_i(I_4)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	29	29	<u>29</u>	0	45	45	<u>45</u>	0
GA_{Yamany}	52	114	70	25	50	149	77	38
GA_{He}	29	33	31	1	45	49	<u>45</u>	2
CHC_{Bin}	29	214	58	56	45	146	54	30
CHC_{Real}	29	29	<u>29</u>	0	45	45	<u>45</u>	0

Tabla 3.4: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_2 Vs. $T_1(I_4)$, I_2 Vs. $T_2(I_4)$, I_2 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada uno de los métodos SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . El mejor valor mínimo de ECM (m) aparece señalado en negrita y el mejor valor medio de ECM (μ) subrayado

de las dieciséis instancias, sólo superado por CHC_{Bin} en la instancia I_2 Vs. $T_1(I_2)$, y consigue el mejor valor medio de ECM en siete de las dieciséis instancias, empatando en todas las instancias restantes con otros métodos. En particular, CHC_{Real} es el método de RI que consigue empatar con nuestra propuesta SS_p en nueve de las dieciséis instancias según el valor medio del ECM. Atendiendo a la desviación típica (σ), SS_p demuestra su robustez frente al resto de métodos, alcanzado en las dieciséis instancias un valor despreciable o nulo, seguido de nuevo por CHC_{Real} . Por otro lado, GA_{He} y CHC_{Bin} se posicionan tras SS_p y CHC_{Real} , obteniendo el primero (GA_{He}) un mejor rendimiento global debido a su mejor diseño al contar con un esquema de codificación real, más apropiado para el problema de RI. Por último, la versión binaria GA_{Yamany} ostenta la última posición, por detrás de CHC_{Bin} , en el ranking de métodos según rendimiento en base al ECM. Al igual que en el capítulo anterior, la Figura 3.2 recoge las inspecciones visuales del mejor solapamiento conseguido por cada métodos de RI en cuatro de las dieciséis instancias consideradas.

Las Figuras 3.3 a 3.5 muestran mediante gráficas de barras lo comentado anteriormente en cuanto al rendimiento promedio según valor medio de ECM (μ). Mientras la Figura 3.3 muestra el rendimiento de cada método en función de la transformación considerada, la Figura 3.4 refleja también el rendimiento de éstos en base a cada uno de los cuatro escenarios tratados. Por último, la Figura 3.5 resume las dos gráficas anteriores y muestra el comportamiento de cada método tras afrontar la resolución de las dieciséis instancias de RI que se han considerado, donde se puede observar cómo los métodos con esquema de codificación real (SS_p , CHC_{Real} y GA_{He}) consiguen un mejor rendimiento frente a los que usan codificación binaria (CHC_{Bin} y GA_{Yamany}), siendo nuestra propuesta SS_p la que consigue un mejor rendimiento global.

3.5. Comparativa resumen entre los dos enfoques de registrado

Esta sección pretende ser el nexo de unión entre el capítulo actual y el anterior, permitiendo que se pueda comparar el rendimiento de nuestras propuestas de RI basadas en el AE SS, cada una de las cuales trata de resolver el problema de registrado desde dos perspectivas de optimización distintas. Además, incluimos también los diferentes métodos de RI del estado del arte ($I - ICP$, $ICP + SA$, ILS , CHC_{Real} , CHC_{Bin} , GA_{Yamany} y GA_{He}) considerados tanto en el enfoque de la búsqueda en el espacio de correspondencias como en el de la búsqueda en el




Figura 3.2: De izquierda a derecha, la primera fila corresponde a los gráficos 3D mostrando la superposición obtenida en cuatro de las dieciséis instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada algoritmo de RI (de arriba a abajo: SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real})

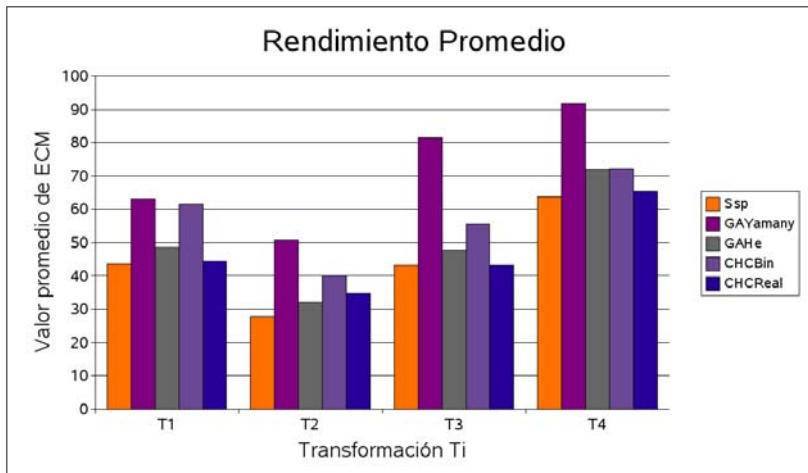


Figura 3.3: Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), se promedia el valor medio de ECM (μ) de cada método en los cuatro escenarios de problema de registrado (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$)




Figura 3.4: Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada uno de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$), se promedia el valor medio de ECM (μ) de cada método en las cuatro transformaciones de registrado a estimar (T_1 , T_2 , T_3 y T_4)




Figura 3.5: Gráfica de barras que muestra el rendimiento promedio de SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada método, en primer lugar, se promedia el valor medio de ECM (μ) de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), y después se obtiene el promedio de los cuatro valores anteriores

espacio de la transformación de registrado f con el objetivo de esclarecer la repercusión que tienen tanto nuestros resultados como el enfoque de RI empleado.

Para llevar a cabo dicho análisis, las Tablas 3.5 a 3.8 presentan la misma estructura que las anteriores en cuanto a la distribución de los resultados. Los datos estadísticos se han extraído de los presentados en las tablas de las correspondientes secciones de análisis de resultados de este capítulo y del anterior.

Las Figuras 3.6 a 3.8 resumen en sendas gráficas de barras y de líneas los datos mostrados en las Tablas 3.5 a 3.8, reflejando, respectivamente, el valor promedio de ECM (obtenido a partir del valor medio μ) por transformación y por escenario, así como el global de ambos.




Figura 3.6: Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), se promedia el valor medio de ECM (μ) de cada método en los cuatro escenarios de problema de registrado (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$)

Podemos observar en las Tablas 3.5 a 3.8 cómo los métodos del enfoque de las correspondencias (SS_m , ILS , $I - ICP$ e $ICP + SA$) ven afectado su rendimiento a medida que aumenta el grado de complejidad del escenario (ver Figura 3.9), comenzando en I_1 Vs. $T_i(I_2)$ y finalizando en I_2 Vs. $T_i(I_4)$. Esto se debe a la inesta-

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	35	40	37	2	37	50	43	4
ILS	97	752	287	186	61	482	184	119
$ICP + SA$	247	344	307	38	131	131	131	0
$I - ICP$	344	-	-	-	131	-	-	-
SS_p	32	32	32	0	21	21	21	0
GA_{Yamany}	34	114	60	32	25	74	53	16
GA_{He}	33	43	38	3	21	50	27	9
CHC_{Bin}	32	113	51	27	21	74	29	15
CHC_{Real}	32	32	32	0	21	49	30	13

I_1 Vs. $T_i(I_2)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	57	67	63	3	49	59	54	3
ILS	96	751	288	186	181	1081	413	268
$ICP + SA$	457	711	559	81	283	611	465	101
$I - ICP$	894	-	-	-	632	-	-	-
SS_p	32	32	32	0	47	47	47	0
GA_{Yamany}	37	122	65	31	49	152	79	42
GA_{He}	32	42	35	2	47	115	55	17
CHC_{Bin}	32	77	37	12	47	221	66	44
CHC_{Real}	32	32	32	0	47	47	47	0

Tabla 3.5: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	90	132	112	12	50	66	57	4
ILS	106	837	362	121	69	549	235	136
$ICP + SA$	305	432	343	32	237	297	261	18
$I - ICP$	518	-	-	-	330	-	-	-
SS_p	65	66	65	0	41	42	41	0
GA_{Yamany}	67	150	81	26	46	119	64	23
GA_{He}	65	77	71	4	42	48	44	2
CHC_{Bin}	65	207	76	35	41	94	55	21
CHC_{Real}	65	66	66	0	41	85	44	11

I_1 Vs. $T_i(I_3)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	43	235	64	46	112	143	123	8
ILS	98	853	357	215	143	1225	520	307
$ICP + SA$	279	389	347	33	336	429	382	24
$I - ICP$	438	-	-	-	478	-	-	-
SS_p	64	65	64	0	93	94	93	0
GA_{Yamany}	79	167	108	33	93	209	123	38
GA_{He}	67	83	71	4	94	200	113	34
CHC_{Bin}	64	134	75	23	93	113	99	9
CHC_{Real}	64	64	64	0	93	191	100	25

Tabla 3.6: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_3)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_3)$ e I_1 Vs. $T_4(I_3)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	149	269	184	33	51	167	89	41
ILS	226	889	385	167	137	561	238	110
$ICP + SA$	236	466	385	61	314	388	359	22
$I - ICP$	704	-	-	-	1493	-	-	-
SS_p	48	48	48	0	31	31	31	0
GA_{Yamany}	48	129	58	23	33	80	48	18
GA_{He}	50	68	55	5	31	67	36	8
CHC_{Bin}	48	123	74	31	31	78	48	18
CHC_{Real}	48	49	48	0	31	65	35	11

I_1 Vs. $T_i(I_4)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	52	227	82	45	95	375	154	86
ILS	215	873	381	169	307	1267	553	241
$ICP + SA$	312	433	381	43	342	413	367	17
$I - ICP$	951	-	-	-	416	-	-	-
SS_p	48	48	48	0	69	70	70	0
GA_{Yamany}	61	135	83	24	73	171	88	33
GA_{He}	49	67	54	5	71	84	75	4
CHC_{Bin}	48	101	52	13	69	72	70	1
CHC_{Real}	48	48	48	0	70	70	70	0

Tabla 3.7: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_4)$, I_1 Vs. $T_2(I_4)$, I_1 Vs. $T_3(I_4)$ e I_1 Vs. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	128	298	193	62	52	188	75	41
ILS	116	971	312	236	78	626	219	153
$ICP + SA$	230	237	236	2	142	341	268	71
$I - ICP$	237	-	-	-	341	-	-	-
SS_p	29	29	29	0	18	18	18	0
GA_{Yamany}	33	101	54	31	27	71	41	15
GA_{He}	29	33	30	1	18	49	21	7
CHC_{Bin}	28	96	45	25	18	68	28	15
CHC_{Real}	29	75	32	12	18	48	30	14

 I_2 V.s. $T_i(I_4)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	70	278	104	67	105	362	150	78
ILS	108	975	338	238	164	1395	481	339
$ICP + SA$	399	439	407	10	962	1533	1247	209
$I - ICP$	609	-	-	-	1588	-	-	-
SS_p	29	29	29	0	45	45	45	0
GA_{Yamany}	52	114	70	25	50	149	77	38
GA_{He}	29	33	31	1	45	49	45	2
CHC_{Bin}	29	214	58	56	45	146	54	30
CHC_{Real}	29	29	29	0	45	45	45	0

Tabla 3.8: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_2 V.s. $T_1(I_4)$, I_2 V.s. $T_2(I_4)$, I_2 V.s. $T_3(I_4)$ e I_2 V.s. $T_4(I_4)$ tras realizar 15 ejecuciones diferentes para cada método SS_m , ILS , $ICP + SA$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} ($I - ICP$ es un algoritmo determinístico). En negrita y subrayado aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ). Además, aparecen resaltados también en negrita los mejores valores mínimo y medio de ECM para los cuatro primeros métodos de RI basados en correspondencias




Figura 3.7: Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada uno de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$), se promedia el valor medio de ECM (μ) de cada método en las cuatro transformaciones de registrado a estimar (T_1 , T_2 , T_3 y T_4)




Figura 3.8: Gráfica de barras que muestra el rendimiento promedio de SS_m , ILS , $ICP + SA$, $I - ICP$, SS_p , GA_{Yamany} , GA_{He} , CHC_{Bin} y CHC_{Real} . Para cada método, en primer lugar, se promedia el valor medio de ECM (μ) de los cuatro escenarios (I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$) para cada una de las cuatro transformaciones (T_1 , T_2 , T_3 y T_4), y después se obtiene el promedio de los cuatro valores anteriores




Figura 3.9: Gráfica de líneas que muestra el rendimiento promedio de SS_m frente a SS_p para cada una de los cuatro escenarios. Para cada uno de los dos métodos, se realiza el promedio del valor medio de ECM (μ) de las transformaciones T_1 , T_2 , T_3 y T_4 en cada escenario I_1 Vs. $T_i(I_2)$, I_1 Vs. $T_i(I_3)$, I_1 Vs. $T_i(I_4)$ e I_2 Vs. $T_i(I_4)$

bilidad de estos métodos al tratar de establecer correspondencias entre conjuntos dispares de puntos, lo que redundaría en perjuicio de la estimación de la transformación de registración por parte del método numérico considerado. A pesar de lo anterior, vemos cómo los métodos basados en metaheurísticas avanzadas, SS_m e ILS , poseen un rendimiento considerablemente superior al de los métodos de la literatura, $I-ICP$ y el método híbrido $ICP+SA$, siendo esto un hecho significativo si tenemos en cuenta que, a diferencia de los primeros, estos dos últimos métodos incorporan mecanismos específicos para responder de forma robusta ante este tipo de instancias complejas. En el extremo opuesto se encuentran los métodos que trabajan en el segundo enfoque de RI, donde no sólo no se observa el comportamiento anterior sino que además consiguen los mejores valores mínimos de ECM.

Analizando nuestras dos propuestas por separado, debemos señalar que tanto SS_m como SS_p mejoran el rendimiento obtenido por los diferentes métodos que operan dentro de sus respectivos espacios de búsqueda. Además, un hecho muy destacable es que SS_m , basada en el espacio de correspondencias, es capaz de

mejorar el rendimiento de GA_{Yamany} en las instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$, I_1 Vs. $T_4(I_2)$, I_1 Vs. $T_2(I_3)$ e I_1 Vs. $T_4(I_3)$, y el de los métodos GA_{He} y CHC_{Bin} en I_1 Vs. $T_1(I_2)$ e I_1 Vs. $T_4(I_2)$, consiguiendo además el mejor resultado, también obtenido por SS_p , en la instancia I_1 Vs. $T_3(I_3)$. Por último, nuestra segunda versión SS_p ofrece el mejor rendimiento promedio sobre el conjunto total de instancias (dieciséis) que hemos considerado en esta experimentación (ver Figura 3.8).

Para finalizar la comparación directa entre nuestras propuestas, la Figura 3.10 muestra con gráficos 3D algunas de las mejores estimaciones de SS_m y SS_p .




Figura 3.10: De izquierda a derecha, la primera fila corresponde a los gráficos 3D mostrando la superposición obtenida en cuatro de las dieciséis instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_3)$, I_1 Vs. $T_3(I_4)$ e I_2 Vs. $T_4(I_4)$, mientras que las siguientes cuatro filas corresponden con las mejores estimaciones de registrado logradas por cada una de nuestras propuestas de RI basadas en SS (de arriba a abajo: SS_m y SS_p)

Conclusiones

En este capítulo hemos descrito el diseño de una nueva propuesta de RI que emplea el algoritmo SS para la búsqueda eficaz y eficiente de soluciones en el espacio de los parámetros de la transformación de registrado. Por motivos de coherencia a nivel experimental, hemos mantenido el diseño experimental del capítulo anterior considerando los mismos escenarios e instancias de RI diseñados a partir del repertorio de imágenes de *BrainWeb*. El método desarrollado se ha comparado con otros métodos de la literatura especializada basados en este enfoque de RI, siendo el que ha obtenido los mejores resultados. Por último, el capítulo ha concluido con la puesta en común de los resultados obtenidos por todos y cada uno de los métodos considerados en estos dos capítulos. En esta comparativa se ha demostrado la superioridad de nuestras propuestas dentro de sus respectivos enfoques de RI, siendo la que opera en el espacio de los parámetros de la transformación la que ha obtenido el mejor rendimiento global de entre todos los métodos de ambos enfoques.

En el siguiente capítulo pretendemos aplicar el trabajo desarrollado hasta ahora en un entorno diferente como es el de la *Antropología Forense*, concretamente trataremos de abordar ciertos problemas existentes en el proceso de *identificación forense* y para los que sería necesario la propuesta de herramientas automáticas que faciliten el trabajo del experto.

Capítulo 4

Aplicación en Antropología Forense

4.1. Introducción

La medicina forense es la disciplina que afronta la identificación de seres humanos vivos y muertos, siendo la identificación de restos humanos uno de sus aspectos esenciales. Además de para consideraciones humanitarias, la identificación es necesaria para rellenar documentos oficiales tales como certificados de defunción, testamentos o seguros de vida. Dentro de la medicina forense podemos encontrar tres especialidades diferentes: Antropología Forense, Odontología Forense y Patología Forense. La Antropología Forense se conceptualiza de forma amplia como el campo de la evaluación forense de restos del esqueleto humano y su entorno [Iscan, 81a, Iscan, 81b].

Con el propósito de desarrollar el estudio del esqueleto haciendo uso de un ordenador, el primer paso en este proceso de identificación es la obtención del modelo digital del objeto real. En este sentido, el experto forense cuenta con los dispositivos tradicionales de adquisición de imagen. El elevado coste, la naturaleza radioactiva y la nula movilidad de los mismos han favorecido el uso de otros conocidos como *escáneres de rango*, mediante los cuales se obtiene un conjunto de imágenes o vistas parciales de la superficie del objeto a partir de las cuales realizar la reconstrucción del modelo 3D del objeto escaneado.

Nuestra intención en este capítulo es analizar el rendimiento de nuestras propuestas de RI como medio para la automatización de ciertas tareas del proceso de identificación forense basadas en el uso de modelos tridimensionales generados a partir de imágenes de rango. En este sentido, contrastaremos los resultados de nuestras propuestas frente a los obtenidos por diferentes métodos de la literatura, algunos ya considerados en capítulos anteriores y otros publicados recientemente [Chow, 04, Lomonosov, 06].

En la Sección 4.2 se introduce el campo de la Antropología Forense para, a

continuación, describir en la Sección 4.3 el proceso de identificación forense y la automatización de ciertas tareas mediante la aplicación de técnicas de RI. El contenido de la Sección 4.4 nos servirá de base para describir dichas tareas. Finalmente, en la Sección 4.5 se analiza el grado de automatización conseguido con nuestras propuestas de RI frente a otras de la literatura al abordarlas. Finalmente, se incluye una sección de conclusiones del capítulo.

4.2. Antropología Forense

La medicina forense es la disciplina que afronta la identificación de seres humanos vivos y muertos. Ésta incluye cada aspecto de la morfología humana, normal y anormal. Dentro de la medicina forense, podemos encontrar tres especialidades diferentes: Antropología Forense, Odontología Forense y Patología Forense. La primera disciplina se conceptualiza de forma amplia como el campo de la evaluación forense de restos del esqueleto humano y su entorno [Iscan, 81a, Iscan, 81b]. Esta evaluación incluye tanto la identificación de características físicas de las víctimas como la causa y forma de la muerte a partir del esqueleto [Krogman, 86]. Una definición formal de Antropología Forense es: «*el estudio de las cuestiones médico-legales relacionadas con la persona fallecida a través del examen de sus restos óseos centrándose, entre otros aspectos, en la determinación de la identidad de la persona y la forma y causa de la muerte*» [Amnesty, 94].

Así pues, la Antropología Forense se relaciona principalmente con los restos óseos. Como enunció Krogman, «*el esqueleto habla, el esqueleto relata su historia*». En el tratamiento con huesos, los antropólogos forenses se ven limitados sólo a los restos del esqueleto de personas fallecidas, salvo aquellas evidencias obtenidas a través de estudios acerca de la vida de la persona.

De esta forma, la Antropología Forense tiene varios campos de aplicación. Uno de los más importantes es la identificación de seres humanos a partir de sus restos óseos, normalmente en casos de personas desaparecidas, así como en circunstancias de guerra o desastres de masas. En el primer caso, el antropólogo forense debe cotejar los restos de una persona con los datos disponibles *ante-mortem* de diferentes personas desaparecidas. En cambio, su papel en enterramientos propios de circunstancias militares o en desastres civiles de masas será cotejar (emparejar) restos óseos (en ocasiones mezclados) según edad, sexo, raza, estatura, etc.

Como veremos más adelante, hay diferentes formas de identificación a través de, por ejemplo: la huella digital, la palma de la mano, la punta del pie, cicatrices, tatuajes y/o detalles faciales de la fisonomía, así como el análisis de ADN (que se

ha convertido en el más empleado en los últimos años). La identificación a partir de huesos se lleva a cabo en escenarios limitados y diferentes [Spitz, 80]:

- *De forma natural:* donde ha transcurrido tanto tiempo desde la muerte que sólo está disponible el esqueleto (al completo o en parte). Aquí también se incluyen aquellos casos donde aún se conserva tejido blando (piel u órganos), pero habitualmente la tarea de identificación se muestra ambigua o imposible.
- *De forma intencionada:* donde los restos del cuerpo han sido desplazados de su lugar natural. Es el caso del asesinato con mutilación o desmembración del cuerpo, o bien los casos de incendio o acciones de agentes corrosivos.
- *De forma accidental:* incluye diversos grados de destrucción del cuerpo por la acción del fuego y daños por aplastamiento o desfiguración que implican una más que considerable destrucción de tejidos blandos, de forma especial, en el área facial.

En resumen, la identificación de restos del esqueleto humano es un tema crucial. Los especialistas en el esqueleto asumen el control cuando es imposible aplicar medios establecidos de identificación alternativos. Para ello, trabajan con variables desconocidas para describir los restos en términos tales que se consiga una copia razonable de un ser humano vivo. El objetivo es proveer a los agentes de la ley y a los analistas médicos de una ayuda tal que les permita decir: «Éste es Juan Pérez», o «Ésta es María Rodríguez» cuando se encuentran frente a un montón de huesos [Krogman, 86].

Por otro lado, en múltiples casos de adopción de paternidad desconocida (o bajo sospecha) se ha contado con la consulta de un antropólogo forense. Un subproblema puede ser la determinación de la edad a partir del esqueleto en circunstancias de inmigración donde es de importancia conocer si el sujeto es o no mayor de edad. Por último, la Antropología Forense también se relaciona con la paleontología humana, donde los restos humanos encontrados presentan un factor de antigüedad importante [Krogman, 86].

4.3. Identificación Forense

Como hemos visto, la identificación de restos humanos es uno de los aspectos esenciales de la medicina forense. Además de para consideraciones humanitarias,

la identificación es necesaria para rellenar documentos oficiales tales como certificados de defunción, testamentos o seguros de vida.

Si los cuerpos a examinar son difícilmente reconocibles por el estado en el que se encuentran, no siendo posible mostrarlos a los familiares o allegados para su identificación visual, se recurre normalmente a un equipo de especialistas forenses para las tareas de identificación. Su trabajo consiste en comparar datos *ante-mortem* (obtenidos mediante inspección visual de material fotográfico y entrevistas a parientes o testigos) con datos *post-mortem* recogidos por ellos mismos. Por ejemplo, esto puede implicar una comparación de datos referentes al sexo, edad, estatura, complexión y dentadura [Rathburn, 84].

Como hemos comentado, la identificación de seres humanos a partir de su esqueleto es una de las tareas principales en Antropología Forense. Esta disciplina empezó a tomar importancia en los años cuarenta, cuando varios grupos de antropólogos forenses americanos comenzaron a trabajar para el FBI en la identificación de soldados desaparecidos durante la Segunda Guerra Mundial. Desde entonces, se ha extendido ampliamente como medio de evaluación forense en el gobierno de los Estados Unidos. Asimismo, se han creado nuevos grupos forenses para identificar restos de personas desaparecidas en los asesinatos en masa perpetrados por regímenes militares de diferentes países de América del Sur.

No obstante, existen otros procedimientos de identificación de más fácil aplicación y más fiables que los basados en el esqueleto [Excuses, 05], como:

1. Comparación de huellas digitales, de pies o manos.
2. Comparación de datos de la mandíbula o dientes (información dental).
3. Autopsia interna o externa. En la primera, se compara la localización, el tamaño y la relevancia de cicatrices, lunares, tatuajes e incluso verrugas en manos y pies.
4. Investigación del ADN para demostrar una relación de consanguinidad con familiares conocidos.

El problema con los métodos anteriores de identificación es que en ciertas ocasiones no hay suficiente información (*ante-* o *post-mortem*) disponible para aplicarlos. Con respecto a los datos *post-mortem*, el estado de preservación de un cadáver puede variar de forma considerable debido a varios factores químicos y mecánicos. Mientras que el esqueleto normalmente sobrevive tanto a los procesos de descomposición natural como a los no naturales (fuego, agua salada, etc.), los tejidos blandos (piel, músculos, pelo, etc.) van corrompiéndose de forma progresiva. El

inconveniente de las pruebas basadas en ADN se centra en que requieren de la disponibilidad de una cantidad relativamente grande de tejido de alta calidad, lo cual no es tan habitual en restos que han sido deteriorados durante un largo período de tiempo.

Por otro lado, con respecto a la información *ante-mortem*, el primer método necesita de una base de datos de huellas, el segundo de un registro dental, el tercero de imágenes previas de rayos X (entre otra información) y el último de ADN de la misma persona o de algún pariente lo más cercano posible.

Así pues, la identificación basada solamente en la información del esqueleto se puede considerar como la última oportunidad para la identificación forense cuando no puede aplicarse ninguno de los métodos anteriores. Adicionalmente, el estudio del esqueleto suele realizarse como el primer paso del proceso de identificación, previo a la aplicación de cualquier otra técnica. Así, la determinación de los parámetros principales (sexo, edad, estatura, complexión, dentadura, posibles patologías, etc.) permite restringir el conjunto de personas con las que comparar.

El proceso habitual es el siguiente. En primer lugar, el antropólogo mide y compara los datos del esqueleto. Por medio de tales mediciones y gracias a la existencia de tablas de sexo, pueden determinarse la edad en el momento de la muerte, la «raza» y la altura más allá de la duda razonable. Entonces, se comienza a trabajar con «información accesoria»: peso y/o complexión corporal; duración del sepelio; causa de la muerte, si se registró en los huesos; un registro final de detalles misceláneos tales como amputaciones, fracturas, patologías óseas, etc. [Krogman, 86].

Si los estudios previos muestran resultados positivos, se aplican técnicas más específicas tales como la *supraproyección* o *superposición fotográfica* [Rathburn, 84, Iscan, 93, Taylor, 98], donde se comparan fotografías o imágenes en vídeo de la persona desaparecida y del cráneo encontrado. Proyectando ambas fotografías una sobre la otra (o, incluso mejor, haciendo corresponder un modelo digital tridimensional del cráneo con la cara presente en la instantánea de una fotografía o vídeo), se puede intentar inferir si se trata de la misma persona.

La metodología empleada se basa en otra anterior relacionada con la reconstrucción de caras. Esta última es una metodología sistemática para recopilar características o rasgos de la fisonomía humana que permitan componer las características morfológicas de una persona en base a la observación de sus peculiaridades individuales con respecto a: la forma de su cara, nariz, labios, orejas; la estructura de su pelo; el contorno de su cara o cabeza; la forma y el color de sus ojos; y su color de piel.

A partir de los fundamentos anteriores, las primeras identificaciones se de-

sarrollaron mediante la superposición de imágenes y comparando dos conjuntos de puntos antropométricos correspondientes a la cara y al cráneo [Rathburn, 84, Iscan, 93]. El procedimiento se basó en obtener el negativo de la fotografía original del sujeto y marcar diferentes regiones antropométricas presentes en la cara del mismo ¹. Se hacía lo mismo con la fotografía del cráneo pero, en este caso, marcando regiones antropométricas craneales. Luego, ambas fotos se cotejaban y se revelaba el positivo con los dos negativos superpuestos. La Figura 4.1 muestra un ejemplo de esto último ².




Figura 4.1: De izquierda a derecha: marcas antropométricas en rojo sobre una imagen que simula la parte lateral de una cabeza humana; fotografía de un cráneo con la misma orientación que la cabeza de la imagen anterior (se marcan en rojo diferentes regiones antropométricas del cráneo); comparación de ambas imágenes mediante su superposición. El resultado de la identificación es negativo al no encontrarse una correspondencia adecuada entre ambos conjuntos de puntos

Las dos fotografías de la Figura 4.2 [Alemán, 05] muestran, de forma gráfica, la localización de diferentes marcas antropométricas del rostro de una persona.

El inconveniente de la identificación mediante superposición fotográfica es que no hay un método sistemático para el análisis mediante la superposición de imágenes. Cada investigador aplica su propia metodología, en ocasiones adaptada a la

¹ Es recomendable seleccionar aquellos puntos donde el grosor de los tejidos blandos sea menor, ya que estarán sujetos en menor medida a variaciones propias de la edad o cambios de peso.

² Imágenes obtenidas de Kandor Graphics, <http://www.melkor.com/accidentes.htm>




Figura 4.2: Principales puntos antropométricos del rostro (vistas frontal y lateral)

calidad del material del que dispone. Sin embargo, hay dos factores comunes en toda investigación [Chandra, 93, Dongsgheng, 93, Yuwen, 93]:

- La determinación del tamaño real de las figuras (escalado), ya que sería imposible superponer dos imágenes con tamaños diferentes. La distancia focal de la imagen del rostro es determinante en este aspecto.
- El método de orientación del cráneo, para hacerlo corresponder con la posición del rostro de la fotografía. Hay tres posibles movimientos: inclinación, extensión y rotación.

De esta forma, se puede observar la relación existente entre el procedimiento desarrollado por el experto para realizar la tarea de superposición fotográfica y la forma de operar de las técnicas de RI al tratar de superponer pares de imágenes 2D, o bien un modelo 3D con una imagen 2D.

Además, a partir de lo anterior podemos constatar la incertidumbre subyacente al proceso. La correspondencia entre marcas antropométricas del rostro y del cráneo no siempre es simétrica y perpendicular. Algunas de estas marcas se localizan en una posición superior en el rostro de la persona viva que en el cráneo y otras no tienen una marca relacionada u homóloga en el otro conjunto. Por otro lado,

la identificación se puede realizar manualmente midiendo las distancias entre los diferentes emparejamientos de puntos, aunque este procedimiento puede estar influenciado por errores debidos al reescalado de las imágenes (Se debe tener en cuenta que en antropometría, el error permitido en la medición es de 1 milímetro para huesos largos y de medio milímetro para el rostro y huesos de menor tamaño). De esta forma, también encontramos una situación evidente de correspondencia parcial y una necesidad de técnicas automáticas que resuelvan este tipo de problemas.

4.4. El modelo digital

4.4.1. Introducción

El primer paso del proceso de identificación es la adquisición de toda la información y datos posibles del objeto físico en estudio. En el caso de desarrollar el estudio del esqueleto haciendo uso de un ordenador, la información más relevante es la ofrecida por el «modelo virtual» del propio objeto.

Para la obtención de este modelo, el experto forense cuenta con los dispositivos tradicionales de adquisición de imagen médica nuclear, como por ejemplo los escáneres de resonancia magnética, de tomografía computerizada, etc. Estos sistemas permiten la adquisición de un modelo 3D completo en una única sesión de escaneado. Sin embargo, el elevado coste, la naturaleza radioactiva y la escasa movilidad de estos dispositivos limitan su uso por parte del experto forense.

En la actualidad, los *escáneres de rango* se han convertido en unos dispositivos de adquisición 3D de gran utilidad en multitud de campos, la Antropología Forense entre ellos (Figura 4.3). Esto se debe principalmente a su reducido coste y gran movilidad para operar en escenarios muy diversos (tanto en interiores como en el exterior). Sin embargo, a diferencia de los dispositivos de imagen médica nuclear, este tipo de sistemas de adquisición toman imágenes o vistas parciales de la superficie del objeto, siendo necesario realizar varias sesiones de escaneado desde diferentes puntos de vista del objeto.

Hoy en día, el procesamiento de imágenes generadas mediante escáneres de rango presenta un gran interés entre la comunidad científica debido al drástico descenso del precio de estos dispositivos y al considerable aumento de las capacidades de cálculo del hardware gráfico de los ordenadores actuales, así como a la cómoda maniobrabilidad que ofrecen estos dispositivos.

El objetivo de este procesamiento se relaciona con la obtención, de forma lo



Figura 4.3: Personal del Laboratorio de Antropología Física de la Universidad de Granada trabajando con un escáner de rango

más eficiente y fiel posible, del modelo 3D correspondiente a un objeto real. Para conseguirlo, se lleva a cabo el registrado o (como se suele decir en la jerga forense) el «*cosido*» de las múltiples vistas parciales (imágenes 3D) del objeto. En la literatura especializada, a este tipo de RI se le conoce como *registrado de imágenes de rango* (RIR) y al proceso en el que éste interviene para generar el correspondiente modelo 3D como *reconstrucción 3D* [Bernardini, 02]. La Figura 4.4 muestra un ejemplo de este proceso. Se puede observar cómo, debido a la naturaleza de las imágenes, el registrado debe hacer coincidir sólo la región de superficie del objeto presente en ambas, conocida como *región de solapamiento*. De no existir un mínimo de solapamiento (debido a un escaneado inadecuado y/o a la geometría del objeto), la reconstrucción no podría ser abordada, cuanto menos resuelta, mediante técnicas de RIR [Silva, 05]. Además, este proceso de adquisición necesita en ocasiones un tiempo y un espacio de almacenamiento elevados (proporcionales al número de imágenes adquiridas). Por tanto, un plan apropiado de escaneado debe contemplar la reducción de ambos factores, además de asegurar un solapamiento mínimo entre las imágenes [Ikeuchi, 01]. La gráfica de la Figura 4.5 muestra la evolución del interés en el RIR en los últimos años.

A continuación, introducimos las bases del problema de reconstrucción 3D con dispositivos de rango y presentamos los métodos de RIR con mayor difusión en la literatura especializada en las subsecciones 4.4.2 y 4.4.3, respectivamente.



Figura 4.4: Ejemplo de adquisición y registrado de dos imágenes de rango correspondientes al busto en escayola de una mujer




Figura 4.5: Número de publicaciones por año en RIR. Los datos de la gráfica de barras se han obtenido de diferentes fuentes electrónicas (ACM SIGGRAPH, ISI Web of Knowledge, CompuScience, IEEEExplore) mediante la consulta «*range AND image AND (registration OR alignment)*»

4.4.2. Enfoques de reconstrucción

El procedimiento para la reconstrucción de modelos 3D se ha tratado en la literatura especializada desde dos enfoques bien diferentes:

- *Acumulativo*: se trata del primer enfoque que se consideró para tratar el problema de la reconstrucción 3D y el que mayor difusión ha tenido en los últimos años debido a su sencilla implementación. El proceso comienza registrando, mediante cualquier método de RIR, dos imágenes adyacentes en la secuencia de escaneado y continua efectuando registros dos a dos hasta haberlas considerado todas. En este caso, se aplicará el RIR tantas veces como imágenes tengamos menos uno. En [Salvi, 06] podemos encontrar una amplia revisión de los métodos de RIR entre pares de imágenes más empleados en la literatura especializada.
- *Múltiples vistas*: en primer lugar, se confecciona un conjunto de pares de imágenes (pares de imágenes adyacentes compartiendo región de solapamiento) y se aplica el RIR a cada uno de ellos para tener una estimación inicial de registrado. Acto seguido se considera el conjunto de pares al completo y se lleva a cabo un proceso de optimización minimizando el error global de todo el modelo [Eggert, 98, Allen, 03, Silva, 06].

El principal defecto del primer enfoque concierne a la acumulación de un error residual a lo largo de las sucesivas aplicaciones del método de RIR entre pares, pero a su vez presenta la ventaja de no tener que esperar a completar la fase de adquisición para llevar a cabo la tarea de reconstrucción 3D y de simplificar la complejidad del problema, tanto en tiempo como en recursos. En general, el segundo enfoque suele realizar una mejor reconstrucción del objeto a costa de invertir mucho más tiempo y recursos de almacenamiento. Sea cual sea el enfoque de resolución, el RIR juega un papel crucial en el proceso de adquisición del modelo 3D.

El método empleado comúnmente para el RIR es el *Iterative Closest Point* (ICP), descrito en la Sección 1.2.4 de esta memoria y propuesto por Besl en 1992 [Besl, 92]. Como sabemos, esta técnica presenta una serie de defectos que diferentes contribuciones posteriores han tratado de solucionar [Feldmar, 96, Gold, 96, Luck, 00, Rusinkiewicz, 01, Sharp, 02, Liu, 04]. Sin embargo, en todas ellas se asume que el punto de partida del algoritmo se encuentra próximo al óptimo, es decir, que el grado de desalineación entre las imágenes es lo suficientemente bajo como para conseguir la correcta convergencia del método. Si dicha asunción se satisface, este tipo de métodos suelen ser la mejor alternativa gracias a la eficiencia y precisión que se consigue con su aplicación.

Para el escaneo de objetos tales como cadáveres u otros restos de menor tamaño (cráneos por ejemplo) en Antropología Forense, el experto puede disponer de los conocidos *sistemas de posicionamiento* para tener un control adecuado del proceso de adquisición [Callieri, 04]. Dicho control se basa en ir «registrando» el cambio de orientación/desplazamiento del objeto o escáner, contando de esta forma con una estimación precisa de la transformación de registrado entre sucesivos escaneos. Entre este tipo de sistemas encontramos las tablas giratorias, los sistemas óptimos o magnéticos de guiado, etc. Gracias a la información que aportan, puede satisfacerse la asunción propia de los métodos basados en ICP.

Sin embargo, existen situaciones en las que no es posible usar los sistemas anteriores. En ciertos entornos, el objeto puede sufrir algún tipo de movimiento incontrolado durante el proceso de adquisición. En otros casos es inviable usar un sistema de posicionamiento. Por ejemplo, si se pretende escanear un cadáver, la única forma de proceder es ir desplazando el escáner alrededor de la superficie de éste, siendo incluso necesario el movimiento del cuerpo para poder completar todo el proceso. Sin la ayuda de los sistemas de posicionamiento, el RIR basado en ICP se convierte en un mecanismo poco fiable al aumentar la probabilidad de que estos métodos queden atrapados en óptimos locales. Ante tales circunstancias, resulta determinante la intervención (manual) del experto para conseguir una correcta reconstrucción 3D del objeto escaneado. Por tanto, el diseño y desarrollo de métodos automáticos de RIR que den soporte a la tarea de reconstrucción 3D resulta de gran importancia en este tipo de áreas.

En la literatura encontramos el enfoque de RIR en dos pasos para solucionar el problema anterior [Salvi, 06]. Como se muestra en la Figura 4.6, este enfoque consta de dos etapas: «*prealineación*» y «*refinamiento*». Para la primera, se hace uso de un método de prealineación³, basado en un enfoque de búsqueda global, con la misión de aproximar lo suficiente el par de imágenes como para que, en la segunda etapa, un método de refinamiento, basado en un enfoque de búsqueda local (habitualmente, un método basado en ICP), pueda conseguir un RIR próximo al óptimo. Para evitar posibles confusiones, diremos que un «método de prealineación» también se considera un «método de RIR», pero el hecho contrario no es cierto, sirva ICP como ejemplo. Por tanto, podemos etiquetar a cada uno de estos pasos como RIR «tosco» y «fino», respectivamente.

³Con el método de prealineación se pretende dar una alternativa basada en software para aquellas ocasiones donde no es posible hacer uso de dispositivos de posicionamiento.

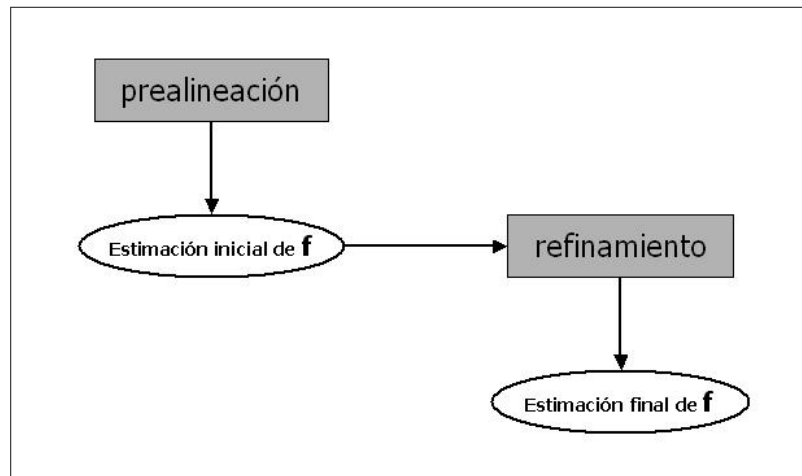


Figura 4.6: Enfoque de RIR en dos etapas

4.4.3. Métodos de prealineación

Todas las contribuciones que presentamos a continuación se centran principalmente en el diseño de heurísticas de búsqueda y estrategias de optimización de mayor orden como las metaheurísticas [Bäck, 97, Glover, 03a]. Podemos encontrar una completa revisión sobre este tema en [Huber, 03, Salvi, 06].

La revisión de métodos de prealineación que vamos a hacer a continuación se subdivide en los dos enfoques de búsqueda de los métodos de RI (Sección 1.2.4), el basado en el espacio de las correspondencias y el basado en el espacio de los parámetros de la transformación.

De entre los métodos de prealineación basados en el primer enfoque, *RANSAC* [Chen, 98] se basa en una heurística simple consistente en encontrar las tres mejores correspondencias entre dos imágenes de rango (tres puntos son suficientes para calcular la transformación de registro considerada). Este proceso de búsqueda se repite hasta alcanzar cierta condición de parada, devolviendo la mejor solución encontrada. Los resultados de este método son de aceptable calidad y, teóricamente, su precisión aumenta con una mejor resolución de las imágenes.

En [Johnson, 99], se propone una aproximación bastante diferente que hace uso de *imágenes spin*, es decir, imágenes 2D que caracterizan un punto emplean-

do la información de la superficie que lo rodea. Para cierto punto, se calcula un vector normal a la superficie aproximada a partir de los puntos próximos a éste. Después, se calculan dos valores de distancia con el propósito de determinar la imagen spin donde cada píxel contiene el número de puntos que pertenecen a esta región. Una vez se encuentran correspondencias mediante la imagen spin, se descartan las correspondencias falsas a través de la media y desviación típica de los errores.

Otro método interesante basado en RANSAC es el propuesto en [Pingi, 05], el cual realiza el RIR en paralelo con el proceso de adquisición. Tras el filtrado de cierta cantidad de puntos característicos de las imágenes, el algoritmo lleva a cabo las siguientes dos tareas: i) mediante la aplicación de una regla voraz se obtienen t correspondencias donde la proximidad entre cada una de ellas se calcula en base a la información de curvatura de los puntos emparejados; y ii) de entre las t correspondencias, se realiza la búsqueda exhaustiva de las tres mejores, cuya transformación de registrado asociada (estimada mediante métodos numéricos) obtenga menor valor de ECM. El proceso de búsqueda se repite hasta alcanzar cierta condición de parada. Si antes de que éste finalice se produce cierto número de iteraciones sin mejora, se considera que el algoritmo ha convergido en un óptimo local. Entonces se aplica una perturbación sobre el mejor conjunto de correspondencias (sustituyendo una de las tres por una nueva generada aleatoriamente). Además del coste computacional asociado al proceso de búsqueda (según t), el método exige que se cumplan ciertas condiciones que garanticen la invarianza de características durante el proceso de adquisición, lo que impide aplicar la propuesta en cualquier tipo de escenario.

Por otro lado, con respecto al enfoque de búsqueda basado en el espacio de los parámetros de la transformación, encontramos varias propuestas recientes cuyo diseño hace uso de la CE [Bäck, 97].

En [Lomonosov, 06], los autores proponen un AG con un esquema de evolución generacional con codificación entera (en cada evaluación de la función objetivo se realiza la conversión a representación real). Considera el método de cruce en un punto y los operadores de mutación de reemplazo y desplazamiento. El torneo es el tipo de estrategia de selección empleada, siguiendo un enfoque de evolución elitista. Con el propósito de mejorar la eficiencia del algoritmo, se realiza un muestreo aleatorio (uniforme) de puntos en ambas imágenes, manteniendo cien puntos en la imagen escena y mil en la imagen modelo.

Con un diseño similar al anterior, en [Chow, 04] los autores usan un AG generacional pero, en este caso, con codificación real, así como una estrategia de selección proporcional según el valor de función objetivo. El operador de cruce selecciona de

forma aleatoria el número y los genes a intercambiar. En el operador de mutación diseñado, el valor acumulado para cada gen de un cromosoma se genera aleatoriamente de manera distinta para los parámetros de rotación y traslación. Para los primeros, de modo uniforme dentro de un rango constante. Para la traslación, se considera un rango dinámico según el valor de la función objetivo, formulada en términos de *error cuadrático mediano*. Además, el algoritmo propone un mecanismo sofisticado para el reinicio de la población, llamado «*dynamic boundary*», el cual consiste en restringir el espacio de búsqueda al descrito por los individuos de la población actual. El criterio considerado para aplicar este reinicio se basa en establecer un máximo de iteraciones sin conseguir mejorar la mejor solución encontrada hasta el momento. Al igual que para el método anterior, esta propuesta realiza un muestreo de puntos, en este caso sólo de la imagen escena, manteniendo un total de trescientos.

4.5. Aplicación de nuestras propuestas de registrado de imágenes a problemas de identificación forense

En esta sección pretendemos analizar el rendimiento que ofrecen nuestras propuestas de RI cuando se trata de automatizar ciertas tareas forenses, concretamente:

- Cotejado de objetos forenses mediante la superposición de sus modelos tridimensionales.
- Obtención de modelos tridimensionales de objetos forenses mediante reconstrucción 3D.

De este modo, en las subsecciones 4.5.1 y 4.5.2 se diseñan y desarrollan los experimentos para cada una de las tareas anteriores.

4.5.1. Cotejado de objetos forenses mediante la superposición de sus modelos tridimensionales

Como comentamos en la Sección 4.4.1, el primer paso en la tarea de identificación forense es la obtención de los modelos digitales de restos óseos en estudio. En este caso, vamos a hacer uso de los sistemas tradicionales de adquisición de imagen médica para la obtención de dichos modelos, mediante los cuales poder

llevar a cabo la tarea de superposición. En particular, los objetos a estudiar corresponden a restos de la mano de una persona de la que se extrajeron los huesos de la muñeca a partir de las imágenes adquiridas mediante un escáner de tomografía computerizada (CT).

A continuación, la subsección 4.5.1.1 detalla el repertorio de imágenes CT que se han considerado para abordar la automatización de esta tarea. Las subsecciones 4.5.1.2 y 4.5.1.3 describen, respectivamente, el diseño experimental y los métodos de RI empleados para resolver este problema. Por último, en la subsección 4.5.1.4 se comentan y analizan los resultados obtenidos.

4.5.1.1. Repertorio de imágenes

El Laboratorio de bioingeniería del *Brown Medical School Hospital* de Rhode Island (EEUU) nos ha facilitado un repertorio de imágenes 3D que comprende dos escaneos CT de la misma muñeca de un paciente, tomados en instantes de tiempo diferentes.

Queremos subrayar la complejidad del nuevo problema de RI que tratamos de abordar, debida a las razones siguientes:

- En este caso, las imágenes no son simuladas, como ocurría con las estudiadas en los capítulos anteriores, sino que se trata de imágenes de objetos reales, adquiridas mediante un dispositivo CT convencional.
- Por otro lado, los huesos que componen la muñeca son propensos a sufrir ciertas *deformaciones locales* de tipo rígido (rotaciones y/o traslaciones), lo que constituye un reto importante al no ajustarse completamente con el modelo de transformación global de similitud tratado hasta el momento.

Al igual que en capítulos anteriores, realizamos un paso previo de procesamiento de este repertorio para extraer un conjunto de puntos característicos, es decir, las líneas de cresta, con su correspondiente información de curvatura asociada. Las Figuras 4.7 y 4.8 muestran los dos pasos fundamentales del mencionado preprocesamiento de las imágenes. Primero, la extracción de la isosuperficie de la región de interés. En nuestro caso, nos quedamos sólo con la parte ósea de la muñeca. A continuación, estudiamos los puntos más representativos de las líneas de cresta para seleccionar aquellos con información de curvatura relevante. Así, se han escogido un total de 575 y 412 puntos característicos tras el preprocesamiento de las figuras citadas.




Figura 4.7: Imagen I_1 . a) Imagen CT original. b) Isosuperficie correspondiente a la primera exploración CT de la muñeca del paciente. c) Extracción de 575 puntos de líneas de cresta




Figura 4.8: Imagen I_2 . a) Imagen CT original. b) Isosuperficie correspondiente a la segunda exploración CT de la muñeca del paciente. c) Extracción de 412 puntos de líneas de cresta

4.5.1.2. Diseño del experimento

A partir del repertorio de imágenes anterior, vamos a generar un conjunto de instancias de cierta complejidad que simulen posibles situaciones reales del proceso de identificación forense.

Con el propósito de medir la eficacia y robustez de nuestras dos propuestas de RI frente a otras de la literatura en este nuevo escenario, vamos a mantener el mismo diseño experimental usado en las Secciones 2.5.1 y 3.4.1. Por tanto, trataremos un total de cuatro instancias de RI: I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$, donde T_1 , T_2 , T_3 y T_4 siguen siendo las mismas transformaciones de prueba consideradas en dichas secciones (ver Tabla 2.1). Nótese que, al igual que en los capítulos anteriores, el conocimiento a priori de las transformaciones de registrado asociadas a este diseño experimental nos permite evaluar de forma precisa el comportamiento de cada uno de los métodos estudiados.

4.5.1.3. Valores de parámetros

La experimentación se ha realizado en la misma plataforma considerada en los capítulos anteriores, empleando un procesador Intel Pentium IV a 2.6 MHz con memoria RAM de 1GB y sistema operativo SuSe GNU-Linux v.9.0.

De entre los métodos de RI considerados hasta ahora, hemos seleccionado aquéllos con un mejor rendimiento medio. Concretamente, para el enfoque de búsqueda en el espacio de correspondencias vamos a considerar nuestra propuesta basada en Scatter Search, SS_m , el método basado en ICP propuesto en [Liu, 04], $I - ICP$, y el algoritmo híbrido compuesto por una versión del algoritmo ICP y otra del enfriamiento simulado [Luck, 00], $ICP + SA$. Dentro del segundo enfoque de búsqueda hemos considerado nuestra propuesta basada en Scatter Search, SS_p , la propuesta basada en AGs con codificación real de [He, 02], GA_{He} , y la versión en codificación real del algoritmo CHC [Damas, 03, Cerdón, 06d], CHC_{Real} .

De la misma forma, hemos decidido mantener los mismos valores de parámetros de los métodos de RI considerados en las experimentaciones de los capítulos anteriores, así como las 15 ejecuciones de cada algoritmo (salvo para $I - ICP$, que se ejecuta una sola vez por instancia al tratarse de un algoritmo determinista) y 20 segundos para cada una.

4.5.1.4. Análisis de resultados

Los resultados estadísticos incluidos en esta sección se basan en la medida del *Error Cuadrático Medio* (ECM), cuya expresión se introdujo en la Sección 2.5.2.2.

En la Tabla 4.1 se muestra el rendimiento de cada método para cada una de las cuatro instancias de RI previamente diseñadas, resaltando en negrita los mejores valores de ECM (mínimo y media). Observemos que nuestra propuesta SS_p se muestra como la alternativa más robusta y eficaz frente al resto de métodos al alcanzar el menor valor medio de ECM en tres de las cuatro instancias. SS_p es también competitiva en cuanto a precisión se refiere al lograr el ECM más bajo en una de las cuatro instancias (I_1 Vs. $T_2(I_2)$) y valores muy próximos al mínimo en otras dos (I_1 Vs. $T_1(I_2)$ e I_1 Vs. $T_4(I_2)$). La Figura 4.9 muestra las mejores estimaciones para cada una de las instancias consideradas ⁴.

Con respecto a nuestra primera propuesta, SS_m , podemos observar cómo, si bien no se encuentra entre los métodos más precisos, es la técnica con mejor rendimiento de entre las que operan en el espacio de correspondencias. La pérdida de rendimiento de SS_m , en comparación con el ofrecido en capítulos anteriores se podría relacionar con las diferencias significativas entre los conjuntos de líneas de cresta del par de imágenes consideradas.

4.5.2. Obtención de modelos tridimensionales de objetos forenses mediante reconstrucción 3D

Como hemos visto en la Sección 4.3, para poder aplicar la técnica de identificación forense por superposición fotográfica, es necesario disponer de los modelos digitales de los objetos en estudio. En la experimentación anterior se consideró un repertorio de imágenes obtenidas con un dispositivo de adquisición de imagen médica nuclear, donde la imagen se obtenía en una única sesión de escaneado. La alternativa a los dispositivos médicos tradicionales de adquisición son los escáneres de rango, cuya sistemática de trabajo se basa en tomar múltiples vistas/imágenes de la superficie del objeto y generar el correspondiente modelo digital 3D mediante un proceso de reconstrucción.

En esta segunda experimentación abordaremos la automatización de la tarea de obtención del modelo digital de objetos forenses afrontando los inconvenientes con los que el experto forense puede encontrarse en el proceso de reconstrucción

⁴ Nótese que cuanto mejor es la estimación, mayor es la superposición que se consigue entre el par de imágenes de la muñeca.

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	12.26	49.01	17.71	8.93	11.97	30.25	16.87	5.64
$ICP + SA$	51.27	52.32	51.62	0.15	35.88	41.08	39.52	1.45
$I - ICP$	52.32	-	-	-	42.57	-	-	-
SS_p	7.88	8.34	8.16	0.18	7.56	9.33	8.80	0.41
GA_{He}	8.22	12.04	9.62	1.18	8.23	12.61	9.78	1.20
CHC_{Real}	7.86	8.18	7.94	0.07	8.93	8.98	8.96	0.02

I_1 Vs. $T_i(I_2)$

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	12.05	48.5	18.35	8.89	10.19	49.42	18.87	11.24
$ICP + SA$	45.21	51.75	48.88	1.64	23.03	37.42	27.93	4.45
$I - ICP$	53.92	-	-	-	36.82	-	-	-
SS_p	8.29	9.14	8.98	0.19	7.91	8.89	8.76	0.24
GA_{He}	6.57	13.75	9.09	1.90	7.72	11.22	9.46	1.10
CHC_{Real}	8.99	9.07	9.04	0.03	8.78	8.89	8.83	0.02

Tabla 4.1: Valores mínimo (m), máximo (M), medio (μ), y desviación típica (σ) del ECM para cada una de las cuatro instancias I_1 Vs. $T_1(I_2)$, I_1 Vs. $T_2(I_2)$, I_1 Vs. $T_3(I_2)$ e I_1 Vs. $T_4(I_2)$ tras realizar 15 ejecuciones diferentes para los métodos que trabajan en el espacio de correspondencias (SS_m e $ICP + SA$) y los que lo hacen en el espacio de la transformación (SS_p , GA_{He} y CHC_{Real}). En negrita aparecen resaltados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ)




Figura 4.9: Mejores estimaciones obtenidas en la instancia I_1 Vs. $T_1(I_2)$ por los diferentes métodos de RI. De izquierda a derecha y de arriba abajo: SS_m , $ICP + SA$, $I - ICP$, SS_p , GA_{He} y CHC_{Real}

(ver Sección 4.4.1). A continuación, la subsección 4.5.2.1 detalla el repertorio de imágenes de rango que se han considerado para esta experimentación. Las subsecciones 4.5.2.2 y 4.5.2.3 describen, respectivamente, el diseño experimental y los métodos de RIR empleados para la misma. Por último, en la subsección 4.5.2.4 se analizan los resultados obtenidos.

4.5.2.1. Repertorio de imágenes

Para desarrollar la experimentación actual, hemos contado con la inestimable colaboración de los miembros del Laboratorio de Antropología Física de la Universidad de Granada, dirigido por el Dr. Miguel Botella. Se nos facilitó el uso del escáner de rango (Konica-Minolta[©] 3D LassesScanner VI-910) con el que ellos trabajan asiduamente, así como del ingente volumen de restos humanos que se encuentran depositados en las dependencias del laboratorio.

En la elección del objeto real con el que llevar a cabo esta experimentación, y bajo la premisa de considerar aquellos objetos de interés a nivel antropológico, hemos elegido el cráneo⁵ que se muestra en la Figura 4.10 para realizar nuestro

⁵La persona fallecida a la que corresponden estos restos, quien los donó para uso científico, tenía

estudio. A partir de él, obtendremos un repertorio de imágenes que nos servirán para la posterior prueba experimental. La Figura 4.10 recoge el proceso seguido para ello. Podemos observar cómo los rasgos relevantes en la superficie del cráneo aparecen débilmente destacados o difuminados en las vistas parciales, debido principalmente al ruido introducido por el escáner. Este factor supone un serio inconveniente para cualquier proceso de extracción de características, en particular para aquellos detectores basados en la curvatura de la superficie del objeto, por lo que es necesario eliminar los «artefactos» introducidos⁶ en el proceso de adquisición. Como solución a este inconveniente se encuentra el uso de filtros para el suavizado de imágenes (ver Figura 4.10).




Figura 4.10: De izquierda a derecha: modelo 3D en bruto resultante del escaneado del cráneo considerado; vista parcial sin artefactos y sin aplicar suavizado; la misma vista tras aplicar un filtro de suavizado sobre ésta

Además del escáner de rango, hemos usado la tabla giratoria de la que dispone el laboratorio como sistema de posicionamiento. De esta forma, el software de reconstrucción del escáner contará con una prealineación de gran calidad asociada a cada escaneo. Como vimos en la Sección 4.4.2, tal información permite llevar a cabo un RIR eficiente y de gran precisión, por lo que en nuestro caso, obtendremos un modelo 3D que podremos considerar óptimo. Disponer a priori del modelo

el sobrenombre de «Cabezón de Gabia».

⁶Cada sesión de escaneado es el resultado del promedio de varios barridos de la superficie del objeto, lo que supone la introducción de una componente de error en la medición. Un número suficiente de barridos repercutirá en la obtención de imágenes de mayor calidad a cambio del aumento proporcional en el tiempo de adquisición.

óptimo del objeto en estudio nos será de gran ayuda para analizar los resultados obtenidos en la experimentación posterior.

Por otro lado, hemos tenido en cuenta factores de importancia para llevar a cabo el proceso de escaneo, tales como el tiempo y el espacio necesarios para obtener un repertorio de imágenes de calidad suficiente. Así, siguiendo las recomendaciones que se indican en [Silva, 05], hemos decidido realizar escaneos de la superficie del cráneo a intervalos de cuarenta y cinco grados (consideración tomada también en [Liu, 06]), generando una secuencia de escaneo de ocho vistas en total: $0^\circ - 45^\circ - 90^\circ - 135^\circ - 180^\circ - 225^\circ - 270^\circ - 315^\circ$. De esta forma, el tiempo total de adquisición/reconstrucción se redujo a cinco minutos, siendo necesario un espacio de almacenamiento de tan sólo 15 MB. Además, para mejorar la precisión en la medición, se han considerado tres barridos para cada escaneo. La Figura 4.11 muestra la región de solapamiento existente en algunas de las imágenes de la secuencia tras la adquisición.




Figura 4.11: En color gris oscuro se muestra la región de solapamiento de imágenes adyacentes. El color gris claro indica la región que pertenece exclusivamente a cada vista. De izquierda a derecha aparecen dos orientaciones distintas de las imágenes adyacentes $0^\circ - 45^\circ$ y $45^\circ - 90^\circ$

El repertorio de imágenes que usaremos para la experimentación posterior se compone de cinco de las ocho vistas anteriores: $270^\circ - 315^\circ - 0^\circ - 45^\circ - 90^\circ$. Así pues, nuestra intención no es obtener el modelo de todo el cráneo, sino una versión parcial de éste en la que se recojan las zonas de mayor interés para el especialista (en nuestro caso la parte frontal y las dos laterales). Tal interés se debe al último propósito tras la obtención del modelo tridimensional del cráneo: la identificación forense de personas desaparecidas mediante superposición fotográfica descrita en

la Sección 4.3. Esta reducción en el número de vistas que componen el repertorio de imágenes es también positiva por motivos de espacio de almacenamiento, factor de gran importancia cuando se pretende realizar el registro digital de grandes depósitos de restos de este tipo. Es importante que el modelo obtenido sea lo suficientemente fiel respecto al objeto real como para abordar la tarea posterior de superposición 3D/2D (es decir, la superposición de un modelo 3D de un cráneo y de una fotografía de la persona en vida a la que podría corresponder dicho cráneo).

Por último, hemos realizado el suavizado y la extracción de las líneas de cresta de las imágenes del repertorio con un software específico [Yoshizawa, 05]. La Tabla 4.2 recoge información acerca del tamaño de cada imagen (nótese cómo tras, extraer las líneas de cresta, el tamaño de las imágenes es prácticamente la centésima parte del original). Asimismo, en la Figura 4.12 se puede observar cómo el conjunto de líneas de cresta que se ha extraído corresponde con los rasgos más característicos destacados de la superficie del cráneo. Además, se debe tener en cuenta que, de la misma forma que las imágenes originales, las imágenes de líneas de cresta adyacentes comparten una región de solapamiento.

Imagen	Original	Líneas de cresta
I_{270°	109936	1380
I_{315°	76794	1181
I_{0°	68751	986
I_{45°	91590	1322
I_{90°	104441	1363

Tabla 4.2: Tamaño de las imágenes del repertorio (en número de puntos), antes y después de la aplicación del método de detección de líneas de cresta

4.5.2.2. Diseño del experimento

En la Sección 4.4.1 señalamos los inconvenientes que afectan al proceso de reconstrucción 3D en situaciones donde no se cuenta con una prealineación aceptable, principalmente por no hacer uso de los sistemas de posicionamiento. En tales casos, los métodos tradicionales de RIR suelen quedar atrapados en óptimos locales, generando una pobre superposición de las imágenes.

El diseño experimental que hemos considerado a continuación se centra en profundizar aún más en la obtención de métodos de prealineación lo más eficaces y




Figura 4.12: De arriba abajo: vistas parciales del objeto obtenidas a 270, 315, 0, 45 y 90 grados. A la derecha de cada una se visualizan las líneas de cresta extraídas

robustos posibles. Éstos deben ofrecer además el máximo grado de automatización en la obtención de un modelo 3D en aquellas situaciones donde el experto forense no pueda hacer uso de sistemas de posicionamiento. Con este propósito, a partir del repertorio de imágenes considerado en esta sección, vamos a generar un conjunto de instancias de problemas de RIR. Éstas simularán un proceso de escaneo no guiado por sistemas de posicionamiento y podremos evaluar así el rendimiento de cada método de RIR considerado como técnica de prealineación.

Con el objetivo de medir la eficacia y robustez de nuestras dos propuestas de RI frente a otras del estado del arte existentes en la literatura, vamos a mantener la misma estructura experimental de los capítulos anteriores. De este modo, trataremos con un total de dieciséis instancias de RIR recogidas en la Tabla 4.3 (resultado de la aplicación de las transformaciones ya presentadas en la Tabla 2.1 sobre los cuatro pares de imágenes que componen los cuatro escenarios de RIR considerados). Debido al proceso de adquisición que se ha seguido para obtener el repertorio de imágenes, no tiene sentido considerar una componente de escalado en el modelo de transformación. Por tanto, estaremos tratando en esta ocasión con un modelo rígido (rotación y traslación) en lugar de una transformación de similitud.

En esta sección, realizaremos el estudio de dos enfoques diferentes para resolver el problema de RIR (ver Sección 1.2): *semiautomático* y *automático*. Mientras el primero hace uso del repertorio de imágenes de líneas de cresta en la etapa de prealineación, el segundo trata con las imágenes originales. A continuación, la etapa de refinamiento de ambos enfoques usa las imágenes originales. Nótese cómo en los dos capítulos anteriores de esta memoria, hemos considerado una aproximación semiautomática al problema de RI para imágenes médicas tridimensionales.

En nuestro caso, considerar un enfoque automático permitiría liberar al experto forense de tener que obtener unas líneas de cresta de calidad de forma manual, siendo esto un proceso laborioso en la mayor parte de las ocasiones. Por otro lado, para acelerar el cálculo de la función objetivo operando en este enfoque, hemos decidido realizar un submuestreo aleatorio y uniforme de las imágenes del repertorio, debido fundamentalmente al elevado número de puntos que éstas poseen (ver Tabla 4.2). Fijar el nivel de muestreo es una tarea simple que el experto debe realizar justo antes del proceso de RIR. Por tanto, hemos realizado un muestreo de las imágenes originales manteniendo un 15 % del total de puntos (quince mil puntos por imagen, aproximadamente).

Por tanto, en total tendremos treinta y dos instancias de RIR a resolver, dieciséis por enfoque. Por último, para cualquiera de los dos enfoques anteriores, una vez se consigue la prealineación de las imágenes, se lleva a cabo el refinamiento del resultado aplicando alguno de los muchos métodos de RIR basados en ICP. En

Escenario	Instancias
I_{0° Vs. $T_i(I_{45^\circ})$	I_{0° Vs. $T_1(I_{45^\circ})$ I_{0° Vs. $T_2(I_{45^\circ})$ I_{0° Vs. $T_3(I_{45^\circ})$ I_{0° Vs. $T_4(I_{45^\circ})$
I_{45° Vs. $T_i(I_{90^\circ})$	I_{45° Vs. $T_1(I_{90^\circ})$ I_{45° Vs. $T_2(I_{90^\circ})$ I_{45° Vs. $T_3(I_{90^\circ})$ I_{45° Vs. $T_4(I_{90^\circ})$
I_{0° Vs. $T_i(I_{315^\circ})$	I_{0° Vs. $T_1(I_{315^\circ})$ I_{0° Vs. $T_2(I_{315^\circ})$ I_{0° Vs. $T_3(I_{315^\circ})$ I_{0° Vs. $T_4(I_{315^\circ})$
I_{315° Vs. $T_i(I_{270^\circ})$	I_{315° Vs. $T_1(I_{270^\circ})$ I_{315° Vs. $T_2(I_{270^\circ})$ I_{315° Vs. $T_3(I_{270^\circ})$ I_{315° Vs. $T_4(I_{270^\circ})$

Tabla 4.3: Instancias de RIR consideradas para cada escenario (I_{0° Vs. $T_i(I_{45^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, y I_{315° Vs. $T_i(I_{270^\circ})$) y transformación de registro (T_1 , T_2 , T_3 , y T_4)

ambos casos, para esta última etapa de registrado se considerarán las imágenes originales del repertorio.

4.5.2.3. Valores de parámetros

La experimentación de esta sección se ha realizado en la misma plataforma de experimentaciones anteriores, un procesador Intel Pentium IV a 2.6 MHz con memoria RAM de 1GB y sistema operativo SuSe GNU-Linux v.9.0.

Como métodos de RIR para la prealineación de las diferentes instancias planteadas en la sección anterior, hemos considerado los métodos de RI empleados en los capítulos anteriores y también en la Sección 4.5.1: SS_m (sólo para el enfoque de RIR semiautomático⁷), SS_p , GA_{He} y CHC_{Real} . Además, hemos incorporado dos contribuciones recientes y del estado del arte en la literatura de RIR (Sección 4.4.3). La primera hace uso de un esquema de búsqueda evolutivo basado en AGs con codificación real [Chow, 04], notado GA_{Chow} . La segunda está basada en AGs con esquema de codificación entera [Lomonosov, 06], notado $GA_{Lomonosov}$. Se debe puntualizar que ambos métodos realizan un submuestreo de las imágenes consideradas, quedándose sólo con algunos cientos de puntos. Por ello, en nuestra experimentación, tanto GA_{Chow} como $GA_{Lomonosov}$ realizan un submuestreo de los repertorios proporcionados en los enfoques semiautomático y automático, respectivamente, los repertorios con las líneas de cresta y con las imágenes originales.

Por otro lado, debido a la naturaleza singular de las imágenes consideradas, la función objetivo de los métodos que trabajan en la búsqueda de los parámetros de la transformación (SS_p , CHC_{Real} , GA_{He} , GA_{Chow} y $GA_{Lomonosov}$) debe adecuarse a esta aplicación concreta. Emplearemos la siguiente:

$$F(f, I_e, I_m) = \frac{1}{1 + Ecm(I_m, f(I_e))} \quad (4.1)$$

$$Ecm(I_m, f(I_e)) = \text{mediana}\{\|f(\vec{p}_i) - \vec{p}_j'\|^2\}, \quad \forall \vec{p}_i \in I_e \quad (4.2)$$

donde \vec{p}_j' es el punto del modelo más cercano a $f(\vec{p}_i)$ de la escena.

Por un lado, podemos observar cómo la función objetivo elimina el segundo término de la Ecuación 3.1, correspondiente a la optimización del parámetro de escalado ya que, como hemos señalado, estamos tratando con un modelo de transformación rígido. Por otro lado, pasamos del cálculo del valor de *Error Cuadrático*

⁷La cantidad de información que se maneja en el enfoque de RIR automático hace que el problema sea intratable para SS_m .

Medio (ECM) de las correspondencias entre todos los puntos al cálculo del valor mediano de éstas (ECm). Esto se debe a que a medida que las imágenes poseen una región de solapamiento menor, el ECM obtiene un resultado más alejado del deseado. Sin embargo, con el ECM se persigue un registrado guiado mayoritariamente por la región de solapamiento. El éxito de una métrica basada en el ECM depende de que la región de solapamiento sea al menos de la mitad del tamaño de las imágenes de entrada.

Por otra parte, dado que estamos tratando con una transformación rígida, los métodos que trabajan en el enfoque de las correspondencias (SS_m y los basados en ICP) ven modificado su método de estimación de la transformación. En concreto, hemos deshabilitado el cálculo del parámetro de escalado que se indica en [Horn, 87].

Hemos decidido mantener los mismos valores de parámetros de los métodos de RI considerados en las experimentaciones de los capítulos anteriores. Para los algoritmos GA_{Chow} y $GA_{Lomonosov}$ hemos considerado los valores propuestos en su publicación [Chow, 04, Lomonosov, 06]. Asimismo, para cada uno de los métodos de prealineación hemos considerado quince ejecuciones (con semillas diferentes para el generador de números aleatorios) y un tiempo de ejecución de 20 y 100 segundos para los enfoques de RIR semiautomático y automático, respectivamente.

Por último, a la hora de decidirnos por un método de refinamiento, en un primer momento optamos por mantener el método $I - ICP$, considerado en las experimentaciones anteriores. Sin embargo, hemos comprobado un comportamiento anormal en éste. A pesar de proporcionarle un punto de partida próximo al óptimo (en ocasiones, el óptimo), observábamos cómo el método finalizaba con un RIR de peor calidad al inicial. Pensamos que esto debe estar relacionado con las características geométricas del objeto en estudio y el grado de solapamiento entre las imágenes, ya que, como muestra la Figura 4.13, el método se comporta de forma correcta con imágenes donde la región de solapamiento es amplia y existe poca oclusión. En [Dalley, 01] se realiza un análisis extenso de este comportamiento. En base a las conclusiones presentadas en [Dalley, 01], hemos elegido la propuesta publicada en [Zhang, 94] como método de refinamiento, notado ICP_{Zhang} . Como criterio de parada del método hemos decidido establecer un valor máximo de 250 iteraciones, número más que suficiente para garantizar la convergencia del algoritmo.




Figura 4.13: Resultados obtenidos por $I - ICP$ al registrar tres repertorios diferentes de imágenes. Los dos primeros («pájaro» y «rana») proceden de escaneos cada 20° , disponibles en el *Signal Analysis and Machine Perception Laboratory* (SAMPL) de la Universidad de Ohio en EEUU. El tercero corresponde a las vistas 0° y 45° de nuestro repertorio

4.5.2.4. Análisis de resultados

Al igual que en experimentaciones anteriores, el ECM⁸ nos va a servir para medir la calidad del proceso de RIR (una vez que finaliza la ejecución del método de RIR). Puesto que en esta ocasión, gracias al empleo de una tabla giratoria, podremos disponer a priori de un modelo 3D cuya reconstrucción puede considerarse la óptima, vamos a calcular el ECM de la siguiente forma:

$$ECM = \frac{\sum_{i=1}^r \|f(\vec{x}_i) - \vec{x}_i'\|^2}{r} \quad (4.3)$$

donde:

- $f(\vec{x}_i)$ corresponde al punto i -ésimo de la escena transformado mediante la transformación f estimada por cada método de RIR,
- r es el número de puntos de la imagen escena, y

⁸No debe confundirse la métrica de similitud considerada para evaluar la calidad del resultado del RIR con la función objetivo empleada durante el proceso de optimización, en nuestro problema, ECM y ECM, respectivamente.

- \vec{x}_i' corresponde a cada punto de la escena transformado usando la transformación óptima f^* conocida a priori al usar el citado sistema de posicionamiento.

En definitiva, tanto \vec{x}_i como \vec{x}_i' son el mismo punto aunque ocupan posiciones eventualmente diferentes en el espacio 3D, el primero no necesariamente alineado con la imagen modelo (si la estimación de f por parte del método de RIR no es la óptima) y el segundo sí. Lo que pretendemos con este cambio en el cálculo del ECM es aprovecharnos de la existencia a priori del modelo óptimo del objeto en estudio para contar con una medida de evaluación de los métodos de RIR mucho más realista. Además, este cambio sólo tiene cabida a nivel experimental ya que en entornos reales las técnicas de RIR no disponen de imágenes previamente registradas.

En primer lugar, hemos querido comprobar que la mera aplicación de un método basado en ICP no resuelve el problema diseñado. Con ello podríamos afirmar que el diseño experimental planteado se ajusta al entorno que pretendemos simular (reconstrucción 3D no asistida por sistemas de posicionamiento). Para dicha prueba hemos elegido el método *ICP + SA* por contar con un mejor rendimiento comparado con otras técnicas basadas en ICP, como se ha podido comprobar en experimentaciones anteriores. Hemos considerado el repertorio de imágenes originales y hemos mantenido la configuración de parámetros del método empleada en experimentaciones anteriores, con dos salvedades: i) el incremento en el número máximo de iteraciones de ICP hasta 250 y ii) la realización de una iteración más de la etapa de enfriamiento simulado y la etapa con ICP, dos iteraciones en total. Estas dos consideraciones se han establecido con el fin de asegurar unos valores de parámetros que garanticen una correcta convergencia del método. La Tabla 4.4 muestra mediante estadísticas el resultado de la ejecución de *ICP + SA*. Además, en la Figura 4.14 se visualizan los resultados de las mejores estimaciones obtenidas por dicho método. Como puede observarse, estos resultados son muy deficientes y, como hemos indicado, nos sirven de base para justificar el diseño experimental realizado, cuyos resultados pasamos a analizar a continuación.

Una vez confirmada la alta complejidad de nuestro problema de RIR, las tablas y figuras que se presentan a continuación muestran los resultados obtenidos por los diferentes métodos de prealineación al enfrentarse con él desde los dos enfoques de RIR considerados (semiautomático y automático). La estructura de las tablas es similar a la empleada en el capítulo anterior, cada una de ellas muestra los resultados obtenidos por cada método para los diferentes escenarios tratados y, a su vez, cada una de estas tablas se divide en cuatro apartados, uno por cada instancia de RIR resultante de considerar cada una de las cuatro transformaciones a estimar.

	I_{0° Vs. $T_i(I_{45^\circ})$				I_{45° Vs. $T_i(I_{90^\circ})$			
	T_1	T_2	T_3	T_4	T_1	T_2	T_3	T_4
m	14489.47	16442.37	8726.84	4652.77	12969.76	17407.50	13083.10	7602.37
M	16954.35	17640.04	10673.62	9319.89	18855.77	20083.11	14727.08	11388.52
μ	15984.32	17006.28	9934.50	6751.90	16288.32	19026.02	13867.02	10012.98
σ	685.89	429.48	471.65	1336.20	1434.25	844.99	480.81	1003.49
	I_{0° Vs. $T_i(I_{315^\circ})$				I_{315° Vs. $T_i(I_{270^\circ})$			
	T_1	T_2	T_3	T_4	T_1	T_2	T_3	T_4
m	14761.53	12632.33	6606.17	6915.59	15360.07	14073.80	8166.27	11148.35
M	17145.78	14231.54	11104.12	10000.04	17666.25	15714.38	13341.40	15753.94
μ	15824.27	13656.79	9333.66	8040.23	16726.80	14893.06	10725.70	12883.90
σ	846.76	442.85	1367.98	749.05	586.35	573.18	1411.95	1324.86

Tabla 4.4: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las dieciséis instancias de RIR (empleando el repertorio de imágenes original) tras realizar 15 ejecuciones diferentes del método $ICP + SA$. En negrita aparecen señalados tanto el mejor valor mínimo de ECM (m) como el mejor valor medio de ECM (μ) para cada uno de los cuatro escenarios (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$, I_{315° Vs. $T_i(I_{270^\circ})$)




Figura 4.14: Mejores estimaciones obtenidas por $ICP + SA$ en los cuatro escenarios. De izquierda a derecha se muestran las instancias: I_{0° Vs. $T_4(I_{45^\circ})$, I_{0° Vs. $T_3(I_{315^\circ})$, I_{45° Vs. $T_4(I_{90^\circ})$, e I_{315° Vs. $T_3(I_{270^\circ})$

Así, las Tablas 4.5 a 4.8 recogen los resultados del primero de los enfoques, realizando un resumen de dichas estadísticas en la Tabla 4.9. Esta última tabla incluye además un apartado indicando la eficacia obtenida en el proceso de reconstrucción 3D, es decir, si el método de RIR aplicado ha conseguido un modelo 3D válido. De la misma forma, en las Tablas 4.10 a 4.13 se detallan los resultados obtenidos al considerar el segundo enfoque de RIR, mostrando en la Tabla 4.14 un resumen de los mismos, junto con la eficacia conseguida en el proceso de reconstrucción.

El éxito del proceso de RIR depende fundamentalmente de la calidad de la solución obtenida en la etapa de prealineación. Por ello, con la intención de poder realizar un análisis más intuitivo de los resultados que se muestran en las tablas 4.5 a 4.14, en la Figura 4.15 mostramos gráficamente cinco ejemplos de RIR extraídos de la Tabla 4.5 en los que pretendemos reflejar la relación existente entre el valor de ECM y la representación visual del resultado obtenido en la etapas de prealineación y de refinamiento. En concreto, los valores de ECM de los ejemplos considerados son (gráficos 3D mostrados de izquierda a derecha en la Figura 4.15):

- $29.27 \rightarrow 1.39$, mejor estimación obtenida por GA_{He} en I_0° V.s. $T_4(I_{45^\circ})$.
- $163.72 \rightarrow 1.38$, mejor estimación obtenida por $GA_{Lomonosov}$ en I_0° V.s. $T_3(I_{45^\circ})$.
- $367.30 \rightarrow 4.01$, mejor estimación obtenida por CHC_{Real} en I_0° V.s. $T_1(I_{45^\circ})$.
- $1099.55 \rightarrow 223.30$, peor estimación obtenida por $GA_{Lomonosov}$ en I_0° V.s. $T_2(I_{45^\circ})$.
- $1356.57 \rightarrow 1356.57$, peor estimación obtenida por GA_{He} en I_0° V.s. $T_4(I_{45^\circ})$.

De esta forma, podemos observar cómo a medida que la prealineación es de menor calidad, la etapa de refinamiento tiene mayor dificultad para converger a una solución próxima a la óptima, lo cual es coherente con el comportamiento de los métodos basados en ICP. Nótese que en el último ejemplo presentado, incluso no se llega a conseguir mejora alguna tras el refinamiento.

A continuación centraremos nuestra atención en el rendimiento ofrecido por los diferentes métodos de RIR. A partir de los datos que se reflejan en el resumen de las Tablas 4.9 y 4.14 podemos observar cómo, para ambos enfoques de RIR, nuestra segunda propuesta basada en SS, centrada en la búsqueda en el espacio de parámetros de la transformación, SS_p , obtiene en un mayor número de ocasiones los mejores resultados en cuanto a precisión y rendimiento medio. Este comportamiento se acentúa aún más para el enfoque de RIR automático. Además, todos

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	20402.25	21844.13	21295.78	407.12	10414.82	11427.26	11137.27	242.80
SS_p	242.71	404.90	348.04	46.73	229.60	480.08	370.03	56.61
CHC_{Real}	367.30	4174.52	1182.76	1486.23	321.35	2929.48	1296.77	1156.37
GA_{He}	82.25	3238.22	745.34	778.66	55.89	2494.22	693.36	758.92
$GA_{Lomonosov}$	50.49	7214.49	1496.35	1658.51	69.42	1099.55	472.78	338.24
GA_{Chow}	502.04	6287.15	2584.47	1808.43	151.41	5056.52	2147.41	1619.21

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	10749.37	22223.93	20748.40	2718.73	2652.88	14628.15	11998.03	4667.06
SS_p	291.03	465.41	356.87	51.54	315.93	389.28	357.38	20.64
CHC_{Real}	358.12	2661.86	2444.97	559.65	329.92	376.37	348.43	12.32
GA_{He}	56.26	4329.50	954.90	1051.51	29.27	1356.57	370.84	321.74
$GA_{Lomonosov}$	163.72	1921.56	688.42	478.09	61.98	2672.56	651.12	648.44
GA_{Chow}	351.20	5238.53	1608.25	1341.75	333.18	5400.94	1897.17	1351.28

RIR semiautomático: I_0° Vs. $T_i(I_{45^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	19667.76	20956.99	20466.89	360.60	7413.27	11284.71	10791.27	915.20
SS_p	3.51	22.44	11.73	6.06	3.31	31.99	13.54	8.82
CHC_{Real}	4.01	4174.52	845.61	1646.26	2.27	2929.48	1081.17	1329.67
GA_{He}	1.36	3238.22	450.04	835.16	1.49	2494.22	440.97	869.91
$GA_{Lomonosov}$	1.48	5601.82	1032.79	1447.07	1.31	223.30	21.18	54.72
GA_{Chow}	1.31	4518.76	2069.30	1858.09	1.39	4434.18	1857.96	1741.17

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	6400.70	21362.10	19738.89	3594.11	2652.88	14492.35	11884.18	4610.23
SS_p	3.41	17.30	8.38	5.07	3.12	13.35	8.17	2.69
CHC_{Real}	7.78	2661.86	2421.61	646.78	6.43	11.05	7.78	1.23
GA_{He}	1.36	4208.54	615.22	1166.80	1.39	1356.57	141.65	360.72
$GA_{Lomonosov}$	1.38	340.58	68.77	116.13	1.48	2672.86	391.27	699.74
GA_{Chow}	2.21	5238.53	1158.02	1596.66	1.40	5368.14	1648.35	1526.32

Tabla 4.5: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_0° Vs. $T_1(I_{45^\circ})$, I_0° Vs. $T_2(I_{45^\circ})$, I_0° Vs. $T_3(I_{45^\circ})$ e I_0° Vs. $T_4(I_{45^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	6768.79	8516.35	7930.26	438.33	4393.93	5281.07	4818.66	226.15
SS_p	20.61	165.04	68.82	42.52	19.30	253.72	93.59	82.18
CHC_{Real}	41.47	106.25	65.21	21.12	36.30	135.38	73.60	28.96
GA_{He}	11.08	567.01	194.43	131.20	77.05	1060.93	378.03	293.72
$GA_{Lomonosov}$	117.28	696.56	288.51	183.72	37.27	895.94	380.13	254.47
GA_{Chow}	178.49	3603.40	1362.47	1107.47	422.67	5806.34	1818.55	1387.97

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	8225.44	9191.38	8687.46	242.33	1710.98	2676.92	2124.02	208.09
SS_p	39.49	218.11	125.73	54.50	11.17	87.49	44.76	22.80
CHC_{Real}	30.59	3983.39	345.72	973.23	67.28	88.77	75.78	5.99
GA_{He}	61.01	988.33	409.25	250.90	11.31	1287.92	272.36	286.21
$GA_{Lomonosov}$	38.12	1735.42	464.88	470.88	54.55	1127.36	412.52	352.49
GA_{Chow}	140.46	4986.99	1360.65	1374.27	101.61	2218.05	1055.85	656.31

RIR semiautomático: I_0° Vs. $T_i(I_{315^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	5730.29	6304.42	6115.38	154.69	2277.43	2571.91	2404.58	90.41
SS_p	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
CHC_{Real}	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
GA_{He}	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
$GA_{Lomonosov}$	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
GA_{Chow}	0.01	47.14	3.47	11.73	0.01	1084.44	79.20	269.39

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	6967.49	7192.42	7056.47	61.81	1710.98	2279.18	2064.50	139.97
SS_p	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
CHC_{Real}	0.01	180.52	12.04	45.02	0.01	0.01	0.01	0.00
GA_{He}	0.01	0.02	0.01	0.00	0.01	0.01	0.01	0.00
$GA_{Lomonosov}$	0.01	0.03	0.01	0.01	0.01	0.01	0.01	0.00
GA_{Chow}	0.01	43.02	4.24	11.39	0.01	2.07	0.16	0.51

Tabla 4.6: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_0° Vs. $T_1(I_{315^\circ})$, I_0° Vs. $T_2(I_{315^\circ})$, I_0° Vs. $T_3(I_{315^\circ})$ e I_0° Vs. $T_4(I_{315^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negra

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	4180.04	13195.95	6514.75	3160.69	3589.85	15310.30	6155.43	4521.15
SS_p	20.04	57.04	39.57	11.20	24.84	49.85	34.24	6.23
CHC_{Real}	19.49	51.53	26.21	7.88	20.83	37.63	30.55	4.9
GA_{He}	74.90	371.49	180.94	78.87	110.28	3171.42	829.47	898.30
$GA_{Lomonosov}$	66.43	4945.76	600.37	1190.03	84.87	2395.04	792.45	857.21
GA_{Chow}	180.97	11348.23	2713.85	2595.53	157.05	20497.82	4811.30	5358.35

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	4376.55	13308.20	6924.63	3618.82	2713.06	14782.55	5977.74	4530.17
SS_p	17.58	39.88	27.47	6.26	21.70	58.95	38.21	10.36
CHC_{Real}	22.15	1595.30	645.22	752.92	20.34	41.66	29.85	6.81
GA_{He}	26.77	3536.55	1398.21	1200.18	40.90	397.97	169.98	115.67
$GA_{Lomonosov}$	76.93	20226.04	3337.61	6646.54	51.41	8708.39	880.28	2139.14
GA_{Chow}	424.40	11713.10	3449.60	2731.66	393.27	6234.63	1614.51	1372.14

RIR semiautomático: I_{45° Vs. $T_i(I_{90^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	2586.11	13151.33	5197.02	3819.60	2925.15	14006.34	5329.77	4316.16
SS_p	1.30	1.42	1.35	0.04	1.32	1.41	1.35	0.02
CHC_{Real}	1.30	1.33	1.31	0.01	1.32	1.36	1.34	0.01
GA_{He}	1.34	2.03	1.63	0.20	1.30	144.04	36.19	52.26
$GA_{Lomonosov}$	1.38	4945.76	331.77	1233.14	1.26	149.51	35.98	56.53
GA_{Chow}	1.34	11348.23	801.60	2818.97	1.68	18764.62	3142.41	5722.17

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	2818.88	13259.88	5729.29	4313.19	2713.06	14782.55	5792.03	4421.43
SS_p	1.30	1.35	1.32	0.01	1.32	1.43	1.36	0.03
CHC_{Real}	1.30	161.39	60.30	72.61	1.31	1.37	1.34	0.01
GA_{He}	1.29	159.15	70.67	62.04	1.26	1.90	1.40	0.16
$GA_{Lomonosov}$	1.39	18715.29	2513.49	6353.48	1.26	8708.39	582.79	2171.66
GA_{Chow}	3.26	9569.70	805.29	2350.93	1.65	6234.63	485.92	1538.29

Tabla 4.7: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{45° Vs. $T_1(I_{90^\circ})$, I_{45° Vs. $T_2(I_{90^\circ})$, I_{45° Vs. $T_3(I_{90^\circ})$ e I_{45° Vs. $T_4(I_{90^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	5655.95	20248.91	7049.49	3532.17	5403.82	17683.26	7107.03	4048.78
SS_p	20.66	64.26	41.77	14.20	23.87	124.44	64.03	41.30
CHC_{Real}	39.63	64.53	51.25	7.31	32.34	54.53	46.63	5.83
GA_{He}	25.81	13691.99	2070.67	4261.81	6.73	1422.31	544.45	477.50
$GA_{Lomonosov}$	149.55	13280.82	1513.42	3175.78	79.62	705.28	306.97	142.83
GA_{Chow}	211.37	8655.23	3120.92	2676.62	223.62	13792.21	6405.40	5227.30

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	3916.71	17269.62	5889.50	4395.44	2989.97	12766.84	3826.74	2393.05
SS_p	17.25	141.44	66.65	38.03	13.97	24.56	20.06	3.47
CHC_{Real}	30.99	134.09	52.26	25.67	18.35	26.73	21.63	2.72
GA_{He}	116.88	1086.51	500.13	252.65	42.60	373.66	147.95	106.09
$GA_{Lomonosov}$	133.35	3747.28	868.65	954.90	75.12	1508.43	427.93	347.65
GA_{Chow}	498.66	13815.26	4064.51	4033.26	242.12	2190.88	926.94	522.43

RIR semiautomático: I_{315° Vs. $T_i(I_{270^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_m	3456.91	18581.08	4808.86	3683.03	2146.12	16675.78	4175.61	4817.12
SS_p	3.61	3.63	3.62	0.01	2.89	3.62	3.33	0.34
CHC_{Real}	3.62	3.63	3.63	0.00	3.59	3.62	3.62	0.01
GA_{He}	2.48	10830.00	1436.37	3654.13	2.48	22.42	6.84	6.76
$GA_{Lomonosov}$	1.75	11143.11	749.93	2777.70	1.86	4.78	3.01	0.78
GA_{Chow}	2.45	5498.43	683.14	1624.90	2.34	10860.12	4238.43	5154.46

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_m	3368.47	15670.27	5185.11	4106.65	2013.92	12067.25	2842.36	2469.03
SS_p	2.73	3.62	3.29	0.36	3.62	3.62	3.62	0.00
CHC_{Real}	2.74	3.62	3.57	0.21	3.62	3.62	3.62	0.00
GA_{He}	2.32	13.14	4.09	2.62	2.06	3.92	3.26	0.51
$GA_{Lomonosov}$	1.50	29.13	8.81	9.17	1.73	3.62	2.65	0.62
GA_{Chow}	2.48	10777.19	2210.65	3805.84	1.87	15.55	5.62	4.25

Tabla 4.8: Valores mínimo (m), máximo (M), medio (μ), y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{315° Vs. $T_1(I_{270^\circ})$, I_{315° Vs. $T_2(I_{270^\circ})$, I_{315° Vs. $T_3(I_{270^\circ})$ e I_{315° Vs. $T_4(I_{270^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes procesadas por detector de líneas de cresta. Se indican por separado los resultados obtenidos por cada método (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	RIR				RECONSTRUCCIÓN CORRECTA
	Prealineación		Refinamiento		
	mínimo	media	mínimo	media	
SS_m	0	0	0	0	×
SS_p	6	8	5	10	✓
CHC_{Real}	4	8	4	7	✓
GA_{He}	5	0	8	4	✓
$GA_{Lomonosov}$	0	0	10	6	✓
GA_{Chow}	0	0	5	0	✓

Tabla 4.9: Resumen de resultados de los escenarios de RIR (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$ e I_{315° Vs. $T_i(I_{270^\circ})$) con imágenes procesadas por un detector de líneas de cresta (enfoque de RIR semiautomático). Se indican el número de veces (dieciséis como máximo) en que cada método de RIR (SS_m , SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) consigue el mejor valor mínimo y medio de ECM, así como la eficacia de cada método en el proceso de reconstrucción




Figura 4.15: Cinco ejemplos de RIR extraídos de la Tabla 4.5 mostrando (de izquierda a derecha) por columnas ordenadas según valor creciente de ECM, el resultado obtenido tras realizar las etapas de prealineación y de refinamiento

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	9.70	11479.33	7560.98	2464.13	6.98	5630.40	1505.89	2304.64
CHC_{Real}	3902.42	10932.29	6732.54	2020.79	2586.08	6391.18	4148.85	983.86
GA_{He}	681.91	14602.85	7951.74	4336.16	1570.23	11655.89	4117.20	3570.24
$GA_{Lomonosov}$	3099.70	15578.35	8467.54	5062.60	1204.28	6834.97	3559.31	1583.57
GA_{Chow}	1391.39	15143.81	8668.86	3928.83	1724.65	17692.65	6191.85	3431.35

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	7.00	3112.36	1140.93	1379.95	8.69	10137.43	6613.69	4108.00
CHC_{Real}	86.19	2759.83	1535.91	932.91	81.79	6820.45	3318.56	2651.48
GA_{He}	249.15	9060.08	2545.18	2710.12	81.07	17545.83	3264.06	4501.06
$GA_{Lomonosov}$	304.76	3953.30	1893.16	1011.34	522.34	17851.20	7757.41	4572.43
GA_{Chow}	950.17	10927.11	3843.40	2393.61	472.45	18101.16	10002.86	4661.63

RIR automático: I_{0° Vs. $T_i(I_{45^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.49	11479.33	7553.89	2465.41	1.37	5630.40	1417.78	2351.80
CHC_{Real}	3902.42	10449.23	6534.39	1901.94	2586.08	6391.18	4141.74	982.97
GA_{He}	240.29	13991.22	7759.04	4254.29	253.81	11655.89	3905.22	3430.91
$GA_{Lomonosov}$	3099.70	15578.35	8401.16	4976.56	854.61	6834.97	3513.20	1649.80
GA_{Chow}	1074.09	15143.81	8067.05	4094.66	1724.65	16093.26	5907.46	3754.55

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.50	3112.36	1112.95	1399.51	1.48	9919.53	6585.65	4092.68
CHC_{Real}	1.66	2759.83	1335.45	1142.99	1.63	6820.45	3138.92	2837.04
GA_{He}	1.59	9060.08	2359.90	2816.46	1.60	17005.08	2872.76	4556.31
$GA_{Lomonosov}$	4.53	3780.89	1684.41	1131.34	16.84	17851.20	7658.33	4701.49
GA_{Chow}	208.77	10927.11	3762.57	2495.64	13.59	18101.16	9717.35	4604.05

Tabla 4.10: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{0° Vs. $T_1(I_{45^\circ})$, I_{0° Vs. $T_2(I_{45^\circ})$, I_{0° Vs. $T_3(I_{45^\circ})$ e I_{0° Vs. $T_4(I_{45^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	0.46	2.03	1.31	0.56	0.03	2.04	1.27	0.54
CHC_{Real}	0.33	536.81	39.16	133.17	6.92	4387.37	849.26	1189.87
GA_{He}	82.43	5445.11	1372.00	1688.71	394.45	10750.93	2906.81	2709.30
$GA_{Lomonosov}$	17.51	873.47	397.86	296.29	38.80	6801.83	901.37	1854.89
GA_{Chow}	160.13	8314.34	2258.00	2597.79	45.10	21072.23	9246.93	7252.42

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	0.60	1.98	1.43	0.45	0.44	1.92	1.31	0.51
CHC_{Real}	22.07	4190.37	883.50	1088.91	0.35	1.92	0.98	0.52
GA_{He}	442.71	11470.86	3387.56	3506.52	64.88	1097.76	466.93	315.39
$GA_{Lomonosov}$	13.87	15915.34	8100.19	6521.79	51.99	6582.46	1774.04	2388.41
GA_{Chow}	232.90	18775.53	8202.90	6336.41	598.60	6160.67	2973.48	1704.06

RIR automático: I_0° Vs. $T_i(I_{315^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
CHC_{Real}	0.01	0.02	0.01	0.00	0.01	4322.85	360.70	1078.12
GA_{He}	0.01	2934.14	519.38	972.28	0.01	7198.02	1343.19	2024.69
$GA_{Lomonosov}$	0.01	82.40	8.16	21.05	0.01	6433.83	611.05	1689.94
GA_{Chow}	0.01	7162.80	1189.77	2225.74	0.01	21165.96	8258.95	7664.76

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.00
CHC_{Real}	0.01	4190.37	356.40	1031.97	0.01	0.01	0.01	0.00
GA_{He}	0.01	11470.86	2533.25	3816.27	0.01	334.64	36.85	86.67
$GA_{Lomonosov}$	0.01	15292.79	8034.59	6503.39	0.01	6429.36	1273.88	2519.95
GA_{Chow}	0.01	17992.58	6658.78	7166.29	0.01	14673.30	1664.11	3612.26

Tabla 4.11: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_0° Vs. $T_1(I_{315^\circ})$, I_0° Vs. $T_2(I_{315^\circ})$, I_0° Vs. $T_3(I_{315^\circ})$ e I_0° Vs. $T_4(I_{315^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.37	19518.23	7639.58	9355.10	1.18	18781.22	1263.14	4682.02
CHC_{Real}	71.66	19237.25	15166.99	7477.44	355.36	19330.64	15324.03	7344.52
GA_{He}	234.28	19401.09	6881.44	8450.11	249.43	19556.05	8216.60	8626.21
$GA_{Lomonosov}$	190.03	19706.94	6800.40	8951.28	39.67	19740.16	5505.17	8402.71
GA_{Chow}	455.75	19952.58	13985.16	7582.15	76.30	20744.82	8550.37	8809.62

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.13	19400.45	2586.62	6590.47	1.10	2.23	1.75	0.31
CHC_{Real}	1.38	19050.05	8848.67	9283.25	1.96	191.89	39.35	56.18
GA_{He}	192.17	18952.49	2983.76	6098.48	163.34	19431.50	6481.14	8645.75
$GA_{Lomonosov}$	6.20	19767.45	4134.15	7653.94	21.98	18795.58	2723.49	6295.71
GA_{Chow}	408.12	19963.54	13023.26	8391.45	228.30	20123.88	11617.05	8425.72

RIR automático: I_{45° Vs. $T_i(I_{90^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.24	19518.23	7638.99	9355.58	1.18	18781.22	1253.63	4684.44
CHC_{Real}	1.57	19237.25	15124.39	7562.25	1.99	19330.64	15197.41	7596.87
GA_{He}	1.64	19401.09	6288.96	8844.56	1.69	19682.63	7522.01	9133.50
$GA_{Lomonosov}$	1.78	19420.03	6452.13	9058.42	1.34	19601.43	5172.05	8502.45
GA_{Chow}	2.24	19952.58	13358.92	8227.04	1.34	19816.55	7776.61	9176.55

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	1.13	19400.45	2586.27	6590.61	1.10	1.27	1.24	0.03
CHC_{Real}	1.25	19050.05	8757.20	9360.11	1.25	1.97	1.39	0.21
GA_{He}	1.27	18952.49	2481.38	6278.84	1.36	19431.50	6253.77	8805.50
$GA_{Lomonosov}$	1.25	19411.10	3864.91	7705.66	1.31	18795.58	2518.45	6373.43
GA_{Chow}	3.61	19505.41	12540.78	8854.98	2.42	19768.89	11240.35	8760.94

Tabla 4.12: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{45° Vs. $T_1(I_{90^\circ})$, I_{45° Vs. $T_2(I_{90^\circ})$, I_{45° Vs. $T_3(I_{90^\circ})$ e I_{45° Vs. $T_4(I_{90^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	2.72	20375.45	1365.01	5080.76	2.72	21670.24	5751.10	9531.05
CHC_{Real}	1.74	20477.43	12164.47	9824.36	1.19	20964.12	1731.04	5146.62
GA_{He}	98.06	20009.51	7202.46	8479.44	62.36	19831.55	5028.31	7501.48
$GA_{Lomonosov}$	28.11	20000.45	2900.82	6678.20	47.69	20600.98	1679.80	5063.88
GA_{Chow}	752.08	20192.43	13688.57	7938.83	499.67	20139.24	10859.70	8078.56

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	2.81	21312.71	2842.64	7087.65	2.02	5.78	3.69	1.06
CHC_{Real}	3.53	20024.75	2752.86	6766.36	1.50	281.50	24.26	68.90
GA_{He}	21.70	19605.53	3053.48	6446.66	37.03	20305.74	3904.38	6968.96
$GA_{Lomonosov}$	20.33	19951.30	4285.74	7733.34	23.56	410.12	134.04	116.60
GA_{Chow}	293.66	21518.90	10013.40	9260.79	485.42	21155.96	6903.99	8301.50

RIR automático: I_{315° Vs. $T_i(I_{270^\circ})$

	T_1				T_2			
	m	M	μ	σ	m	M	μ	σ
SS_p	2.72	20375.45	1361.59	5081.66	2.72	21605.61	5742.59	9517.60
CHC_{Real}	1.74	20477.43	12112.18	9888.13	1.19	20964.12	1400.38	5228.62
GA_{He}	2.46	20009.51	6932.43	8691.36	2.45	19831.55	4610.33	7740.75
$GA_{Lomonosov}$	2.45	20000.45	2658.30	6767.95	2.61	20600.98	1377.29	5137.74
GA_{Chow}	2.65	20192.43	13260.02	8590.65	2.57	20139.24	10200.25	8796.53

	T_3				T_4			
	m	M	μ	σ	m	M	μ	σ
SS_p	2.81	21290.11	2788.46	7101.72	2.02	3.62	3.20	0.5
CHC_{Real}	2.53	20024.75	2669.73	6797.25	1.50	3.62	3.09	0.66
GA_{He}	1.95	19605.53	2596.97	6610.00	2.15	20305.74	3497.45	7156.07
$GA_{Lomonosov}$	2.47	19951.30	3951.35	7893.31	2.29	4.17	3.42	0.5
GA_{Chow}	2.48	21362.86	9265.16	9920.66	2.60	21155.96	5491.44	9085.52

Tabla 4.13: Valores mínimo (m), máximo (M), medio (μ) y desviación típica (σ) de ECM para cada una de las cuatro instancias I_{315° Vs. $T_1(I_{270^\circ})$, I_{315° Vs. $T_2(I_{270^\circ})$, I_{315° Vs. $T_3(I_{270^\circ})$ e I_{315° Vs. $T_4(I_{270^\circ})$ tras realizar 15 ejecuciones diferentes de RIR con imágenes muestreadas uniformemente a un 15 % del tamaño original. Se indican por separado los resultados obtenidos por cada método (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) en cada etapa (prealineación y refinamiento). El mejor valor mínimo de ECM (m) y el mejor valor medio de ECM (μ) aparecen resaltados en negrita

	RIR				RECONSTRUCCIÓN CORRECTA
	Prealineación		Refinamiento		
	mínimo	media	mínimo	media	
SS_p	11	10	12	10	✓
CHC_{Real}	5	3	7	4	×
GA_{He}	0	1	5	3	×
$GA_{Lomonosov}$	0	2	5	0	×
GA_{Chow}	0	0	0	0	×

Tabla 4.14: Resumen de resultados de los escenarios de RIR (I_{0° Vs. $T_i(I_{45^\circ})$, I_{0° Vs. $T_i(I_{315^\circ})$, I_{45° Vs. $T_i(I_{90^\circ})$ e I_{315° Vs. $T_i(I_{270^\circ})$) con imágenes muestreadas uniformemente a un 15 % del tamaño original (enfoque de RIR automático). Se indican el número de veces (dieciséis como máximo) en que cada método de RIR (SS_p , CHC_{Real} , GA_{He} , $GA_{Lomonosov}$ y GA_{Chow}) consigue el mejor valor mínimo y medio de ECM, así como la eficacia de cada método en el proceso de reconstrucción

los métodos excepto nuestra primera propuesta (SS_m) consiguen una reconstrucción correcta ⁹ del modelo al afrontar el RIR desde el enfoque semiautomático. Sin embargo, nuestra segunda propuesta, SS_p , es la única que consigue una reconstrucción correcta para el enfoque automático (ver Figura 4.16).

En este punto, es preciso analizar el bajo rendimiento de nuestra primera propuesta, SS_m , con el objetivo de aclarar los puntos débiles en su diseño al enfrentarse a un problema de naturaleza diferente a los tratados en experimentaciones anteriores, como es el RIR. A partir de las tablas de resultados, podemos observar cómo SS_m no consigue una prealineación de suficiente calidad que ayude a la convergencia adecuada de la etapa de refinamiento. Para analizar este comportamiento, en la Figura 4.17 mostramos las cuatro mejores estimaciones (tras finalizar la etapa de refinamiento) de cada escenario de RIR obtenidas por SS_m . Podemos observar cómo se consigue una orientación de buena calidad entre cada par de imágenes, en particular si lo comparamos con los mejores resultados obtenidos por $ICP + SA$ (ver Figura 4.14). Sin embargo, se genera una desalineación entre las imágenes

⁹Tras realizar la inspección visual de múltiples resultados de RIR, hemos concluido que una reconstrucción se puede considerar correcta según el siguiente criterio: la media de las mejores estimaciones (columna m de las tablas de resultados) no debe superar un valor de ECM igual a 5 en ninguno de los cuatro escenarios de RIR.




Figura 4.16: Gráficos 3D mostrando, desde diferentes puntos de vista, el modelo 3D reconstruido por SS_p siguiendo el enfoque de RIR automático

producto de un desplazamiento pronunciado entre ellas. Su magnitud es lo suficientemente grande como para provocar que la etapa de refinamiento quede atrapada en un óptimo local. Recordando el diseño de SS_m , la estimación de la componente de traslación de la transformación de registrado (f) se realiza a partir de la diferencia de los centros de masas del par de imágenes de entrada al problema de RI. Esta consideración es apropiada para los entornos de RI donde ambas imágenes recogen la totalidad de la superficie del objeto escaneado, o bien un alto porcentaje de ésta. Dicho de otra forma, la oclusión entre las imágenes no debe ser pronunciada. Por tanto, cuanto menor es la región de solapamiento entre imágenes adyacentes, mayor es la desviación entre el centro de masas calculado sobre el global de la imagen respecto del centro de masas calculado sólo sobre la región de solapamiento. Esto explica la desalineación anterior generada por SS_m , ya que el método calcula la traslación a partir del primero de los dos centros de masas anteriores. A pesar de que los métodos del enfoque de la búsqueda de los parámetros de f también consideran como centro de masas el de la imagen al completo, el diseño de éstos permite la búsqueda de la componente de traslación dentro de un cierto grado del dominio.

Además, el bajo rendimiento de SS_m también se relaciona con las decisiones tomadas para obtener el actual repertorio de imágenes. Concretamente, nos referimos a haber realizado escaneos de la superficie del objeto cada 45° . Esta consideración es de especial influencia en los métodos de RI que realizan la búsqueda en el espacio de las correspondencias [Moreels, 05]. En esta contribución se concluye que la extracción de características en imágenes obtenidas mediante escaneos superiores a 30° provoca que el establecimiento de correspondencias entre las mismas sea poco fiable debido al reducido porcentaje de puntos válidos con los que poder estimar una transformación de registrado óptima. Así queda reflejado también en

nuestra experimentación.




Figura 4.17: Mejores estimaciones obtenidas por SS_m en los cuatro escenarios del enfoque de RIR semiautomático. De izquierda a derecha se muestran las instancias: I_{0° Vs. $T_4(I_{45^\circ})$, I_{0° Vs. $T_2(I_{315^\circ})$, I_{45° Vs. $T_1(I_{90^\circ})$, e I_{315° Vs. $T_4(I_{270^\circ})$

Por otro lado, en las Figuras 4.18 y 4.19 se muestran sendas gráficas de barras con una valoración cuantitativa del éxito de cada método de RIR al afrontar cada uno de los enfoques de RIR tratados. En ambas figuras se muestra el rendimiento de cada método de prealineación y el resultado final de RIR tras completar la etapa de refinamiento con ICP_{Zhang} para cada uno de los cuatro escenarios considerados en los enfoques semiautomático y automático, respectivamente. Analizando las dos figuras citadas, es con el enfoque semiautomático con el que se obtienen los mejores resultados de RIR, tanto en la etapa de prealineación como al finalizar el proceso de RIR con la etapa de refinamiento. Además, la gráfica de la Figura 4.20 resume (promediando los resultados de los cuatro escenarios) lo mostrado en las dos figuras anteriores tratando de reflejar, de forma cuantitativa, el error promedio obtenido por cada método de prealineación en la reconstrucción del modelo 3D. De un lado, podemos ordenar los métodos de prealineación según la calidad del modelo obtenido tratando el enfoque semiautomático: SS_p , GA_{He} , CHC_{Real} , $GA_{Lomonosov}$, GA_{Chow} e SS_m . De otro lado, en el enfoque automático, los métodos considerados mantendrían prácticamente el mismo orden, con CHC_{Real} por debajo de $GA_{Lomonosov}$ y dejando fuera de la lista a SS_m por las consideraciones citadas anteriormente.

En particular, a pesar de que los métodos GA_{Chow} y $GA_{Lomonosov}$ realizan un mayor número de evaluaciones de la función objetivo (gracias al submuestreo específico que ambas aplican sobre las imágenes, ver Sección 4.4.3), dicho factor no resulta determinante en el rendimiento de ambas propuestas, como así lo demuestran los resultados presentados en las gráficas de las Figuras 4.18 a 4.20. Mientras




Figura 4.18: Rendimiento promedio según valor de ECM ofrecido por los diferentes métodos de RIR al afrontar el problema desde el enfoque semiautomático. Las gráficas de barras corresponden, en la parte superior, al rendimiento obtenido en la etapa de prealineación, y en la parte inferior, al obtenido en la etapa final de refinamiento, considerando en ambos casos cada uno de los cuatro escenarios de RIR




Figura 4.19: Rendimiento promedio según valor de ECM ofrecido por los diferentes métodos de RIR al afrontar el problema desde el enfoque automático. Las gráficas de barras corresponden, en la parte superior, al rendimiento obtenido en la etapa de prealineación, y en la parte inferior, al obtenido en la etapa final de refinamiento, considerando en ambos casos cada uno de los cuatro escenarios de RIR




Figura 4.20: Comparativa del rendimiento promedio según valor de ECM entre los dos enfoques de RIR (semiautomático y automático). Los datos que se muestran de cada método corresponden al promedio de los valores medios de ECM de los cuatro escenarios

que $GA_{Lomonosov}$ consigue ser competitivo frente a CHC_{Real} , GA_{Chow} por su parte, a pesar de realizar un submuestreo menos severo que $GA_{Lomonosov}$, se convierte en el método con peor rendimiento promedio superando solamente a SS_m . La única salvedad es que, como ya hemos comentados, GA_{Chow} consigue realizar una correcta reconstrucción del modelo en el enfoque semiautomático. El bajo rendimiento de estas dos contribuciones recientes ($GA_{Lomonosov}$ y GA_{Chow}) lo asociamos con el diseño de algunos de sus componentes (ver Sección 4.4.3) como: la representación de la rotación (tres ángulos de Euler), el criterio empleado en GA_{Chow} para aplicar el mecanismo de reinicialización llamado «dynamic boundary» o el empleo de un esquema de codificación entera de la solución en $GA_{Lomonosov}$.

Una vez analizado el rendimiento de los diferentes métodos de prealineación

afrontando los dos enfoques de RIR, observamos cómo todos mantienen un comportamiento similar al ofrecido en experimentaciones anteriores, con los métodos basados en la búsqueda en el espacio de la transformación como la mejor alternativa. De entre estos últimos, es nuestra propuesta SS_p la que consigue los mejores resultados para cualquiera de los enfoques de RIR tratados, a diferencia del bajo rendimiento que ofrece la primera propuesta SS_m , que además presenta la limitación de no poder operar en un enfoque automático.

Por último, y a partir de los resultados anteriores, vamos a comentar las luces y sombras de los enfoques de RIR semiautomático y completamente automático. Fundamentalmente, con el primero se reduce la complejidad del problema, permitiendo así que un mayor número de métodos consiga la reconstrucción correcta del modelo 3D en un tiempo reducido, a diferencia del segundo enfoque, en el que esto ocurre con poca frecuencia. Sin embargo, en estas pocas ocasiones, el valor de ECM tras la etapa de prealineación es incluso mejor que el del primer enfoque tras la etapa de refinamiento. En cambio, el inconveniente básico del primero se centra en la necesidad de usar un método robusto para la detección de aquellas características que el experto forense considere relevantes en la imagen, siendo éste un proceso manual y laborioso en numerosas ocasiones, lo que puede llevar una considerable cantidad de tiempo.

Conclusiones

Con este capítulo hemos pretendido abordar la automatización de ciertas tareas de gran importancia en el campo de la Antropología Forense, como son el cotejado de objetos forenses mediante la superposición de sus modelos 3D y la obtención de los modelos 3D de objetos forenses mediante un proceso de reconstrucción. Para afrontar la solución a ambos problemas, hemos decidido aplicar el RI en este nuevo entorno debido a las similitudes que encontramos entre la forma de proceder del experto y las técnicas de este área.

Con el propósito de validar el rendimiento de nuestras dos propuestas en este escenario, hemos dedicado secciones específicas al diseño de los experimentos necesarios para abordar el objetivo de automatización de las dos tareas de identificación forense mencionadas. Del análisis realizado en dichas secciones podemos concluir que la aplicación de técnicas de RI basadas en metaheurísticas proporciona resultados satisfactorios afrontando los problemas que se plantean en este campo. Observando el conjunto de métodos empleados en dichas experimentaciones, son los que operan en el espacio de búsqueda de los parámetros los que consiguen una mayor satisfacción en cuanto al grado de automatización se refiere. De entre estos

últimos, nuestra propuesta basada en SS , SS_p , copa la clasificación en la lista de métodos con mejor rendimiento.

Por otro lado, hemos podido constatar cómo para este nuevo entorno de aplicación, el proceso de extracción de características (en nuestro caso las líneas de cresta y la información de curvatura asociada a éstas) supone una ganancia significativa en el resultado final (enfoque de RIR semiautomático), frente al enfoque que trabaja con la imagen original (enfoque de RIR automático) que, si bien ofrece en un número muy limitado de casos una mayor precisión en la etapa de prealineación, provoca que el rendimiento global de los métodos caiga de forma considerable. En cambio, el enfoque de RIR semiautomático tiene el inconveniente de depender del uso de métodos robustos de extracción de características y de requerir la intervención manual del experto, que debe de estar suficientemente preparado para realizar la tarea laboriosa de extracción de líneas de cresta.

Capítulo 5

Comentarios finales

5.1. Resultados Finales y Conclusiones

En esta memoria hemos abordado el registro de imágenes tridimensionales, una de las tareas más relevantes y de mayor interés en los últimos años para las comunidades de la visión por computador y de los gráficos por computador. Nuestra intención ha sido afrontar la problemática de esta tarea desde una perspectiva de optimización. Así, hemos hecho uso de los esquemas de búsqueda global ofrecidos por las metaheurísticas como alternativa a los métodos de registro tradicionales, los cuales están centrados principalmente en técnicas de búsqueda local. Para ello, en el Capítulo 1 hemos sentado las bases del problema de registro y enfocado su resolución desde el campo de las metaheurísticas.

Debido al éxito que han tenido en los últimos años los algoritmos evolutivos al resolver de forma satisfactoria el problema de registro, en nuestra memoria hemos considerado el algoritmo Scatter Search por las interesantes características que proporciona su metodología de diseño y por el éxito obtenido en su aplicación en otros problemas. En los Capítulos 2 y 3 hemos desarrollado dos nuevas propuestas de registro con Scatter Search afrontando el problema de registro desde los dos enfoques de resolución de mayor difusión en la literatura: la búsqueda en el espacio de correspondencias y la búsqueda en el espacio de los parámetros de la transformación. Así, nuestras propuestas cuentan con diseños específicos para ambos enfoques. Por otro lado, para validar nuestros métodos hemos tratado un conjunto de instancias del problema diseñadas con el propósito de afrontar escenarios de complejidad notable. Para ello hemos hecho uso del conocido repositorio *BrainWeb*, comúnmente utilizado en la literatura especializada. Asimismo, debido al éxito obtenido por aquellos métodos de registro que trabajan con información característica extraída de las imágenes, antes de llevar a cabo la tarea de registro, hemos realizado un proceso de extracción de un conjunto suficientemente reducido

y relevante de puntos de líneas de cresta de las imágenes consideradas, junto con la información de curvatura asociada a cada uno de ellos.

Por último, en el Capítulo 4 hemos aplicado nuestras propuestas de registrado a algunos problemas de la Antropología Forense, los cuales suelen ser resueltos por el experto de forma manual. En concreto, hemos abordado dos tareas relacionadas con la identificación forense: el cotejado de objetos forenses mediante la superposición de sus modelos tridimensionales y la obtención de modelos tridimensionales de objetos forenses mediante reconstrucción 3D. Para desarrollar ambas aplicaciones, hemos usado sendos repertorios de imágenes, uno del Laboratorio de bioingeniería del *Brown Medical School Hospital* de Rhode Island en EEUU y otro del Laboratorio de Antropología Física de la Universidad de Granada.

En los apartados siguientes analizaremos los resultados obtenidos en esta memoria, así como el grado de satisfacción conseguido para cada uno de los objetivos planteados al comienzo de la misma:

- *Diseño de nuevas técnicas de registrado de imágenes basadas en nuevos modelos de computación evolutiva.* Los resultados obtenidos en esta memoria corroboran el mejor rendimiento obtenido por las técnicas de búsqueda basadas en metaheurísticas, en especial las estrategias evolutivas, frente al obtenido por las consideradas en los métodos tradicionales de registrado.

El éxito de nuestras propuestas basadas en Scatter Search se debe en gran medida a la consideración de decisiones concretas de diseño que hemos tomado para la implementación de cada una de sus componentes:

- *Determinar un conjunto inicial de soluciones adecuado.* En particular, el diseño del *Método de Generación de Soluciones Diversas*. Gracias a la filosofía del mismo, que potencia un equilibrio entre determinismo y aleatoriedad, unido al interés por hacer uso de información específica del problema tratado, es posible conseguir un conjunto de soluciones mejor distribuido dentro del espacio de búsqueda con mayor probabilidad. A partir de este muestreo inicial, se llevará a cabo un mejor proceso de exploración/explotación. Además, el uso del *Método de Mejora* sobre este conjunto de soluciones incide en la obtención de soluciones de gran calidad.
- *Dotar de una mayor capacidad de explotación al proceso de búsqueda.* En este sentido, el *Método de Mejora* tiene como misión realizar una búsqueda en profundidad para la mejora de soluciones. Si bien no es obligado su uso, en nuestro trabajo hemos podido constatar cómo su

consideración repercute de forma positiva en el rendimiento global del proceso de búsqueda.

- *Mejorar la eficiencia del proceso de búsqueda.* Contar con un conjunto de referencia de tamaño considerablemente reducido, así como de un criterio de aplicación selectiva del *Método de Mejora*, favorece la consecución de este objetivo.

Por otro lado, una amenaza siempre presente en este tipo de técnicas es la convergencia prematura. Hemos podido apreciar cómo la consideración de una generación completamente aleatoria del conjunto inicial de soluciones hace que el rendimiento de Scatter Search adolezca en cierto grado de este inconveniente. Esto se debe principalmente a la acentuada capacidad de intensificación del algoritmo tras aplicar el *Método de Generación de Soluciones Diversas*, el cual tiene por objetivo introducir una apropiada diversificación desde el inicio de la búsqueda tratando de evitar el inconveniente mencionado. Gracias al especial diseño de dicho método en nuestras propuestas, hemos conseguido reducir en gran medida este tipo de situaciones.

- *Formulación del problema de registro de imágenes estudiando conjuntamente la puesta en correspondencia o matching y la búsqueda de parámetros de la transformación de registro.* Hemos propuesto dos algoritmos distintos gracias al estudio que hemos realizado del problema de registro abordando los enfoques de búsqueda en el espacio de correspondencias y en el espacio de los parámetros de la transformación. Ambas propuestas han mejorado el rendimiento de los métodos del estado del arte de sus respectivos enfoques.
- *Relajación de consideraciones sobre la función objetivo.* Hemos demostrado cómo haciendo cambios sólo en la descripción de la función objetivo, las metaheurísticas se convierten en técnicas genéricas de optimización para entornos de registro diferentes. En particular, hemos comprobado este hecho con el uso de funciones simples como son el error cuadrático medio (ECM) para aplicaciones médicas con imágenes MRI y CT, y el error cuadrático mediano (ECm) para aplicaciones de Antropología Forense con imágenes obtenidas por escáneres de rango.
- *Resolución de problemas de registro de imágenes médicas tridimensionales.* Hemos abordado el problema del registro de imágenes considerando varios repertorios de imágenes 3D de diferente naturaleza. Concretamente, hemos hecho uso de imágenes del ámbito de la medicina, tales como MRI y CT, así como las del área de la Antropología Forense, como son las imágenes de rango. Como consecuencia, hemos tenido que afrontar escenarios

de mayor complejidad, bien por la presencia de ruido y oclusión en las imágenes, bien por el diseño de conjuntos de experimentos donde las instancias a resolver consideraban pares de imágenes diferentes en todos los casos. Además, la extracción de las características más relevantes en las imágenes médicas tridimensionales nos ha permitido reducir tanto la complejidad del problema como coste en la evaluación de la calidad de las soluciones. En esta línea, gracias al análisis en profundidad que se ha hecho de las propiedades de dicha información característica, hemos podido diseñar técnicas de optimización que mejoran el rendimiento del registrado de imágenes.

- *Análisis del rendimiento de nuestras propuestas frente a un conjunto de métodos de referencia propuestos en la literatura especializada.* Hemos podido constatar cómo nuestras dos propuestas basadas en Scatter Search ofrecen resultados competitivos. En un alto porcentaje de las ocasiones, la calidad de las soluciones es significativamente mejor a la obtenida por los métodos del estado del arte ([Yamany, 99, Luck, 00, He, 02, Chow, 04, Liu, 04, Cordón, 06a, Cordón, 06d, Lomonosov, 06]). En particular, hemos contrastado el rendimiento de SS_m frente a $ICP + SA$ [Luck, 00], $I - ICP$ [Liu, 04] e ILS [Cordón, 06a]; y el de SS_p frente a GA_{Yamany} [Yamany, 99], GA_{He} [He, 02], GA_{Chow} [Chow, 04], CHC_{Real} [Cordón, 06d] y $GA_{Lomonosov}$ [Lomonosov, 06]. Hemos verificado que SS_m ofrece el mejor rendimiento de entre los métodos que operan en su enfoque, mejorando también incluso a alguno de los del segundo tratando con imágenes médicas. Por su parte, SS_p se muestra como la mejor alternativa para cualquiera de los dos enfoques en la consecución del principal objetivo que nos planteábamos en esta memoria: «maximizar tanto el rendimiento como el grado de automatización en tareas de registrado».
- *Aplicación de nuestras propuestas de registrado de imágenes en Antropología Forense.* Por último, hemos demostrado la aplicabilidad de las técnicas de registrado para la automatización de ciertas tareas habituales en identificación forense. De nuestras dos propuestas de registrado de imágenes, SS_p es la que resuelve los problemas planteados con mayor éxito, superando al resto de técnicas existentes en la literatura especializada en la gran mayoría de los casos. En cambio, SS_m ha adolecido de ciertas limitaciones impuestas por el diseño considerado inicialmente, el cual se encuentra más adaptado a las imágenes de medicina nuclear (MRI y CT).

En otro sentido, gracias al estudio comparativo entre los enfoques *semiautomático* y *automático* hemos constatado cómo el primero ofrece un marco de trabajo más adecuado con el que conseguir mejores resultados. Sin em-

bargo, requiere de la interacción del experto para llevar a cabo un proceso de extracción de las características más relevantes en las imágenes de forma manual, siendo ésta una tarea laboriosa en la mayoría de los casos.

Por último y como validación final del trabajo realizado, debemos destacar que éste ya ha sido reconocido en diversas publicaciones en congresos de ámbito nacional e internacional [Cordón, 04, Cordón, 05a, Cordón, 05b, Cordón, 05c, Santamaría, 06a], así como en varias revistas incluidas en el Citation Index [Cordón, 06b, Cordón, 06c, Santamaría, 06b] y en un capítulo de libro [Cordón, 06e].

5.2. Trabajos Futuros

A continuación, discutiremos algunas líneas de trabajo que quedan aún abiertas sobre los temas tratados en esta memoria. Además, consideraremos las extensiones sobre nuestras propuestas que serán objeto de futuros estudios.

- *Mejora del rendimiento de nuestras propuestas actuales.* El uso de \mathcal{M} -estimadores, en detrimento de los métodos basados en mínimos cuadrados, o de técnicas como las *medianas repetidas* podría ser de gran ayuda para solventar los inconvenientes de SS_m , como se vió en [Bardinet, 00]. Por otro lado, nos planteamos considerar métricas de similitud como la «*interpenetration measure*» [Silva, 05], que ha demostrado ser una medida de error con un considerable poder discriminador de falsos positivos. En esta línea, pensamos que el uso de éstas u otras nuevas métricas supondría un salto cuantitativo y cualitativo en términos de rendimiento de nuestra mejor propuesta, SS_p .
- *Diseño de nuevos métodos de registrado de imágenes para la reconstrucción de modelos 3D.* La consideración de un enfoque de *registrado simultáneo de múltiples vistas* para la reconstrucción de modelos digitales 3D [Eggert, 98] es una línea de trabajo en la que se han aplicado recientemente técnicas de optimización basadas en metaheurísticas [Silva, 06]. Por ello, nos planteamos extender nuestros algoritmos actuales para realizar nuevas propuestas en esta línea.
- *Diseño de nuevas técnicas para aplicaciones médicas en tiempo real.* Se trataría de desarrollar nuevos algoritmos de registrado de imágenes con capacidades de tiempo real. En concreto, la cirugía operativa guiada por computador es una disciplina médica que ha sufrido una gran expansión gracias

a los avances técnicos producidos en los últimos años y que ha permitido sustituir la mesa de operaciones por la pantalla de un ordenador con cierto grado de efectividad. Debido al escaso número de propuestas de registrado para aplicaciones de este tipo, es necesario extender los métodos actuales para afrontar entornos con fuertes requerimientos de tiempo real. En este sentido, pensamos que la paralelización de métodos de registrado basados en metaheurísticas podría suponer un salto de calidad frente a las técnicas actuales.

- *Generalización de la transformación de registrado.* La extensión de nuestro trabajo a transformaciones afines o aún más genéricas puede ser alcanzable tomando como base esta memoria. En el caso de considerar un enfoque de registrado semiautomático, habrá que estudiar propiedades invariantes ante el tipo de transformaciones elegido.
- *Diseño de nuevas técnicas de registrado de imágenes en base a nuevas metaheurísticas.* Los excelentes resultados conseguidos con el empleo de algoritmos evolutivos avanzados nos inclinan a pensar que otras técnicas bioinspiradas propuestas recientemente pueden ser igualmente apropiadas: los algoritmos de competición familiar («*Family Competition*») [Yang, 00], las colonias de hormigas («*Ant Colony Optimization*») [Dorigo, 04] y los sistemas de nubes de partículas («*Particle Swarm Optimization*») [Kennedy, 95]. Estos últimos se han empleado recientemente en aplicaciones de registrado de imágenes médicas [Wachowiak, 04], destacando por la velocidad de convergencia de los métodos desarrollados.
- *Diseño de una herramienta específica para automatizar el proceso de identificación forense.* Nuestro principal objetivo en esta línea es desarrollar un sistema automático que asista al experto forense en tareas de identificación de personas desaparecidas mediante superposición fotográfica. Por un lado, las técnicas evolutivas y la visión por computador nos servirán para diseñar la tarea encargada de superponer rostro y cráneo. Por otro lado, consideraremos técnicas de lógica difusa tanto para establecer la correspondencia de puntos en ambos dominios de imágenes como para proporcionar el veredicto final del proceso de identificación.

Esta línea ha comenzado a desarrollarse en esta memoria, concretamente en el Capítulo 4, y continuaremos trabajando en ella de forma conjunta con el Laboratorio de Antropología Física de la Universidad de Granada dentro del proyecto de investigación «*Soft Computing y Visión por Ordenador en Identificación Forense*», concedido recientemente por el *Ministerio de Educación y Ciencia* en el marco del *Plan Nacional de I+D+I (2004-2007)*.

Bibliografía

- [Aarts, 89] Aarts, E. H. (1989). *Simulated Annealing and Boltzmann Machines: A Stochastic Approach to Combinatorial Optimization and Neural Computing*. John Wiley and Sons.
- [Akca, 03] Akca, D. (2003). Full automatic registration of laser scanner point clouds. En Gruen, A. y Kahmen, H., editores, *Optical 3-D Measurement Techniques VI*, volumen 1, páginas 330–337, Zurich, Switzerland.
- [Alemán, 05] Alemán, I. (2005). Identificación mediante análisis de imágenes. Máster Virtual en Antropología y Genética Forense (Módulo 4, Unidad 5), Centro de Enseñanzas Virtuales de la Universidad de Granada (CEVUG), España.
- [Allen, 03] Allen, P. K., Troccoli, A., Smith, B., Murray, S., Stamos, I., y Leordeanu, M. (2003). New methods for digital modeling of historic sites. *IEEE Computer Graphics and Applications*, 23(6):32–41.
- [Amnesty, 94] Amnesty (1994). *Amnesty International Manual*.
- [Arun, 87] Arun, K. S., Huang, T. S., y Blostein, S. D. (1987). Least-squares fitting of two 3-D points sets. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(5):698–700.
- [Audette, 00] Audette, M. A., Ferrie, F. P., y Peters, T. M. (2000). An algorithmic overview of surface registration techniques for medical imaging. *Medical Image Analysis*, 4(3):201–217.
- [Bäck, 97] Bäck, T., Fogel, D. B., y Michalewicz, Z. (1997). *Handbook of Evolutionary Computation*. IOP Publishing Ltd and Oxford University Press.
- [Bardinet, 00] Bardinet, E., Fernández-Vidal, S., Damas, S., Malandain, G., y Pérez de la Blanca, N. (2000). Structural object matching. En *The 2nd In-*

- ternational Symposium on Advanced Concepts for Intelligent Vision Systems (ACIVS'00)*, volumen II, páginas 73–77, Baden-Baden, Germany.
- [Barnea, 72] Barnea, D. I. y Silverman, H. F. (1972). A class of algorithms for fast digital image registration. *IEEE Transactions on Computers*, 21:179–186.
- [Bernardini, 02] Bernardini, F. y Rushmeier, H. (2002). The 3D model acquisition pipeline. *Computer Graphics Forum*, 21(2):149–172.
- [Besl, 92] Besl, P. J. y McKay, N. D. (1992). A method for registration of 3D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14:239–256.
- [Blum, 03] Blum, C. y Roli, A. (2003). Metaheuristics in combinatorial optimization: overview and conceptual comparison. *ACM Computing Surveys*, 35(3):268–308.
- [Brassard, 97] Brassard, G. y Bratley, P. (1997). *Fundamentos de Algoritmia*. Prentice Hall, Madrid, España.
- [Brown, 92] Brown, L. G. (1992). A survey of image registration techniques. *ACM Computing Surveys*, 24(4):325–376.
- [Brunnström, 96] Brunnström, K. y Stoddart, A. (1996). Genetic algorithms for free-form surface matching. En *International Conference of Pattern Recognition*, páginas 689–693, Vienna, Germany.
- [CEC] CEC. En *IEEE Congress on Evolutionary Computation*.
- [CVPR] CVPR. En *IEEE Conference on Computer Vision and Pattern Recognition*.
- [Callieri, 04] Callieri, M., Fasano, A., Impoco, G., Cignoni, P., Scopigno, R., Parrini, G., y Biagini, G. (2004). Roboscan: An automatic system for accurate and unattended 3d scanning. En *The 2nd International Symposium on 3D Data Processing, Visualization and Transmission (3DPVT'04)*, páginas 805–812, Tessaloniki, Greece. IEEE Computer Society.
- [Campos, 01] Campos, V., Glover, F., Laguna, M., y Martí, R. (2001). An Experimental Evaluation of a Scatter Search for the Linear Ordering Problem. *Journal of Global Optimization*, 21:397–414.

- [Cao, 03] Cao, Z., Pan, S., Li, R., Balachandran, R., Fitzpatrick, M. J., Chapman, W. C., y Dawant, B. M. (2003). Registration of Medical Images Using an Interpolated Closest Point Transform: Method and Validation. En Sonka, M. y Fitzpatrick, J. M., editores, *Medical Imaging Conference (SPIE2003)*, volumen 5032, páginas 325–333.
- [Chalermwat, 01] Chalermwat, P., El-Ghazawi, T., y LeMoigne, J. (2001). 2-phase GA-based image registration on parallel clusters. *Future Generation Computer Systems*, 17:467–476.
- [Chalermwat, 99] Chalermwat, P. y El-Ghazawi, T. A. (1999). Multi-Resolution Image Registration Using Genetics. En *International Conference on Image Processing*, páginas 452–456.
- [Chandra, 93] Chandra, P. (1993). Positioning the skull for superposition. En Iscan, M. y Helmer, R., editores, *Forensic Analysis of the Skull: Craniofacial Analysis, Reconstruction, and Identification*, páginas 105–118. Wiley Liss, New York.
- [Chao, 05] Chao, C. y Stamos, I. (2005). Semi-automatic range to range registration: a feature-based method. En *5th International Conference on 3-D Digital Imaging and Modeling*, páginas 254–261, Ottawa, Canada.
- [Chen, 98] Chen, C. S., Hung, Y. P., y Cheng, J. B. (1998). A fast automatic method for registration of partially overlapping range images. En *International Conference on Computer Vision (ICCV'98)*, páginas 242–248.
- [Chow, 01] Chow, C. K., Tsui, H. T., Lee, T., y Lau, T. K. (2001). Medical image registration and model construction using genetic algorithms. En *International Workshop on Medical Imaging and Augmented Reality (MIAR 2001)*, páginas 174–179, Shatin N.T. (Hong Kong). IAPR.
- [Chow, 04] Chow, C. K., Tsui, H. T., y Lee, T. (2004). Surface registration using a dynamic genetic algorithm. *Pattern Recognition*, 37:105–117.
- [Collins, 98] Collins, D. L., Zijdenbos, A. P., Kollkian, V., Sled, J. G., Kabani, N. J., Holmes, C. J., y Evans, A. C. (1998). Design and construction of a realistic digital brain phantom. *IEEE Transactions on Medical Imaging*, 17:463–468.
- [Cordón, 04] Cordón, O., Damas, S., y Santamaría, J. (2004). A Scatter Search Algorithm for the 3D Image Registration Problem. En Yao, X., Burke, E. K., Lozano, J. A., Smith, J., Merelo, J. J., Bullinaria, J. A., Rowe, J. E., Tiño, P.,

- Kabán, A., y Schwefel, H., editores, *The 8th International Conference on Parallel Problem Solving from Nature (PPSN VIII)*, páginas 471–480. Lecture Notes in Computer Science 3242, Springer-Verlag, Birmingham, UK.
- [Cordón, 05a] Cordón, O., Damas, S., y Santamaría, J. (2005a). A Scatter Search-based Optimizer for the Registration of 3D Surfaces. En *IEEE Conference on Evolutionary Computation (CEC'05)*, páginas 2738–2744.
- [Cordón, 05b] Cordón, O., Damas, S., Santamaría, J., y Martí, R. (2005b). 3D inter-subject medical image registration by scatter search. En *The 2nd International Workshop on Hybrid Metaheuristics*, páginas 90–103. Lecture Notes in Computer Science 3636, Springer-Verlag.
- [Cordón, 05c] Cordón, O., Damas, S., Santamaría, J., y Martí, R. (2005c). Una aplicación de scatter search al problema del registrado de imágenes tridimensionales. En *IV Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB'05)*, páginas 725–732.
- [Cordón, 06a] Cordón, O. y Damas, S. (2006a). Image Registration with Iterated Local Search. *Journal of Heuristics*, 12:73–94.
- [Cordón, 06b] Cordón, O., Damas, S., Martí, R., y Santamaría, J. (2006b). Scatter Search for the 3D Point Matching Problem in Image Registration. *INFORMS Journal of Computing*, sometido.
- [Cordón, 06c] Cordón, O., Damas, S., y Santamaría, J. (2006c). A Fast and Accurate Approach for 3D Image Registration using the Scatter Search Evolutionary Algorithm. *Pattern Recognition Letters*, 27(11):1191–1200.
- [Cordón, 06d] Cordón, O., Damas, S., y Santamaría, J. (2006d). Feature-based image registration by means of the CHC evolutionary algorithm. *Image and Vision Computing*, 22:525–533.
- [Cordón, 06e] Cordón, O., Damas, S., y Santamaría, J. (2006e). A practical review on the applicability of different EAs to 3D feature-based registration. En Cagnoni, S., Lutton, E., y Olague, G., editores, *Genetic and Evolutionary Computation in Image Processing and Computer Vision*, in press. EURASIP Book Series on SP&C.
- [Cotta, 98] Cotta, C. y Troya, J. M. (1998). Genetic Forma Recombination in Permutation Flowshop Problems. *Evolutionary Computation*, 6(1):25–44.

- [Dalley, 01] Dalley, G. y Flynn, P. (2001). Range image registration: A software platform and empirical evaluation. En *Third International Conference on 3-D Digital Imaging and Modeling (3DIM'01)*, páginas 246–253.
- [Damas, 03] Damas, S. (2003). *Registrado de Imágenes Basado en Características Mediante Metaheurísticas*. Tesis doctoral, ETSI Informática, Dpto. Ciencias de la Computación e Inteligencia Artificial, Universidad de Granada, España.
- [Deb, 89] Deb, K. y Goldberg, D. E. (1989). An investigation of niche and species formation in genetic function optimization. En Schaffer, J. D., editor, *3rd International Conference on Genetic Algorithms and Their Applications*, páginas 42–50, San Mateo, EEUU. Morgan Kaufmann Publishers.
- [Detmer, 94] Detmer, P. R., Bashein, G., Hodges, T., Beach, K. W., Filer, E. P., Burns, D. H., y Strandness, D. (1994). 3D Ultrasound Image Feature Localization based on Magnetic Scanhead Traking: In Vitro Calibration and Validation. *Ultrasound in Medicine and Biology*, 20(4):923–936.
- [De Castro, 87] De Castro, E. y Morandi, C. (1987). Registration of translated and rotated images using finite fourier transforms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(4):700–703.
- [Donsgsheng, 93] Donsgsheng, C. y Yuwen, L. (1993). Standards for skull-to-photo superposition. En Iscan, M. y Helmer, R., editores, *Forensic Analysis of the Skull: Craniofacial Analysis, Reconstruction, and Identification*, páginas 171–182. Wiley Liss, New York.
- [Dorigo, 04] Dorigo, M. y Stützle, T. (2004). *Ant Colony Optimization*. MIT Press.
- [ECCV] ECCV. En *European Conference on Computer Vision*.
- [Eggert, 98] Eggert, D. W., Fitzgibbon, A. W., y Fisher, R. B. (1998). Simultaneous registration of multiple range views for use in reverse engineering of CAD models. *Computer Vision and Image Understanding*, 69(3):253–272.
- [El Hakim, 84] El Hakim, S. F. y Ziemann, H. (1984). A step-by-step strategy for gross-error detection. *Photogrammetric Engineering and Remote Sensing*, 50(6):713–718.
- [Escalera, 01] Escalera, A. (2001). *Visión por computador. Fundamentos y métodos*. Pearson Education.

- [Eshelman, 91] Eshelman, L. J. (1991). The CHC adaptive search algorithm: how to safe search when engaging in non traditional genetic recombination. En Rawlins, G. J. E., editor, *Foundations of Genetic Algorithms 1*, páginas 265–283, San Mateo, EEUU. Morgan Kaufmann.
- [Eshelman, 93] Eshelman, L. J. (1993). Real-coded genetic algorithms and interval schemata. En Whitley, L. D., editor, *Foundations of Genetic Algorithms 2*, páginas 187–202, San Mateo, EEUU. Morgan Kaufmann.
- [EuroGP] EuroGP. En *European Conference on Genetic Programming*.
- [Excuses, 05] Excuses (2005). EXCUSES FOR THE TRUTH: Disappearances and their consequences, Forensic Medicine. <http://home.planet.nl/loz/maneng.htm>.
- [Förstner, 85] Förstner, W. (1985). The Reliability of Block Triangulation. *Photogrammetric Engineering and Remote Sensing*, 51(6):1137–1149.
- [Faugeras, 96] Faugeras, O. (1996). *Three-Dimensional Computer Vision*. MIT Press.
- [Feldmar, 96] Feldmar, J. y Ayache, N. (1996). Rigid, affine and locally affine registration of free-form surfaces. *International Journal of Computer Vision*, 18(2):99–119.
- [Feo, 95] Feo, T. A. y Resende, M. G. C. (1995). Greedy randomized adaptive search procedures. *Journal of Global Optimization*, 6:109–133.
- [Fitzpatrick, 84] Fitzpatrick, J., Grefenstette, J., y Gucht, D. (1984). Image registration by genetic search. En *IEEE Southeast Conference*, páginas 460–464, Louisville, EEUU.
- [Flusser, 94] Flusser, J. y Suk, T. (1994). A moment-based approach to registration on images with affine geometric distortions. *IEEE Transactions on Geoscience and Remote Sensing*, 32:382–387.
- [GECCO] GECCO. En *Genetic and Evolutionary Computation Conference*.
- [Gagnon, 94] Gagnon, H., Soucy, M., Bergevin, R., y Laurendeau, D. (1994). Registration of multiple range views for automatic 3D model building. En *IEEE International Conference on Computer Vision and Pattern Recognition*, páginas 581–586, Seattle, WA.

- [Garey, 79] Garey, M. y Johnson, D. (1979). *Computers and Intractability: A Guide to the Theory of \mathcal{NP} -Completeness*. Freeman, San Francisco, CA, EE. UU.
- [Glover, 03a] Glover, F. y Kochenberger, G. A. (2003a). *Handbook of Metaheuristics*. Kluwer Academic Publishers.
- [Glover, 03b] Glover, F., Laguna, M., y Martí, R. (2003b). Scatter search. En Ghosh, A. y Tsutsui, S., editores, *Advances in Evolutionary Computation: Theory and Applications*, páginas 519–537. Springer-Verlag, New York.
- [Glover, 77] Glover, F. (1977). Heuristic for integer programming using surrogate constraints. *Decision Sciences*, 8:156–166.
- [Glover, 97] Glover, F. y Laguna, M. (1997). *Tabu search*. Kluwer Academic Publishers.
- [Glover, 98] Glover, F. (1998). A Template for Scatter Search and Path Relinking. En Hao, J. K., Lutton, E., Ronald, E., Schoenauer, M., y Snyers, D., editores, *3rd European Conference on Artificial Evolution*, páginas 3–54. Lecture Notes in Computer Science 1363, Springer-Verlag, London, UK.
- [Gold, 96] Gold, S. y Rangarajan, A. (1996). A Graduated Assignment Algorithm for Graph Matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18:377–388.
- [Goldberg, 85] Goldberg, D. E. y Lingle, R. (1985). Alleles, Loci, and the Traveling Salesman Problem. En *International Conference on Genetic Algorithms and Their Applications*, páginas 154–159, Pittsburgh, PA.
- [Goldberg, 87] Goldberg, D. E. y Richardson, J. (1987). Genetic algorithms with sharing for multimodal function optimization. En *2nd International Conference on Genetic Algorithms and Their Applications*, páginas 41–49, Hillsdale, EEUU. L. Erlbraum Associates.
- [Goldberg, 89] Goldberg, D. E. (1989). *Genetic Algorithms in Search*. Addison-Wesley, New York, EEUU.
- [González, 02] González, R. C. y Woods, R. E. (2002). *Digital Image Processing*. Prentice-Hall.
- [Goshtasby, 03] Goshtasby, A., Staib, L., Studholme, C., y Terzopoulos, D. (2003). Special issue on nonrigid image registration. *Computer Vision and Image Understanding*, 89(2-3):109–318.

- [Goshtasby, 05] Goshtasby, A. (2005). *2D and 3D Image Registration for Medical, Remote Sensing, and Industrial Applications*. Wiley Interscience.
- [Guiliang, 03] Guiliang, Y. (2003). The Multi-Sensor Fusion: Image Registration Using Artificial Immune Algorithm. En *International Workshop on Soft Computing Techniques in Instrumentation, Measurement and Related Applications*, páginas 32–36, Provo, Utah, EEUU.
- [Hart, 94] Hart, W. E. (1994). *Adaptive global optimization with local search*. PhD thesis, University of California, San Diego, California.
- [He, 02] He, R. y Narayana, P. A. (2002). Global optimization of mutual information: application to three-dimensional retrospective registration of magnetic resonance images. *Computerized Medical Imaging and Graphics*, 26:277–292.
- [Held, 04] Held, M., Weiser, W., y Wilhelmstotter, F. (2004). Fully Automatic Elastic Registration of MR Images. *Journal of WSCG*, 12(1):153–160.
- [Herrera, 05] Herrera, F., Lozano, M., y Molina, D. (2005). Continuous scatter search: an analysis of the integration of some combination methods and improvement strategies. *European Journal of Operational Research*, 169(2):450–476.
- [Herrera, 98] Herrera, F., Lozano, M., y Verdegay, J. L. (1998). Tackling real-coded genetic algorithms: operators and tools for the behavioural analysis. *Artificial Intelligence Reviews*, 12(4):265–319.
- [Holland, 75] Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor: The University of Michigan Press.
- [Horn, 87] Horn, B. K. P. (1987). Closed-form solution of absolute orientation using unit quaternions. *Journal of the Optical Society of America*, 4:629–642.
- [Huber, 03] Huber, D. y Hebert, M. (2003). Fully automatic registration of multiple 3d data sets. *Image and Vision Computing*, 21(7):637–650.
- [Huber, 81] Huber, P. J. (1981). *Robust Statistics*. John Wiley, New York.
- [ICCV] ICCV. En *International Conference on Computer Vision*.
- [ICPR] ICPR. En *International Conference on Pattern Recognition*.
- [Ikeuchi, 01] Ikeuchi, K. y Sato, Y. (2001). *Modeling from Reality*. Kluwer Academic Publishers.

- [Iscan, 81a] Iscan, M. Y. (1981a). Concepts in teaching forensic anthropology. *Medical Anthropol Newsletter*, 13(1):10–12.
- [Iscan, 81b] Iscan, M. Y. (1981b). Integral forensic anthropology. *Practicing Anthropol*, 3(4):21–30.
- [Iscan, 93] Iscan, M. (1993). Introduction to techniques for photographic comparison. En Iscan, M. y Helmer, R., editores, *Forensic Analysis of the Skull: Craniofacial Analysis, Reconstruction, and Identification*, páginas 57–70. Wiley Liss, New York.
- [Johnson, 99] Johnson, A. E. y Hebert, M. (1999). Using spin images for efficient object recognition in cluttered 3D scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(5):433–449.
- [Kennedy, 95] Kennedy, J. y Eberhart, R. (1995). Particle swarm optimization. En *IEEE International Conference on Neural Networks*, volumen 4, páginas 1942–1948.
- [Krogman, 86] Krogman, W. M. y Iscan, M. Y. (1986). *The human skeleton in forensic medicine*. Springfield.
- [Kwan, 99] Kwan, R. K. S., Evans, A. C., y Pike, G. B. (1999). MRI simulation-based evaluation of image-processing and classification methods. *IEEE Transactions on Medical Imaging*, 18(11):1085–1097.
- [Laguna, 03] Laguna, M. y Martí, R. (2003). *Scatter search: methodology and implementations in C*. Kluwer Academic Publishers, Boston.
- [Laguna, 99] Laguna, M., Martí, R., y Campos, V. (1999). Intensification and diversification with elite tabu search solutions for the linear ordering problem. *Computers & Operations Research*, 26(12):1217–1230.
- [Leotta, 97] Leotta, D. F., Detmer, P. R., y Martin, R. W. (1997). Performance of a Miniature Magnetic Position Sensor for Three-dimensional Ultrasound Imaging. *Ultrasound in Medicine and Biology*, 23(4):597–609.
- [Levitin, 02] Levitin, A. V. (2002). *Introduction to the Design and Analysis of Algorithms*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, EEUU.
- [Liu, 04] Liu, Y. (2004). Improving ICP with easy implementation for free form surface matching. *Pattern Recognition*, 37(2):211–226.
- [Liu, 06] Liu, Y. (2006). Automatic registration of overlapping 3D point clouds using closest points. *Image and Vision Computing*, 24:762–781.

- [Lomonosov, 06] Lomonosov, E., Chetverikov, D., y Ekart, A. (2006). Pre-registration of arbitrarily oriented 3D surfaces using a genetic algorithm. *Pattern Recognition Letters*, 27(11):1201–1208.
- [Lourenço, 03] Lourenço, H. R., Martin, O. C., y Stützle, T. (2003). Iterated local search. En Glover, F. y Kochenberger, G., editores, *Handbook of Metaheuristics*, páginas 321–353. Kluwer Academic Publishers.
- [Lozano, 04] Lozano, M., Herrera, F., Krasnogor, N., y Molina, D. (2004). Real-coded memetic algorithms with crossover hill-climbing. *Evolutionary Computation*, 12(3):273–302.
- [Lozano, 06] Lozano, J. A., Larrañaga, P., Inza, I., y Bengotxea, E. (2006). *Towards a New Evolutionary Computation: Advances on Estimation of Distribution Algorithms*. Springer Verlag.
- [Luck, 00] Luck, J. P., Little, C. Q., y Hoff, W. (2000). Registration of Range Data Using a Hybrid Simulated Annealing and Iterative Closest Point Algorithm. En *IEEE International Conference on Robotics and Automation (ICRA'00)*, páginas 3739–3744.
- [Luenberger, 97] Luenberger, D. G. (1997). *Optimization by Vector Space Methods*. John Wiley & Sons, Inc., New York, NY, EEUU.
- [Maes, 99] Maes, F., Vandermeulen, D., y Suetens, P. (1999). Comparative evaluation of multiresolution optimization strategies for image registration by maximization of mutual information. *Medical Image Analysis*, 3(4):373–386.
- [Maglogiannis, 04] Maglogiannis, I. y Zafiroopoulos, E. (2004). Automated Medical Image Registration Using the Simulated Annealing Algorithm. En Vouros, G. A. y Panayiotopoulos, T., editores, *Methods and Applications of Artificial Intelligence*, páginas 456–465. Lecture Notes in Artificial Intelligence 3025, Springer Berlin / Heidelberg.
- [Mahfoud, 95] Mahfoud, S. W. (1995). Niching methods for genetic algorithms. Technical Report IlliGAL-95001, University of Illinois at Urbana-Champaign, Genetic Algorithms Laboratory.
- [Maintz, 96] Maintz, J. B. A., Van den Elsen, P. A., y Viergever, M. A. (1996). Evaluation on ridge seeking operators for multimodality medical image matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18:353–365.

- [Maintz, 98] Maintz, J. B. y Viergever, M. A. (1998). A survey of medical image registration. *Medical Image Analysis*, 2(1):1–36.
- [Mandava, 89] Mandava, V. R., Fitzpatrick, J. M., y Pickens, D. R. (1989). Adaptive search space scaling in digital image registration. *IEEE Transactions on Medical Imaging*, 8(3):251–262.
- [Manjunath, 96] Manjunath, B. S., Shekhar, C., y Chellapa, R. (1996). A new approach to image feature detection with applications. *Pattern Recognition*, 29:627–640.
- [Martí, 03] Martí, R. (2003). Multi-start methods. En Glover, F. y Kochenberger, G., editores, *Handbook of Metaheuristics*, páginas 355–368. Kluwer Academic Publishers.
- [Masuda, 95] Masuda, T. y Yokoya, N. (1995). A robust method for registration and segmentation of multiple range images. *Computer Vision and Image Understanding*, 61(3):295–307.
- [Matsopoulos, 99] Matsopoulos, G. K., Mouravliansky, N. A., Delibasis, K. K., y Nikita, K. S. (1999). Automatic retinal image registration scheme using global optimization techniques. *IEEE Transactions on Information Technology in Biomedicine*, 3(1):47–60.
- [Maurer, 93] Maurer, C. y Fitzpatrick, J. M. (1993). Interactive image-guided neurosurgery. En Maciunas, R. J., editor, *A Review of Medical Image Registration*, páginas 17–44. American Association of Neurological Surgeons, Park Ridge, IL.
- [Michalewicz, 96] Michalewicz, Z. (1996). *Genetic algorithms + data structures = evolution programs*. Springer-Verlag.
- [Mladenović, 97] Mladenović, N. y Hansen, P. (1997). Variable neighborhood search. *Computers Operations Research*, 24:1097–1100.
- [Monga, 92] Monga, O., Benayoun, S., y Faugeras, O. (1992). From partial derivatives of 3-D density images to ridges lines. En *Computer Vision and Pattern Recognition*, páginas 354–389, Champaign, Illinois, EEUU. IEEE.
- [Moreels, 05] Moreels, P. y Perona, P. (2005). Evaluation of Features Detectors and Descriptors Based on 3D Objects. En *10th IEEE International Conference on Computer Vision (ICCV'05)*, páginas 800–807.

- [Muratore, 02] Muratore, D. M., Russ, J. H., Dawant, B. M., y Jr. Galloway, R. L. (2002). Three-Dimensional Image Registration of Phantom Vertebrae for Image-Guided Surgery: A Preliminary Study. *Computer Aided Surgery*, 7:342–352.
- [Nelder, 65] Nelder, J. A. y Mead, R. (1965). A simplex method for function minimization. *Computer Journal*, 7:308–313.
- [Olague, 05] Olague, G. y Hernández, B. (2005). A new accurate and flexible model based multi-corner detector for measurement and recognition. *Pattern Recognition Letters*, 26:27–41.
- [PPSN] PPSN. En *Parallel Problem Solving from Nature*.
- [Pingi, 05] Pingi, P., Fasano, A., Cignoni, P., Montani, C., y Scopigno, R. (2005). Exploiting the scanning sequence for automatic registration of large sets of range maps. *Computer Graphics Forum*, 24(3):517–526.
- [Pluim, 00] Pluim, J. P. W., Maintz, J. B. A., y Viergever, M. A. (2000). Interpolation artefacts in mutual information-based image registration. *Computer Vision and Image Understanding*, 77(9):211–232.
- [Preparata, 86] Preparata, F. y Shamos, M. (1986). *Computational Geometry, an Introduction*. Springer Verlag.
- [Rangarajan, 97] Rangarajan, A., Chui, H., Mjolsness, E., Pappu, S., Davachi, L., Goldman-Rakic, P. S., y Duncan, J. S. (1997). A robust point matching algorithm for autoradiograph alignment. *Medical Image Analysis*, 1(4):379–398.
- [Rangarajan, 99] Rangarajan, A., Chui, H., y Duncan, J. S. (1999). Rigid point feature registration using mutual information. *Medical Image Analysis*, 3(4):425–440.
- [Rathburn, 84] Rathburn, T. (1984). Personal identification. En Rathburn, T. y Buikstra, J., editores, *Human Identification*, páginas 647–356. Thomas, Springfield.
- [Resende, 01] Resende, M. G. C. y Ribeiro, C. C. (2001). Greedy Randomized Adaptive Search Procedures. En Glover, F. y Kochenberger, G., editores, *State-of-the-art Handbook in Metaheuristics*, páginas 219–250. Kluwer Academic Publishers.
- [Robertson, 02] Robertson, C. y Fisher, R. B. (2002). Parallel Evolutionary Registration of Range Data. *Computer Vision and Image Understanding*, 87:39–50.

- [Robinson, 04] Robinson, D. y Milanfar, P. (2004). Fundamental performance limits in image registration. *IEEE Transactions on Image Processing*, 13(9):1185–1199.
- [Rogelj, 02] Rogelj, P. y Kovacic, S. (2002). Validation of a Non-Rigid Registration Algorithm for Multimodal Data. En Sonka, M. y Fitzpatrick, J. M., editores, *SPIE in Medical Imaging*, páginas 299–307.
- [Rohr, 01] Rohr, K. (2001). *Landmark-Based Image Analysis: Using Geometric and Intensity Models*. Kluwer Academic Publishers.
- [Rouet, 00] Rouet, J. M., Jacq, J. J., y Roux, C. (2000). Genetic algorithms for a robust 3-D MR-CT registration. *IEEE Transactions on Information Technology in Biomedicine*, 4(2):126–136.
- [Rusinkiewicz, 01] Rusinkiewicz, S. y Levoy, M. (2001). Efficient variants of the ICP algorithm. En *Third International Conference on 3D Digital Imaging and Modeling (3DIM'01)*, páginas 145–152, Quebec, Canada.
- [Salvi, 06] Salvi, J., Matabosch, C., Fofi, D., y Forest, J. (2006). A review of recent range image registration methods with accuracy evaluation. *Image and Vision Computing*, in press.
- [Santamaría, 06a] Santamaría, J., Cerdón, O., Damas, S., Alemán, I., y Botella, M. (2006a). 3D Forensic Model Reconstruction by Scatter Search-based Pair-wise Image Registration. En *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE'06)*, páginas 1086–1092, Vancouver, Canada.
- [Santamaría, 06b] Santamaría, J., Cerdón, O., Damas, S., Alemán, I., y Botella, M. (2006b). A Scatter Search-based technique for pair-wise 3D range image registration in forensic anthropology. *Soft Computing*, in press.
- [Sharp, 02] Sharp, G. C., Lee, S. W., y Wehe, D. K. (2002). ICP registration using invariant features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(1):90–102.
- [Shoemake, 85] Shoemake, K. (1985). Animating rotation with quaternion curves. En *ACM SIGGRAPH*, páginas 245–254, San Francisco.
- [Silva, 05] Silva, L., Bellon, O. R. P., y Boyer, K. L. (2005). *Robust range image registration using genetic algorithms and the surface interpenetration measure*. World Scientific.

- [Silva, 06] Silva, L., Bellon, O. R. P., y Boyer, K. L. (2006). Multiview range image registration using the surface interpenetration measure. *Image and Vision Computing*, in press.
- [Simunic, 98] Simunic, K. y Loncaric, S. (1998). A genetic search-based partial image matching. En *2nd IEEE International Conference on Intelligent Processing Systems (ICIPS'98)*, páginas 119–122, Gold Coast, Australia.
- [Solis, 81] Solis, F. J. y Wets, R. J. B. (1981). Minimization by random search techniques. *Mathematical Operations Research*, 6:19–30.
- [Spitz, 80] Spitz, W. y Fisher, R., editores (1980). *Medicolegal Investigation of Death: Guidelines for the Applications of Pathology to Crime Investigation*. Thomas, Springfield.
- [Stewart, 03] Stewart, C. V., Tsai, C., y Roysam, B. (2003). The Dual Bootstrap Iterative Closest Point Algorithm with Application to Retinal Image Registration. *IEEE Transaction on Medical Imaging*, 22(11):1379–1394.
- [Svedlow, 76] Svedlow, M., Mc-Gillem, C. D., y Anuta, P. E. (1976). Experimental examination of similarity measures and preprocessing methods used for image registration. En *Symposium on Machine Processing of Remotely Sensed Data*, volumen 4(A), páginas 9–17, Indiana, EEUU.
- [Taylor, 94] Taylor, H. M. y Karlin, S. (1994). *An introduction to stochastic modeling*. Academic Press.
- [Taylor, 98] Taylor, J. y Brown, K. (1998). Superimposition techniques. En Clement, J. y Ranson, D., editores, *Craniofacial Identification in Forensic Medicine*, páginas 151–164. Arnold, London.
- [Thirion, 96] Thirion, J. P. y Gourdon, A. (1996). The 3D marching lines algorithm: new results and proofs. *Graphical Models and Image Processing*, 58(6):503–509.
- [Tsang, 97] Tsang, P. W. M. (1997). A genetic algorithm for aligning object shapes. *Image and Vision Computing*, 15:819–831.
- [Ugray, 05] Ugray, Z., Lasdon, L., Plummer, J., Glover, F., Kelly, J., y Martí, R. (2005). A multistart scatter search heuristic for smooth NLP and MINLP problems. En Rego, C., editor, *Metaheuristic optimization via memory and evolution. Tabu search and scatter search*, páginas 25–57. Boston, MA : Kluwer Academic Publishers. Operations Research/Computer Science Interfaces Series 30.

- [Van den Elsen, 93] Van den Elsen, P. A., Pol, E. J. D., y Viergever, M. A. (1993). Medical image matching: a review with classification. *IEEE Engineering in Medicine and Biology Magazine*, 12:26–39.
- [Viola, 97] Viola, P. y Wells, W. M. (1997). Alignment by maximization of mutual information. *International Journal of Computer Vision*, 24:137–154.
- [Wachowiak, 01] Wachowiak, M. P. y El-maghraby, A. S. (2001). The Continuous Tabu Search as an Optimizer for 2D-to-3D Biomedical Image Registration. En Niessen, W. y Viergever, M., editores, *4th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI'01)*, páginas 1273–1274. Lecture Notes in Computer Science 2207, Springer Berlin / Heidelberg, Utrecht, The Netherlands.
- [Wachowiak, 04] Wachowiak, M. P., Smolikova, R., Zheng, Y., Zurada, J. M., y El-Maghraby, A. S. (2004). An Approach to Multimodal Biomedical Image Registration Utilizing Particle Swarm Optimization. *IEEE Transactions on Evolutionary Computation*, 8(3):289–301.
- [Weik, 97] Weik, S. (1997). Registration of 3-D Partial Surface Models using Luminance and Depth Information. En *International Conference on Recent Advances in 3-D Digital Imaging and Modeling (3DIM'97)*, páginas 93–100.
- [West, 96] West, J., Fitzpatrick, J. M., Wang, M. Y., Dawant, B. M., Maurer, C. R., Kessler, R. M., Maciunas, R. J., Barillot, C., Lemoine, D., Collignon, A., Maes, F., Suetens, P., Vandermeulen, D., van den Elsen, P. A., Hemler, P. F., Napel, S., Sumanaweera, T. S., Harkness, B., Hill, D. L. G., Studholme, C., Malandin, G., Pennec, X., Noz, M. E., Maguire, G. Q., Pollack, M., Pellizzari, C. A., Robb, R. A., Hanson, D., y Woods, R. (1996). Comparison and evaluation of retrospective intermodality image registration techniques. En *Medical Imaging: Image Processing (SPIE'96)*, volumen 2710, páginas 332–347.
- [West, 99] West, J. B., Fitzpatrick, J. M., Wang, M. Y., Dawant, B. M., Maurer Jr., C. R., Kessler, R. M., y Maciunas, R. J. (1999). Retrospective intermodality registration techniques for images of the head: surface-based versus volume-based. *IEEE Transactions on Medical Imaging*, 18(2):144–150.
- [Yamany, 99] Yamany, S. M., Ahmed, M.Ñ., y Farag, A. A. (1999). A new genetic-based technique for matching 3D curves and surfaces. *Pattern Recognition*, 32:1817–1820.

- [Yang, 00] Yang, J. M. y Kao, C. Y. (2000). Integrating adaptive mutations and family competition into genetic algorithms as function optimizer. *Soft Computing*, 4(2):89–102.
- [Yetik, 06] Yetik, I. S. y Nehorai, A. (2006). Performance bounds on image registration. *IEEE Transactions on Signal Processing*, 54:1737–1749.
- [Yoshizawa, 05] Yoshizawa, S., Belyaev, A., y Seidel, H. P. (2005). Fast and robust detection of crest lines on meshes. En *SPM '05: Proceedings of the 2005 ACM symposium on Solid and physical modeling*, páginas 227–232, New York, NY, EEUU. ACM Press.
- [Yuwen, 93] Yuwen, L. y Dongsheng, C. (1993). Technical advances in skull-to-photo superposition. En Iscan, M. y Helmer, R., editores, *Forensic Analysis of the Skull: Craniofacial Analysis, Reconstruction, and Identification*, páginas 119–130. Wiley Liss, New York.
- [Zhang, 94] Zhang, Z. (1994). Iterative point matching for registration of free-form curves and surfaces. *International Journal of Computer Vision*, 13(2):119–152.
- [Zitová, 03] Zitová, B. y Flusser, J. (2003). Image registration methods: a survey. *Image and Vision Computing*, 21:977–1000.