

UNIVERSIDAD DE GRANADA

DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN
E INTELIGENCIA ARTIFICIAL



PROGRAMA DE DOCTORADO EN TECNOLOGÍAS DE LA
INFORMACIÓN Y LA COMUNICACIÓN

TESIS DOCTORAL

**Técnicas de Inteligencia Artificial Explicable
para Modelado Basado en Agentes**

Elena Romero Contreras

DIRECTORES

Sergio Damas Arroyo
Manuel Chica Serrano

Granada, Julio 2024

Editor: Universidad de Granada. Tesis Doctorales
Autor: Elena Romero Contreras
ISBN: 978-84-1195-619-2
URI: <https://hdl.handle.net/10481/97732>

Financiación

Esta tesis doctoral ha sido parcialmente financiada por los siguientes proyectos de investigación: los proyectos nacionales EXASOCO (PGC2018-101216-B-I00) y CONFIA (PID2021-122916NB-I00) y el proyecto regional SIMARK (P18-TP-4475). La doctoranda es beneficiaria de la ayuda PRE2019-089558 financiada por MICIU/AEI/10.13039/501100011033 y por “FSE invierte en tu futuro”.

Resumen

Introducción al problema

El Modelado Basado en Agentes (ABM, por sus siglas en inglés) es una conocida herramienta para modelar y simular sistemas complejos [Bon02, Eps06]. Estos modelos están formados por una población de agentes autónomos que toman sus decisiones en base a unas reglas de comportamiento individuales. Los agentes pueden interactuar entre ellos y con el entorno. Esta metodología sigue un enfoque *bottom-up* o de abajo hacia arriba, en el que a partir del modelado del comportamiento individual se obtienen resultados emergentes a nivel global. Ha sido ampliamente utilizado en diversas áreas como la economía [PMHR23], sociología [MW02] o epidemiología [Cue20], entre otras. En particular, en marketing permite simular mercados reales, capturar la heterogeneidad de diversos participantes y adaptarse a entornos dinámicos [RRK18]. Su aplicabilidad se extiende también a la adopción de tecnologías sostenibles, facilitando la simulación de cómo estas tecnologías penetran en el mercado, reflejando la interacción de actores variados con intereses diferentes.

El ABM permite la definición de escenarios hipotéticos y la evaluación de distintas estrategias, constituyendo un buen sistema de soporte a la decisión. Para su uso efectivo, es fundamental que estos modelos estén correctamente calibrados y validados, y que ofrezcan un alto nivel de transparencia. Aunque son modelos de caja blanca, la complejidad de los sistemas que modelan y el volumen de sus salidas hacen que a menudo requieran una capa adicional de explicabilidad [Mac16]. Aumentar la transparencia de estos modelos y de sus soluciones nos permitirá no solo aprender del sistema, sino mejorar la comunicación con distintas audiencias, aumentar su credibilidad y confianza y facilitar la toma de decisiones a los interesados en estos sistemas o *stakeholders* [DRDSC⁺23]. Mejorar la comprensión de estos modelos puede proporcionar hallazgos valiosos para elegir las acciones más efectivas en distintos escenarios, asegurando un impacto positivo y real en la toma de decisiones estratégicas.

En los últimos años, el área de Inteligencia Artificial Explicable (XAI, por sus siglas en inglés) ha cobrado relevancia con el objetivo de hacer los sistemas de inteligencia artificial más comprensibles y transparentes sin sacrificar rendimiento [AB18]. La XAI desempeña un papel importante en el aumento de la transparencia no solo para modelos de caja negra sino también para cualquier sistema de inteligencia artificial o sistema complejo que integre este enfoque [BDGP22]. Integrar técnicas de XAI con ABM puede contribuir en la mejora de la comprensión tanto de las salidas como de los modelos basados en agentes. A pesar de

los avances en XAI en otras áreas, existe un notable vacío en la aplicación de estas técnicas en ABM.

El eje central de esta tesis es el desarrollo y aplicación de un enfoque multidisciplinar que integre ABM y técnicas de XAI para obtener información comprensible a partir de simulaciones de ABM, logrando así profundizar en la comprensión del comportamiento de los agentes y mejorar la toma de decisiones en el ámbito del marketing. En particular, se abordan los siguiente tres subobjetivos:

1. El primero consiste en una revisión de la literatura y análisis bibliométrico sobre el uso del ABM en marketing en las dos últimas décadas, dada la ausencia de revisiones recientes en este ámbito.
2. El segundo objetivo plantea la aplicación de técnicas de XAI para el descubrimiento de patrones a partir de las salidas de los modelos basados en agentes. En particular, aplicar técnicas de Descubrimiento de Subgrupos (SD, por sus siglas en inglés) para explicar el comportamiento de los agentes a partir de las salidas de los modelos.
3. El tercer objetivo consiste en diseñar y aplicar estrategias de focalización con ABM para la asignación de subsidios que incentiven la adopción de tecnologías sostenibles, junto con el uso de técnicas de visualización de XAI para mejorar la efectividad y comprensión de dichas estrategias en escenarios hipotéticos.

Desarrollo

El desarrollo de la tesis puede dividirse en tres bloques diferenciados, cada uno asociado a uno de los objetivos planteados en la misma.

Análisis bibliométrico sobre el uso del ABM en marketing. Comenzamos la tesis con el análisis bibliométrico de la literatura sobre el uso del ABM en marketing desde el año 2000 hasta marzo de 2023. En esta contribución se proporciona tanto un análisis de rendimiento como un análisis de redes. En el primero se explora la evolución temporal, citas, autores, países, instituciones y revistas. En el segundo examina las relaciones entre palabras clave, autores y países. Una aportación fundamental de esta contribución es la exhaustiva caracterización de los modelos basados en agentes recopilados, resumida en una tabla de referencia. Esta tabla detalla los principales objetivos de los modelos y evalúa el cumplimiento de ciertas características, sirviendo de orientación para cualquier interesado en el campo. Estas características incluyen el uso de modelos de difusión, si los agentes tienen la posibilidad de elegir entre múltiples opciones, si el entorno es una red social, si es un entorno físico, y si se ha validado mediante datos reales. Esta caracterización ofrece una visión clara sobre la naturaleza de los modelos basados en agentes en el ámbito del marketing, mostrando la diversidad y aplicabilidad del ABM en este campo.

Explicación de salidas de modelos basados en agentes usando descubrimiento de subgrupos. Como mencionamos anteriormente, es fundamental que los modelos basados en agentes sean transparentes. En esta contribución nos centramos en aumentar la explicabilidad de sus salidas, en concreto de la gran cantidad de información que se genera sobre todas las acciones que realizan los agentes durante las simulaciones. Proponemos el uso de técnicas de XAI inherentemente interpretables, en particular técnicas de SD [Klö96, Wro97], para extraer reglas interesantes e interpretables a partir de las salidas a nivel micro de las simulaciones de ABM. Su finalidad es descubrir conocimiento valioso sobre el comportamiento de los agentes, sus interacciones y las dinámicas globales del sistema que ayude a los *stakeholders* en su proceso de toma de decisiones. Para ello, proponemos una metodología genérica aplicable a cualquier modelo basado en agentes adecuadamente calibrado y validado. La metodología consta de los siguientes pasos: preprocesamiento de datos, extracción de reglas mediante la aplicación de algoritmo de SD, filtrado de reglas y visualización de las mismas. Además, se incorpora durante el proceso el *feedback* u opinión de un experto en el área. Mostramos la eficacia de la metodología propuesta a través de un caso de estudio en el área de marketing, analizando la integración de diferentes algoritmos de SD (concretamente, SDMap [AP06], FuGePSD [CRRdJ⁺15] y NMEEFSD [CGdJH10]). Además, estudiamos el conjunto de reglas obtenidas para una instancia concreta del caso de estudio desde la perspectiva de un experto en el área con el objetivo de validar la metodología propuesta. Se observa cómo las reglas pueden ser fácilmente comprendidas y proporcionar conocimiento útil sobre las dinámicas de comportamiento del consumidor.

Focalización de micropolíticas de incentivos para la adopción de tecnologías verdes con ABM. En esta última contribución se propone el diseño y aplicación de políticas de incentivos a nivel micro dirigidas a un subconjunto de la población para fomentar la adopción de tecnologías sostenibles, en particular, tecnologías de propulsión eólica en la industria marítima. Nuestra propuesta se centra en la evaluación de la efectividad de las estrategias propuestas usando ABM, donde los agentes representan embarcaciones. Proponemos un modelo en tres fases: una fase previa de selección de individuos a los que dirigir los incentivos, fase de conocimiento de la tecnología y fase de adopción. Una vez que los agentes conocen la tecnología, deciden si adoptarla o no teniendo en cuenta factores económicos y sociales. Diseñamos ocho políticas de incentivos, considerando diferentes atributos de las embarcaciones (edad, consumo de energía y conectividad dentro de la red) para identificar a los agentes clave a los que dirigir los incentivos. Se realizan experimentos en diferentes escenarios comparando las tasas de adopción de la tecnología para distintas políticas de focalización (es decir, estrategias dirigidas a individuos específicos) y con la estrategia de referencia en la que los incentivos se distribuyen de manera uniforme entre toda la población. Además, se integran estrategias XAI post-hoc de visualización (concretamente, curvas S-ICE [BPR⁺22] y PDP [Fri01]) para evaluar los impactos potenciales bajo diversos escenarios (incluyendo variaciones en los precios del combustible, la densidad de la red social, las distancias de navegación, la cantidad de incentivos y el porcentaje de embarcaciones seleccionadas) y mejorar así la comprensión de la relación entre diferentes escenarios, políticas y salidas del modelo. Este análisis proporciona un conocimiento fundamental para la planificación y optimización de estrategias.

Conclusiones y trabajos futuros

Los tres objetivos planteados en esta tesis se han abordado de manera exitosa. La revisión de la literatura constituye un punto de partida sólido, ya que explora en profundidad el uso del ABM, su aplicación práctica y problemas abordados en el área del marketing. Destaca un incremento de las publicaciones sobre el uso del ABM en marketing desde el año 2000, mostrando una participación significativa de países como Estados Unidos y más recientemente España y Australia. Además, se sugiere que la colaboración entre grupos de coautoría podría ser mayor. Se realiza un análisis detallado de los modelos basados en agentes en marketing, destacando la prevalencia de modelos de difusión y redes sociales, y la variabilidad en los objetivos de los estudios, destacando la extensiva investigación sobre el efecto de la topología y la heterogeneidad del consumidor en la difusión de innovaciones.

En la segunda contribución, se desarrolla una metodología de XAI para mejorar la interpretación de los resultados de las simulaciones de ABM. La metodología propuesta demuestra ser sencilla y efectiva, facilitando la comprensión de las salidas de los modelos, como ilustra el caso de estudio en marketing. El mecanismo de filtrado funciona bien, asegurando que retenemos las reglas más significativas y fiables, a la vez que hace el análisis más interpretable. La visualización también enriquece la interpretación, presentando las reglas en un formato claro y accesible. La comparación entre algoritmos de SD es compleja. Aunque SD-Map resulta el más ventajoso en nuestro caso de estudio, se reconoce que otros algoritmos, como FuGePSD o NMEEFSD, pueden ser más adecuados en diferentes contextos. Desde la perspectiva de marketing, las reglas extraídas proporcionan una comprensión más profunda del comportamiento del consumidor, de sus interacciones y las dinámicas del mercado. Los hallazgos de este análisis refuerzan la importancia de las interacciones *word-of-mouth* o boca a boca en las decisiones de compra, muestran la efectividad de los distintos canales de marketing y ayudan a identificar grupos de clientes objetivo y potenciales áreas de oportunidad.

La tercera contribución se centra en el diseño de políticas de focalización mediante el uso de ABM para impulsar la adopción de tecnologías sostenibles en la industria marítima. Los resultados demuestran que dirigir los incentivos a un subgrupo de embarcaciones es más efectivo que dirigirlos a toda la población. Es esencial elegir estratégicamente qué embarcaciones serán las destinatarias de estos incentivos, siendo criterios como el grado y el consumo energético los más determinantes, dependiendo del presupuesto total. Además, se consigue una comprensión más profunda de la relación entre políticas, escenarios y salidas del modelo, lo que facilita una planificación de políticas más efectiva. Por ejemplo, mediante la identificación de puntos de saturación, se garantiza que los subsidios no sean demasiado bajos para ser ineficaces ni demasiado altos como para desperdiciar recursos.

Las contribuciones realizadas aportan innovación al campo de investigación mejorando la literatura ya existente al mismo tiempo que abren líneas de investigación futuras. En la primera contribución, surgen líneas de trabajos futuros relacionadas con algunas de las limitaciones actuales del ABM: se sugiere la integración de técnicas de *big data* con simulaciones a gran escala para paliar la limitación de rendimiento y, por otra parte, se destaca la necesidad de desarrollar estándares de validación más robustos así como la publicación de código abierto y prototipos funcionales. Respecto a la segunda contribución, se plantea aplicar la

metodología a modelos en diferentes áreas, como la adopción de tecnologías sostenibles, y explorar nuevas formas de análisis como las relaciones causales y el uso de otros algoritmos de XAI. Finalmente, en la tercera contribución, se propone investigar cómo diferentes niveles de subsidios afectan la adopción de tecnologías, y el uso de algoritmos de optimización para maximizar la tasa de adopción en la industria marítima.

Abstract

Agent-Based Modeling (ABM) is a well-known tool for modeling and simulating complex systems through a population of autonomous entities, known as agents. Widely applied in different areas such as economics, sociology, and epidemiology, ABM is particularly effective in marketing for simulating real markets, capturing the heterogeneity of various participants, and adapting to dynamic environments. Its applicability also extends to the adoption of sustainable technologies, facilitating the simulation of market penetration and interactions among different stakeholders.

ABM allows for the definition of hypothetical scenarios and the evaluation of different strategies, making it a good decision support system. For effective use, it is necessary that these models are properly calibrated and validated, and that they offer a high level of transparency. Although they are white-box approaches, the complexity of the systems they model and the volume of their outputs often require an additional layer of explainability. Increasing the transparency of these models and their solutions will allow us not only to learn from the system but also to improve communication with different audiences, increase their credibility and trust, and facilitate decision-making by stakeholders. Improving the understanding of these models can provide valuable findings to choose the most effective actions in different scenarios, ensuring a positive and real impact on strategic decision-making.

In recent years, the area of eXplainable Artificial Intelligence (XAI) has gained prominence with the aim of making artificial intelligence systems more understandable and transparent without sacrificing performance. Integrating XAI techniques with ABM can contribute to improving the understanding of both the outputs and the agent-based models. The central axis of this PhD thesis is the development and application of a multidisciplinary approach that integrates ABM and XAI techniques to obtain comprehensible information from ABM simulations, thus deepening the understanding of agent behavior and improving decision-making in the field of marketing.

This PhD thesis is structured into three distinct core sections, each related to a sub-objective of the thesis. The first contribution conducts a bibliometric analysis of ABM literature in marketing since 2000, providing both a performance and a science mapping analysis. The performance analysis explores highly cited articles, researchers, and geographical features, highlighting a growing research interest in this area. The science mapping analysis examines the relationships between words, authors, and citations of the literature. Moreover,

this contribution includes a comprehensive reference table characterizing the agent-based models collected by their main goals and features, like the use of diffusion models, social networks, or real-data validation. We observe the prevalence of diffusion models and social networks, and the variability in the studies' goals, particularly noting extensive research into the effects of topology and consumer heterogeneity on the diffusion of innovations.

The second contribution addresses the explainability of ABM outputs by applying XAI techniques, particularly Subgroup Discovery (SD). We propose a methodology based on applying SD to ABM to gain deep insight into the agents' behavior, their interactions, and the overall system dynamics in order the human expert can design optimal behavior-based policies. This methodology is generic and applicable to the outputs of any properly calibrated and validated agent-based model. We show the effectiveness of our methodology through a case study in the marketing area, analyzing the integration of different SD algorithms. We study the obtained set of rules from the viewpoint of a marketing expert, with the aim of validating the proposed methodology. The results show that our methodology can provide a deeper understanding of consumer behavior and market dynamics, delivering potential areas of opportunity for marketers.

The final contribution of this PhD thesis proposes and evaluates micro-targeting incentive policies using ABM to promote the adoption of wind propulsion technologies within the maritime industry. Our proposal is to engineer micro-level incentives to target a reduced set of adopters to optimize subsidies while encouraging ship-owners adoption. The agent-based model employs a three-phase process, influenced by technology awareness, economic factors, and networking. Experiments under different scenarios robustly analyze targeting policies and their impact on adoption rates. Additionally, post-hoc XAI visualization strategies are integrated to evaluate potential impacts under different scenarios, providing a deeper understanding of how targeting policies behave. Our findings reveal that targeted incentives significantly improve adoption compared to a uniform distribution. The most effective targeting policies are those that select receptors based on their social activity and energy consumption, although the available budget affects the selection of criteria.

This PhD thesis enriches the existing literature and opens new paths for future work. The first contribution identifies future research opportunities to overcome current ABM limitations by integrating big data techniques with large-scale simulations to enhance performance. It also highlights the need for more robust validation standards and the publication of open-source code and functional prototypes. The second contribution suggests extending the XAI methodology to models in various domains, such as green technology adoption, and exploring new analytical approaches like causal relationships or different XAI algorithms. Finally, the third contribution proposes investigating the impact of using different subsidy levels and employing optimization algorithms to maximize adoption rates of green technologies in the maritime industry.

Índice general

1. Introducción	1
1.1. Introducción	3
1.2. Justificación	4
1.3. Objetivos	5
1.4. Estructura	6
2. Fundamentos	7
2.1. Modelado basado en agentes	9
2.1.1. Introducción	9
2.1.2. Definición y características principales del modelado basado en agentes	10
2.1.3. Red social asociada al modelado basado en agentes	13
2.1.4. Aplicación del modelado basado en agentes en marketing	16
2.2. Inteligencia artificial explicable	19
2.2.1. Introducción	19
2.2.2. Técnicas agnósticas de explicabilidad post-hoc	20
2.2.3. Explicabilidad en modelado basado en agentes	21
2.3. Descubrimiento de reglas descriptivas supervisadas	24
2.3.1. Introducción	24
2.3.2. Descubrimiento de subgrupos	24
3. Propuesta I: Análisis bibliométrico sobre el uso del ABM en marketing	29
3.1. Introducción	31
3.2. Metodología	31
3.3. Análisis bibliométrico	33

3.3.1.	Número de publicaciones a lo largo del tiempo	33
3.3.2.	Publicaciones con mayor número de citas	33
3.3.3.	Autores más frecuentes	36
3.3.4.	Países e instituciones más frecuentes	38
3.3.5.	Revistas científicas más frecuentes	39
3.3.6.	Análisis de co-palabras	40
3.4.	Principales objetivos y características	42
3.5.	Conclusiones	47
4.	Propuesta II: Aumento de la explicabilidad de las salidas de los modelos basados en agentes usando descubrimiento de subgrupos	49
4.1.	Introducción	51
4.2.	Metodología propuesta	52
4.2.1.	Diseño del preprocesamiento de datos	53
4.2.2.	Algoritmos de descubrimiento de subgrupos	56
4.2.3.	Filtrado de reglas	56
4.2.4.	Visualización de reglas	57
4.3.	Caso de estudio: un modelo de mercado basado en agentes	58
4.3.1.	Modelo de mercado basado en agentes	58
4.3.2.	Descripción de los datos	59
4.3.3.	Marco experimental	61
4.3.4.	Comparación de algoritmos y experimentos	62
4.4.	Análisis experto sobre el caso de estudio	66
4.5.	Conclusiones	70
5.	Propuesta III: Focalización de micropolíticas de incentivos para la adopción de tecnologías verdes con ABM	73
5.1.	Introducción	75
5.2.	Estado del arte del ABM para la adopción de tecnologías verdes y focalización de incentivos	76
5.3.	Metodología propuesta	77
5.3.1.	Estructura general del modelo	78
5.3.2.	Selección de embarcaciones para políticas de focalización	80

5.3.3.	Fase de conocimiento	80
5.3.4.	Cálculo del factor económico	81
5.3.5.	Fase de adopción basada en factores económicos y sociales	82
5.4.	Resultados	83
5.4.1.	Diseño de la experimentación	83
5.4.2.	Impacto de diferentes estrategias de focalización	84
5.4.3.	Rendimiento de las políticas de focalización bajo diferentes semillas iniciales y subsidios	86
5.4.4.	Análisis de la mejor política de focalización en diferentes escenarios .	88
5.5.	Discusión	94
5.6.	Conclusiones	95
6.	Conclusiones	97
6.1.	Conclusiones	99
6.2.	Trabajos futuros	100
6.3.	Publicaciones	101
	Bibliografía	103

Lista de acrónimos

ABM Modelado Basado en Agentes (*Agent-based Modeling*)

IA Inteligencia Artificial

ICE Expectativa Condicional Individual (*Individual Conditional Expectation*)

KPI Indicadores Clave de Rendimiento (*Key Performance Indicator*)

PDP Gráficos de Dependencia Parcial (*Partial Dependence Plot*)

SD Descubrimiento de Subgrupos (*Subgroup Discovery*)

SDRD Descubrimiento de Reglas Descriptivas Supervisadas (*Supervised Descriptive Rule Discovery*)

SN Red Social (*Social Network*)

WOM Boca a Boca (*Word-Of-Mouth*)

WPT Tecnología de Propulsión Eólica (*Wind-assisted Propulsion Technology*)

XAI Inteligencia Artificial Explicable (*eXplainable Artificial Intelligence*)

Capítulo 1

Introducción

En este capítulo se presenta el contexto y los propósitos fundamentales de la tesis, sirviendo como base para comprender su relevancia y los objetivos específicos del trabajo. Comienza con una sección introductoria que motiva la tesis, explicando la importancia del tema y las limitaciones existentes actualmente. A continuación, la sección de justificación expone las razones y la necesidad de abordar este tema. Posteriormente, se establece el objetivo principal de la tesis, así como los subobjetivos específicos que derivan de este. Finalmente, se describe la estructura de la tesis, ofreciendo una guía sobre el contenido y la organización de los siguientes capítulos.

1.1. Introducción

El Modelado Basado en Agentes (ABM, por sus siglas en inglés) [Bon02, Eps06] es un metodología popular y versátil para modelar y simular sistemas complejos de diversas disciplinas. Estos modelos consisten en un conjunto de agentes autónomos, cada uno con reglas de comportamiento definidas, que interactúan dentro de un entorno específico. Se centran en las acciones e interacciones individuales con el fin de generar patrones globales de comportamiento, como la difusión de información, la transmisión de enfermedades virales o la participación en acciones colectivas [MW02]. El ABM proporciona un valioso marco donde los patrones globales de comportamiento aportan mucho más conocimiento que la simple agregación de atributos individuales. Además, el ABM es una herramienta útil como sistema de apoyo a la toma de decisiones. Permite definir y analizar escenarios hipotéticos, facilitando la evaluación de estrategias antes de su implementación real, reduciendo así el riesgo de aplicarlas sin testear [CR17, TR18]. Por ejemplo, permite analizar cómo respondería una población ante una evacuación de emergencia, proporcionando información crítica para planificar y ejecutar acciones efectivas.

Desde principios de los años 2000, ha habido un aumento significativo en el número de publicaciones que aplican ABM para abordar diversos problemas de marketing. La capacidad del ABM para reflejar la heterogeneidad y la adaptatividad de los agentes entre otras características, lo convierte en una herramienta ideal para estudiar fenómenos de marketing, donde se producen interacciones entre individuos heterogéneos (consumidores, vendedores, distribuidores y otros actores) con diferentes intereses y características en un entorno dinámico y, a menudo, impredecible [RRK18]. En este contexto, el ABM permite simular mercados reales incorporando mecanismos como el Boca a Boca (WOM, por sus siglas en inglés), proporcionando un valioso soporte para la toma de decisiones estratégicas y la planificación de campañas de marketing. Por ejemplo, el ABM puede analizar cómo las promociones impactan en diferentes segmentos de consumidores, permitiendo a las empresas optimizar sus estrategias de precios y maximizar la efectividad de sus campañas promocionales.

Para poder entender y confiar en los resultados de las simulaciones de ABM como sistemas de apoyo a la decisión, se requiere un gran nivel de transparencia. Tanto los diseñadores como los usuarios de ABM deben entender cómo el modelo recrea el comportamiento que se está estudiando. Aunque estos modelos se consideran interpretables *per se*, el volumen y la complejidad de sus salidas pueden dificultar la comprensión intuitiva del modelo, teniendo en cuenta que estas no están formadas solo por indicadores a nivel global sino que también generan información detallada a nivel de agente. Mejorar la explicabilidad del modelo asegura una comunicación efectiva, optimiza la toma de decisiones e incrementa la confianza en los resultados por parte de todas las partes interesadas o *stakeholders*.

La integración de técnicas de Inteligencia Artificial Explicable (XAI, por sus siglas en inglés) en el ABM puede ser beneficiosa, ya que puede proporcionar esa capa adicional de explicabilidad que necesitan. En los últimos años, el área de XAI ha cobrado bastante relevancia, especialmente en el contexto del aprendizaje profundo o *deep learning*, con el objetivo de hacer los sistemas de Inteligencia Artificial (IA) más comprensibles y transparentes para los humanos sin sacrificar rendimiento [AB18, GSC⁺19]. La falta de entendimiento en los modelos de IA puede conducir a decisiones erróneas o sesgadas, además de socavar

la confianza en las decisiones tomadas por dichos modelos. Aunque las técnicas de XAI se aplican principalmente sobre modelos de caja negra, los modelos de caja blanca también pueden beneficiarse de estas técnicas para aumentar la interpretabilidad de sus soluciones y, en consecuencia, aumentar la confianza en el comportamiento y rendimiento del modelo. A pesar de los avances en XAI en otros dominios, existe un notable vacío en la aplicación de estas técnicas en ABM.

En esta tesis, se propone contribuir al campo del ABM mediante tres propuestas principales. La primera consiste en abordar la ausencia de revisiones de la literatura recientes que engloben todo el campo del marketing en el ABM, mediante un análisis bibliométrico exhaustivo de la literatura existente sobre el uso del ABM en marketing, proporcionando una perspectiva global de las tendencias y las prácticas predominantes. En segundo lugar, abordamos el desafío de aplicar técnicas de XAI sobre las salidas de los modelos basados en agentes, concretamente técnicas de Descubrimiento de Reglas Descriptivas Supervisadas (SDRD, por sus siglas en inglés) [NLW09] y, en particular, algoritmos de Descubrimiento de Subgrupos (SD, por sus siglas en inglés) [Klö96, Wro97]. Se propone una metodología genérica aplicable a la salida de cualquier modelo basado en agentes adecuadamente calibrado y validado, con la finalidad de extraer reglas interesantes e interpretables sobre el comportamiento de los agentes que ayuden a los *stakeholders* en su proceso de toma de decisiones. Se muestra la efectividad de la propuesta a través de un caso de estudio en el área de marketing. En tercer lugar, contribuimos a un problema real actual en el campo de la adopción de eco-innovaciones proponiendo la aplicación de estrategias de focalización, es decir, estrategias dirigidas a individuos específicos de la población, con ABM. Estas estrategias se usan para la asignación de subsidios que incentiven la adopción de tecnologías verdes en la industria marítima. En esta última propuesta, integramos técnicas de visualización de XAI para entender las dinámicas del sistema y mejorar la efectividad de las estrategias propuestas en diferentes escenarios.

1.2. Justificación

La explicabilidad del ABM ha surgido como un desafío para abordar la creciente necesidad de transparencia en sistemas de soporte a la decisión. El ABM consiste en la simulación de interacciones entre agentes autónomos para estudiar la emergencia de fenómenos complejos, y su uso como laboratorio de pruebas con escenarios hipotéticos puede ser de gran utilidad en la toma de decisiones estratégicas en campos como el marketing. Sin embargo, para su uso efectivo es necesario un alto grado de transparencia, que asegure la confianza en el sistema. Por lo tanto, integrar técnicas de XAI con ABM puede proporcionar información más comprensible de las simulaciones, permitiendo así una toma de decisiones estratégicas más informada. Las razones específicas que motivan esta tesis se enumeran a continuación.

- Primero, necesidad de mejorar explicabilidad: El volumen alto y la complejidad de las salidas de las simulaciones hacen necesario desarrollar técnicas que faciliten la interpretación y comunicación de sus resultados, lo cual es esencial para asegurar la utilidad práctica de los modelos basados en agentes en la toma de decisiones y la confianza en sus previsiones.

- Segundo, limitaciones de la literatura actual: Aunque se han propuesto diversas técnicas de aprendizaje automático para analizar las salidas de los modelos basados en agentes, no abordan el problema de analizar la información detallada que se genera a nivel de agente con el objetivo de hacer más comprensible el comportamiento del sistema y para informar decisiones sobre políticas y acciones estratégicas a nivel global.
- Tercero, actualización de revisión de la literatura: Dada la creciente evolución de la investigación sobre el uso del ABM en marketing en las últimas dos décadas y la antigüedad de las últimas revisiones en el área, es fundamental realizar una revisión bibliométrica actualizada y exhaustiva para identificar tendencias actuales, prácticas predominantes y oportunidades en la aplicación del ABM en marketing.
- Finalmente, aplicaciones prácticas, reales y actuales: El ABM tiene un amplio potencial de aplicación en diversos campos, como el marketing y la adopción de tecnologías sostenibles. Mejorar la comprensión de estos modelos puede proporcionar hallazgos o *insights* valiosos y prácticos para elegir las políticas y acciones más efectivas en distintos escenarios.

En resumen, una tesis centrada en la explicabilidad del ABM en el área de marketing se justifica por la novedad, relevancia y naturaleza desafiante del problema, así como su utilidad práctica en problemas reales. Además, debido a la novedad, todavía existe un amplio campo en el que desarrollar investigaciones e innovaciones de calidad que tengan verdadera relevancia e impacto tanto en el mundo de la investigación como en diferentes aplicaciones.

1.3. Objetivos

El objetivo principal de esta tesis es desarrollar y aplicar un enfoque multidisciplinar que integre ABM y técnicas de XAI con el fin de extraer información explicable de las simulaciones de ABM, logrando así una comprensión más profunda del comportamiento de los agentes y mejorar la toma de decisiones en el ámbito del marketing. Para lograr este objetivo, nos planteamos los siguientes subobjetivos:

Primer objetivo: Realizar una revisión de la literatura sobre ABM en el ámbito del marketing y análisis bibliométrico para identificar tendencias, áreas de interés y limitaciones en la investigación actual. Este análisis proporcionará una visión global de cómo se ha utilizado el ABM en marketing.

Segundo objetivo: Desarrollar y aplicar técnicas explicables de aprendizaje automático para el descubrimiento de patrones a partir de los resultados de simulaciones basadas en agentes. En particular, aplicar técnicas de SD para explicar el comportamiento de los agentes a partir de las salidas de los modelos basados en agentes.

Tercer objetivo: Diseñar, desarrollar y aplicar estrategias de focalización (es decir, estrategias dirigidas a ciertos individuos de la población) con ABM para la asignación de subsidios que incentiven la adopción de tecnologías verdes, junto con el uso de técnicas de visualización de XAI para mejorar la efectividad y comprensión de dichas estrategias en diferentes escenarios hipotéticos.

1.4. Estructura

Esta tesis está organizada en varios capítulos asociados a los distintos objetivos propuestos y a los conocimientos preliminares necesarios para el desarrollo de los mismos. De esta manera, la estructura del resto de capítulos de la tesis es la siguiente:

Capítulo 2. Introduce al lector los conceptos fundamentales y las teorías relevantes que sustentan la investigación. En particular, se presentan los fundamentos del ABM, incluyendo una descripción detallada de sus componentes y un resumen de su aplicación en marketing. También se presentan los fundamentos del área de XAI, destacando algunos de los métodos más habituales y proporcionando un resumen del estado del arte de explicabilidad en ABM. Finalmente, se presentan los principios del SDRD, resaltando en particular las técnicas de SD.

Capítulo 3. Presentamos la primera contribución de esta tesis, relacionada con el primer subobjetivo. Consiste en una revisión de la literatura y un análisis bibliométrico sobre el uso del ABM en el ámbito del marketing durante las dos últimas décadas. Esta revisión ofrece una perspectiva global de cómo se ha aplicado el ABM en este ámbito, identificando tendencias, áreas de interés y limitaciones en la investigación actual.

Capítulo 4. Asociada al segundo subobjetivo y al objetivo principal de esta tesis, en este capítulo se presenta la segunda contribución de esta tesis. Consiste en el desarrollo y aplicación de técnicas de SD para identificar patrones a partir de los resultados de simulaciones de ABM. Se analiza un caso de estudio en marketing para ilustrar la aplicabilidad de estas técnicas y su capacidad para mejorar la interpretabilidad y la toma de decisiones.

Capítulo 5. Se presenta la última contribución, correspondiente al tercer subobjetivo. Este capítulo se centra en el diseño, desarrollo y aplicación de estrategias de focalización con ABM para la asignación de subsidios que incentiven la adopción de tecnologías verdes en la industria marítima. Además, se integran técnicas de visualización de XAI para mejorar la comprensión y efectividad de dichas estrategias.

Capítulo 6. Finalmente, en este capítulo mostramos las conclusiones extraídas a partir de los trabajos realizados durante esta tesis y discutimos las posibles direcciones para futuros estudios.

Capítulo 2

Fundamentos

En este capítulo se presentan los conceptos fundamentales para comprender el resto de capítulos de la tesis. En primer lugar, se abordan los fundamentos del ABM, proporcionando una descripción detallada de sus características, de las redes sociales asociadas a estos modelos y un resumen de su aplicación en marketing. A continuación, se presentan los fundamentos del área de XAI, destacando algunos de los métodos más habituales y proporcionando un resumen del estado del arte de explicabilidad en el ABM. Finalmente, se introducen los principios del SDRD, destacando en particular las técnicas de SD. Se describen las medidas de calidad y algoritmos habituales de SD, así como algunos ejemplos de aplicación en el mundo real.

2.1. Modelado basado en agentes

En esta sección se presentan los conceptos fundamentales sobre ABM. Tras una introducción en la Sección 2.1.1, se describen y caracterizan los modelos basados en agentes en la Sección 2.1.2, se aborda el concepto de redes sociales en la Sección 2.1.3 y finalmente se presentan las aplicaciones de ABM en marketing en la Sección 2.1.4.

2.1.1. Introducción

Un sistema complejo es un conjunto de numerosos componentes autónomos, interdependientes e interactivos, donde la salida del sistema no se limita a la suma de las partes individuales [Mit09, Wal93, Cas94]. Estos sistemas exhiben comportamientos no lineales y dinámicos. Pequeños cambios en una parte del sistema pueden desencadenar efectos significativos en todo el sistema. Debido a la alta dimensionalidad de estos sistemas, sus complejas interacciones y a su naturaleza no lineal y descentralizada, son muy difíciles de modelar, predecir y controlar [Ran15]. Estas características también hacen que a menudo estos sistemas sean difíciles de interpretar.

Una característica clave en los sistemas complejos es la emergencia, la idea de que “la acción del todo es más que la suma de las partes” [Hol14]. Una propiedad emergente es aquella que no puede descubrirse inspeccionando a los agentes individuales, sino que surge de las interacciones entre ellos y solo puede observarse a nivel de macroscópico [Hol00, MP09]. Por ejemplo, un atasco de tráfico no es resultado del comportamiento de un conductor individual, sino del comportamiento y las interacciones entre conductores. Ninguno de estos conductores genera un atasco de tráfico por sí mismo. En cambio, un atasco de tráfico es el producto emergente de muchas decisiones individuales diferentes [Res97]. Otra característica clave de los sistemas complejos es la retroalimentación, en el sentido de que las propiedades emergentes afectan a las decisiones individuales [Ran15]. En el ejemplo del atasco, el patrón de tráfico congestionado influye en las decisiones individuales de los conductores, creando un ciclo de retroalimentación donde las acciones individuales y el patrón emergente de tráfico se influyen mutuamente.

Los sistemas complejos están muy presentes en nuestra vida. Las sociedades humanas son un claro ejemplo de ello. Las interacciones sociales, políticas, económicas y culturales dentro de una sociedad generan una variedad de comportamientos emergentes y patrones que no pueden ser explicados simplemente observando a los individuos por separado [Saw05]. No solo la sociedad humana, sino también otras sociedades biológicas, como las colonias de hormigas o los enjambres de abejas, son sistemas complejos cuyo funcionamiento emerge de la cooperación entre numerosos individuos sin un control centralizado [Bon01]. Otros ejemplos habituales son los fenómenos migratorios [DCCM20], donde patrones complejos emergen de las decisiones individuales en respuesta a factores ambientales y sociales. El cerebro humano también es un sistema complejo [TSB⁺11], con billones de conexiones neuronales que producen comportamientos y procesos cognitivos emergentes. Las pandemias son otro ejemplo [AM20], que involucran interacciones dinámicas entre individuos, comunidades y agentes patógenos, cuyos resultados son difíciles de prever y controlar. Tam-

bién encontramos sistemas complejos en otros ámbitos como la economía [Art09], por ejemplo, el mercado de valores donde interactúan millones de componentes a nivel mundial, generando fluctuaciones y tendencias que no se pueden deducir fácilmente, o los fenómenos de marketing [HS08], de los que hablaremos con más detalle en la Sección 2.1.4.

Como se ha mencionado anteriormente, modelar sistemas complejos no es sencillo. Existen principalmente dos paradigmas para abordar la modelización de estos sistemas: el enfoque *top-down* (de arriba hacia abajo) y el enfoque *bottom-up* (de abajo hacia arriba) [CGL08]. El primero adopta una perspectiva global del sistema, donde se establecen suposiciones globales comenzando desde lo macroscópico hasta lo microscópico. Este enfoque, empleado por técnicas tradicionales como los modelos estadísticos [RA03] o analíticos [SHP⁺22], tiene limitaciones al depender de suposiciones globales y no poder capturar comportamientos heterogéneos [WR15]. Por otro lado, en el enfoque *bottom-up*, se modela a nivel de componentes individuales, lo que permite relajar las suposiciones, ya que estas se establecen a nivel de individuo, y el comportamiento macroscópico emerge de las interacciones entre los componentes y con el entorno [EA96]. Este enfoque no requiere suposiciones globales y es más flexible, como es el caso del ABM [MN05b].

2.1.2. Definición y características principales del modelado basado en agentes

El ABM [Bon02, MN05b, Eps06] es una conocida técnica de simulación para estudiar el comportamiento de sistemas complejos. Una de las ventajas de esta técnica es que no requiere ningún conocimiento de las macro-dinámicas del sistema; sino que se establecen micro-reglas de comportamiento a nivel de individuo, y luego se observan y analizan los resultados emergentes a nivel macro [RR11]. Su enfoque *bottom-up* nos permite estudiarlo tanto a nivel de agente como de sistema.

Los modelos basados en agentes están formados por dos componentes principales: los agentes y el entorno [RRK18]. Los agentes son unas entidades autónomas que actúan según unas reglas de comportamiento simples y predefinidas, que pueden incorporar condiciones para interactuar con otros agentes. La distribución de estas entidades autónomas, tanto en número como en características principales, debe reflejar la propia de los individuos reales del sistema que se pretende representar. El entorno es la estructura y condiciones que describen dónde se ubican los agentes y cómo están conectados. El entorno más habitual son las redes sociales artificiales, que tratan de reflejar fielmente el contexto en el que se dan las interacciones entre los agentes. El uso de redes sociales permite a los modelos basados en agentes replicar de forma realista las dinámicas de procesos epidemiológicos [SBL⁺20], de difusión de información [ZV19] o mecanismos WOM [CR17]. Alternativamente, en lugar de redes sociales, en algunas ocasiones se usan representaciones físicas o geográficas para modelar el entorno [BRR⁺05]. Además, los agentes de la población pueden estar expuestos a estímulos externos.

Se lleva a cabo la simulación del comportamiento de los agentes y sus interacciones a

lo largo de un periodo de tiempo determinado. Una vez que el modelo ha sido suficientemente simulado (es decir, se ha ejecutado durante el número de iteraciones necesarias para que las dinámicas del sistema se manifiesten de manera completa y estable), los resultados emergentes derivados de las interacciones entre los agentes se agregan y se presentan como resultados [RRK18]. Debido a la naturaleza estocástica del modelo (es decir, a la presencia de elementos aleatorios), se requieren múltiples ejecuciones independientes para cada configuración de parámetros para capturar la distribución de los posibles resultados que pueden existir. Es importante observar un evento suficientes veces para que se pueda realizar una inferencia estadística sobre la relación entre las entradas y las salidas [RR11]. Estas ejecuciones independientes, conocidas como simulaciones de Monte Carlo, aumentan considerablemente la carga computacional.

El ABM reúne características que son difíciles de encontrar en su conjunto en los modelos tradicionales:

- **Emergencia.** El ABM es capaz de capturar comportamientos emergentes. En el ABM, se modela y simula el comportamiento de los agentes y sus interacciones, capturando la emergencia desde abajo hacia arriba cuando se ejecuta la simulación [Bon02].
- **Heterogeneidad.** Los agentes son diversos en cuanto a atributos y comportamientos. Cada agente puede ser modelado de manera única. Las características y comportamientos del agente pueden variar en su alcance y sofisticación, en cuánta información se considera en las decisiones del agente, en la percepción del agente de las posibles reacciones de otros agentes, y en la memoria de eventos pasados utilizada en la toma de decisiones [MN10].
- **Adaptatividad.** Los agentes tienen la capacidad de adaptar su comportamiento a las circunstancias basándose en su conocimiento y su experiencia [Ran06]. Si un agente realiza una acción con resultado negativo, es probable que en el futuro cambie su estrategia.
- **Interactividad.** El ABM ofrece la capacidad de representar las interacciones a través del entorno, modelando quién está o podría estar conectado con quién y los mecanismos de estas interacciones. Los agentes pueden moverse en el entorno, interactuar con otros agentes o con el entorno en sí. Además, tienen la capacidad de reconocer y distinguir los rasgos de otros agentes [MN10].
- **Autonomía.** Los agentes deciden independientemente sus acciones teniendo en cuenta sus objetivos y el conocimiento del que disponen en cada momento. Su conocimiento del sistema está limitado, basado en la idea de la racionalidad humana limitada [Art94]. Esta limitación introduce incertidumbre. Además, sus acciones pueden no surtir el efecto deseado por la acción concurrente con los demás agentes.

Todas estas características otorgan realismo al modelo, convirtiéndose en una herramienta valiosa como sistema de apoyo a la toma de decisiones. Permite definir escenarios hipotéticos o *what-if*, facilitando la evaluación de las estrategias antes de su implementación real,

reduciendo así el riesgo de aplicarlas sin testear [CR17, TR18]. El uso efectivo de estos modelos requiere un alto nivel de transparencia. Tanto los usuarios como los diseñadores de un modelo basado en agentes deben entender en profundidad el modelo. Además, incrementar la interpretabilidad del modelo y mejorar la comunicación a distintas audiencias, generará a su vez una mayor confianza en su comportamiento.

El ABM se ha utilizado con éxito en diversas áreas como la epidemiología [Cue20, KSV⁺22], la economía [PMHR23], la política [MCSLC21], el turismo [CHP22], la simulación de evacuaciones [CDM⁺23] y el marketing. Profundizaremos en las aplicaciones de este último campo en la Sección 2.1.4.

Aunque el ABM ofrece ventajas significativas, también presenta ciertas limitaciones que es importante considerar. A continuación, se detallan algunas de las principales limitaciones [RS21]:

- **Parametrización.** Los modelos basados en agentes tienen un gran número de parámetros y no siempre es posible determinar el valor correcto para todos ellos. Esta tarea puede ser compleja y depende en gran medida de la disponibilidad de datos precisos. Un enfoque común para ajustar estos parámetros es la calibración automática, que utiliza medidas de error para comparar los datos reales con la salida del modelo y ajusta los parámetros en consecuencia [Oli03]. Los algoritmos evolutivos se han usado frecuentemente con este fin [MCC21, RBCC21].
- **Verificación y validación.** La verificación es el proceso de garantizar que el modelo implementado se corresponde con el modelo conceptual, mientras que la validación asegura que el modelo representa con precisión el sistema real [Bal94]. Estos procesos son difíciles de realizar completamente [GR13], pero son esenciales para la credibilidad del modelo. Rand y Rust sugieren una serie de pautas para la correcta verificación y validación del modelo [RR11]. La falta de una verificación y validación rigurosas puede llevar a una percepción de arbitrariedad en los resultados del modelo, lo que socava su credibilidad y utilidad.
- **Escalabilidad.** Los modelos basados en agentes pueden ser computacionalmente costosos, especialmente cuando se simulan millones de agentes. Esto puede limitar la capacidad de ejecutar simulaciones a gran escala o en tiempo real. Aunque los costes computacionales están disminuyendo con el tiempo, la necesidad de recursos significativos sigue siendo una limitación importante. Se puede reducir el coste computacional tomando decisiones como reducir la resolución de los agentes o no registrar todas las acciones realizadas por cada agente. Es inevitable tener que buscar un equilibrio entre el tiempo de cálculo y el nivel de detalle que se registra [WR15].
- **Falta de causalidad.** Una de las limitaciones más significativas del ABM es la falta de causalidad clara, lo cual afecta directamente su explicabilidad. Los modelos basados en agentes pueden reproducir patrones observados en el mundo real, pero frecuentemente no pueden explicar por qué ocurren estos patrones. Esta incapacidad para

establecer relaciones causales dificulta la interpretación y comunicación de los resultados del modelo. Esto supone un problema para la adopción efectiva del ABM en la toma de decisiones y su aceptación por parte de las audiencias no técnicas.

En [DLG⁺23] se recopila el uso de técnicas de aprendizaje automático para abordar estas limitaciones en el ABM. Plantean seis desafíos divididos en dos ejes: (1) especificaciones estructurales, y (2) análisis de salidas del modelo. El primer grupo abarca tareas como mejorar el preprocesamiento de datos para la entrada del modelo basado en agentes, mejorar la precisión del modelado del comportamiento, mejorar la eficiencia computacional, facilitar la implementación y aumentar la comprensión del modelo. En cuanto al segundo grupo, el desafío es aumentar la comprensión de las salidas del modelo, ya que la creciente complejidad de los modelos basados en agentes a gran escala hace que sea más difícil extraer información significativa de los resultados de la simulación [Mac16].

2.1.3. Red social asociada al modelado basado en agentes

Una red es un grafo formado por conjunto de items, denominados nodos, con conexiones entre ellos, denominados arcos o enlaces. La ciencia de redes [Lew11] es un campo multidisciplinar que estudia las estructuras y dinámicas que representan fenómenos de redes complejas, como las redes de telecomunicaciones, las redes biológicas, las redes cognitivas, las redes informáticas y las redes sociales, que conduce a modelos predictivos de dichos fenómenos [BA99, NBW06].

Una Red Social (SN, por sus siglas en inglés) es un tipo de red compleja que modela las relaciones existentes entre un conjunto de entidades sociales [NBW06]. Su análisis y estudio originaron el campo del análisis de redes sociales [WF94], que se centra en el modelado y el estudio de fenómenos sociales, con especial énfasis en las interacciones y relaciones entre las entidades dentro de estas redes. Se viene usando desde hace mucho tiempo en diversas aplicaciones, que van desde los negocios (por ejemplo, para predecir la pérdida de clientes, es decir, detectar clientes que podrían cambiar de operador móvil identificando cambios en los patrones de contactos telefónicos) [WC02], a la epidemiología (por ejemplo, en el estudio de la propagación de enfermedades infecciosas [FA01]). En los últimos años, con el auge de las SN en línea u *online*, este campo ha ganado aún más importancia [CA19]. Es una herramienta poderosa para comprender la estructura y dinámica de las interacciones humanas en la era digital.

La forma en que los nodos están conectados entre sí se denomina topología o conectividad de la red. Una topología describe quién transfiere información a quién [MN10]. Los nodos normalmente interactúan con un subconjunto de nodos, denominados vecinos, que será determinado por la estructura específica de la topología. A continuación, se enumeran las topologías más usadas en la literatura y en la Figura 1 se muestran ejemplos de redes para ilustrar cada una de estas estructuras:

- **Redes aleatorias** [ER59]. En estas redes, las conexiones entre los nodos se establecen

de manera aleatoria, de manera que cada nodo tiene la misma probabilidad de estar conectado con cualquier otro nodo de la red. Como resultado, la mayoría de los nodos tienden a tener un número similar de conexiones. Es importante destacar que estas redes no son una representación precisa de las redes reales. A pesar de ello, han sido muy usadas en la literatura [WD07] y a menudo sirven de referencia para comparar con otras estructuras de red, como en [JJ03].

- **Redes regulares.** En estas redes cada nodo tiene exactamente el mismo número de conexiones. Aunque este tipo de redes no son una representación precisa sobre las redes reales, se han usado con frecuencia en la literatura debido a su simplicidad y uniformidad [GLM10]. Además, a menudo sirven como referencia para comparar con otras estructuras de red, como en [DJJ07].
- **Redes de mundo pequeño** [WS98]. Estas redes se basan en el fenómeno del mundo pequeño [Mil67]: cualesquiera dos nodos de la red se comunican por un camino de nodos intermedios de longitud relativamente corta. A medida que se añaden nuevos nodos a la red, la distancia máxima entre pares de nodos crece de forma logarítmica. Además, se caracterizan por un alto coeficiente de agrupamiento o *clustering*, esto es, si dos nodos no están conectados directamente entre sí, existe una alta probabilidad de que lo estén mediante conexiones entre otros nodos. Este tipo de redes se usan con frecuencia para modelar redes reales como las redes neuronales del cerebro humano [BB06].
- **Redes libres de escala** [BA99]. Las conexiones en estas redes siguen la distribución de la ley de la potencia: unos pocos nodos, denominados *hubs*, tienen numerosas conexiones mientras la mayoría de los nodos tienen pocas conexiones. Es habitual generar estas redes usando el algoritmo propuesto por Barabási-Albert, conocido como algoritmo de unión preferencial (*preferential attachment* en inglés) [BA99]. En este modelo, la probabilidad de que un nuevo nodo se conecte a un nodo existente es proporcional al número de conexiones que ya tiene ese nodo. Por lo tanto, los nodos que ya tienen un alto número de conexiones tienen más probabilidades de recibir nuevas conexiones, lo que refuerza aún más su posición como *hubs* en la red. Matemáticamente, la probabilidad $P(k)$ de que un nodo de la red esté conectado a k nodos es proporcional a $k^{-\gamma}$, donde el exponente γ depende del tipo de red. Se ha observado que en la mayoría de los sistemas, este exponente se encuentra en el rango $2 < \gamma \leq 3$. Este tipo de redes se usan con frecuencia para modelar redes reales como Internet [CCGJ02].
- **Redes reales.** Se construyen a partir de datos extraídos de los sitios de SN (un ejemplo se puede encontrar en [LAH07]). Sin embargo, crear una red de este tipo normalmente es difícil, ya que la obtención de datos confiables y completos puede ser difícil debido a la falta de acceso a los mismos o a restricciones de privacidad impuestas por las plataformas [RS21]. La alternativa que los investigadores han empleado a lo largo de los años es generar redes sintéticas que simulan las propiedades de una red conocida [CR17, TRJ13].

Adicionalmente, las redes pueden ser estáticas, donde todos los vínculos entre los nodos permanecen fijos, o dinámicas, donde pueden añadirse o eliminarse algunos vínculos en el transcurso de la simulación. Las conexiones en una red también pueden ser dirigidas, cuando las relaciones tienen un sentido específico, o no dirigidas, donde las relaciones son simétricas y bidireccionales. Asimismo, las conexiones pueden estar ponderadas, representando la fuerza, la importancia o la cantidad de interacción entre los nodos conectados.

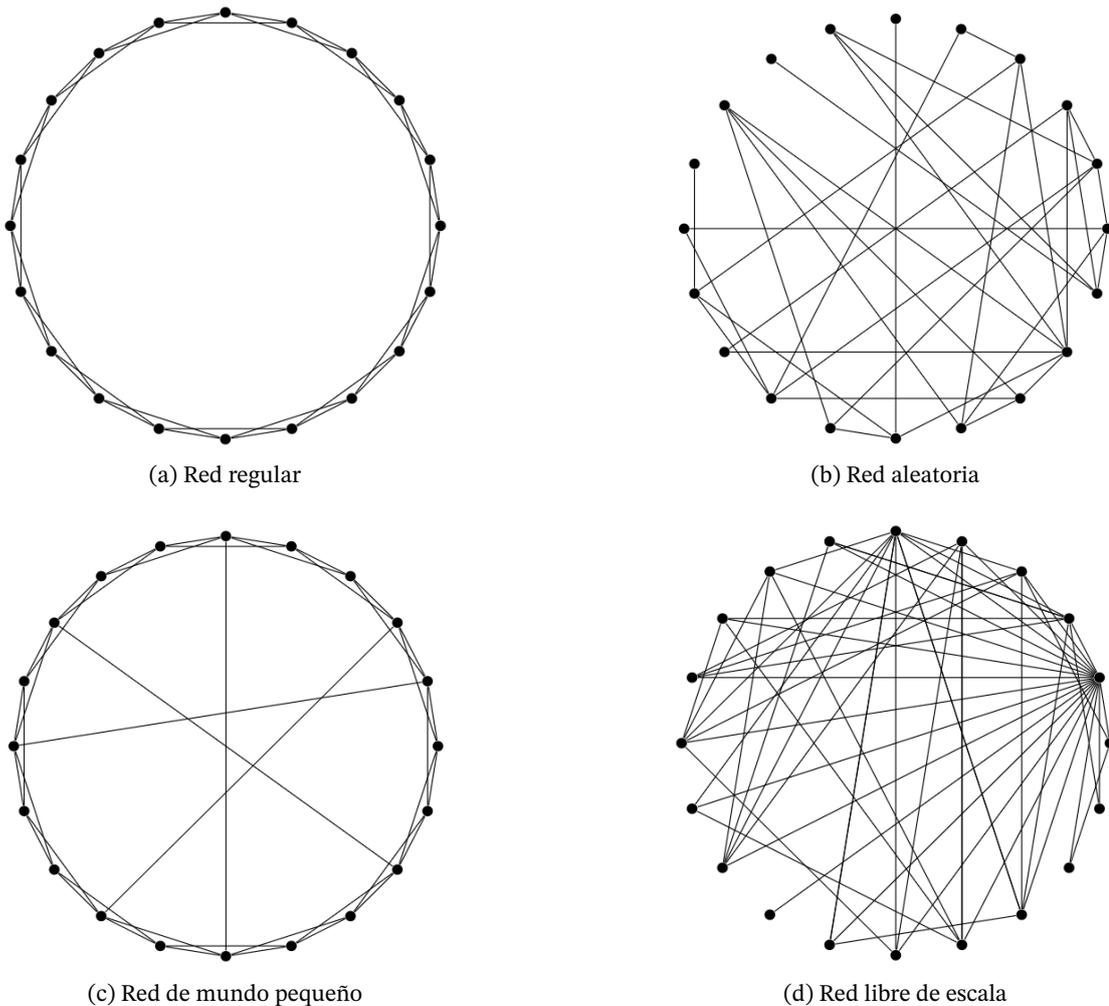


Figura 1: Ejemplos de diferentes topologías de redes: (a) red regular, (b) red aleatoria, (c) red de mundo pequeño y (d) red libre de escala.

Las SN son un elemento fundamental en el ABM ya que nos permiten representar los sistemas complejos de forma estructurada, de manera que los nodos corresponden a los agentes y las conexiones establecen las relaciones entre ellos. Son muy útiles para estudiar comportamientos emergentes en ABM, permitiendo evaluar cómo las variaciones en la estructura

de la red pueden afectar la dinámica del modelo y el impacto de estas estructuras en los resultados obtenidos [NC16, WGFM20]. La integración de las SN en los modelos basados en agentes permite analizar la aparición de distintos fenómenos organizativos [DCSM17], sociales [WGFM20] o cognitivos [Mom22], entre otros.

2.1.4. Aplicación del modelado basado en agentes en marketing

El marketing es un campo en constante evolución [CI06, MBA14, SV18] con un objetivo claro: identificar y satisfacer de manera rentable las necesidades humanas y sociales [KS19]. La clave para lograr este objetivo consiste en conocer cómo reaccionarán los clientes ante ciertos estímulos publicitarios, con el fin de definir estrategias adecuadas que beneficien a las marcas no solo en términos de volumen de ventas, sino también en cuanto a la notoriedad e imagen de la marca. La proliferación de nuevos canales de comunicación, la explosión de datos disponibles y el impacto cada vez mayor de los medios digitales y sociales han transformado la forma en que los consumidores reciben y procesan la información. Además, una competencia cada vez más agresiva ha generado un cambio de paradigma, donde los modelos convencionales de apoyo a la toma de decisiones de marketing basados en econometría y matemáticas han perdido parte de su eficacia.

Los fenómenos de marketing son difíciles de modelar, analizar y predecir debido principalmente a dos factores: (1) interacciones entre individuos heterogéneos (consumidores, vendedores, distribuidores y otros *stakeholders*) con diferentes intereses y características, y (2) la simultaneidad de sus acciones, que ocurren en un contexto dinámico y complejo [RRK18]. Por ejemplo, consideremos el lanzamiento de un nuevo teléfono móvil. Las decisiones de compra de los consumidores están determinadas por numerosos factores personales como la valoración de la innovación tecnológica, la sensibilidad al precio, la lealtad a ciertas marcas, o la susceptibilidad a recomendaciones de amigos y familiares. Además, simultáneamente pueden ser influenciados por estrategias de marketing de competidores. Todos estos elementos interactuando en un entorno dinámico y a menudo impredecible, hace que prever la respuesta del mercado sea un desafío considerable. Los mercados de consumo son ejemplos de sistemas complejos donde es crucial analizar tanto el análisis a nivel micro (por ejemplo, la decisión de un consumidor de comprar un producto) como a nivel macro (por ejemplo, el patrón global de difusión de un producto) [RS21]. Además, la toma de decisiones en marketing son costosas y, en muchas ocasiones, solo tienen una oportunidad para tomar la decisión adecuada.

El ABM destaca como una herramienta idónea para abordar estas dificultades. Permite simular mercados reales reflejando la heterogeneidad y adaptatividad de los diferentes actores, así como las interacciones entre ellos y con el entorno, y capturar los fenómenos emergentes que resultan de estas interacciones. Además, el ABM nos permite incorporar mecanismos habituales en marketing, como el WOM, y simular escenarios *what-if* para evaluar la respuesta del mercado a distintas alternativas de marketing [CR17], consolidándose así como un sistema robusto de apoyo a la toma de decisiones en marketing.

Han sido muchas las aplicaciones del ABM a marketing [NY14]. Desde principios de la

década de 2000, la aplicación del ABM en la investigación de marketing ha adquirido una importancia significativa. El Modelo SimStore (Bizsim) [Cas00] fue una de las primeras herramientas efectivas de ABM para la investigación de marketing. Posteriormente, se desarrollaron marcos más complejos como el modelo CUBES [SDB01], que integró las preferencias del consumidor y las elecciones de marca. Una de las aportaciones más conocidas fue el modelo CONSUMAT, propuesto por Janssen y Jager [Jag00], el cual relaciona las preferencias personales de los consumidores y la utilidad social de los productos para representar la toma de decisiones y, por tanto, la compra.

Las aplicaciones de ABM en el ámbito del marketing son diversas. Destaca la extensa investigación realizada sobre la difusión de innovaciones y, en particular, la difusión de eco-innovaciones, así como el estudio de diferentes estrategias de marketing (de precios, promoción, focalización, etc.). A continuación, exploramos algunas de estas aplicaciones.

La difusión de innovaciones [Rog10] es un área destacada dentro del marketing que estudia cómo se propagan nuevas ideas, productos, tecnologías o prácticas a través de una sociedad a lo largo del tiempo. Encontramos varias revisiones sobre la aplicación de ABM en este área [RS21, ZV19, KGSW12]. Muchos estudios en este campo examinan cómo se propagan las nuevas ideas o productos en la sociedad y analizan el impacto de diversos factores, como la topología de la SN [BCZ10, DJBJ10, DJJ07, GLM10]. Además, se ha prestado especial atención al papel de los individuos influyentes en los procesos de difusión [GHLH09, VEJL11]. En [Wat02], el autor presentó una posible explicación de las cascadas globales, un fenómeno en el que las decisiones de agentes en redes aleatorias pueden desencadenarse en cascada siguiendo las acciones de sus vecinos según una simple regla de umbral. Posteriormente, los autores en [WD07] descubrieron que la mayoría de las cascadas globales no están impulsadas por personas influyentes, sino por individuos fácilmente influenciados. Otros trabajos como [XH16] han demostrado la utilidad del ABM para realizar predicciones precisas sobre la difusión de nuevos productos, una vez que los parámetros del modelo han sido correctamente calibrados.

Dentro de la difusión de innovaciones, ha ganado popularidad el área de difusión de eco-innovaciones, donde se usa ABM para identificar y analizar los factores y las políticas que pueden fomentar la adopción de tecnologías y prácticas sostenibles. Varias revisiones de la literatura destacan el uso del ABM en el estudio de la adopción de la eficiencia energética [RH16, HC19]. El ABM también ha sido muy utilizado en estudios sobre la penetración de mercado de vehículos eléctricos [EGMR11, ML14, MdH09] y combustibles alternativos [ZGG11, SKGV15]. Más allá, esta herramienta ha sido fundamental en la exploración de otras innovaciones sostenibles, como la adopción de tecnologías verdes en la industria marítima [CHL23], la difusión de innovaciones para ahorrar agua [SE09] y la adopción de nuevas prácticas agrícolas sostenibles [BLS19].

Como hemos mencionado previamente, muchos trabajos han usado ABM para evaluar el impacto de diferentes estrategias de precios o promoción antes de implementarlas en el mercado real. Estudios como [HWC13, ZGN⁺18, LLK14] han explorado la optimización de estrategias de precios y tiempos para el lanzamiento de nuevos productos. Por otro lado, en [DBB16, DPW17, DJBJ07] han investigado las promociones de productos hedónicos, co-

mo las películas, destacando la importancia de los tiempos adecuados en las campañas publicitarias para evitar fracasos en el mercado. En [VPMCC23] han usado ABM para optimizar las estrategias de planificación de medios.

Otras estrategias de marketing estudiadas con ABM son las estrategias de focalización, las cuales buscan dirigir promociones a segmentos específicos de la población. La creciente confianza de los consumidores en las recomendaciones de amigos o personas influyentes o *influencers* en las SN, en contraste con los canales tradicionales como la televisión, ha favorecido el desarrollo de estas estrategias dirigidas en las campañas de marketing. El enfoque clave de estas estrategias es el marketing viral, el cual se basa en fomentar en un grupo seleccionado de individuos la adopción de un producto, con el fin de que su opinión positiva e influencia social, generen una reacción en cadena que acelere la adopción del producto en el resto de la población. En este contexto, el ABM se ha usado para abordar el problema de maximización de influencia [KKT03], que consiste en identificar los individuos más influyentes. Varios trabajos han desarrollado algoritmos de optimización para identificar a estos individuos [SRW10, RCC20]. En [SBST13], los autores concluyeron que la decisión de a quién dirigirse es más importante que determinar el número de consumidores a seleccionar, y en [DJB07], los autores demostraron que el momento adecuado para lanzar la estrategia promocional es fundamental.

En la actualidad, el ABM continúa siendo una herramienta relevante y en constante evolución en el campo del marketing, adaptándose a los cambios en los comportamientos del consumidor y a las tendencias emergentes. Como los nuevos patrones de consumo impulsados por las aplicaciones de entrega a domicilio [HHC⁺19], la adopción de las ya mencionadas tecnologías sostenibles [CHL23, NKZ23] y de dispositivos inteligentes [ZDZJ22], así como la difusión de productos a través de redes sociales *online* dinámicas [WGS23].

Debido al interés por el uso del ABM en este campo y su evolución en las últimas dos décadas, surge la necesidad de realizar un exhaustivo análisis bibliométrico de la literatura en el área, proporcionando una perspectiva global de las tendencias y las prácticas predominantes. Esta es una de las contribuciones principales de esta tesis y se detalla en el Capítulo 3.

2.2. Inteligencia artificial explicable

En esta sección se presentan los conceptos fundamentales sobre la XAI. En primer lugar, la Sección 2.2.1 sirve como introducción al área. La Sección 2.2.2 se centra en un tipo concreto de técnicas de XAI: las técnicas agnósticas de explicabilidad post-hoc. Finalmente, en la Sección 2.2.3 se explora cómo la explicabilidad se ha aplicado en el ABM.

2.2.1. Introducción

La IA cada vez está más integrada en nuestras vidas, llegando a una amplia gama de sectores, incluidos algunos especialmente sensibles como los sistemas bancarios o de salud. Es fundamental que estos sistemas sean no solo eficaces, sino también transparentes y comprensibles para los usuarios finales, de manera que puedan confiar en ellos.

Los modelos de IA se clasifican comúnmente en dos tipos: de caja negra y de caja blanca. Los modelos de caja negra son aquellos altamente no transparentes, donde no es evidente qué información en los datos de entrada conduce a sus decisiones [SWM17], como es el caso de las redes neuronales profundas. En contraste, los modelos de caja blanca, como los árboles de decisión, son inherentemente más transparentes y permiten a los usuarios comprender cómo se llega a las decisiones finales. La falta de transparencia en los modelos de caja negra puede ser un gran inconveniente, lo que ha impulsado el desarrollo de métodos para visualizar, explicar e interpretar estos modelos. Surge así el campo de la XAI, cuyo objetivo es hacer los sistemas basados en IA más comprensibles y transparentes para los humanos sin sacrificar rendimiento [AB18, GSC⁺19]. Esto es crucial en aplicaciones sensibles como el sector biosanitario, donde los médicos podrían ser asesorados por sistemas de IA para diagnosticar enfermedades. Para estos profesionales, no es suficiente con obtener un diagnóstico, también deben entender las razones que llevan a la IA a recomendar dicho diagnóstico. Actualmente, la XAI es una de las bases de la Estrategia de IA confiable (*Trustworthy AI*) de la Comisión Europea [DRDSC⁺23].

Aunque las técnicas de XAI se aplican principalmente sobre modelos de caja negra, los modelos de caja blanca también pueden beneficiarse de estas técnicas para aumentar la interpretabilidad de sus soluciones y, en consecuencia, aumentar la confianza en el comportamiento y rendimiento del modelo [RSG16].

Existen numerosas técnicas, enfoques y clasificaciones de la XAI que han sido detalladas en recientes revisiones de la literatura [AB18, BADRD⁺20, Mol22, AAES⁺23, BDEQEH⁺24]. En general, las técnicas de XAI se pueden clasificar según los siguientes criterios:

- **Complejidad:** Los métodos pueden ser inherentemente interpretables o post-hoc, según en qué momento se consigue la interpretabilidad. Los métodos inherentemente o intrínsecamente interpretables integran la interpretabilidad directamente en el diseño del modelo, resultando en estructuras más simples y transparentes. Ejemplos de ello son los modelos de regresión lineal, los árboles de decisión o los sistemas basados en reglas, como los algoritmos de SD empleados en la segunda contribución de esta tesis (Capítulo 4) y detallados en la Sección 2.3.2. Por otro lado, los métodos de

interpretación post-hoc se aplican *a posteriori* sobre un modelo ya entrenado, e incluyen técnicas como la importancia de características. Los métodos post-hoc también pueden aplicarse sobre modelos intrínsecamente interpretables, por ejemplo se puede calcular la importancia de las características para árboles de decisión [Mol22].

- **Metodología:** Las técnicas pueden ser agnósticas o dependientes del modelo. Las técnicas agnósticas al modelo son aplicables a cualquier tipo de modelo sin necesidad de ajustes específicos, lo que las hace flexibles. Suelen aplicarse de manera post-hoc, como es el caso de los Gráficos de Dependencia Parcial (PDP, por sus siglas en inglés) [Fri01]. En contraste, las técnicas dependientes del modelo están diseñadas específicamente para ser usadas con ciertos modelos, aprovechando detalles de su arquitectura para generar explicaciones, lo cual puede limitar su aplicabilidad pero aumentar la precisión de las explicaciones en contextos específicos. Por ejemplo, la interpretación de los pesos de regresión en un modelo lineal es una interpretación específica del modelo.
- **Ámbito:** Las explicaciones pueden ser locales o globales. Locales si las explicaciones se centran en predicciones individuales, proporcionando detalles sobre por qué el modelo tomó una decisión específica en un caso concreto. Un ejemplo es la técnica LIME [RSG16]. Las explicaciones globales buscan ofrecer una visión general de cómo funciona el modelo en todos los casos, proporcionando una comprensión general de las características más importantes. Algunas técnicas globales, como SHAP [LL17], pueden ofrecer también explicaciones locales.

2.2.2. Técnicas agnósticas de explicabilidad post-hoc

En esta sección nos centraremos en las técnicas agnósticas de explicabilidad post-hoc, una categoría prolífica dentro de las técnicas de XAI. Estas técnicas han ganado popularidad debido a su versatilidad y aplicabilidad universal. Se han desarrollado numerosos métodos en esta categoría, incluyendo algunos de los que se aplicarán en esta tesis. Estos métodos que emplean técnicas de estadística, aprendizaje automático y ciencia de datos proporcionan conocimiento sobre el funcionamiento de modelos complejos después de haber sido entrenados [AB18]. A grandes rasgos, podemos clasificar las técnicas agnósticas de explicabilidad post-hoc en los siguientes grupos según [BADRD⁺20]:

- **Explicación por simplificación.** Estas técnicas crean un modelo nuevo y simplificado (modelo subrogado) que imita el comportamiento del modelo original, reduciendo su complejidad mientras mantiene un rendimiento similar para facilitar su interpretación e implementación. En ocasiones estas explicaciones son locales, como es el caso de la conocida técnica LIME (*Locally Interpretable Model-Agnostic Explainer*) [RSG16], que se centra en explicar predicciones individuales. La idea es generar un nuevo conjunto de datos con pequeñas modificaciones alrededor de una instancia. Sobre este nuevo conjunto, se entrena un modelo interpretable, ponderando por la proximidad

de las instancias muestreadas a la instancia de interés. Este proceso ayuda a identificar qué características influyeron en la predicción específica.

- **Explicación de relevancia de características.** Estas técnicas cuantifican la influencia (sensibilidad) de cada variable de entrada en la salida del modelo. Las características más importantes son aquellas con mayor impacto en la salida. Ejemplo de este tipo de técnicas es el valor Shapley [Rot88] de una característica que nos indica cuánto contribuye esta a la predicción del modelo. SHAP (*SHapley Additive exPlanations*) [LL17] es una extensión de este concepto que utiliza agregaciones de los valores de Shapley para calcular una puntuación aditiva de la importancia de cada característica en una predicción específica.
- **Visualización.** Las técnicas de visualización representan un enfoque fundamental para lograr explicaciones agnósticas del modelo. Algunas de las técnicas más populares son los PDP y las curvas de Expectativa Condicional Individual (ICE, por sus siglas en inglés), las cuales se emplean en la tercera contribución de esta tesis en el Capítulo 5. Los PDP [Fri01] muestran el efecto promedio que tiene una o más variables de entrada en la salida de un modelo. Las curvas ICE [GKBP15] son una extensión de los PDP. Muestran cómo la salida del modelo varía para instancias individuales al modificar una variable de entrada mientras las demás permanecen constantes. A diferencia de los PDP, que muestran el efecto medio de una variable de entrada sin enfocarse en instancias individuales y pueden ocultar relaciones heterogéneas creadas por interacciones entre variables, las curvas ICE son particularmente útiles para estudiar estas interacciones complejas [Mol22].

Diferentes técnicas de estas categorías pueden combinarse o solaparse en sus aplicaciones prácticas. Un ejemplo de esto es la integración de métodos de visualización con técnicas de relevancia de características para ilustrar la importancia de manera visual y facilitar así la interpretación del modelo.

2.2.3. Explicabilidad en modelado basado en agentes

Como se ha mencionado anteriormente, el ABM es una herramienta muy valiosa para simular escenarios hipotéticos. Permite, de esta manera, que investigadores, diseñadores y usuarios puedan evaluar el impacto de distintas estrategias antes de aplicarlas en el mundo real, lo cual facilita una toma de decisiones más informada. Estos modelos funcionan como laboratorios de pruebas y para que sean útiles es fundamental que los datos estén correctamente calibrados y validados y que tanto los resultados como el modelo sean comprensibles y confiables. Aunque los modelos basados en agentes se consideran interpretables *per se*, la complejidad de los sistemas que simulan, hacen que en muchas ocasiones sea necesaria una capa adicional de explicabilidad [Mac16]. Además, las salidas de estos modelos son a menudo de alta dimensionalidad y requieren técnicas de análisis sofisticadas para asegurar la confianza en los resultados y su comunicación efectiva a diversas audiencias, en especial

a públicos no técnicos [LFLZ⁺15]. Dos de los desafíos actuales en el campo del ABM, como señala [DLG⁺23], son mejorar la comprensión tanto del modelo como de sus salidas.

Numerosos estudios han aplicado técnicas tradicionales como el análisis exploratorio de datos, el análisis de sensibilidad y otros métodos estadísticos para analizar las salidas de los modelos basados en agentes. Aunque estas herramientas son útiles, a menudo no son suficientes [LFLZ⁺15]. Por ello, muchos investigadores han incorporado técnicas de aprendizaje automático para profundizar en la comprensión de las salidas de estos modelos [PLGHQCCR23, ZVC21]. En este sentido, la XAI juega un papel fundamental para mejorar la transparencia no solo de los modelos de caja negra sino también de cualquier sistema de IA o sistema complejo que integre este tipo de tecnología [BDGP22].

En la literatura encontramos que las salidas de los modelos basados en agentes han sido analizadas utilizando tanto algoritmos de aprendizaje automático no explicables como enfoques de XAI, incluyendo métodos inherentemente interpretables y técnicas de explicabilidad post-hoc. En cuanto a los algoritmos de aprendizaje automático no explicables, encontramos, por ejemplo, que los algoritmos genéticos se aplican con frecuencia para la optimización de parámetros [LHJ⁺23, RCC20] y calibración [HEB07, RBCC21]. Para mejorar la eficiencia de la exploración del espacio de parámetros, se han creado modelos subrogados utilizando redes neuronales [vdH19, YYF⁺18] y máquinas de soporte vectorial [tBvVLM21]. En [EY19] y en [MHL⁺19] se usa Random Forest [Bre01] para comprender la dinámica de los sistemas modelados y para predecir características emergentes del modelo, respectivamente. Además, se ha empleado aprendizaje por refuerzo para optimizar el comportamiento de los agentes a nivel micro. En concreto, uno de los algoritmos de aprendizaje por refuerzo más adoptados es el *Q-learning* [JHA⁺17] y su extensión, *Deep Q-Network* [VPMCC23].

Los algoritmos inherentemente interpretables, como las redes bayesianas, los árboles de decisión y las técnicas de regresión, también se han utilizado para analizar las salidas de los modelos basados en agentes. En [MBTT22] se usan redes bayesianas para la validación del modelo. En [JSCL19] se propone una metodología llamada AbACaD (*Agent-based model Analysis using Causal Discovery*), que aplica algoritmos de descubrimiento causal combinados con regresión lineal y agrupamiento *k-means* para analizar las propiedades emergentes en el ABM. En [PASA18] se presenta un esquema para analizar la relación entre la entrada y la salida de simulaciones basadas en agentes combinando técnicas exploratorias, árboles de decisión y técnicas de agrupamiento *k-means*. En [RC06] se proponen diferentes técnicas como la regresión, el análisis de clústeres y las redes bayesianas para encontrar los parámetros más influyentes. En [BMWG19] se usan árboles de decisión como clasificadores para detectar patrones y entender la dinámica entre los parámetros de entrada y salida. Además, los árboles de decisión también se han aplicado para crear modelos subrogados [RWT⁺19].

En cuanto al uso de técnicas de explicabilidad post-hoc, en [SABA21] se usa SHAP para interpretar las predicciones de un algoritmo Random Forest a partir de los datos de simulaciones de ABM en escenarios militares. En [GC23] se usan valores Shapley para identificar los parámetros y características más influyentes. En [ADR23] se usan valores de Shapley y Myerson para evaluar la contribución tanto de las políticas como de los atributos de los agentes. En [DBZS23] se propone una metodología que combina el uso de modelos subrogados y

otras técnicas como LIME y SHAP. En [BPR⁺22] proponen una modificación de las curvas ICE teniendo en cuenta la naturaleza estocástica de los modelos basados en agentes. Este enfoque modificado incorpora un test estadístico para validar si son significativos los hallazgos obtenidos. Además, en [FGL⁺22], se presenta BEAUT, un modelo de *deep learning* diseñado para mejorar tanto la precisión como la explicabilidad en el ABM, modificando el algoritmo Q-learning para integrar matrices de transición probabilística explicables.

2.3. Descubrimiento de reglas descriptivas supervisadas

En esta sección se presentan los conceptos fundamentales sobre el SDRD. En primer lugar, se presenta el SDRD y se describen las principales tareas asociadas a este en la Sección 2.3.1. La Sección 2.3.2 se centra en la tarea de SD incluyendo sus medidas de calidad y algoritmos habituales, así como algunos ejemplos de aplicación en el mundo real.

2.3.1. Introducción

La minería de datos [FPSS96] es el proceso de aplicación de algoritmos específicos para extraer patrones a partir de un conjunto de datos. Las tareas de minería de datos se pueden agrupar en dos vertientes bien diferenciadas: predictivas y descriptivas. El objetivo de las tareas predictivas es predecir el comportamiento de nuevas instancias y se suele emplear aprendizaje supervisado. Por tanto, requieren datos etiquetados. El objetivo de las tareas descriptivas es describir las relaciones existentes en los datos y se suele usar aprendizaje no supervisado. Por tanto, estas últimas no necesitan datos etiquetados.

El SDRD [NLW09] combina ambas tareas, predictivas y descriptivas, con el objetivo de describir los datos respecto a una propiedad de interés, es decir, describir datos etiquetados. No busca clasificar los datos, sino entenderlos. Por ejemplo, si queremos conocer las circunstancias por las que un cliente puede ser insolvente, no se trata de predecir la insolvencia, sino de comprender los factores que llevarían a la insolvencia.

Dentro del SDRD encontramos tres tareas principales:

- **Minería de conjuntos de contraste** [BP01]: Busca diferencias significativas entre grupos en forma de patrones como conjunto de atributos y valores. Son grupos excluyentes respecto a una propiedad de interés. Uno de los algoritmos más populares es STUCCO [BP01] que obtiene conjuntos de contraste con alta diferencia de soporte entre grupos.
- **Minería de patrones emergentes** [DL99]: Busca conjuntos de elementos que aumentan significativamente su soporte de un conjunto de datos a otro. Uno de los algoritmos más representativos es DeEPs [LDRW04], un método de extracción basado en límites.
- **Descubrimiento de subgrupos** [Wro97, Klö96]: Busca relaciones inusuales entre diferentes elementos de un conjunto respecto a una propiedad de interés. Se detalla en la sección 2.3.2.

2.3.2. Descubrimiento de subgrupos

El SD, introducido por [Klö96, Wro97], busca relaciones inusuales entre diferentes variables que expliquen el comportamiento estadísticamente interesante de subgrupos de individuos respecto a una propiedad de interés. Es decir, el objetivo es identificar subconjuntos de la población cuya distribución estadística con respecto a una variable de interés o variable

objetivo difiera significativamente respecto a la distribución del conjunto total de la población. Los patrones extraídos, denominados subgrupos [Sie95], se representan con reglas de la forma: $R : Cond \implies Target_{value}$, donde $Cond$ es el antecedente de la regla compuesto por pares atributo-valor y $Target_{value}$ es el consecuente que hace referencia a la variable de interés y a un valor particular de la misma. Es deseable que las reglas cumplan las siguientes propiedades [CGdJH14]:

- **Interpretabilidad.** El número de reglas y su complejidad deben ser fácilmente comprensibles para los expertos. Es deseable un bajo número de reglas con un bajo número de variables.
- **Interés.** Las reglas deben ser estadísticamente interesantes, revelando comportamientos inusuales dentro de los datos.
- **Balance entre generalidad y precisión.** Las reglas deben abarcar la mayor cantidad de ejemplos para el valor objetivo con la mayor precisión posible.

El SD forma parte de la familia de modelos basados en reglas, ampliamente aceptados como los más interpretables para los humanos [FKP20]. Las técnicas de SD se han empleado con éxito para el desarrollo de modelos explicables y confiables [LRP⁺20]. Su capacidad para identificar patrones locales y presentarlos de una forma fácilmente comprensible, como un conjunto de reglas *si-entonces* que describen las características del subgrupo, ayuda a entender sistemas complejos y lo convierte en una valiosa herramienta para aplicaciones de XAI. Por ello, hemos elegido algoritmos de SD en nuestra segunda contribución, detallada en el Capítulo 4.

2.3.2.1. Medidas de calidad en descubrimiento de subgrupos

Dado un conjunto de datos, notamos N al número total ejemplos. La frecuencia de x en el conjunto de datos se representa como $n(x)$. Así, $n(Cond)$ indica el número de ejemplos que cumplen el antecedente de la regla, es decir, el número de elementos en el subgrupo. $n(Target_{value})$ representa el número de ejemplos en los que la propiedad de interés toma el valor $value$, mientras que $n(Target_{value} \cdot Cond)$ indica el número de ejemplos correctamente cubiertos, es decir, que cumplen tanto el antecedente como el consecuente.

Teniendo en cuenta los tres principales objetivos en SD, las medidas más adecuadas para evaluar la calidad de las reglas obtenidas mediante SD son las siguientes [HCGdJ11]:

- **Número de reglas (n_r).** Mide la cardinalidad del conjunto total de reglas. Relacionada con la interpretabilidad.
- **Número de variables (n_v).** Mide el número de variables en el antecedente de una regla. Para un conjunto de reglas se calcula como la media del número de variables de cada regla. Relacionada con la interpretabilidad de las reglas.

- **Confianza** ($Conf$). Mide la precisión de un subgrupo, es decir, la proporción de ejemplos en el subgrupo que verifican tanto el antecedente como el consecuente de la regla. Se calcula como [AMS⁺96]:

$$Conf(R) = \frac{n(Target_{value} \cdot Cond)}{n(Cond)} \quad (1)$$

- **Inusualidad** ($WRAcc$). La inusualidad, también conocida como *weighted relative accuracy* [LFZ99], mide el balance existente entre el interés, generalidad y precisión de una regla. Se puede calcular como:

$$WRAcc(R) = \frac{n(Cond)}{N} \left(\frac{n(Target_{value} \cdot Cond)}{n(Cond)} - \frac{n(Target_{value})}{N} \right) \quad (2)$$

También se puede describir como el equilibrio entre la cobertura de la regla (Cob) y su ganancia de precisión o *accuracy* ($AccG$). Si su ganancia de *accuracy* es positiva, indica que ese valor de la clase es más común en el subgrupo que en el total, aunque la confianza sea pequeña.

$$Cob(R) = \frac{n(Cond)}{N}$$

$$AccG(R) = Conf(R) - \frac{n(Target_{value})}{N}$$

El dominio de esta medida es específico para cada problema ya que depende directamente de la variable de interés. Concretamente, depende del porcentaje de ejemplos del valor mayoritario de la variable de interés ($Target_{mayor_v}$) [CRRdJ⁺15]. Por tanto, es necesario normalizarla en el intervalo $[0, 1]$ como se muestra a continuación:

$$NWRAcc(R) = \frac{WRAcc(R) - LB_{WRAcc}}{UB_{WRAcc} - LB_{WRAcc}} \quad (3)$$

donde LB_{WRAcc} y UB_{WRAcc} son los límites inferior y superior de $WRAcc$ respectivamente

$$LB_{WRAcc}(R) = \left(1 - \frac{n(Target_{mayor_v})}{N} \right) \left(0 - \frac{n(Target_{mayor_v})}{N} \right)$$

$$UB_{WRAcc}(R) = \frac{n(Target_{mayor_v})}{N} \left(1 - \frac{n(Target_{mayor_v})}{N} \right)$$

Consideramos que el nivel de inusualidad de una regla es bueno si el valor normalizado es mayor que 0.5. Además, es deseable que este valor sea mayor que 0.55, lo cual, según [CdJH18], quiere decir que obtenemos conjuntos de contraste. Aunque no hay consenso sobre el uso de una medida concreta en SD, esta es una de las más usadas en la literatura.

- **Sensibilidad** (TPR). La sensibilidad o ratio de positivos reales mide la generalidad mediante la proporción de ejemplos cubiertos correctamente para ese valor de la variable de interés [Klö96].

$$TPR(R) = \frac{n(Target_{value} \cdot Cond)}{n(Target_{value})} \quad (4)$$

- **Ratio de falsos positivos (FPR).** Mide la proporción de ejemplos cubiertos incorrectamente respecto al total de ejemplos que no toman ese valor de la variable objetivo [GL02]

$$FPR(R) = \frac{n(\overline{Target_{value}} \cdot Cond)}{n(\overline{Target_{value}})} \quad (5)$$

donde $n(\overline{Target_{value}} \cdot Cond)$ es el número de ejemplos que cumplen el antecedente de la regla pero no toman ese valor de la variable de interés y $n(\overline{Target_{value}})$ es el total de ejemplos que no toman ese valor de la variable de interés.

2.3.2.2. Algoritmos de descubrimiento de subgrupos

Existe una gran variedad de algoritmos de SD pero todos ellos pueden agruparse en tres categorías según [HCGdJ11]:

- **Algoritmos basados en clasificadores.** Son adaptaciones de clasificadores clásicos basados en reglas. Mientras que estos algoritmos buscan generar conjuntos de reglas para todas las clases de la variable objetivo, el descubrimiento de subgrupos tiene como objetivo descubrir reglas individuales de interés. Por lo tanto, es necesario adaptarlos para que aborden adecuadamente la tarea de descubrimiento de subgrupos. Uno de los algoritmos más populares es CN2-SD [LFKT02], basado en el algoritmo CN2.
- **Algoritmos basados en reglas de asociación.** Los algoritmos de reglas de asociación, al igual que los de SD, buscan reglas que relacionen variables del conjunto de datos entre sí. La diferencia es que mientras que en el primero varias variables pueden aparecer tanto en el antecedente como en el consecuente de la regla, en el descubrimiento de subgrupos se fija el consecuente de la regla. Es factible adaptar los algoritmos de reglas de asociación a la tarea de descubrimiento de subgrupos. Uno de los algoritmos más usados es SDMap [AP06], un algoritmo de búsqueda exhaustiva que emplea el conocido método FP-growth [HPY00]. Este algoritmo es empleado en la experimentación asociada a nuestra propuesta presentada en el Capítulo 4. Otro ejemplo es el algoritmo Apriori-SD [KL06], basado en el clásico algoritmo para reglas de asociación Apriori [AIS93]. Apriori-SD incorpora un mecanismo de posprocesamiento que filtra las reglas cuyo consecuente no es la propiedad de interés.
- **Algoritmos basados en computación evolutiva.** El SD es una tarea que puede abordarse y resolverse como problema de optimización y búsqueda. Por tanto, los enfoques evolutivos resultan muy útiles para esta tarea. La codificación de soluciones se adapta al SD, y la función objetivo de estos algoritmos se diseñan considerando métricas propias de SD. NMEEFSD [CGdJH10] y FuGePSD [CRRdJ⁺15] son ejemplos de algoritmos evolutivos para SD. Concretamente, ambos son algoritmos evolutivos basados en sistemas difusos, que adaptan los operadores propios de los algoritmos evolutivos

(mutación, cruce, etc.) al problema de SD. El primero tiene un enfoque multiobjetivo mientras que el segundo es monoobjetivo. Ambos algoritmos los empleamos en la experimentación asociada a nuestra propuesta en el Capítulo 4.

2.3.2.3. Aplicaciones en el mundo real

Podemos encontrar aplicaciones de SD en un gran número de ámbitos del mundo real. La calidad y la interpretabilidad de los resultados obtenidos en diferentes estudios reflejan la eficacia de esta técnica y su utilidad para los expertos en sus respectivos campos.

En el ámbito del marketing, por ejemplo, se ha empleado el SD para seleccionar subgrupos de potenciales consumidores a los que dirigir campañas publicitarias, como en [FG01, LCGF04]. Otro ejemplo es el presentado en [DJGHM07] donde se aplica SD para extraer información relevante para mejorar las políticas de planificación de ferias comerciales.

Existen numerosas publicaciones relacionadas con problemas de medicina y bioinformática. Por ejemplo, en [CCSdJ13] se desarrolla el análisis de frecuencias del virus de la gripe A para identificar relaciones desconocidas. En [KNLGK09], los autores buscan características distintivas de dos grupos de pacientes con ictus cerebral. En [CGdJ⁺11], se aborda la descripción de los pacientes psiquiátricos de un hospital con el fin de organizar los servicios para los diferentes períodos del día. Por último, es interesante destacar una adaptación a la regresión para la tarea de SD en [PPY19] donde se aborda una aplicación a datos de cáncer de mama.

Además, el SD ha encontrado aplicación en otros campos como el e-learning [CGdJV11, HLL⁺19, LFP⁺22] con análisis de datos obtenidos de cursos y MOOCs impartidos en plataformas de e-learning como Moodle. En estas contribuciones los algoritmos de SD buscan relaciones inusuales entre el comportamiento de los alumnos y las notas obtenidas. También podemos encontrar aplicaciones en la industria [CGGD⁺13, JFW⁺14] y en otras áreas interdisciplinarias, como el deporte [dLvZvBK22] y el procesamiento del lenguaje natural [LMCLH21].

Capítulo 3

Propuesta I: Análisis bibliométrico sobre el uso del ABM en marketing

En este capítulo se presenta la primera contribución de la tesis: revisión de la literatura y análisis bibliométrico sobre el uso del ABM en el ámbito del marketing durante las dos últimas décadas. Tras una introducción al capítulo, se describe la metodología utilizada durante el estudio, seguida de una presentación detallada del análisis bibliométrico y sus resultados. Posteriormente, se examinan los artículos recopilados en cuanto a sus principales objetivos y características. Finalmente, el capítulo termina con las conclusiones obtenidas.

3.1. Introducción

En este capítulo, presentamos la primera contribución de esta tesis, que consiste en una revisión de la literatura y análisis bibliométrico sobre la aplicación del ABM en el ámbito del marketing durante las dos últimas décadas. Esta contribución constituye un buen punto de partida para esta tesis, ya que nos permite explorar en profundidad los modelos basados en agentes, su aplicación práctica, y los problemas resueltos, además de identificar las lagunas y tendencias actuales en el área del marketing. Esto nos proporciona una perspectiva global que nos facilitará la resolución de los problemas planteados en los subobjetivos siguientes.

Como detallamos en la Sección 2.1.4, el ABM es una herramienta que ha ganado una notable popularidad en el campo del marketing desde los años 2000. A lo largo de estas dos décadas, el campo ha evolucionado significativamente y existe un volumen considerable de publicaciones científicas dedicadas a diversos aspectos del ABM. Entre estos trabajos, encontramos varias revisiones de la literatura sobre la aplicación del ABM en marketing, pero la mayoría se centran en dominios específicos como la difusión de innovaciones [Gar05, KGSW12, ZV19, RS21]. Aunque también existen algunas revisiones generales sobre ABM en marketing [ZWD09, NY14], la más reciente es de 2014.

Hasta donde sabemos, no existe un análisis bibliométrico reciente sobre el uso del ABM en marketing. Si bien se han realizado análisis bibliométricos sobre ABM en otras disciplinas como economía [ZU22], construcción [KP21] y agricultura sostenible [SRE22], falta un análisis similar para el ABM en marketing. Este estudio pretende cubrir ese vacío.

Nuestra contribución proporciona: (1) un análisis de rendimiento detallado en términos de evolución temporal, citas, autores, países, instituciones y revistas; (2) un análisis de redes que examina las relaciones entre autores, países y palabras clave; (3) una tabla de referencia detallada que caracteriza los modelos por sus principales objetivos y el cumplimiento de determinadas características clave. Estas características incluyen el uso de modelos de difusión, si los agentes tienen la posibilidad de elegir entre múltiples opciones, si el entorno es una SN, si es un entorno físico, y la validación mediante datos reales.

Esta caracterización exhaustiva proporciona una visión clara sobre la naturaleza de los modelos basados en agentes en el ámbito del marketing. Es de gran utilidad para investigadores y profesionales interesados en este campo, ya que sirve de orientación sobre las características fundamentales de estos modelos y destaca las prácticas predominantes. Además, establece un marco comparativo para futuros desarrollos en el área.

El capítulo está estructurado como sigue. En la Sección 3.2 comenzamos describiendo la metodología usada durante el estudio. A continuación, en la Sección 3.3 presentamos el análisis bibliométrico y sus resultados. En la Sección 3.4 analizamos los artículos recopilados respecto a sus principales objetivos y ciertas características. Finalmente, presentamos las conclusiones obtenidas en la Sección 3.5.

3.2. Metodología

En esta sección describimos la estrategia de búsqueda de literatura, la recolección de datos y las técnicas y herramientas de análisis empleadas en este análisis bibliométrico. Seguimos los pasos y las pautas para realizar análisis bibliométricos propuestos en [DKM⁺21].

El objetivo de este estudio bibliométrico es evaluar las contribuciones de los componentes de la investigación (por ejemplo, autores, países, revistas...) e investigar las relaciones entre ellos. El ámbito de este estudio abarca artículos centrados en el ABM en el área de marketing desde el año 2000 hasta marzo de 2023.

Elegimos las técnicas para el análisis bibliométrico combinando el análisis de rendimiento y los mapas bibliométricos. Concretamente, en el análisis de rendimiento, consideramos el número de publicaciones a lo largo del tiempo y sus citas, así como los autores, instituciones, países y revistas más prolíficos usando las publicaciones como medida. En cuanto a los mapas bibliométricos, empleamos el análisis de co-autoría, co-citación y co-palabras para explorar la relación entre autores, países y palabras clave. Aunque hay algunas herramientas alternativas para los mapas bibliométricos (por ejemplo, SciMAT [CLHHVH12]), el software elegido fue VOSviewer [VEW10], ya que permite crear mapas bidimensionales para analizar las relaciones entre publicaciones, investigadores o países de una manera fácil de interpretar.

Una vez elegidas las técnicas y herramientas, el siguiente paso es la recopilación de datos. El proceso de búsqueda y selección de literatura para nuestro análisis consistió en las siguientes fases:

1. Búsqueda en principales bases de datos científicas: El proceso comenzó con la selección de artículos indexados en Google Scholar, Web Of Science y Scopus publicados después del año 2000 y relacionados con ABM en marketing. Esta búsqueda inicial se realizó usando los siguientes términos en la consulta: (“*agent-based model**” OR “*multi-agent*” OR “*agent simulation*”) AND (“*marketing*” OR “*market*” OR “*innovation diffusion*” OR “*targeting*” OR “*consumer behavior*”). El símbolo * indica que cualquier conjunto de caracteres, incluyendo la ausencia de caracteres, puede aparecer en esta posición. Fueron considerados aquellos documentos que contenían cualquiera de los términos de búsqueda ya sea en el título, resumen o palabras clave. Solo se incluyeron artículos en inglés en la búsqueda, y los tipos de documentos considerados fueron artículos de revistas, artículos de congresos y artículos de revisión. La fecha de exportación de los artículos fue el 15 de marzo de 2023. Se recopilaron un total de 7057 documentos de la base de datos Web Of Science.
2. Descarte de artículos poco relacionados con el ámbito de estudio: Examinamos el contenido de cada artículo de esta lista, descartando aquellos cuya área de aplicación no era marketing o no empleaban ABM. Este proceso de verificar si los artículos considerados eran relevantes para el tema de investigación fue una tarea laboriosa. Este paso es necesario debido a que los dos temas principales de este estudio pueden identificarse con diferentes términos. En el caso del ABM, podemos encontrarlo en la literatura como “*multi-agent systems*”, “*agent-based modeling*”, etc. Sin embargo, dependiendo del contexto, algunos de estos términos, como “*multi-agent systems*”, pueden no referirse al ABM. Además, los conceptos relacionados con el marketing son amplios y genéricos. Por ejemplo, el término “*targeting*” produce numerosas referencias que son irrelevantes en el área del marketing. De manera similar, el término “*market*” engloba

una amplia gama de temas, por ejemplo, artículos sobre el mercado laboral, que no están relacionados con marketing.

3. Exploración del árbol de citas: Para cada artículo de la lista buscamos dentro de sus referencias y artículos que lo citan publicaciones candidatas que se ajusten al alcance de nuestro estudio pero que no fueron capturadas por la consulta inicial.

La selección final de artículos relevantes de ABM en marketing contiene un total de 113 publicaciones. Realizamos un análisis bibliométrico de esta colección de artículos y presentamos los resultados en la Sección 3.3. Además, analizamos sus principales características en la Sección 3.4.

3.3. Análisis bibliométrico

En esta sección analizamos el conjunto de artículos seleccionados en función del número de publicaciones y citas a lo largo del tiempo (Sección 3.3.1 y 3.3.2, respectivamente) y los autores, países, instituciones y revistas más frecuentes (Secciones 3.3.3, 3.3.4 y 3.3.5, respectivamente). Por último, en la Sección 3.3.6 se lleva a cabo un análisis de co-palabras.

3.3.1. Número de publicaciones a lo largo del tiempo

La Figura 1 muestra el número de artículos publicados cada año. Se puede observar un bajo número de publicaciones hasta el año 2007, cuando comenzaron a aparecer un número significativo de artículos. La tendencia general es un aumento en el número de publicaciones a lo largo del tiempo, alcanzando un pico en 2022 cuando se publicaron 11 artículos. Esta tendencia confirma el creciente interés en el área. Cabe destacar que el proceso de recopilación para este estudio se realizó hasta marzo de 2023. Por lo tanto, el número relativamente bajo de artículos encontrados para el año 2023 se debe a que apenas representan el primer trimestre de 2023.

3.3.2. Publicaciones con mayor número de citas

Para analizar el impacto de los artículos seleccionados, consideramos sus citas como medida. Utilizamos el concepto H-Clásicos o *H-Classics*, que se basa en la noción del índice h , para identificar los trabajos más citados en el área de estudio evitando posibles sesgos. Este concepto se formuló de la siguiente manera [MHLGHV14]: “Los *H-Classics* de un área de investigación A podrían definirse como el núcleo H de A que está compuesto por los h artículos altamente citados con más de h citas recibidas.” El índice h de un área de investigación representa la cardinalidad del núcleo H de ese área.

El índice h en nuestra área de investigación es 41, por lo que mostramos los 41 artículos más citados en la Tabla 1 incluyendo su número total de citas y su impacto normalizado de citas [WvEvL⁺11], es decir, el número total de citas de un artículo dado dividido por el número medio de citas de todos los artículos publicados en la misma categoría, mismo

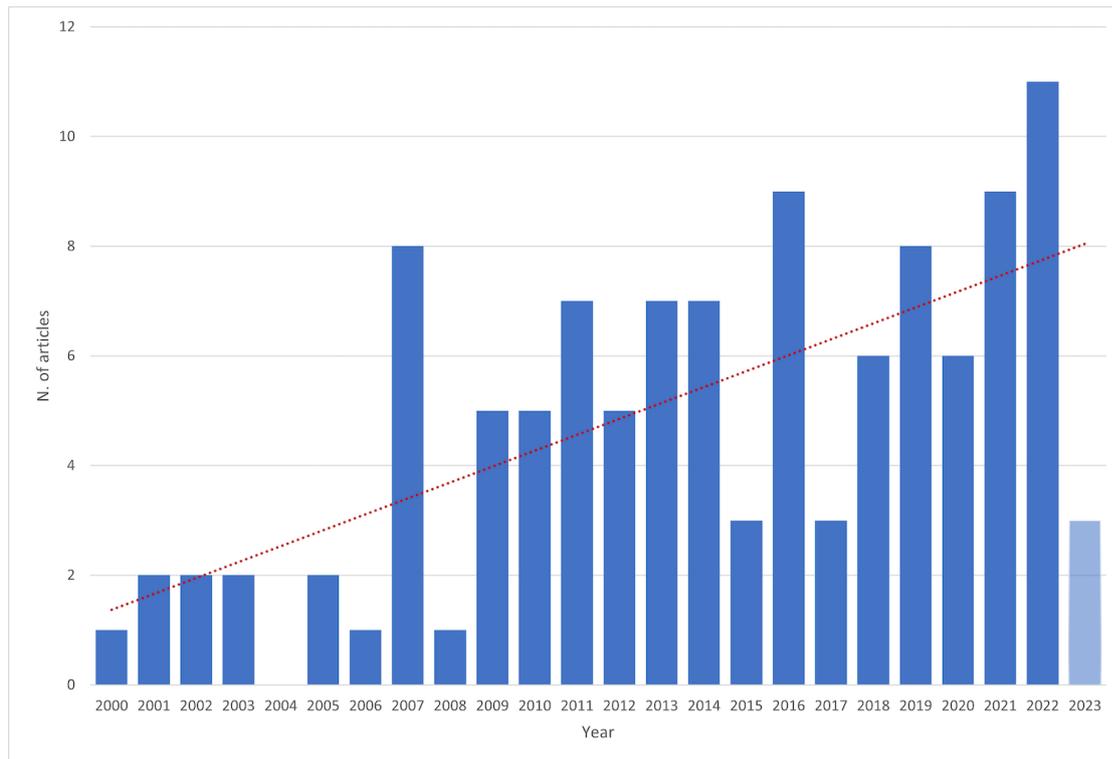


Figura 1: Número de publicaciones por año (2000-2023). Cabe destacar que la recolección de datos se completó antes de finalizar el año 2023.

año y mismo tipo de documento. Adoptamos las categorías establecidas en la base de datos Web Of Science. El uso de este indicador nos permite evaluar la significancia de las citas de un artículo. Si la puntuación de un artículo es mayor que uno, significa que el artículo ha recibido más citas que la media y, por tanto, se considera una contribución significativa.

Si nos centramos en el número total de citas, [Wat02] destaca con casi 1500 citas, seguido por [WD07] con casi 1000 y luego una larga cola de publicaciones con menos de 400. En términos de impacto normalizado de citas, la gran mayoría de los artículos tienen un impacto mayor que uno. Según este indicador, la contribución más significativa es [GHLH09]. Le sigue la contribución de [Wat02], que recibió el mayor número de citas. Notablemente, [ZZ07] destaca por su alto impacto en su categoría y año, a pesar de no estar entre los artículos más citados.

Artículo	Referencia	Citas totales	Impacto normalizado de citas
Watts DJ, 2002	[Wat02]	1499	11.81
Watts DJ, 2007	[WD07]	993	5.59
Goldenberg J, 2009	[GHLH09]	372	11.88
Kiesling E, 2012	[KGSW12]	265	2.41
Rand W, 2011	[RR11]	258	9.91
Eppstein MJ, 2011	[EGMR11]	229	7.31
Hui SK, 2013	[HIHS13]	194	8.81
Schwarz N, 2009	[SE09]	183	7.75
Garcia R, 2005	[Gar05]	169	4.03
Janssen MA, 2002	[JJ02]	164	3.11
Libai B, 2013	[LMP13]	158	7.18
Shafiei E, 2012	[STÁ ⁺ 12]	144	6.69
Delre SA, 2010	[DJB10]	143	4.52
Goldenberg J, 2010	[GLM10]	142	4.38
Zhang T, 2011	[ZGG11]	138	4.96
Van Eck PS, 2011	[VEJL11]	137	4.89
Zhang T, 2007	[ZZ07]	123	10.93
Goldenberg J, 2007	[GLMM07]	119	3.28
Delre SA, 2007	[DJB07]	116	3.11
Rai V, 2016	[RH16]	111	4.83
Bohlmann JD, 2010	[BCZ10]	95	3.00
Janssen MA, 2001	[JJ01]	90	1.85
Karsai M, 2014	[KIKK14]	79	1.90
Hesselink LXW, 2019	[HC19]	77	3.85
Mueller MG, 2009	[MdH09]	74	2.20
He Z, 2019	[HHC ⁺ 19]	71	4.50
Stummer C, 2015	[SKGV15]	70	3.08
McCoy D, 2014	[ML14]	68	2.47
North, MJ, 2010	[NMA ⁺ 10]	66	2.00
Amini, M, 2012	[AWRN12]	64	2.26
Haenlein, M, 2013	[HL13]	63	2.86
Roozmand, O, 2011	[RGAH ⁺ 11]	61	1.66
Janssen, MA, 2003	[JJ03]	61	2.97
Ma, TJ, 2005	[MN05a]	53	1.24
Chica, M, 2017	[CR17]	49	3.23
Schenk, TA, 2007	[SLR07]	47	1.26
Zhang, HF, 2019	[ZV19]	46	0.92
Byrka, K, 2016	[BJSWW16]	46	0.50
Stavrakas, V, 2019	[SPF19]	44	2.21
Negahban, A, 2014	[NY14]	43	0.49
Schramm, ME, 2010	[STSH10]	41	1.47

Tabla 1: Lista de artículos *H-Classics* con total de citas e impacto normalizado de citas.

3.3.3. Autores más frecuentes

En esta sección examinamos los autores más relevantes de nuestro conjunto, considerando aquellos que tienen al menos tres publicaciones. La Tabla 2 muestra a los autores más frecuentes de las publicaciones por el número de sus artículos incluidos en nuestra selección. W. Jager es el investigador más productivo en el área con ocho publicaciones, seguido por M. Chica y M. A. Janssen con seis.

Podemos correlacionar estos autores con la lista de artículos *H-Classics* (Tabla 1). 16 de los 18 autores más frecuentes contribuyeron al menos en uno de los artículos *H-Classics* y, en particular, 10 de estos autores publicaron al menos un artículo como primer autor, listados en orden alfabético: M. Chica, S.A. Delre, R. Garcia, J. Goldenberg, M.A. Janssen, E. Kiesling, B. Libai, M.G. Negahban, W. Rand y C. Stummer.

Autor	Total publicaciones
Jager W	8
Chica M	6
Janssen MA	6
Stummer C	6
Cordon O	5
Delre SA	4
Libai B	4
Bijmolt THA	3
Garcia R	3
Goldenberg J	3
Gunther M	3
Kiesling E	3
Kim CO	3
Muller E	3
Negahban A	3
Nejad MG	3
Rand W	3
Sznajd-weron K	3

Tabla 2: Autores más frecuentes ordenados por su número total de publicaciones (al menos tres).

La Figura 2 muestra la red de co-autoría de todos los autores contribuyentes. En esta red, cada nodo representa un autor y el tamaño del nodo es proporcional al número de artículos

publicados. La distancia entre los clústeres representa la relación de los investigadores en términos de vínculos de co-autoría. Cuanto más cercana es la ubicación de los investigadores en la figura, más fuerte es su relación [VEW10]. Están incluidos todos los autores que tienen al menos un artículo publicado en el conjunto recopilado. Además, el umbral mínimo para establecer un vínculo de co-autoría es una publicación compartida. Los clústeres en gris abarcan menos de cinco autores y los clústeres en otros colores representan cinco o más autores. Los clústeres grises representan el 73 % de los autores. Cada autor de un clúster gris solo contribuyó con una o dos publicaciones.

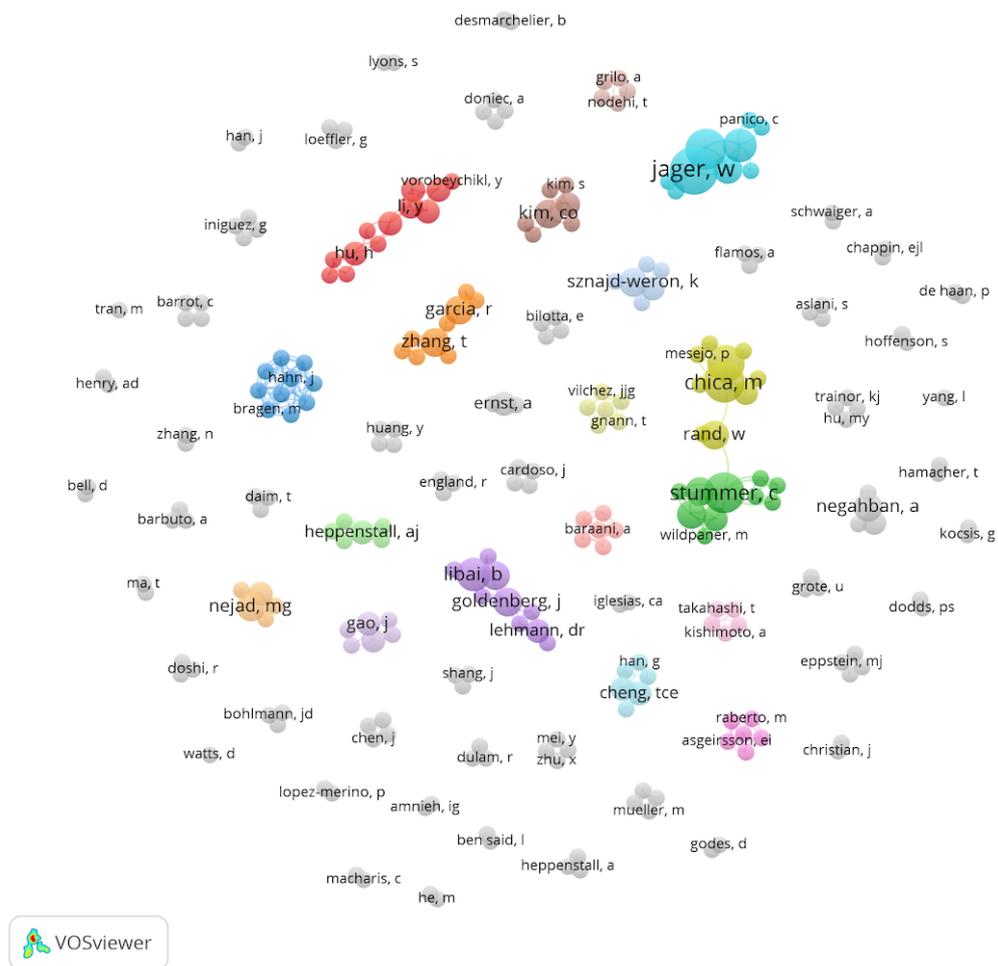


Figura 2: Red de co-autoría de todos los autores contribuyentes, generada con el software VOSviewer. Cada nodo representa a un autor y están agrupados en clústeres basados en la co-autoría.

Aunque los clústeres pueden incluir colaboraciones entre diferentes países o instituciones, la tendencia general es de aislamiento con los colaboradores habituales (es decir, apenas hay colaboración entre grupos). Se debe hacer una mención especial al nodo de W. Rand, ya que es el único que colabora con los autores principales de dos grupos diferentes (C. Stummer y M. Chica), sirviendo como nexo entre ellos.

3.3.4. Países e instituciones más frecuentes

En esta sección analizamos los países más importantes en cuanto a número de publicaciones. En muchos casos, el artículo es el resultado de una colaboración internacional que involucra a diferentes países. En estos casos, consideramos una publicación por cada uno de los países participantes. La Tabla 3 muestra los países más relevantes según su actividad de publicación. Se puede observar que Estados Unidos es el país más productivo, contribuyendo en un tercio de las publicaciones, seguido por Alemania y China. En cuanto a las instituciones, la más productiva es la Universidad de Groninga (Países Bajos) con nueve publicaciones, seguida por la Universidad de Bielefeld (Alemania), la Universidad de Granada (España) y la Universidad de Newcastle (Australia) con cinco publicaciones cada una.

País	Total publicaciones
Estados Unidos	38
Alemania	16
China	14
Países Bajos	13
Reino Unido	11
Italia	8
España	7
Australia	5
Austria	5
Israel	5
Corea del Sur	5

Tabla 3: Países más frecuentes ordenados por su número total de publicaciones (al menos cinco).

La Figura 3 muestra la red de citas basada en países. Cada nodo representa un país y el color del nodo indica el año medio de publicación, que va desde 2012 en morado hasta 2020 en amarillo. El tamaño del nodo es proporcional al número de artículos publicados. La relación entre los nodos se determina en base al número de veces que se citan entre sí. Los

umbrales mínimos para considerar un país son una publicación y una cita. Aunque Estados Unidos tiene el mayor número de publicaciones, España y Australia destacan en términos de publicaciones recientes, seguidos por China, Francia y Singapur.

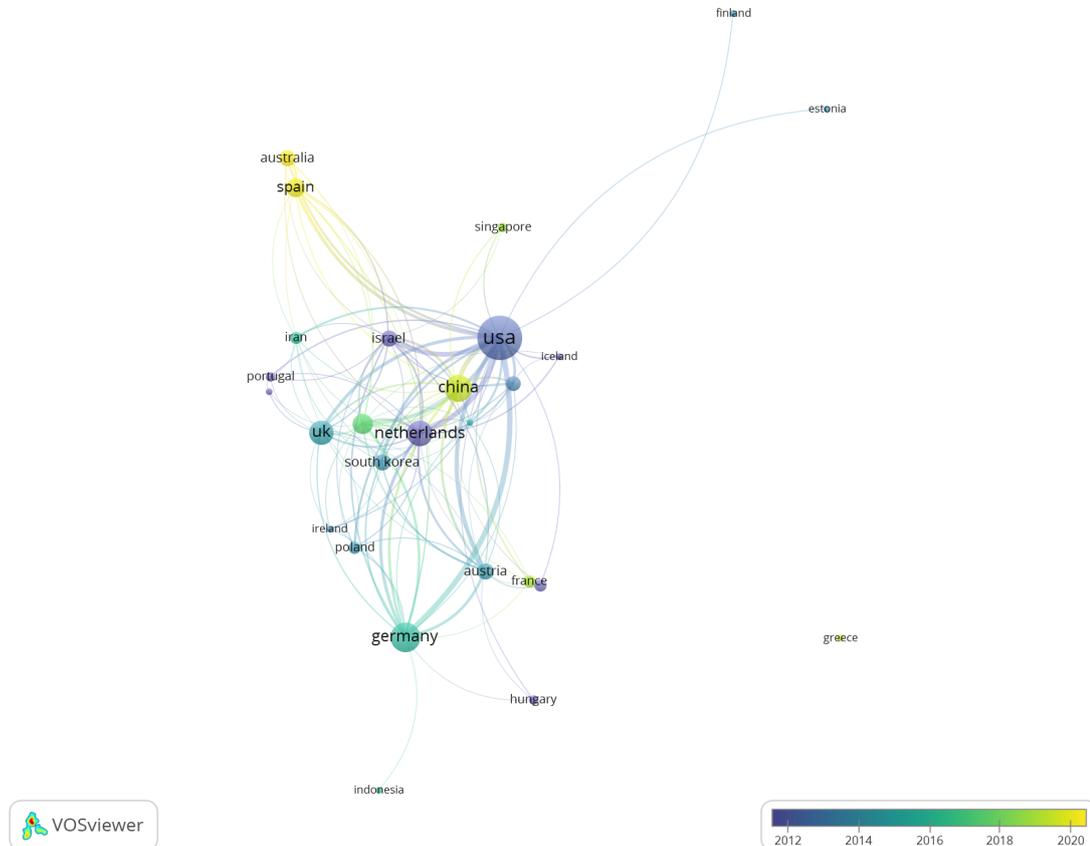


Figura 3: Red de citas entre países, generada con el software VOSviewer. Cada nodo representa un país, el color del nodo indica el año medio de publicación, desde 2012 en morado hasta 2020 en amarillo.

3.3.5. Revistas científicas más frecuentes

Las publicaciones se distribuyen en 73 revistas que abarcan una amplia variedad de temas, siendo la mayoría de las revistas en las áreas de negocios, gestión y ciencias de la computación. La revista *Journal of Business Research* (JBR) es la que tiene el mayor número de publicaciones en este tema, con siete, seguida por tres revistas que están empatadas con cinco publicaciones cada una: *International Journal of Research in Marketing* (IJRM), *Journal of Artificial Societies and Social Simulation* (JASSS) y *Journal of Product Innovation Management* (JPIM).

3.3.6. Análisis de co-palabras

En esta sección analizamos los temas en nuestro conjunto de publicaciones y las relaciones entre ellos. Con este objetivo, mostramos la red de co-ocurrencia de palabras clave en la Figura 4. Solo consideramos las palabras que aparecen en más de una publicación. Cada nodo en la red representa una palabra clave en el artículo (las especificadas por los autores), el tamaño del nodo indica el número de veces que la palabra aparece, el enlace entre los nodos representa la co-ocurrencia de palabras clave (es decir, cuando aparecen juntas) y el grosor del enlace representa el número de veces que se da dicha co-ocurrencia. Antes de obtener la red, fue necesario un primer paso de mapeo de palabras clave. Por ejemplo, agrupamos las diferentes formas de referirse al ABM bajo el término “*agent-based modeling*”. También fusionamos otras palabras que representaban el mismo concepto, como “*diffusion of innovation*” e “*innovation diffusion*”, así como “*retail*”, “*retailer*”, y “*retailing*”. Además, estandarizamos términos que aparecen tanto en singular como en plural, como “*market*”, “*innovation*”, “*influentials*”, y “*applications*”, así como términos que aparecen con guiones y sin ellos, como “*decision-making*” y “*word-of-mouth*”. Además, abordamos las diferencias de ortografía entre el inglés británico y americano, como “*behavior*” y “*behaviour*”.

Como era de esperar, la palabra clave más frecuente fue “*agent-based modeling*”, seguida por “*social networks*”, “*innovation diffusion*”, “*word-of-mouth*” y “*consumer behavior*”. Además, estas palabras representan *hubs* con un número significativo de enlaces, siendo “*agent-based modeling*” el más prominente entre ellos.

Podemos observar siete clústeres en diferentes colores, donde cada clúster representa un tema de estudio en el ámbito del ABM en marketing:

1. Clúster rojo (“*diffusion*”, “*evolutionary multiobjective optimization*”, “*homophily*”, “*influentials*”, “*innovation*”, “*mobile applications*”, “*opinion leader*”, “*seeding*”, “*social hubs*”, “*social networks*” y “*viral marketing*”): Este clúster incluye artículos relacionados con la difusión de información o influencia a través de redes sociales [GHLH09, RCC20, DRR22].
2. Clúster verde (“*agent-based modeling*”, “*competition*”, “*consumer purchase behavior*”, “*location*”, “*retail*”, “*stores’ simulation*” y “*supply chain*”): Este clúster incluye palabras clave relacionadas con la simulación de competición y el comportamiento de compra del consumidor, particularmente en el contexto del comercio minorista o retail [DLMS20, SNH18, VM11] y la gestión de cadenas de suministro [HWC13, TXS22].
3. Clúster azul (“*consumer behavior*”, “*data mining*”, “*decision-making*”, “*market dynamics*”, “*marketing*”, “*networks*” y “*social simulation*”): Los artículos en este clúster se centran en el comportamiento del consumidor y sus mecanismos de toma de decisiones [Jag07, GCC23, DFK21].
4. Clúster amarillo (“*advertising*”, “*new product diffusion*”, “*social influence*”, “*strong ties*”, “*weak ties*”, “*targeting strategies*” y “*word-of-mouth*”): Los artículos que encontramos en este clúster se centran en entender cómo la influencia social [DBB16], las relaciones [HWJY19, GLMM07] y las estrategias de focalización [DJB07] pueden afectar a la difusión de nuevos productos en un mercado.

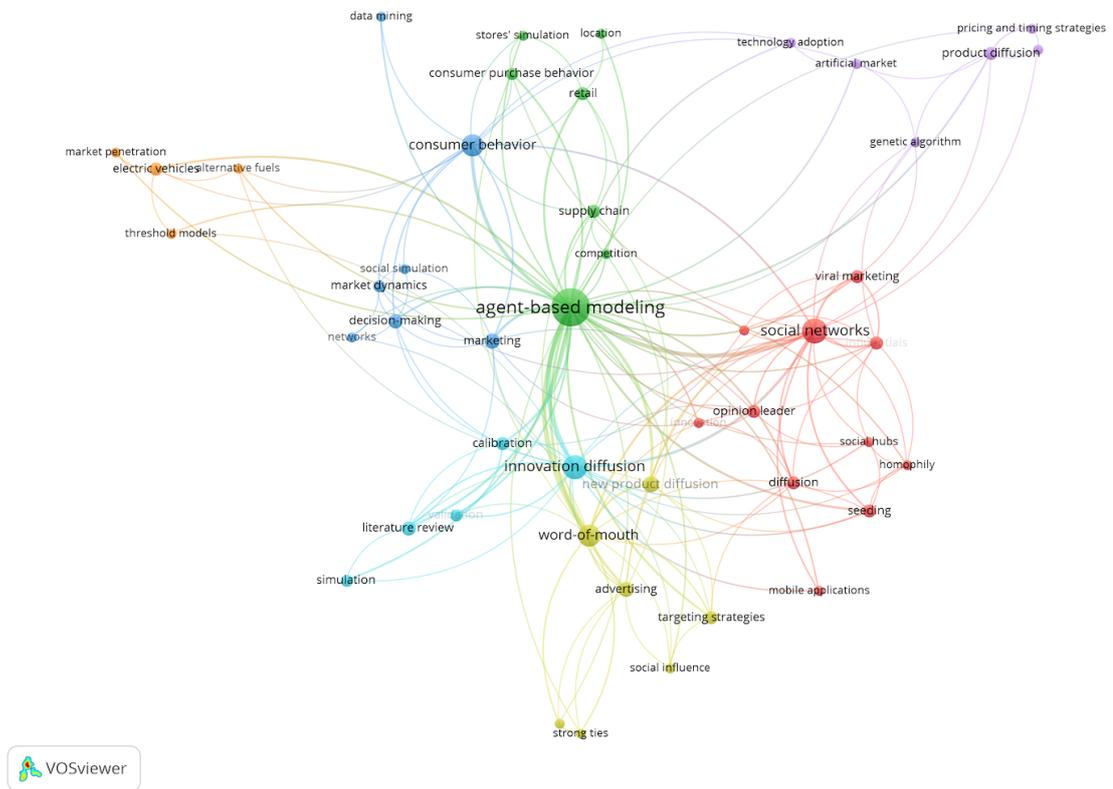


Figura 4: Red de co-ocurrencia de palabras clave, generada con el software VOSviewer. Cada nodo representa una palabra clave y los nodos están agrupados en siete clústeres que representan diferentes temas de estudio.

5. Clúster morado (“*artificial market*”, “*genetic algorithm*”, “*pricing and timing strategies*”, “*product diffusion*”, “*sensitivity analysis*” y “*technology adoption*”): Este clúster se centra en el uso de algoritmos genéticos y mercados artificiales para identificar estrategias óptimas de precios y tiempos [LLK14].
6. Clúster azul claro (“*calibration*”, “*innovation diffusion*”, “*literature review*”, “*simulation*”, y “*validation*”): En este clúster encontramos artículos metodológicos que comúnmente están relacionados con la difusión de innovaciones [ZV19, KGSW12, GRH07].
7. Clúster naranja (“*alternative fuels*”, “*electric vehicles*”, “*market penetration*” y “*threshold models*”): Los artículos en este clúster estudian el potencial para la adopción de nuevas tecnologías, como combustibles alternativos [GSS⁺22, GSWW11] y vehículos eléctricos [ML14, STÁ⁺12], y cómo diferentes factores, como el coste y los incentivos gubernamentales, pueden afectar a la penetración de estas tecnologías en el mercado.

3.4. Principales objetivos y características

En esta sección analizamos los artículos recopilados con respecto a cinco características clave utilizadas comúnmente en modelos basados en agentes. Se han seleccionado estas características por su uso generalizado en el desarrollo del ABM y su extensa documentación en la literatura. De los 113 artículos recopilados, se han excluido las revisiones bibliográficas, ya que no aportaban modelos propios o aplicaciones prácticas del ABM. Así, nuestro análisis se centra en 102 artículos que usan o implementan modelos basados en agentes, ya sea desarrollando modelos originales o adaptando modelos existentes. La Tabla 4 agrupa los artículos según su objetivo principal y evalúa si sus modelos satisfacen ciertas características. La última fila muestra el número total de artículos en los que se da cada característica. Las características consideradas son:

- **Modelo de difusión:** El modelo considerado describe cómo se difunden productos o información a través de la población de agentes. La mayoría de los modelos de difusión siguen dos enfoques: modelo umbral [Gra78, WD07] y modelo cascada [GLM01, GLM10]. En los modelos de cascada estocásticos, cada agente que adopta un producto puede influir en sus vecinos para que hagan lo mismo con una probabilidad determinada. En el modelo de umbral, cada agente decide adoptar un producto si la fracción de vecinos que han adoptado supera cierto umbral. Este puede ser determinista o estocástico, si el agente decide si adoptar con cierta probabilidad una vez se alcanza cierto umbral, como en [BCZ10]. A partir de estos modelos clásicos han surgido numerosas extensiones como el modelo Bass-ABM [RR11], una adaptación para ABM del clásico modelo de Bass [Bas69]. Este modelo, ampliamente usado, es una forma de modelo cascada que incorpora un parámetro de influencia externa. También es muy usado el modelo de contagio complejo [CM07], similar al modelo umbral, con la diferencia de que el umbral es absoluto en lugar de relativo. Además, se han propuesto funciones de utilidad donde se combinan preferencias individuales con influencia social [DJB07].
- **Elección múltiple:** El modelo considerado simula una competición donde los agentes tienen la posibilidad elegir entre múltiples productos, marcas u otras opciones. Para decidir entre las diferentes opciones, encontramos algunos trabajos en los que se utilizan modelos logísticos multinomiales [STÁ⁺12], en otros proponen funciones de maximización de la utilidad [GCCCH20] y en algunos proponen heurísticas propias como en [JJ03].
- **Red social:** El entorno en el que se ubican los agentes es una SN. Encontramos los diferentes tipos de SN presentados en la Sección 2.1.3: aleatorias [ER59], regulares, mundo pequeño [WS98], libre de escala [BA99] o redes del mundo real [LAH07]. Muchos de los modelos no se limitan a un tipo de red sino que experimentan con varios de ellos. Aunque la mayoría de redes son estáticas, también encontramos redes dinámicas [ZGN⁺18]. Además, algunos modelos también incorporan redes ponderadas y/o dirigidas ([DJB10] y [GAK15], respectivamente).

- **Información espacial:** La estructura del entorno en el que se ubican los agentes es una representación espacial o física. En particular, destacan las representaciones geográficas de ciertas regiones como en [SLR07] o los planos de establecimientos como en [PPBP21].
- **Validación con datos reales:** Se ha verificado si el modelo considerado se ajusta a datos reales. Es un paso crucial para garantizar la fiabilidad del modelo, aunque no siempre se disponen de los datos necesarios para llevar a cabo este proceso. Entre los trabajos considerados, algunos incluyen un paso de calibración previo, a menudo usando algoritmos genéticos [HEB07], otros incluyen un paso de validación posterior, y algunos incluyen ambos. En [RR11] proponen una serie de pautas para validar adecuadamente el modelo que han sido adoptadas en trabajos posteriores como [DBB16].

Objetivo	Referencias	MD	EM	SN	IE	VR
Simulador del comportamiento del consumidor	[JJ03, JJ00, JJ01, SB01]	✓	✓	✓		
Mercado completo con diferentes actores	[NMA ⁺ 10]		✓			✓
	[STSH10]	✓	✓	✓		
	[SKGV15]	✓	✓	✓		✓
Efectos de topología y heterogeneidad en difusión de innovación	[DJB10, BCZ10, GLM10, SL16, Wat02, GHLH09, PSWW14, DF16, HL20, GLMM07]	✓		✓		
	[ZZZL21, ZLLZ20]	✓		✓		✓
	[KK08, Tra12]	✓	✓	✓		
	[ZDZJ22, LMR22]	✓	✓	✓		✓
Simulación de negocios	[SK21]	✓	✓	✓		
Predicción de difusión de innovación	[KIKK14, XH16]	✓		✓		✓
Toma de decisiones de compra del consumidor	[ZZ07]		✓		✓	✓
	[RGAH ⁺ 11]		✓			✓
	[ZZ19]		✓		✓	
	[KSSW12]	✓	✓	✓		

Tabla 4 – Continúa en la siguiente página

Objetivo	Referencias	MD	EM	SN	IE	VR
	[DFK21]				✓	
Toma de decisiones difusa de compra del consumidor	[GCCCH20, GCC23]		✓			✓
	[LKKP13]	✓	✓	✓		
	[CH16]				✓	✓
Diseño de producto	[MN05a]		✓			
	[KHK14, ZH22]	✓	✓	✓		✓
Localización de los establecimientos	[SLR07, SNH18, HHC ⁺ 19]		✓		✓	✓
	[VM11]		✓		✓	
Actividades de los consumidores en establecimientos	[DLMS20]		✓		✓	✓
	[SS03]		✓			
	[TKT ⁺ 09, HIHS13]		✓		✓	
	[PPBP21]				✓	
Retención de clientes	[EOW22]	✓	✓	✓		✓
	[BM18]		✓	✓		
Estrategias de precios	[LLK14]	✓	✓	✓		
	[ZGN ⁺ 18, Yan22]	✓		✓		✓
	[HEB07]		✓		✓	✓
	[HHRO13]		✓		✓	
	[VRR06, HWC13]		✓			
Estrategias de publicidad	[DBB16, VPMCC23]	✓	✓	✓		✓
	[ZGBL23]	✓	✓	✓		
	[DPW17]	✓	✓			✓
	[BAM22]	✓		✓		
	[HWJY19]	✓		✓		✓

Tabla 4 – Continúa en la siguiente página

Objetivo	Referencias	MD	EM	SN	IE	VR
Estrategias de cadena de suministro	[BJL ⁺ 21]		✓	✓		
	[TXS22]		✓			
	[AWRN12]	✓		✓		
	[NS18, NYN14]	✓		✓		✓
Rol de los líderes de opinión	[CKWZ21]		✓	✓		
	[HL13, VEJL11, WD07]	✓		✓		
	[DRR22]	✓		✓		✓
Estrategias de focalización	[DJB07, SBST13, NAB15, PG18]	✓		✓		
	[LMP13]	✓	✓	✓		
	[NWG20]	✓		✓	✓	✓
	[HLQS18, CR17, XMSZ21]	✓		✓		✓
Técnicas de optimización para problema de maximización de influencia	[GAK15]	✓		✓		
	[RCC20]	✓	✓	✓		✓
Marketing viral: difusión de rumores	[SI16]	✓		✓		✓
Marketing de contenidos generados por usuarios	[ZGCR21]	✓	✓	✓		✓
Calibración	[KH22]	✓			✓	✓
	[MCC19, GRH07]	✓	✓	✓		✓
Difusión de eco-innovaciones	[SE09]	✓	✓	✓	✓	✓
	[ML14, EB17]	✓		✓	✓	✓
	[ZGG11, SPF19]	✓	✓	✓		✓
	[EGMR11]	✓	✓	✓	✓	
	[JJ02]	✓	✓	✓		
	[GSWW11]	✓		✓	✓	

Tabla 4 – Continúa en la siguiente página

Objetivo	Referencias	MD	EM	SN	IE	VR
	[BLS19]	✓		✓		✓
	[BJSWW16, RMPS22]	✓		✓		
	[STÁ ⁺ 12, GSS ⁺ 22]	✓	✓			
	[MdH09]		✓			✓
Total Referencias	102	75	57	74	21	47

Tabla 4: Caracterización de los modelos basados en agentes de los artículos recopilados. MD = modelo de difusión, EM = elección múltiple, SN = red social, IE = información espacial, VR = validación con datos reales.

Los nombres de los objetivos en la Tabla 4 se han creado con el fin de unificar los propósitos principales de los artículos tal como se indican en sus resúmenes, palabras clave o a lo largo del artículo. A tener en cuenta, estos objetivos no son exclusivos, es decir, un artículo puede tener determinado objetivo principal pero estar relacionado con otros. Los objetivos de los artículos son bastante diversos, y van desde la exploración de diferentes mecanismos de toma de decisiones de compra del consumidor [ZZ19] o el estudio del comportamiento de los consumidores en establecimientos físicos [DLMS20] hasta la evaluación del impacto de diferentes estrategias como las de precios [LLK14] o publicitarias [BAM22]. Observamos que se ha realizado una investigación extensa en el área de difusión de innovaciones, particularmente con respecto al estudio de los efectos de la topología y la heterogeneidad del consumidor en la difusión de innovaciones [BCZ10], así como el caso particular de la difusión de eco-innovaciones [RMPS22].

Para analizar mejor el número de artículos que cumplen una o varias de las características, representamos gráficamente esta información en la Figura 5. El paquete UpSetR proporciona la herramienta ideal para obtener una visualización de las intersecciones que se dan entre características. El histograma de la izquierda representa el número de artículos que cumplen cada característica, mientras que el histograma superior considera todas las intersecciones encontradas entre dichas características. Las características implicadas en las combinaciones se indican en la matriz de puntos central. Por ejemplo, el histograma de la izquierda muestra que un total de 21 modelos usan información espacial, y el histograma superior muestra que dos de ellos cumplen únicamente dicha característica, mientras que el resto de modelos junto con esa característica verifican también otras.

Observamos que las características más comunes son el uso de modelos de difusión y redes sociales, presentes en el 74% y el 73% de los artículos, respectivamente. La menos común es el uso de información espacial, presente en solo el 21% de los artículos. Solo se realiza validación con datos reales en el 46% de los modelos, aunque esta es necesaria para asegurar la precisión y relevancia de los modelos.

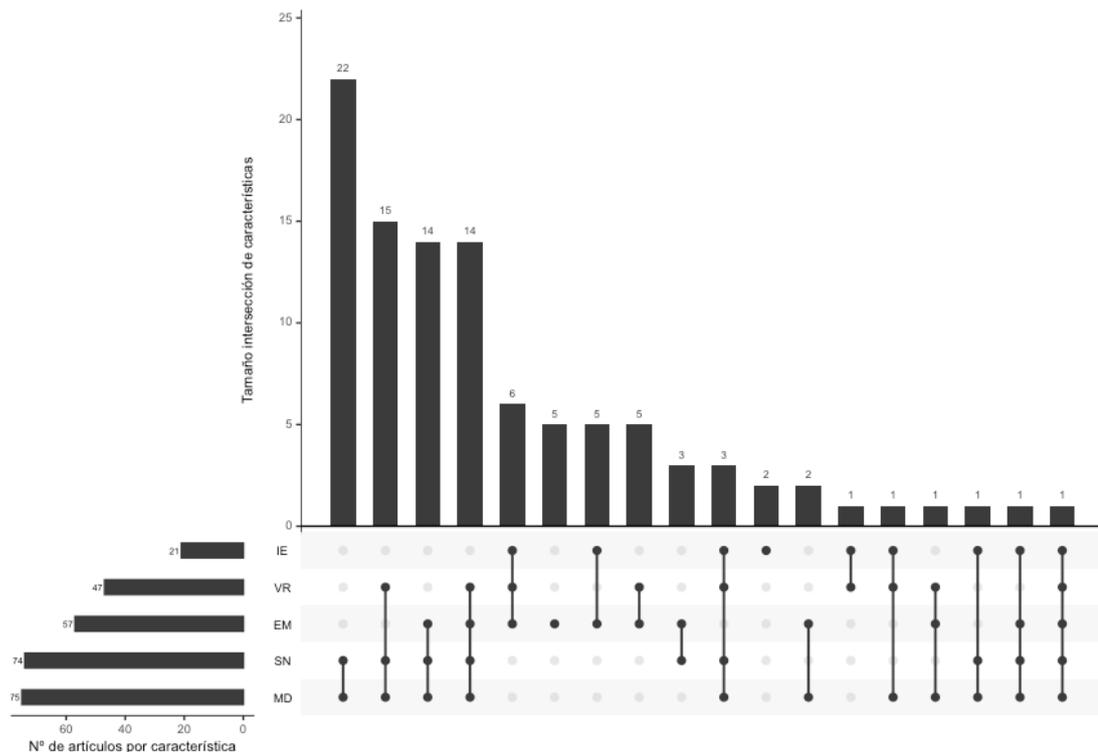


Figura 5: N° de artículos que cumplen cada característica (histograma izquierdo) e intersecciones (histograma superior).

La mayoría de los artículos (93 %) cumplen al menos dos características. El uso de modelo de difusión es la que está presente en más combinaciones. Además, no se da en solitario, es decir, sin combinarla con otras características. Lo mismo ocurre con las redes sociales y la validación de datos reales. La combinación más frecuente es el uso conjunto de modelos de difusión y redes sociales, como en [GLM10], seguida por la combinación de estas con la validación de datos reales, la elección múltiple o la combinación de las cuatro características. No es habitual la combinación de los dos tipos de entorno (redes sociales e información espacial), presente solo en el 6 % de los artículos. Solo uno de los artículos incluye todas las características [SE09], aunque el 18 % de los artículos incluye todas menos una característica [ZDZJ22].

3.5. Conclusiones

En este capítulo hemos llevado a cabo un análisis bibliométrico exhaustivo de la literatura existente sobre ABM en marketing desde el año 2000 hasta marzo de 2023, periodo durante el cual el uso del ABM en las ciencias sociales, y más específicamente en marketing, se ha vuelto particularmente popular. Nuestra revisión incluyó un total de 113 publicaciones, cuyo análisis revela una tendencia creciente en el número de publicaciones anuales en

el área, con contribuciones destacadas de países como Estados Unidos, y más recientemente España y Australia. Los resultados también indican que existe una limitada colaboración entre grupos de coautoría; el campo podría beneficiarse de una mayor colaboración.

Asimismo, se ha realizado una detallada caracterización que nos ayuda a conocer la naturaleza de los modelos basados en agentes usados en marketing, aportando una visión clara de cómo se han integrado y aplicado los distintos elementos en estas dos décadas. Se observa que, aunque las características analizadas y sus combinaciones varían en los artículos recopilados, los modelos de difusión y las redes sociales son las más comunes, mientras que la información espacial aparece como la menos común. Los objetivos de los artículos son bastante diversos, destacando la considerable cantidad de investigaciones enfocadas en estudiar los efectos de la topología y la heterogeneidad del consumidor en la difusión de innovaciones o las centradas en la difusión de eco-innovaciones.

Capítulo 4

Propuesta II: Aumento de la explicabilidad de las salidas de los modelos basados en agentes usando descubrimiento de subgrupos

En este capítulo proponemos una metodología de aplicación de técnicas de SD para identificar patrones interesantes y fácilmente interpretables a partir de las salidas de simulaciones de ABM. Tras una introducción al capítulo, se describe la metodología propuesta, seguida del estudio experimental sobre el caso de estudio en marketing. A continuación, se analiza una instancia específica de un caso de estudio desde la perspectiva de un experto en el área. Finalmente, el capítulo termina con las conclusiones obtenidas.

4.1. Introducción

En este capítulo, presentamos la segunda contribución de esta tesis, que consiste en una metodología para aplicar técnicas de XAI, en particular SD, sobre las salidas de los modelos basados en agentes con el fin de mejorar la interpretabilidad de dichas salidas y, por tanto, la comprensión del modelo. Requisito que, como se ha mencionado anteriormente, es fundamental para el uso efectivo del ABM como herramienta de soporte a la toma de decisiones.

Las simulaciones de ABM no solo generan Indicadores Clave de Rendimiento (KPI, por sus siglas en inglés) a nivel macro, sino que también producen un registro detallado del comportamiento de los agentes. Sin embargo, el volumen de datos generados es tan grande que es difícil de analizar y entender. Mejorar la comprensión de las salidas del modelo es uno de los retos que se plantean en el campo del ABM [DLG⁺23]. Para abordar este desafío, la aplicación de técnicas de aprendizaje automático a ABM se presenta como una solución prometedora. Como se ha detallado en la Sección 2.2.3, varios estudios han empleado técnicas de aprendizaje automático para analizar las salidas de los modelos basados en agentes [DLG⁺23, ZVC21, PLGHQCCR23], principalmente con el propósito de: (i) validar el modelo; (ii) entender la relación entre las entradas y salidas del modelo para crear modelos subrogados, hacer predicciones o identificar parámetros o características clave; u (iii) optimizar el comportamiento de los agentes a nivel micro. Pero faltan estudios enfocados en analizar los datos simulados con el fin de mejorar la interpretabilidad de los resultados y extraer *insights* útiles sobre el comportamiento de los agentes para informar decisiones sobre políticas y acciones estratégicas a nivel macro. Nuestro objetivo es contribuir a esta área poco explorada mejorando la comprensión de las salidas del modelo, y en consecuencia potenciando la confianza en el modelo, tanto facilitando la comunicación con las partes interesadas como facilitando el proceso de toma de decisiones [DRDSC⁺23].

Para abordar este problema, proponemos el uso de técnicas de XAI [BADRD⁺20] inherentemente interpretables, en particular SD, para extraer reglas interesantes e interpretables a partir de las salidas a nivel micro (*roadmap* de los agentes) de las simulaciones de ABM. Nuestro objetivo final es descubrir conocimiento valioso sobre el comportamiento de los agentes para ayudar a los *stakeholders* en su proceso de toma de decisiones. Por tanto, nuestra propuesta es genérica y puede ser aplicada a la salida de cualquier modelo basado en agentes correctamente calibrado y validado.

En nuestra contribución, presentamos una metodología para la aplicación de SD a las salidas de los modelos basados en agentes siguiendo ciertos pasos clave (preprocesamiento de datos, aplicación de algoritmo de SD, filtrado de reglas y visualización), a los que también se incorpora durante el proceso el *feedback* de un experto en el área. Como hemos detallado previamente en la Sección 2.3, el SD [Klö96, Wro97] es una técnica que intenta descubrir relaciones inusuales entre diferentes variables con respecto a una propiedad de interés. A diferencia del descubrimiento de reglas de asociación, que explora dependencias arbitrarias entre atributos en un contexto de aprendizaje no supervisado, el SD analiza una propiedad de interés predefinida dentro de un marco de aprendizaje supervisado [AP06]. Comparamos el rendimiento de diferentes métodos de SD: un algoritmo basado en métodos de reglas de asociación (SDMap) y dos algoritmos basados en computación evolutiva (NMEEFSD y FuGePSD). Los tres algoritmos se evalúan considerando las medidas de calidad habituales

en SD [CdJH18] definidas en la Sección 2.3.2.1: número de reglas y variables, inusualidad, confianza y sensibilidad.

Finalmente, como un ejemplo ilustrativo de nuestra metodología, analizamos una instancia específica del caso de estudio en marketing, considerando la perspectiva de un experto en dicha área. Mostramos cómo las reglas obtenidas pueden ser fácilmente comprendidas por expertos en marketing y pueden proporcionar conocimiento valioso sobre las dinámicas de comportamiento del consumidor. Por ejemplo, una regla podría indicar que los consumidores que tienen altos niveles de exposición a la publicidad en televisión y bajos niveles de exposición a las SN tienen más probabilidades de realizar una compra. Esta información puede ayudar a los profesionales del marketing a ajustar su estrategia publicitaria para dirigirse mejor a estos consumidores y, así, aumentar las ventas.

Este capítulo se organiza como sigue. En la Sección 4.2 se detalla la metodología propuesta. La Sección 4.3 presenta el estudio experimental en un caso de estudio de marketing. La Sección 4.4 analiza una instancia específica del caso de estudio en marketing para ilustrar la efectividad de nuestra propuesta. Finalmente, se comunican las principales conclusiones en la Sección 4.5.

4.2. Metodología propuesta

Las simulaciones de ABM no solo generan KPI a nivel macro, sino que también generan un registro detallado o *roadmap* de las acciones de los agentes durante todo el periodo, el cual puede proporcionarnos información valiosa sobre el comportamiento de los agentes. Esto implica un gran volumen de datos que describen adecuadamente las dinámicas del sistema pero que son difíciles de analizar y comprender. Como se detalló en la Sección 2.2, uno de los propósitos de la XAI es mejorar la comprensión de los modelos de IA, promoviendo tanto la apertura de modelos de caja negra como potenciando las soluciones de modelos de caja blanca. De hecho, aumentar la transparencia de las soluciones debería incrementar la confianza en el comportamiento y rendimiento de estas soluciones [DRDSC⁺23]. En el contexto del ABM, una comprensión más profunda del comportamiento de los agentes facilita la toma de decisiones de los modeladores y *stakeholders* en el ABM [DLG⁺23, ZVC21, PLGHQCCR23].

El objetivo de esta contribución es aumentar la explicabilidad de las salidas de los modelos basados en agentes usando técnicas que extraigan conocimiento útil del comportamiento de los agentes a partir de los datos simulados. En particular, queremos descubrir relaciones inusuales entre diferentes variables de la población de agentes con respecto a una variable objetivo mediante enfoques de SD. Como se menciona en el Capítulo 2, hay que tener en cuenta que los algoritmos basados en reglas se usan habitualmente en XAI debido a su fácil interpretación. Su relación natural e intuitiva con el comportamiento humano los convierte en un enfoque muy adecuado para entender y explicar otros tipos de modelos de IA [BADRD⁺20].

La Figura 1 representa el proceso propuesto para aplicar SD sobre las salidas del modelo basado en agentes. En primer lugar, se requieren algunas transformaciones de datos para

adaptar los registros del ABM a una entrada adecuada para el algoritmo de SD (detalladas en la Sección 4.2.1). En segundo lugar, se aplica un algoritmo de SD para obtener un conjunto de reglas (Sección 4.2.2). Una vez que se obtiene el conjunto de reglas, se aplica un paso de filtrado para incrementar su interpretabilidad (Sección 4.2.3). Finalmente, se muestra una visualización de las reglas filtradas para facilitar el análisis del experto (Sección 4.2.4). Un experto humano se incorpora al ciclo para proporcionar *feedback* que ayude a refinar los resultados de los algoritmos de SD. Por ejemplo, asesorando sobre el rediseño de las transformaciones de datos. El conocimiento extraído durante el proceso puede ser empleado para entender la dinámica del sistema, mejorar el modelo basado en agentes y desarrollar la toma de decisiones.

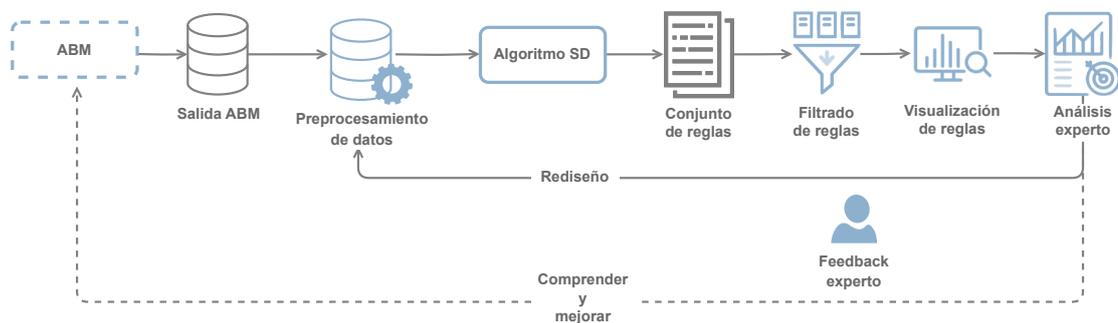


Figura 1: Diagrama de flujo de la metodología propuesta para aplicar SD en ABM.

4.2.1. Diseño del preprocesamiento de datos

El algoritmo de SD requiere un preprocesamiento de datos apropiado para poder detectar subgrupos de agentes a partir de la salida del modelo basado en agentes. Esta salida consiste en un registro del *roadmap* de los agentes para un sistema específico (un mercado virtual en nuestro caso, ver Sección 4.3).

La salida del modelo consta de un archivo generado a partir de una ejecución de la simulación, en el cual se recopila información sobre el número de veces $x_{i,a}^t$ que un agente $i \in \{1, \dots, I\}$ ha realizado una acción (hablar, escuchar, comprar o recibir impactos publicitarios en nuestro caso de estudio) en cada instante de tiempo $t \in \{0, \dots, T-1\}$. Como se muestra en la Figura 2, inicialmente la salida del modelo basado en agentes consiste en una tabla en la que cada fila corresponde a la tupla (agente i , acción a) y cada columna corresponde a un instante de tiempo t .

Nuestro objetivo es que los algoritmos de SD identifiquen grupos de agentes en los que existan relaciones inusuales entre diferentes variables con respecto a una propiedad de interés. Para ello, primero debemos definir cuál es esa propiedad de interés y después construir las variables de entrada y transformar los datos de manera que cada fila corresponda a un

agente i . A continuación, se presentan los aspectos clave del diseño, los cuales han evolucionado y se han ajustado a lo largo del proceso en base a los resultados obtenidos en una experimentación preliminar y las recomendaciones del experto:

1. **Variable objetivo.** En primer lugar, es necesario determinar qué acción del agente se considerará para representar la variable objetivo. Por ejemplo, en un modelo basado en agentes de marketing, podríamos considerar el total de compras realizadas por cada agente durante todo el periodo como la variable objetivo, entre muchos otros posibles KPI. Además, es necesario discretizar el rango de valores de la variable objetivo en clases, eligiendo el número más apropiado de clases y el método de discretización más adecuado para el conjunto de datos.
2. **Variables de entrada.** El siguiente paso es construir las variables de entrada que describen la variable objetivo, que serán las acciones de los agentes. Dado que tenemos las acciones realizadas por cada agente en cada instante de la simulación, debemos determinar cómo agregar estos instantes. Consideramos una agregación de periodo completo, es decir, las variables de entrada se construyen como el número total de veces que un agente i realizó una acción a durante todo el periodo, siguiendo la fórmula:

$$y_{i,a} = \sum_{t=0}^{T-1} x_{i,a}^t$$

El número de variables de entrada sería, por tanto, el número total de acciones desarrolladas por los agentes, A . Dado que estamos considerando una variable objetivo completamente agregada sin componente temporal, este enfoque completamente agregado es más consistente y comparable que construir variables donde la temporalidad juega un papel significativo, como la agregación por meses o trimestres. Este enfoque también reduce el número de variables que el algoritmo necesita considerar. Finalmente, cuando el algoritmo de SD no admite variables continuas, como ocurre con SDMap, es imprescindible discretizar estas variables. Para este propósito, se puede utilizar el algoritmo de Fayyad [FI93] u otro método de discretización, como la discretización de frecuencia uniforme [GLH15], dependiendo de cuál sea más adecuado para el problema en particular.

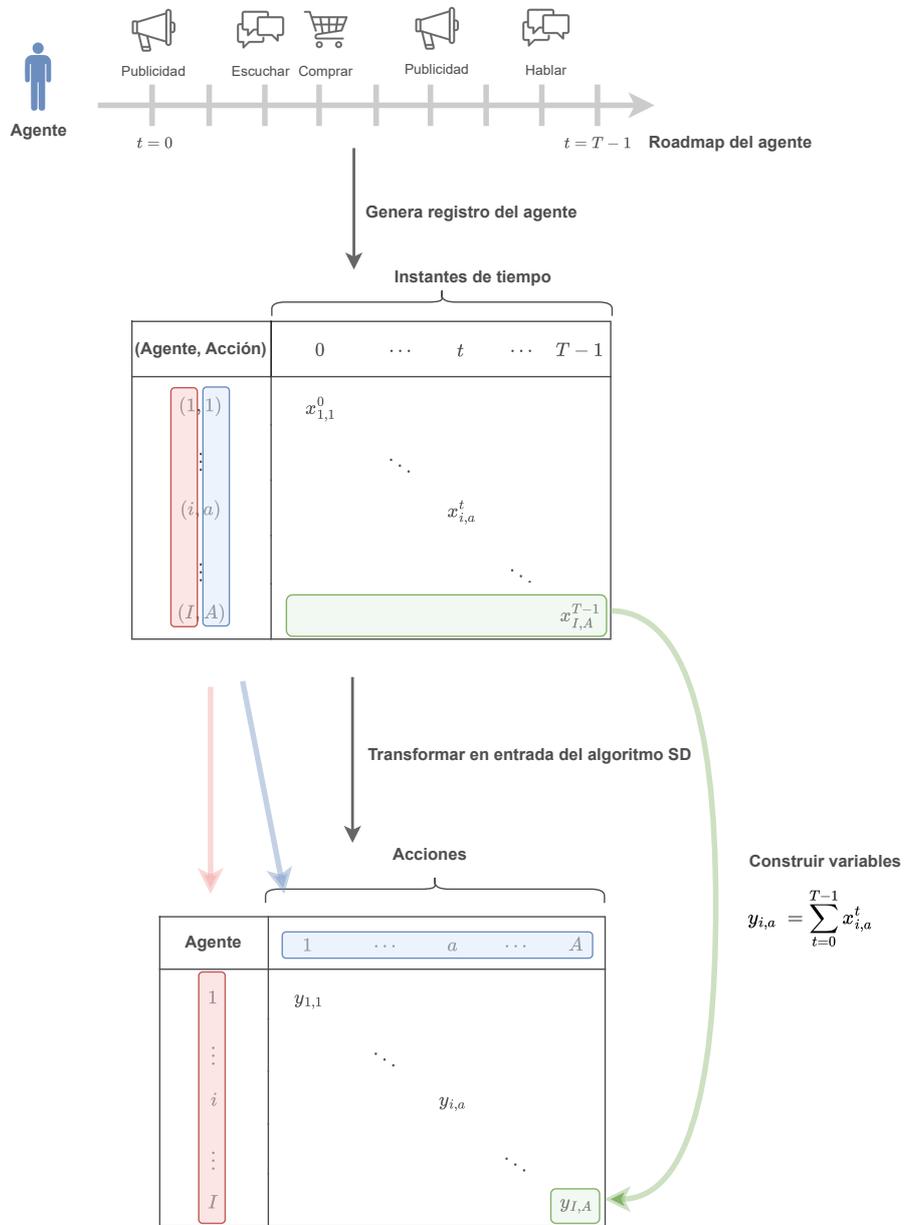


Figura 2: Preprocesamiento del conjunto de datos desde la salida ABM (tabla superior) a la entrada del algoritmo de SD (tabla inferior). La salida ABM se genera a partir de las acciones que cada agente realiza en cada instante (diagrama superior). Las flechas rojas, azules y verdes representan transformaciones entre tablas.

4.2.2. Algoritmos de descubrimiento de subgrupos

En esta sección describimos más detalladamente los algoritmos empleados en este trabajo, ya introducidos en la Sección 2.3.2.2. Hemos escogido los algoritmos SDMap, NMEEFSD y FuGePSD, algoritmos habitualmente usados en la literatura.

SDMap. Propuesto en [AP06]. Es un algoritmo exhaustivo que emplea el conocido método FP-growth [HPY00] para la minería de reglas de asociación con adaptaciones para la tarea de SD. SDMap incorpora un paso de FP-growth modificado capaz de calcular directamente la calidad de los subgrupos sin hacer referencia a otros resultados intermedios. El algoritmo utiliza un umbral de soporte mínimo para reducir eficazmente el espacio de búsqueda. Su naturaleza exhaustiva garantiza una exploración completa de los posibles subgrupos. SDMap solo puede manejar variables categóricas por lo que requiere un paso de discretización previo de las variables numéricas.

NMEEFSD. Propuesto en [CGdJH10]. Es un algoritmo evolutivo multiobjetivo basado en sistemas difusos que sigue el enfoque NSGA-II [DPAM02]. Su enfoque multiobjetivo permite la optimización simultánea de diferentes medidas de calidad asociadas a la tarea de SD. Es capaz de manejar tanto variables numéricas como categóricas sin necesidad de discretización previa, gracias a su aplicación de la lógica difusa, donde las variables numéricas se tratan como lingüísticas y los valores se representan con etiquetas difusas.

FuGePSD. Propuesto en [CRRdJ⁺15]. Es otro destacado algoritmo evolutivo basado en sistemas difusos. Combina la programación genética con la lógica difusa. Emplea un enfoque genético competitivo-cooperativo fomentando la competencia y la cooperación entre los individuos de la población con el fin de descubrir las soluciones óptimas para la tarea de SD. También es capaz de manejar tanto variables numéricas como categóricas sin necesidad de discretización previa. A diferencia de NMEEFSD, no es un algoritmo multiobjetivo.

4.2.3. Filtrado de reglas

El paso de filtrado asegura que solo se mantengan las reglas más significativas y fiables para el análisis, a la par que facilita la interpretabilidad del conjunto de reglas al reducir el número de reglas. La aplicación de este paso es especialmente necesaria en algoritmos exhaustivos, como SDMap, que pueden generar una gran cantidad de reglas. Aplicamos dos filtros de calidad: umbrales de inusualidad y de confianza. Primero, como se indica en la Sección 2.3.2.1, es deseable que las reglas obtenidas tengan una inusualidad normalizada mayor que 0.55. Esto se puede observar visualmente representando el espacio ROC, como se usa en [KL06]. Este método ayuda a descartar reglas poco significativas con una relación $TPR - FPR$ cercana a la diagonal principal. Esas reglas tienen la misma distribución porcentual de ejemplos positivos y negativos cubiertos que la distribución en todo el conjunto

de datos. Como se muestra en la Figura 3, observamos tres áreas diferentes en el espacio ROC [CdJH18]: área roja (reglas de baja calidad), área amarilla (reglas emergentes pero no de contraste) y área blanca (reglas óptimas: interesantes, emergentes y de contraste).

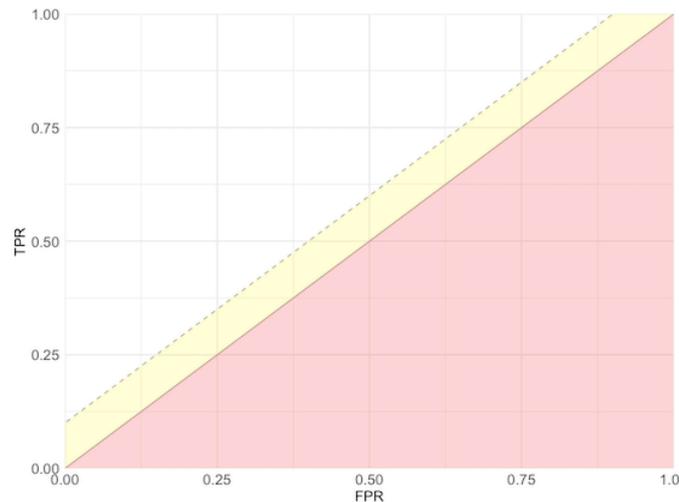


Figura 3: Espacio ROC. Las reglas en el área roja tienen $NWRAcc < 0.5$, las reglas en el área amarilla tienen $0.5 < NWRAcc < 0.55$, y las reglas en el área blanca tienen $NWRAcc > 0.55$.

Asimismo, es importante que las reglas tengan una confianza mayor que 0.5 para asegurar que sean fiables. Al superar este umbral de confianza, mejoramos la fiabilidad de los conocimientos derivados de las reglas, facilitando así una toma de decisiones más precisa.

Después de aplicar estos dos filtros de calidad, aplicamos un tercer filtro para seleccionar las reglas más específicas, es decir, aquellas que no están contenidas en otras, ya que una regla más específica normalmente es más precisa que una más general. Además, de esta manera cada regla aportará información única, evitando redundancias. Aunque sería posible obtener algunas reglas con demasiadas variables, este efecto se mitiga durante el proceso de búsqueda al enfatizar la inusualidad, haciendo que este caso sea poco común.

4.2.4. Visualización de reglas

Además de mostrar las reglas obtenidas en forma de texto, añadimos una visualización intuitiva para facilitar el análisis del experto. La visualización elegida es un dendrograma, que es un gráfico jerárquico que proporciona una visión clara y sencilla de la estructura de las reglas. Cada nodo en el dendrograma representa un antecedente de regla, y las aristas conectan las variables dentro de la misma regla, ilustrando el flujo de una condición a la siguiente. El color de los nodos hoja indica el valor del consecuente de la regla, permitiendo una evaluación visual rápida del valor objetivo asociado a cada regla. Esta visualización representa las relaciones y jerarquías entre las reglas, facilitando al experto la identificación de patrones y la comprensión de las interconexiones entre diferentes reglas.

4.3. Caso de estudio: un modelo de mercado basado en agentes

El objetivo de este estudio experimental es aplicar la metodología propuesta en la Sección 4.2 a un caso de estudio específico y comparar el rendimiento de los algoritmos de SD más relevantes en diferentes experimentos. En primer lugar, se presenta el modelo de mercado basado en agentes y el conjunto de datos considerado en las Secciones 4.3.1 y 4.3.2, respectivamente. A continuación, en la Sección 4.3.3 se presenta el marco experimental, donde se describen la configuración de los algoritmos y las medidas de calidad consideradas en el estudio. Finalmente, la Sección 4.3.4 muestra la comparativa del rendimiento de los algoritmos de SD SMap, FuGePSD y NMEEFSD en los diferentes experimentos.

4.3.1. Modelo de mercado basado en agentes

El modelo de mercado basado en agentes en el que se basan nuestros experimentos es el propuesto por [MCC19, MBCC21]. Este modelo imita un mercado compuesto por B marcas competidoras durante un periodo de tiempo T . Usando un paso temporal o *time-step* de una semana, el modelo simula el comportamiento de I agentes y cómo reaccionan ante la exposición a influencias sociales a través de una SN en un proceso WOM y ante influencias externas (puntos de contacto o *touchpoints*) procedentes de canales publicitarios. Puede obtener diferentes resultados principales o KPI, como el volumen de ventas para cada marca. Los elementos principales del modelo se resumen en la Figura 4.



Figura 4: Figura adaptada de [MBCC21]. Resumen y elementos clave del modelo basado en agentes. Los agentes expuestos a la publicidad de los touchpoints pueden conocer la marca anunciada, hablar de ella a sus vecinos y comprarla.

El valor de conocimiento o *awareness* de cada agente indica si el agente conoce o no una marca en cada instante. Es dinámico porque los agentes pueden ganar o perder el conocimiento sobre cualquier marca en cada paso de la simulación. Los agentes pueden tomar cons-

ciencia de una marca a través de la publicidad o interactuando con otros agentes mediante un proceso de difusión WOM. En cada instante, los agentes que conocen una marca toman la decisión de comprarla o no dependiendo de sus percepciones (por ejemplo, hábitos de consumo, lealtad o ingresos). Consideran diferentes heurísticas, como se hace en [GCC23], para elegir una marca del conjunto de marcas de las que el agente i es consciente.

Los agentes están conectados a través de una SN artificial modelada como una red libre de escala [BA99]. Como detallamos en la Sección 2.1.3, este tipo de redes se caracteriza por que solo hay unos pocos nodos en la SN con un número considerablemente alto de conexiones, conocidos como *hubs*, mientras que la mayoría de los nodos tienen muy pocas conexiones.

Durante la simulación, los agentes pueden hablar con sus vecinos en la SN y difundir su conocimiento de las marcas. Esta interacción social se modela como un proceso de contagio en el que la información fluye a través de la red dependiendo de la conectividad de los nodos [NBW06].

Las influencias externas, como la publicidad, se representan como *touchpoints* pagados (es decir, medios de comunicación masivos [GACK⁺07]) y están parametrizados para definir las diferencias entre medios publicitarios (por ejemplo, SN, televisión y prensa). Los *touchpoints* pueden influir en cualquier número de agentes al azar dependiendo del potencial del *touchpoint* para alcanzar a la población y la inversión de cada marca. El porcentaje máximo de la población de agentes alcanzados está limitado por las propiedades del propio *touchpoint*. Por ejemplo, el porcentaje máximo de la población que una campaña de televisión puede alcanzar está limitado por el porcentaje máximo de la población que realmente ve televisión.

De manera similar a las interacciones sociales, cada *touchpoint* tiene un parámetro de impacto de conocimiento que representa la probabilidad de que el agente tome consciencia de la marca anunciada después de un único impacto del *touchpoint*. El modelo también considera el potencial de un efecto viral o *buzz* creado por los *touchpoints* [MCSLC17], que incrementaría la probabilidad de conversación sobre una marca. Este efecto decae con el paso del tiempo si no se refuerza

4.3.2. Descripción de los datos

El estudio experimental se llevó a cabo utilizando un conjunto de datos proporcionado por el software comercial Zio [CCR⁺23], que emplea ABM para analizar y predecir las dinámicas de mercado y facilitar la toma de decisiones estratégicas para los profesionales del marketing. Para garantizar la replicabilidad, este conjunto de datos y recursos adicionales de apoyo se proporcionan al lector¹. El enfoque de ABM implementado por Zio se basa en el modelo descrito en la subsección anterior. El conjunto de datos considerado es la salida del modelo para un mercado específico en el sector de la restauración, que consiste en el *road-map* de los agentes a lo largo del periodo de simulación, en el cual se recopila información

¹El conjunto de datos y los recursos necesarios para la experimentación están disponibles en https://github.com/eromeroc/Explaining_ABM_SD.git

sobre varios *touchpoints* (como publicidad en televisión, SN y promociones en tienda), interacciones de los consumidores (WOM) y compras. En particular, el conjunto de datos está compuesto por información de 16,000 agentes y 13 acciones (hablar, escuchar, comprar y recibir impactos de cualquiera de los 10 *touchpoints* considerados). Para nuestra experimentación, seleccionamos el KPI compras totales de la marca como variable objetivo y aplicamos el preprocesamiento de datos necesario para manejar adecuadamente la salida de ABM:

1. **Discretización de la variable objetivo.** Es necesario determinar las distintas clases de la variable objetivo, que en nuestro caso son las compras totales. Las compras están estrechamente relacionadas con el sector del mercado que estemos considerando, en este caso, el mercado de la restauración. Los valores de compras serían mucho más altos en un mercado de consumo masivo y la discretización sería diferente. Se consideraron las siguientes combinaciones para componer los diferentes experimentos siguiendo las recomendaciones del experto:
 - Experimento 1 - Dos categorías: (0) si el valor de la variable objetivo es igual a 0, es decir, consumidores que no compran en todo el periodo; y (1) si el valor es mayor que 0, es decir, consumidores que compran al menos un artículo.
 - Experimento 2 - Tres categorías: (0) si el valor objetivo es igual a 0; (1) si el valor objetivo es mayor que 0 y menor que la mediana, es decir, consumidores que compran solo una vez en todo el periodo; (2) si el valor objetivo es mayor o igual a la mediana, es decir, consumidores que compran más de una vez en todo el periodo.
 - Experimento 3 - Tres categorías: (0) si el valor objetivo es igual a 0; (1) si el valor objetivo es mayor que 0 y menor o igual que la mediana, es decir, consumidores que compran una o dos veces en todo el periodo; (2) si el valor objetivo es mayor que la mediana, es decir, consumidores que compran más de dos veces en todo el periodo.
 - Experimento 4 - Cuatro categorías: (0) si el valor objetivo es igual a 0; las tres categorías restantes (1), (2) y (3) se establecen usando el método de discretización por frecuencia uniforme.
2. **Construcción y discretización de variables de entrada.** Las variables de entrada, agregadas por el periodo completo, se recogen en la Tabla 5. Realizamos la siguiente discretización en tres categorías siguiendo las recomendaciones del experto:
 - Ninguno: si el valor de la variable es igual a 0.
 - Bajo: si el valor de la variable es mayor que 0 y menor que la mediana de la distribución de la variable.
 - Alto: si el valor de la variable es mayor o igual a la mediana de la distribución de la variable.

VARIABLES DE ENTRADA	DESCRIPCIÓN
Hablar	Nº total de veces que un agente habla sobre la marca
Escuchar	Nº total de veces que un agente escucha sobre la marca
TV Short HH	Nº total de impactos de TV Short HH recibidos por un agente
TV Short Rest	Nº total de impactos de TV Short Rest recibidos por un agente
TV Long HH	Nº total de impactos de TV Long HH recibidos por un agente
TV Long Rest	Nº total de impactos de TV Long Rest recibidos por un agente
TV Long Agg. HH	Nº total de impactos de TV Long Aggregator HH recibidos por un agente
TV Long Agg. Rest	Nº total de impactos de TV Long Aggregator Rest recibidos por un agente
OOH	Nº total de impactos de publicidad exterior u <i>Out Of Home</i> recibidos por un agente
SN (pagadas)	Nº total de impactos de redes sociales (pagadas) recibidos por un agente
SN (orgánicas)	Nº total de impactos de redes sociales (orgánicas) recibidos por un agente
Tiendas	Nº total de impactos de tiendas o establecimientos recibidos por un agente

Tabla 5: Descripción de las variables de entrada

4.3.3. Marco experimental

En esta sección se presentan la configuración de los parámetros de los algoritmos de SD empleados durante la experimentación y las medidas de calidad consideradas.

Configuración algoritmos. Los algoritmos seleccionados para los experimentos (SDMap, NMEEFSD y FuGePSD) se ejecutaron usando las configuraciones de parámetros que se muestran en la Tabla 6, donde se emplean los valores recomendados en la literatura. Como hemos mencionado anteriormente, SDMap requiere variables categóricas, mientras que los algoritmos difusos pueden manejar variables continuas porque trabajan con etiquetas lingüísticas (3, 5 y 7 en nuestros experimentos preliminares). Se seleccionó la granularidad que proporcionaba la mejor WRAcc para cada uno de los algoritmos (véase la Tabla 6).

Medidas de calidad analizadas. Los valores mostrados en la tabla de resultados corresponden a la media de las distintas medidas de calidad para cada regla el conjunto de reglas. Los indicadores considerados son: número de reglas (n_r) y número de variables (n_v) para medir la concisión; $NWRAcc$ para medir el interés y la precisión, $Conf$ para medir la precisión, y TPR para medir la generalidad. Además, se incorpora la medida FPR para representar reglas en el espacio ROC. Aplicamos los tests no paramétricos de Iman-Davenport [ID80] y Friedman [Fri40] para buscar diferencias significativas. En todos los experimentos se consideró un nivel de significancia $\alpha = 0.05$.

Algoritmo	Parámetro
SDMap	Soporte mínimo = 0.05; función de calidad = $WRAcc$
NMEEFSD	Objetivo 1 = $WRAcc$; objetivo 2 = TPR ; nº de etiquetas lingüísticas = 7; tamaño población = 100; evaluaciones máximas = 10,000; probabilidad de cruce = 0.60; probabilidad de mutación = 0.10
FuGePSD	Fitness = $WRAcc$; nº de etiquetas lingüísticas = 3; tamaño población = 100; generaciones máximas = 1,000; probabilidad de cruce = 0.50; probabilidad de mutación = 0.20; probabilidad de inserción = 0.15; probabilidad de eliminación = 0.15; $w_1 = 0.7$; $w_2 = 0.15$; $w_3 = 0.15$

Tabla 6: Configuración de parámetros para cada algoritmo

4.3.4. Comparación de algoritmos y experimentos

Nuestro objetivo es analizar tanto las diferencias de rendimiento entre los distintos algoritmos de SD considerados y también entre los distintos experimentos correspondientes a distintas elecciones de diseño para la tarea de aprendizaje automático explicable abordada, antes del paso de filtrado. Los resultados promedio por algoritmo y experimento para cada medida de calidad se muestran en la Tabla 7, donde los nombres de los algoritmos se abrevian como NM (NMEEFSD), SD (SDMap) y FU (FuGePSD). Se incluye una última columna con las medias por algoritmo.

La aplicación del test Iman-Davenport presenta diferencias significativas entre algoritmos en Conf, TPR y FPR, y no hay diferencias significativas con respecto a $NWRAcc$. El ranking de Friedman para cada algoritmo en cada medida de calidad se presenta en la Figura 5. El valor mínimo se considera el mejor. Observamos que, en el caso de estudio actual, SDMap es significativamente mejor que NMEEFSD y FuGePSD en Conf y FPR, mientras que FuGePSD es significativamente mejor que NMEEFSD y SDMap en TPR.

La Tabla 7 y la Figura 6 nos permiten extraer las siguientes conclusiones:

- En cuanto a la comprensibilidad de los resultados, podemos observar que los métodos basados en algoritmos evolutivos NMEEFSD y FuGePSD obtienen un número de reglas mucho menor que SDMap. Además, el número de variables de las reglas también es menor. De hecho, NMEEFSD y FuGePSD representan el conocimiento adquirido con sólo 13 y 6 reglas, respectivamente, mientras que el algoritmo SDMap obtiene más de 400 reglas. Esta representación es muy compleja para proporcionársela a los expertos, es necesario aplicar el paso de filtrado para reducir el número de reglas.
- El interés de las reglas se representa mediante la medida de calidad $NWRAcc$. El algoritmo NMEEFSD obtiene la mejor media con un valor ligeramente superior al del algoritmo SDMap.

Métrica	Algoritmo	Exp. 1	Exp. 2	Exp. 3	Exp. 4	Media
nr	SD	605	450	424	365	461
	NM	10	16	11	15	13
	FU	3	7	6	8	6
nv	SD	2.32	2.17	2.07	2.06	2.18
	NM	1.40	1.37	1.36	1.40	1.38
	FU	2.00	1.57	1.67	1.62	1.67
NWRAcc	SD	0.5155	0.5214	0.5173	0.5192	0.5181
	NM	0.5247	0.5206	0.5225	0.5179	0.5210
	FU	0.5344	0.5109	0.5026	0.5030	0.5091
TPR	SD	0.1568	0.1980	0.2076	0.2198	0.1910
	NM	0.6487	0.6168	0.6335	0.6275	0.6295
	FU	0.6495	0.8173	0.8284	0.7861	0.7887
Conf	SD	0.5652	0.4757	0.4444	0.4478	0.4923
	NM	0.5073	0.3815	0.4316	0.362	0.4107
	FU	0.5423	0.4178	0.4018	0.3601	0.4101

Tabla 7: Resultados promedio por algoritmo y experimento para cada métrica de calidad. La última columna muestra la media por algoritmo.

- Con respecto al balance entre generalidad y precisión, es muy difícil decidir cuál es el mejor algoritmo, ya que los algoritmos evolutivos (NMEEFSD y FuGePSD) obtienen buenos resultados en generalidad, mientras que SDMap es el mejor algoritmo en confianza. Esta afirmación se debe en sí misma a las reglas que se han obtenido en los distintos experimentos. Por lo tanto, las necesidades de los expertos guiarán el estudio posterior de este problema.
- Si observamos las áreas ROC, hay una clara diferencia entre algoritmos: SDMap obtiene numerosas reglas que se encuentran en la zona blanca para los cuatro experimentos, es decir, reglas con una buena relación entre TPR y FPR, y con NWRAcc superior a 0.55. Sin embargo, NMEEFSD y FuGePSD sólo obtienen una regla cada uno en la zona blanca para el experimento 2 y el experimento 1, respectivamente. Aunque los resultados de TPR de SDMap son bajos y proporciona un número muy elevado de reglas para analizar, la inusualidad y la relación TPR/FPR indican que las reglas obtenidas por SDMap pueden ser más interesantes para el caso de estudio que aquellas extraídas por los algoritmos evolutivos que son más genéricas y menos interesantes para este problema.

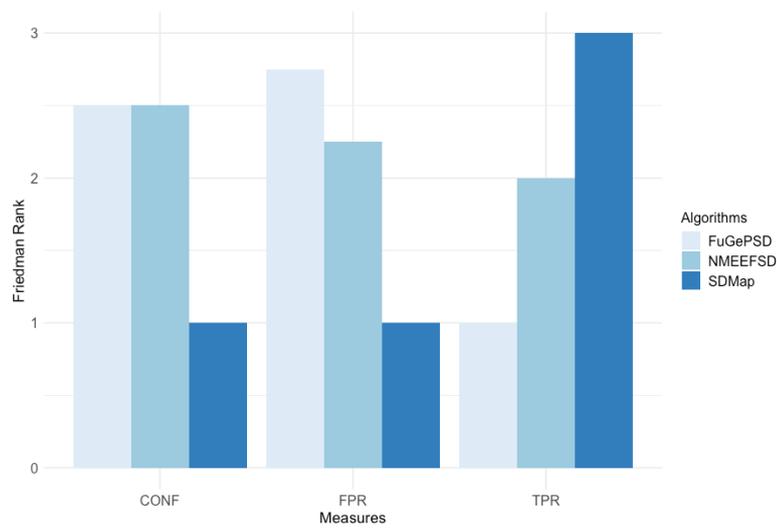


Figura 5: Ranking de Friedman de los algoritmos analizados. Para cada medida, el algoritmo con el valor mínimo se considera el mejor.

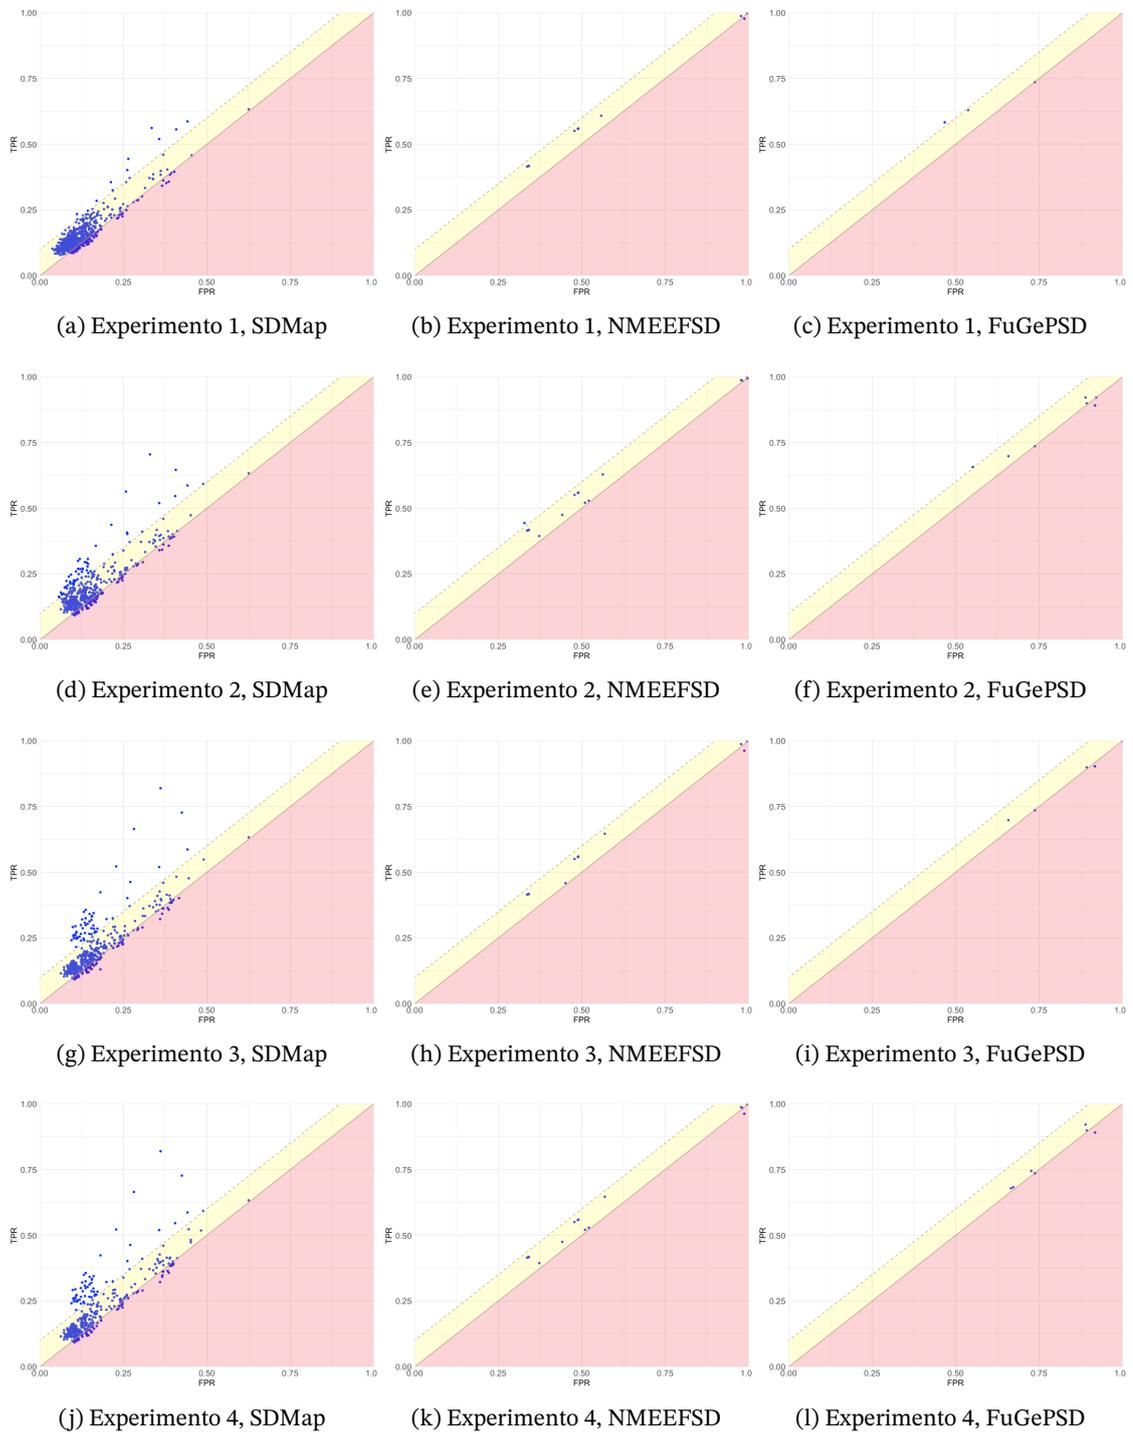


Figura 6: Curvas ROC para cada experimento y algoritmo. Los puntos en el área roja corresponden a reglas con $WR_{Acc} < 0,5$, los puntos del área amarilla representan reglas con $0,5 < WR_{Acc} < 0,55$, y los puntos restantes corresponden a reglas con $WR_{Acc} > 0,55$.

4.4. Análisis experto sobre el caso de estudio

En esta sección, seleccionamos una instancia concreta del caso de estudio y, mostrando las reglas obtenidas por el algoritmo seleccionado, las analizamos desde el punto de vista de un experto en marketing. Pretendemos mostrar la eficacia de la metodología propuesta mediante la demostración de la utilidad práctica de las reglas generadas para obtener *insights* valiosos sobre el mercado analizado.

Seleccionamos las reglas obtenidas por SDMap, ya que en este caso de estudio es el único algoritmo que proporciona reglas que superen el filtro de inusualidad. Este conjunto de reglas tiene buena precisión, inusualidad y ratio TPR/FPR. Estas métricas son de mayor interés para el problema actual. El conjunto inicial de se reduce filtrándolas mediante umbrales de calidad para la inusualidad ($NWR_{Acc} > 0.55$) y la confianza ($Conf > 0.5$), y seleccionando aquellas reglas más específicas (es decir, aquellas no contenidas en otras). Además, nos centramos en el experimento 2 por ser el que tiene un mayor número de reglas tras el filtrado y el que proporciona un conocimiento más valioso para los profesionales del marketing. Tras aplicar todos los filtros, reducimos el conjunto de reglas de 450 a 23.

En el experimento 2, la variable objetivo se dividió en tres categorías teniendo en cuenta el número de compras: agentes que no compren (*ninguna compra*), agentes que compren solo una vez (*una compra*) y agentes que compren más de una vez (*más de una compra*). La Tabla 8 muestra el conjunto de reglas seleccionadas, incluyendo tanto la composición de la regla como sus medidas. Para proporcionar una visión más clara y sencilla de la estructura de las reglas para el experto, incluimos un gráfico jerárquico en la Figura 7. Al analizar estas reglas podemos observar los hechos descritos a continuación.

Como se ha dicho, obtuvimos 23 reglas con un buen equilibrio entre generalidad y fiabilidad. En particular, obtuvimos 20 reglas para la categoría *más de una compra* y tres para la categoría *ninguna compra*. Por lo tanto, no obtuvimos reglas para todos los valores de la variable objetivo debido a los umbrales de calidad establecidos. Esto significa que no hay reglas fiables y de interés para la categoría *una compra*. Esto es común en SD, ya que este enfoque de XAI no busca obtener patrones genéricos en el dominio de aplicación, sino descubrir conocimiento específico e interesante. Las reglas seleccionadas tienen un máximo de tres variables en el antecedente, lo que las hace fácilmente interpretables.

Para la categoría *más de una compra*, la regla con los NWR_{Acc} y TPR más altos es R_1 , que relaciona que los agentes que hablan y escuchan mucho sobre una marca pero no reciben ningún impacto del *touchpoint Tiendas*, compran más de una vez. La regla más fiable es R_{13} , que indica que los agentes que hablan y escuchan mucho sobre una marca y reciben un impacto bajo del *touchpoint TV Long Agg. HH* suelen comprar más de una vez.

Para la categoría *no compra*, la regla R_{21} indica que los agentes que hablan y escuchan poco sobre una marca no suelen comprar el producto. Esta regla es la que alcanza los valores más altos para NWR_{Acc} , $Conf$ y TPR. Aunque parezca una regla obvia, la presencia de este tipo de reglas ayuda a aumentar la confianza en el conocimiento extraído de la salida del algoritmo.

Regla	NWRAcc	Conf	Sens
R_1 : Hablar = Alto y Escuchar = Alto y Tiendas = Ninguno \rightarrow Compras >1	0.5850	0.5196	0.3569
R_2 : Hablar = Alto y Escuchar = Alto y OOH = Ninguno \rightarrow Compras >1	0.5597	0.5214	0.2491
R_3 : Hablar = Alto y Escuchar = Alto y TV Short Rest = Alto \rightarrow Compras >1	0.5693	0.5745	0.2472
R_4 : Hablar = Alto y Escuchar = Alto y TV Long Agg. Rest = Ninguno \rightarrow Compras >1	0.5689	0.5850	0.2398
R_5 : Hablar = Alto y Escuchar = Alto y SN (pagadas) = Alto \rightarrow Compras >1	0.5524	0.5082	0.2296
R_6 : Hablar = Alto y Escuchar = Alto y TV Short HH = Alto \rightarrow Compras >1	0.5559	0.5306	0.2258
R_7 : Hablar = Alto y Escuchar = Alto y SN (orgánicas) = Alto \rightarrow Compras >1	0.5528	0.5160	0.2249
R_8 : Hablar = Alto y Escuchar = Alto y TV Long Agg. HH = Alto \rightarrow Compras >1	0.5583	0.5524	0.2203
R_9 : Hablar = Alto y Escuchar = Alto y TV Long Rest = Alto \rightarrow Compras >1	0.5524	0.5210	0.2193
R_{10} : Hablar = Alto y Escuchar = Alto y SN (orgánicas) = Bajo \rightarrow Compras >1	0.5546	0.5427	0.2128
R_{11} : Hablar = Alto y Escuchar = Alto y TV Short HH = Bajo \rightarrow Compras >1	0.5506	0.5205	0.2119
R_{12} : Hablar = Alto y Escuchar = Alto y SN (pagadas) = Bajo \rightarrow Compras >1	0.5555	0.5578	0.2063
R_{13} : Hablar = Alto y Escuchar = Alto y TV Long Agg. HH = Bajo \rightarrow Compras >1	0.5524	0.5920	0.1794
R_{14} : Hablar = Alto y Tiendas = Ninguno y TV Long Agg. Rest = Ninguno \rightarrow Compras >1	0.5557	0.5757	0.1980
R_{15} : Hablar = Alto y Tiendas = Ninguno y TV Short Rest = Alto \rightarrow Compras >1	0.5514	0.5512	0.1952
R_{16} : Hablar = Alto y TV Long HH = Alto \rightarrow Compras >1	0.5625	0.5134	0.2677
R_{17} : Hablar = Alto y TV Long Rest = Ninguno \rightarrow Compras >1	0.5516	0.5188	0.2175
R_{18} : Hablar = Alto y TV Long Rest = Bajo \rightarrow Compras >1	0.5524	0.5236	0.2165
R_{19} : Hablar = Alto y OOH = Alto \rightarrow Compras >1	0.5557	0.5461	0.2147
R_{20} : Hablar = Alto y TV Long HH = Ninguno \rightarrow Compras >1	0.5559	0.5714	0.2007
R_{21} : Escuchar = Bajo y Hablar = Bajo \rightarrow Compras = 0	0.5699	0.5727	0.4015
R_{22} : Escuchar = Bajo y Tiendas = Ninguno \rightarrow Compras = 0	0.5510	0.5464	0.3706
R_{23} : Hablar = Bajo y Tiendas = Ninguno \rightarrow Compras = 0	0.5532	0.5654	0.3244

Tabla 8: Reglas obtenidas para una instancia concreta del caso de estudio mediante el algoritmo SDMap.

Respecto a la estructura de las reglas, las variables relacionadas con eventos de *hablar* y *escuchar* están normalmente presentes en todos los antecedentes de las reglas. Su importancia es clara. Cuando los agentes hablan y escuchan mucho sobre una marca, sus compras son más altas, como se ve en las reglas R_1 a R_{13} . Por el contrario, cuando los agentes no hablan mucho sobre una marca, no hay compras, como se ve en las reglas R_{21} a R_{23} . Este hecho refuerza la relevancia del efecto WOM en el mercado actual.

La estructura básica representada por los eventos de hablar y escuchar (proceso WOM) se combina con el resto de las variables (*touchpoint*) en las reglas, permitiéndonos analizar diferentes comportamientos del mercado. Como se muestra en diferentes subconjuntos de reglas en las Tablas 9, 10 y 11, los *touchpoints* afectan a los agentes de diferentes maneras.

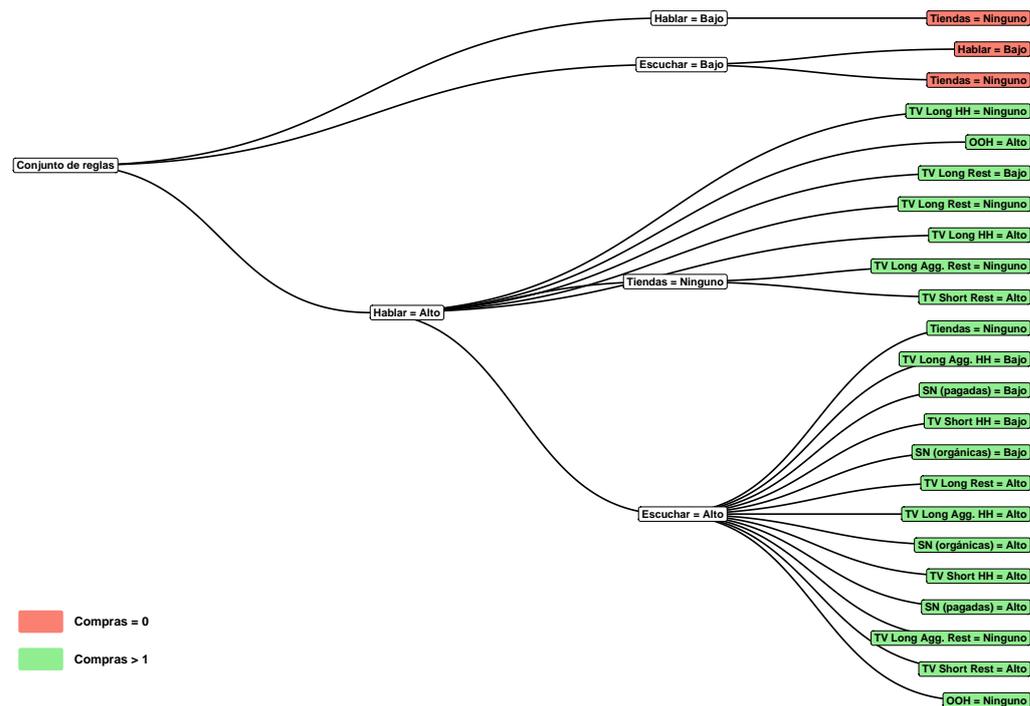


Figura 7: Gráfico jerárquico que representa la estructura del conjunto de reglas obtenidas para una instancia concreta del caso de estudio. Cada nodo representa un antecedente, y las aristas conectan variables dentro de la misma regla. El color de los nodos de las hojas indica el valor del consecuente (es decir, las compras): rojo para *ninguna compra* y verde para *más de una compra*.

Variables cuyo valor alto implica más de una compra. Estas reglas, mostradas en la Tabla 9, representan subgrupos de agentes que recibieron muchos impactos de estos *touchpoints* y, por lo tanto, compran más de una vez. Por ejemplo, observamos este comportamiento en las reglas R_3 y R_9 que corresponden a los *touchpoints* *TV Short Rest* y *TV Long Rest*, respectivamente.

Regla
R_3 : Hablar = Alto y Escuchar = Alto y TV Short Rest = Alto \rightarrow Compras >1
R_9 : Hablar = Alto y Escuchar = Alto y TV Long Rest = Alto \rightarrow Compras >1

Tabla 9: Subconjunto de reglas de una instancia concreta del caso de estudio donde un alto número de impactos de un *touchpoint* implica más de una compra.

Variables cuyos valores alto y bajo implican más de una compra. En este caso, independientemente de la intensidad de los *touchpoints*, los agentes compran más de una vez (ver Tabla 10). Por ejemplo, observamos este hecho en las reglas R_5 , donde el *touchpoint* *SN (pagadas)* tiene un valor alto, y R_{12} , donde el mismo *touchpoint* tiene un valor bajo. Esto también ocurre con el *touchpoint* *SN (orgánicas)* en las reglas R_7 y R_{10} , *TV Long Agg. HH* en las reglas R_8 y R_{13} , y *TV Short HH* en las reglas R_6 y R_{11} . Este análisis nos permite identificar *touchpoints* altamente influyentes en el mercado actual que, independientemente de su volumen, pueden impulsar a los agentes a incrementar sus compras. Por un lado, para ciertos subgrupos de consumidores es posible incentivarlos a comprar más de una vez con pocos impactos. Por otro lado, para otros subgrupos de consumidores se necesita un mayor número de impactos para alcanzar el mismo nivel de compras.

Regla
R_5 : Hablar = Alto y Escuchar = Alto y SN (pagadas) = Alto \rightarrow Compras >1
R_6 : Hablar = Alto y Escuchar = Alto y TV Short HH = Alto \rightarrow Compras >1
R_7 : Hablar = Alto y Escuchar = Alto y SN (orgánicas) = Alto \rightarrow Compras >1
R_8 : Hablar = Alto y Escuchar = Alto y TV Long Agg. HH = Alto \rightarrow Compras >1
R_{10} : Hablar = Alto y Escuchar = Alto y SN (orgánicas) = Bajo \rightarrow Compras >1
R_{11} : Hablar = Alto y Escuchar = Alto y TV Short HH = Bajo \rightarrow Compras >1
R_{12} : Hablar = Alto y Escuchar = Alto y SN (pagadas) = Bajo \rightarrow Compras >1
R_{13} : Hablar = Alto y Escuchar = Alto y TV Long Agg. HH = Bajo \rightarrow Compras >1

Tabla 10: Subconjunto de reglas de una instancia concreta del caso de estudio donde un número alto y bajo de impactos de un *touchpoint* implica más de una compra.

Variables no asociadas positivamente a más de una compra. Como se muestra en las reglas de la Tabla 11, este comportamiento está vinculado a los *touchpoints* *Tiendas* en la regla R_1 , *OOH* en la regla R_2 , y *TV Long Agg. Rest* en la regla R_4 . En estos casos, el conocimiento adquirido es útil para descubrir *touchpoints* ineficientes del mercado.

Regla
R_1 : Hablar = Alto y Escuchar = Alto y Tiendas = Ninguno \rightarrow Compras >1
R_2 : Hablar = Alto y Escuchar = Alto y OOH = Ninguno \rightarrow Compras >1
R_4 : Hablar = Alto y Escuchar = Alto y TV Long Agg. Rest = Ninguno \rightarrow Compras >1

Tabla 11: Subconjunto de reglas de una instancia concreta del caso de estudio que muestran *touchpoints* que no están asociados positivamente con más de una compra.

Finalmente, resumimos las conclusiones generales extraídas de las observaciones y análisis realizados sobre los diferentes subconjuntos de reglas. Cabe destacar los siguientes aspectos:

- En este mercado, uno de los principales factores para obtener ventas para una marca es la comunicación social entre los consumidores objetivo. Como hemos observado a través de las reglas, aquellos impactos publicitarios que refuerzan la viralidad de una marca son capaces de aumentar notablemente el número de compras de la marca. Por lo tanto, el análisis refuerza la importancia del WOM en impulsar las compras en una representación de mercado del sector de la restauración.
- Las reglas permiten evaluar la efectividad de los distintos *touchpoints*. Por ejemplo, como podemos ver que las reglas que muestran valores altos para la variable *TV Short Rest* están asociadas con más de una compra, podemos inferir que este *touchpoint* es un canal de marketing efectivo, al menos en ciertos grupos de consumidores. Por otra parte, es posible identificar canales publicitarios que no son eficientes. Hay subgrupos de consumidores en los que ciertos *touchpoints* no están asociados positivamente con compras (por ejemplo, *OOH*). Este conocimiento puede ayudar a los profesionales del marketing a redirigir el presupuesto y las campañas hacia los canales más efectivos del mercado específico.
- Podemos identificar grupos de consumidores objetivo y ajustar microestrategias para cada uno de ellos. Por ejemplo, hay un grupo de consumidores que, al recibir un alto impacto del *touchpoint SN (orgánicas)*, realizan más de una compra, mientras que otros consumidores alcanzan el mismo nivel de compras habiendo recibido un impacto bajo del mismo *touchpoint*. Identificar estos subgrupos puede ayudar a dirigir las estrategias más adecuadas para cada uno. Además, al analizar las reglas que no incluyen la variable (por ejemplo, *SN (orgánicas)*), los profesionales del marketing pueden identificar otros grupos de consumidores que pueden no ser tan receptivos a las campañas de SN orgánicas, y dirigirse a ellos con diferentes estrategias de marketing. Esta segmentación permite una optimización más efectiva de los recursos y una mejor orientación de las campañas publicitarias.

4.5. Conclusiones

En este capítulo hemos propuesto una metodología XAI basada en la aplicación de SD para extraer reglas interesantes e interpretables a partir de los resultados a nivel micro de las simulaciones de ABM, con el objetivo final de interpretar mejor el comportamiento de los agentes. La metodología propuesta engloba pasos de preprocesamiento de datos, aplicación del algoritmo de SD, filtrado de reglas y visualización, junto con la integración de un experto humano en el proceso para proporcionar *feedback* que ayude a refinar los resultados. Aunque la metodología es genérica para cualquier modelo basado en agentes calibrado y validado, en este capítulo se ha aplicado a un caso de estudio real de ABM en marketing para demostrar su efectividad. Analizamos la integración de diferentes algoritmos de SD (específicamente SMap, NMEEFSD y FuGePSD). Finalmente, estudiamos las reglas obtenidas para una instancia concreta del caso de estudio desde la perspectiva de un experto en marketing, confirmando su utilidad práctica para obtener información valiosa sobre el mercado

analizado. El estudio experimental se realizó con un conjunto de datos resultante de una simulación específica de una empresa proporcionada por el software Zio [CCR⁺23]. Este trabajo nos ha llevado a los siguientes hallazgos:

- La metodología propuesta es fácil de aplicar y generalizable. Los pasos detallados en nuestra metodología se pueden seguir y adaptar fácilmente a diferentes áreas, lo que la convierte en una herramienta versátil para analizar las salidas de modelos basados en agentes en distintos dominios.
- El mecanismo de filtrado integrado en nuestra metodología funciona bien, asegurando que solo se mantengan las reglas más significativas y fiables para el análisis a la vez que reduce significativamente el número de reglas, lo que hace que el análisis sea más interpretable.
- El paso de visualización de reglas facilita el análisis por parte de los expertos. Las reglas extraídas se presentan en un formato claro y accesible, lo cual ayuda en su interpretación.
- La comparación entre algoritmos es difícil ya que cada uno destaca en algún aspecto. Sin embargo, SDMap es el más ventajoso en nuestro problema porque la inusualidad (medida clave en SD) de las reglas obtenidas es de más interés para este contexto que las reglas genéricas obtenidas por los algoritmos evolutivos.
- Para la instancia seleccionada del caso de estudio, obtuvimos reglas interesantes con un buen equilibrio entre generalidad y fiabilidad. Además, como máximo tienen tres variables en el antecedente, lo que las hace fácilmente interpretables.
- Desde un punto de vista de marketing, reforzamos la idea que la interacción WOM entre los agentes es un motor clave de las ventas en el mercado de la restauración analizado. También descubrimos que los *touchpoints* afectan a los agentes de diferentes maneras y que algunos canales publicitarios no están asociados positivamente con las compras. Las reglas obtenidas nos permiten evaluar la efectividad de los canales de marketing e identificar grupos de clientes objetivo y potenciales áreas de oportunidad para la empresa, lo que ayuda a los profesionales del marketing a ajustar su estrategia.

Nuestra metodología tiene ciertas limitaciones y factores clave para su aplicación exitosa. Una limitación es la necesidad de la intervención de expertos para asegurar una aplicación efectiva. Además, se pueden generar demasiadas reglas, pero gracias al mecanismo de filtrado, podemos mejorar la interpretabilidad para los expertos en cuanto al número de reglas obtenidas y así facilitar su análisis. Otro inconveniente es que la agregación de datos durante todo el período puede resultar en la pérdida de información, como puntos de inflexión en el comportamiento de los agentes.

Para aplicar nuestra metodología con éxito, es esencial que nos aseguremos de usar un conjunto de datos generado por un modelo basado en agentes calibrado y validado. Además, no se recomienda usar solo un algoritmo de SD, ya que no es universal. Emplear y comparar

múltiples métodos puede ayudar a determinar la opción que mejor se ajusta al problema. También es importante contar con un experto en el área de aplicación que pueda proporcionar orientación durante la fase de diseño inicial, para la toma de decisiones y para interpretar los resultados de manera efectiva. Al abordar estas limitaciones y considerar estos factores clave, podemos mejorar la efectividad y precisión de nuestra metodología.

Capítulo 5

Propuesta III: Focalización de micropolíticas de incentivos para la adopción de tecnologías verdes con ABM

En este capítulo se propone la aplicación de estrategias de focalización de incentivos con ABM para fomentar la adopción de tecnologías sostenibles en la industria marítima. Tras la introducción, se presenta el estado del arte sobre el uso de ABM en la adopción de tecnologías verdes y focalización. Luego, se describe el modelo propuesto y los datos empleados en los experimentos, seguidos de la presentación y análisis de los resultados principales. Posteriormente, se discuten las implicaciones del trabajo y, finalmente, se resumen las conclusiones obtenidas.

5.1. Introducción

En este capítulo presentamos la tercera y última contribución de esta tesis donde abordamos un problema práctico y relevante en el área de adopción de tecnologías sostenibles en de la industria marítima. Esta contribución se centra en el diseño de políticas de focalización de incentivos para fomentar la adopción de estas tecnologías, usando ABM para evaluar la efectividad de las estrategias. Además, se incorporan técnicas de visualización de XAI para mejorar la comprensión de la relación entre diferentes escenarios, políticas y salidas del modelo. Esta integración potencia el papel del ABM como herramienta para la toma de decisiones, ya que permite optimizar la efectividad de las políticas diseñadas y obtener conocimiento fundamental para la planificación de políticas.

La industria marítima es una gran contribuyente a las emisiones de gases de efecto invernadero, a pesar de los esfuerzos por introducir mejoras tecnológicas y prácticas de transporte más sostenibles [Lis15, LLWC13]. Los costes de ampliación y las limitaciones de producción dificultan la adopción de estas tecnologías a gran escala. Estudios recientes cuestionan el impacto de los marcos regulatorios debido a sus complejidades financieras, sugiriendo la necesidad de soluciones inteligentes de ingeniería financiera y de incentivos a nivel micro adaptados a empresas navieras o embarcaciones específicas [Sch22, CHL23]. El uso de políticas de incentivos, como los subsidios, parece ser una forma de aumentar la adopción de tecnologías verdes, aunque no hay demasiada literatura al respecto. Se ha demostrado que los subsidios institucionales son esenciales para equilibrar las dinámicas del mercado hasta que ya no sean necesarios [ZTWZ24]. Los subsidios en la industria marítima mejoran las ganancias, la sostenibilidad y el bienestar social, y pueden estabilizar las dinámicas del mercado en comparación con otros tipos de regulaciones [HLZ23]. Sin embargo, la cuestión de cómo elegir mejor los destinatarios de los subsidios para mejorar la eficacia en la promoción de tecnologías verdes sigue sin respuesta.

Para abordar esta laguna de conocimiento, la pregunta que nos planteamos es cómo se pueden utilizar de manera más eficiente los subsidios para la adopción de tecnologías sostenibles. Nuestra propuesta es resolver este problema optimizando la selección de beneficiarios de los subsidios dentro de una población heterogénea de posibles adoptantes. Por lo tanto, en lugar de distribuir uniformemente los incentivos entre todas las embarcaciones, proponemos asignarlos estratégicamente para optimizar el uso de recursos y el impacto. Nuestro estudio se centra en la adopción de Tecnología de Propulsión Eólica (WPT, por sus siglas en inglés) [TR23] como tecnología verde, dada su importancia y la disponibilidad de datos sobre la tecnología. En concreto, se considera la readaptación de las embarcaciones más antiguas frente a la integración de la WPT en las embarcaciones nuevas, dados los costes de construcción y el riesgo de que la WPT no funcionen como se espera [BÖBN17]. Aún así, una de las barreras más importantes para adoptar esta tecnología son los costes de instalación, por lo que los subsidios del estudio están destinados a mitigar dichos costes.

Por tanto, nuestro modelo se centra en aplicar políticas de focalización [RMPS22] a un conjunto reducido de posibles adoptantes que obtienen subsidios para los costes de instalación de la WPT. Se usa ABM [Bon02] para simular cómo se adopta la WPT al aplicar las políticas de focalización. La capacidad del ABM para representar la interacción entre agentes facilitan la inclusión de actividades de *networking* o red de contactos como una forma

de aumentar el conocimiento sobre la tecnología, dada su importancia en la adopción de tecnologías verdes [JPM⁺17].

Nuestra propuesta tiene como objetivo extender el diseño previo de [CHL23] incorporando una forma de dirigir las políticas de incentivos a un conjunto limitado de agentes clave o semillas. La decisión de adoptar o no se basa en una función de utilidad que combina factores sociales y económicos mediante un factor modulador, pero un posible adoptante necesita previamente tener conocimiento de la tecnología. Diseñamos varias políticas de incentivos, considerando diferentes atributos de las embarcaciones para identificar a los agentes clave a los que se deben dirigir los incentivos. Se consideran factores como la edad de las embarcaciones, su consumo de energía y su conectividad dentro de la red para asegurar que los incentivos se dirijan a las embarcaciones con mayor probabilidad de adoptar la WPT y que también sean capaces de contribuir a su difusión.

A través de simulaciones basadas en agentes, se analizan las diferentes estrategias de focalización para entender cuáles superan a las demás y también se comparan con la estrategia de asignar subsidios a todas las embarcaciones. Los experimentos también evalúan la eficacia de las políticas diseñadas en diferentes escenarios, incluyendo variaciones en los precios del combustible, en la densidad de la SN, las distancias de navegación, los subsidios y el porcentaje de embarcaciones seleccionadas. Los impactos potenciales de estos escenarios se estudian utilizando curvas S-ICE, una modificación de las curvas ICE presentadas en la Sección 2.2.2. Esta técnica de XAI nos proporcionará una comprensión más profunda de cómo se comportan las políticas de focalización bajo diferentes escenarios, permitiendo optimizar la efectividad de las mismas y mejorar la confianza de los responsables del diseño de las políticas de incentivos.

El capítulo está estructurado como sigue. En primer lugar, la Sección 5.2 proporciona un estado del arte sobre el uso del ABM en la adopción de tecnologías verdes y focalización. La Sección 5.3 describe el modelo propuesto. La Sección 5.4 describe el diseño de la experimentación (datos reales utilizados y configuración de parámetros); además, esta sección muestra y analiza los resultados principales alcanzados. La Sección 5.5 discute los principales hallazgos derivados de la experimentación. Finalmente, la Sección 5.6 resume las principales conclusiones del estudio realizado, así como los posibles trabajos futuros a partir de las limitaciones que presenta el trabajo llevado a cabo.

5.2. Estado del arte del ABM para la adopción de tecnologías verdes y focalización de incentivos

Como mencionamos en la Sección 2.1.4, el ABM se ha convertido en un método popular para analizar la adopción de tecnologías verdes y las políticas de promoción para dichas tecnologías [RRB24]. Una de las tecnologías verdes más estudiadas en la literatura de ABM ha sido la adopción de vehículos eléctricos [STÁ⁺12, ML14, HLZ⁺21] y combustibles alternativos en la industria automovilística [ZGG11, SKGV15]. En [RH16] se presenta una revi-

sión centrada en las elecciones energéticas de los consumidores con un énfasis particular en cómo crear y promover la adopción de tecnologías verdes utilizando ABM. En [HC19] se proporciona una revisión de la adopción de eficiencia energética usando ABM, destacando cómo estos modelos pueden ayudar a formular recomendaciones de políticas concretas, como reducciones de impuestos. En [SZE⁺20] se explora la relación entre la calidad de la información para los usuarios potenciales y la aceptación tecnológica entre pequeñas y medianas empresas, y cómo las redes interempresariales se relacionan con el flujo de información y la calidad de la difusión tecnológica.

Concretamente en la industria marítima, el ABM se ha utilizado para analizar políticas que promuevan la difusión de tecnologías de transporte más limpias. En [KPR19] se analizan la división de incentivos de agentes con información imperfecta y su relación con las políticas climáticas y energéticas en la difusión de un tipo de WPT. En [CHL23] se usa ABM para estudiar los efectos de diferentes escenarios de políticas y mercados (es decir, subsidios, precios del combustible y *networking*) en la adopción de soluciones de readaptación de WPT, incluyendo tres opciones de WPT. Más recientemente, en [MSK24] se propone MATISSE-SHIP, un modelo basado en agentes que muestra los impactos potenciales de la readaptación en la industria marítima y las barreras e incentivos que pueden afectar la adopción de tecnologías de bajas emisiones.

La literatura de ABM también ha explorado los factores que impulsan la adopción de tecnologías sostenibles. Los agentes deciden adoptar basándose en factores internos, como beneficios y capacidad, así como factores externos vinculados con las relaciones y redes entre agentes [KGSW12, ZV19]. En [KPMS⁺14] se destaca el papel de la opinión del consumidor y su susceptibilidad al cambio como factores clave. En [PM20] se sugiere que se necesita una mejor comprensión de las intenciones del usuario y cómo estas intenciones se traducen en comportamiento. En [BJSWW16] se centran en la importancia de los factores sociales y la dificultad de participar en la adopción de productos y prácticas sostenibles.

El papel social en la adopción es importante y, dentro de este marco, la identificación de actores clave y el desarrollo de estrategias para dirigirse a ellos pueden influir y acelerar significativamente la difusión de información y la adopción de innovaciones [MB17]. Aunque hay numerosos ejemplos de ABM sobre estrategias de focalización para la difusión de innovaciones [DJB07, VEJL11, CKWZ21], hay menos investigación sobre focalización de agentes centrada en políticas de incentivos y específicamente para energía y tecnología verdes. El ejemplo más cercano es el modelo de [RMPS22]. Los autores usaron ABM para estudiar varias estrategias de focalización basadas en redes interempresariales. Las empresas seleccionadas reciben información sobre tecnología verde, tras lo cual deciden si quieren adoptarla o no.

5.3. Metodología propuesta

Esta sección proporciona una descripción detallada del modelo propuesto para la adopción de WPT y la aplicación de políticas de focalización. En primer lugar, la Sección 5.3.1 presenta el esquema general del modelo. La Sección 5.3.2 explica cómo incorporar políticas de focalización en el modelo. A continuación, las Secciones 5.3.3, 5.3.4 y 5.3.5 describen los

módulos principales del modelo.

5.3.1. Estructura general del modelo

El modelo basado en agentes representa una población de N embarcaciones y simula la adopción de WPT durante un periodo de tiempo T . Cada instante de tiempo $t \in \{0, \dots, T - 1\}$ de la simulación representa un mes. Al principio de la simulación, todas las embarcaciones $i \in \{1, \dots, N\}$ tienen tecnología basada en combustible por defecto, por lo que no se consideran adoptantes iniciales, dada la baja tasa de adopción real de WPT en la industria marítima. La simulación sigue tres fases diferentes: focalización de incentivos, conocimiento de la WPT y adopción final por las embarcaciones. Es importante destacar que las embarcaciones deben conocer la existencia de la tecnología para ser capaces de adoptarla. Una vez que conocen la tecnología, deciden si la adoptan utilizando una heurística de adopción que combina factores económicos y sociales. El diagrama de flujo principal del modelo propuesto se ilustra en la Figura 1.

La WPT a adoptar se caracteriza por un conjunto de características a ser consideradas por los propietarios de las embarcaciones de la población. El conjunto incluye el coste mensual de mantenimiento de la tecnología (C), los costes de instalación o capital (K) y el ratio de reducción del consumo de combustible cuando se instala la WPT ($\sigma \in [0, 1]$). Estas características son fijas para todo el periodo de simulación y para todas las embarcaciones de la población cuando toman la decisión de adoptar o no la tecnología.

En contraste, la población de embarcaciones pertenece a diferentes propietarios y tiene características heterogéneas. Las principales características de cada embarcación i son las siguientes:

- $y_i^0 \in \{1, \dots, Y\}$ representa la edad de la embarcación en años al comienzo de la simulación $t = 0$. La edad de las embarcaciones se usa para calcular los meses restantes de uso (r_i) con una vida útil máxima global de 30 años ($Y = 30$).
- EC_i representa el consumo de energía (es decir, combustible) esperado de la embarcación i bajo condiciones climáticas y operaciones marítimas promedio.
- $a_i^t \in \{0, 1\}$ indica si la embarcación i conoce la tecnología ($a_i = 1$) o no ($a_i = 0$). Esta variable es dinámica y puede cambiar en cada instante de tiempo t . Proporcionaremos más detalles en la Sección 5.3.3.

Además, la población de N embarcaciones se encuentra conectada a través de una SN artificial [WS98, BA99], que representa las relaciones entre las embarcaciones. En particular, elegimos una red libre de escala [BA99] dada su proximidad a las SN reales. Como detallamos en la Sección 2.1.3, este tipo de redes se caracteriza por que la mayoría de los nodos tienen pocas conexiones, mientras que algunos nodos, conocidos como *hubs*, tienen muchas conexiones.

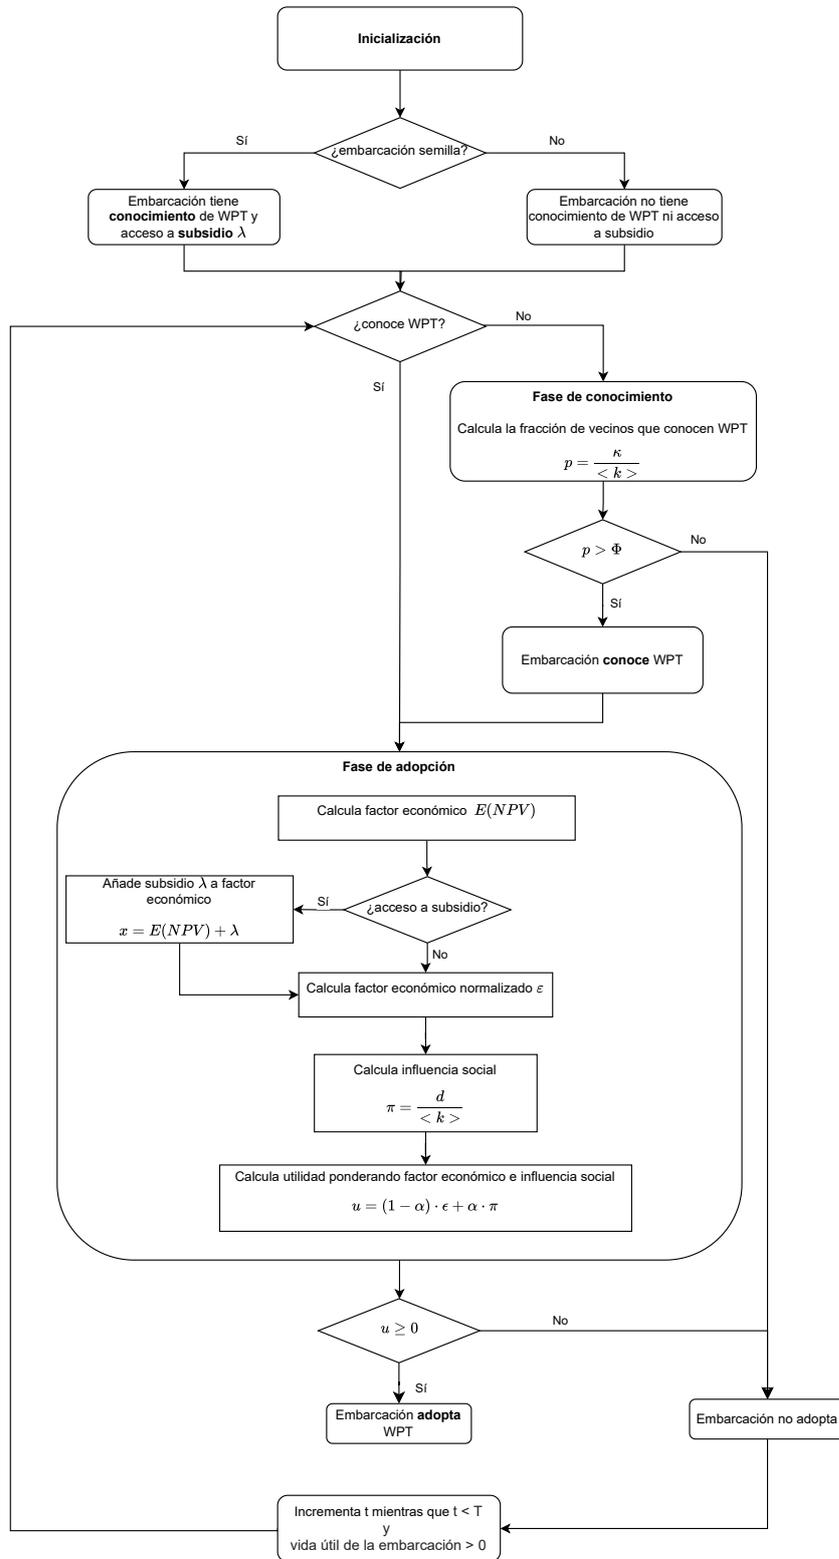


Figura 1: Diagrama de flujo de la adopción de WPT para una sola embarcación, aplicable a todas las embarcaciones de la población.

5.3.2. Selección de embarcaciones para políticas de focalización

Para abordar el objetivo de aplicar políticas de micro-incentivos, necesitamos seleccionar solo un subconjunto de $s \in \{0, 1, \dots, N - 1\}$ embarcaciones de la población a las que dirigir estas políticas. Como veremos en las subsecciones siguientes, la idea principal es que estas embarcaciones seleccionadas (o semillas) sean conscientes de la WPT y tengan acceso a subsidios para aliviar sus costes de instalación.

La selección de embarcaciones se basa en los siguientes atributos: edad (y_i), consumo energético (EC) y número de contactos directos o vecinos en la SN $\langle k \rangle$, también conocido como grado del nodo, un criterio comúnmente utilizado en la literatura de focalización [VEJL11, NWG20]. Estos criterios se combinan para evaluar la conveniencia de cada embarcación i para ser considerado una semilla. La Ecuación 6 muestra la combinación ponderada de estos atributos para obtener su valor de calidad de selección τ_i :

$$\tau_i = \omega_y \left(1 - \frac{y_i}{y_{max}} \right) + \omega_{EC} \frac{EC_i}{EC_{max}} + \omega_{\langle k \rangle} \frac{\langle k \rangle_i}{\langle k \rangle_{max}}, \quad (6)$$

donde ω_y , ω_{EC} y $\omega_{\langle k \rangle}$ representan pesos dentro del rango $[0, 1]$ que se combinan adecuadamente para calcular τ , cumpliendo $\omega_y + \omega_{EC} + \omega_{\langle k \rangle} = 1$.

Al comienzo de la simulación, las s embarcaciones semilla se eligen para aplicar las políticas de subsidios específicas. El algoritmo para identificar el conjunto de semillas consiste primero en evaluar y calcular todos los valores τ_i de las embarcaciones. Luego, esos valores se ordenan en orden descendente para seleccionar a los primeros s agentes a ser seleccionados según τ . Este enfoque se sigue en otros trabajos, como en [CS23].

Según la Ecuación 6, las embarcaciones más nuevas con grados de nodo más altos y EC esperado más alto tendrán un valor τ más favorable y más probabilidades de ser consideradas como una semilla a seleccionar. Los valores finales de τ y las s semillas seleccionadas dependerán de los pesos, e investigaremos sus valores adecuados en la experimentación.

5.3.3. Fase de conocimiento

Este mecanismo permite a los propietarios de las embarcaciones obtener el conocimiento sobre la WPT necesario para determinar si la tecnología es adecuada para sus embarcaciones. Empleamos un proceso ampliamente conocido de difusión de innovación llamado modelo de contagio complejo con umbral [CM07], similar a otros trabajos de ABM sobre la adopción de eco-innovaciones [RMPS22].

Así, en cada instante de tiempo t , una embarcación i que no tiene conocimiento de la WPT tomará consciencia (es decir, $a_i = 1$) si la fracción de vecinos que tienen conocimiento (p_i^t) supera un umbral global de conocimiento $\phi \in [0, 1]$. La Ecuación 7 define este proceso, donde $\langle k \rangle_i$ es el número de vecinos de i en la SN y κ_i^t es el número de vecinos de i que conocen la tecnología en el instante de tiempo t .

$$p_i^t = \frac{\kappa_i^t}{\langle k \rangle_i}. \quad (7)$$

5.3.4. Cálculo del factor económico

Un aspecto clave al adoptar una nueva tecnología como la WPT es el impacto económico, que habitualmente se calcula mediante el *Net Present Value* esperado $E(NPV)$, como en trabajos previos relacionados [CHL23, KPR19]. Definimos $E(NPV)$ en la Ecuación 8.

$$E(NPV)_i^t = \sum_1^{r_i} \frac{F_i^t - C}{(1 + DR)^t} - K, \quad (8)$$

donde DR es una tasa de descuento (fijada en 0.085 como en [KPR19, LMT13]). F_i son los ahorros mensuales de combustible de la embarcación i cuando tiene la WPT bajo condiciones promedio, se calculan usando el factor de ahorro de combustible de la tecnología σ , los precios dinámicos mensuales del combustible $f(t)$ y el consumo de combustible de la embarcación EC_i para una determinada distancia de navegación. Concretamente, los ahorros de combustible para la embarcación i usando WPT, denotados como F_i , se calculan como $F_i^t = \sigma \cdot EC_i \cdot f(t)$. Cuanto mayor sea F_i , más beneficiosa financieramente es la tecnología para la embarcación i .

En el método propuesto, incorporamos políticas de incentivos en el cálculo $E(NPV)$, con el objetivo de fomentar la adopción de la tecnología proporcionando subsidios a un subconjunto específico de embarcaciones, en lugar de proporcionar subsidios a toda la población, como se ha hecho previamente en la literatura relacionada. Un agente embarcación i , si es seleccionado como uno del subconjunto de s agentes a los que se dirigen las políticas de incentivos, se favorece con un valor monetario de subsidio λ para reducir los costes de instalación K . Por lo tanto, podemos extender el factor económico para que el agente i adopte la WPT, x_i , como en la Ecuación 9.

$$x_i^t = \begin{cases} E(NPV)_i^t + \lambda, & \text{si la embarcación } i \text{ es seleccionada} \\ E(NPV)_i^t, & \text{en otro caso} \end{cases} \quad (9)$$

El factor económico debe ser normalizado dentro del rango $[-1, 0]$. La normalización de x_i dentro de este rango se calcula como sigue. Primero, se define un valor mínimo teórico x_{min} , asumiendo el peor escenario de adopción basado en la suposición de tener combustible gratuito ($f(t) = 0, \forall t$) y el número máximo de meses operativos para la embarcación (decir, $r_{max} = 360$). Por tanto, la normalización del factor económico se realiza según la Ecuación 10, con x_{min} igual a $\sum_1^{r_{max}} \frac{-C}{(1+DR)^t} - K$.

$$\epsilon_i^t = \begin{cases} 0, & \text{if } x_i^t \geq 0 \\ \frac{x_i^t - x_{min}}{0 - x_{min}} - 1, & \text{if } x_{min} < x_i^t < 0. \end{cases} \quad (10)$$

En esta formulación, ϵ_i^t representa el valor normalizado de x_i^t . Si x_i^t es no negativo, se asigna 0 a ϵ_i^t . Si x_i^t se encuentra entre x_{min} y 0, se escala y desplaza para ajustarse dentro del rango $[-1, 0]$, usando x_{min} como referencia.

5.3.5. Fase de adopción basada en factores económicos y sociales

Cuando una embarcación i conoce la WPT ($a_i = 1$) y está operativa, puede decidir si adopta o no la tecnología basándose en una función heurística de utilidad. Consideramos que una embarcación está operativa mientras que sus meses de operación restantes sean mayores que cero (es decir, $r_i > 0$). Esta variable r_i se actualiza mensualmente, comenzando en $t = 0$ desde la edad inicial de la embarcación (y_i^0).

Nuestra heurística de adopción sigue la literatura existente sobre la adopción de innovaciones [DJB10]. Aquí, la decisión de adopción de un agente está determinada por un promedio ponderado de factores internos y la influencia social externa de los vecinos. Establecemos los factores internos como el componente económico de la decisión (es decir, completamente racional). La función de utilidad de la Ecuación 11 pondera este promedio de factores internos o económicos $\epsilon_i^t \in [-1, 0]$ ya definidos en la sección previa y una influencia social π_i^t . El parámetro $\alpha \in [0, 1]$ determina el peso dado a la influencia social en la decisión de adopción.

$$u_i^t = (1 - \alpha) \cdot \epsilon_i^t + \alpha \cdot \pi_i^t. \quad (11)$$

La influencia social para cada embarcación i en cada instante t se calcula como la fracción de vecinos que ya han adoptado la WPT, definida por la Ecuación 12:

$$\pi_i^t = \frac{d_i^t}{\langle k \rangle_i}, \quad (12)$$

donde d_i^t es el número de vecinos que ya han adoptado la tecnología en el instante t y $\langle k \rangle_i$ es su grado en la red. Es importante tener en cuenta que esta influencia social $\pi_i \in [0, 1]$ es diferente de p , definida en la Sección 5.3.3, vinculada al conocimiento de la WPT. Por tanto, un agente i puede tener conocimiento de la WPT sin haber adoptado la tecnología, afectando de manera diferente a sus vecinos.

Una embarcación operativa i que tenga tecnología basada en combustible en el instante de tiempo t adoptará la WPT si su valor de utilidad $u_i^t \in [-1, 1]$ es mayor o igual a cero. Este diseño asegura que el componente social solo tenga un impacto positivo en el proceso de toma de decisiones, al mismo tiempo que permite el potencial impacto negativo del factor económico, siendo diferente y más rico que los enfoques similares anteriores en la literatura, donde ambos componentes afectan de manera idéntica. La utilidad será igual o mayor que 0 cuando el factor económico normalizado sea 0. Es decir, cuando el componente económico no normalizado no sea negativo, lo cual indica que la adopción de la tecnología no implica

pérdidas. Esta propiedad garantiza la adopción independientemente del valor del componente social. Sin embargo, si el componente económico normalizado es negativo (es decir, el componente económico no normalizado es negativo), la adopción puede ocurrir cuando el valor positivo social es lo suficientemente alto como para compensar un factor económico relativamente bajo.

5.4. Resultados

En esta sección presentamos el diseño de la experimentación y los principales resultados obtenidos. En primer lugar, la Sección 5.4.1 detalla los datos reales utilizados para alimentar el modelo y los parámetros que configuran la experimentación a realizar. Tras esto, ejecutamos un conjunto diverso de estrategias de focalización siguiendo diferentes criterios para obtener las embarcaciones iniciales a ser incentivadas en la Sección 5.4.2. En la Sección 5.4.3, exploramos cómo cambiar el número inicial de semillas y el presupuesto para subsidios impacta en la adopción. Finalmente, la Sección 5.4.4 estudia cómo diferentes escenarios afectan la adopción de la WPT para la mejor estrategia de focalización.

5.4.1. Diseño de la experimentación

La información y los datos sobre la WPT se obtienen gracias al proyecto WASP financiado por la Unión Europea (<https://northsearegion.eu/wasp>). Recopilamos datos para la WPT Ventifoil, que es la usada en los experimentos. Esta se instaló en una embarcación piloto, permitiéndonos obtener los valores de sus características principales, detalladas en la Tabla 12. Por tanto, para nuestros experimentos, los parámetros C , K , y σ se establecen según los de la tabla.

Característica WPT	Valor
Costes de instalación (K)	321,151€
Costes mensuales de mantenimiento (C)	535.25€
Ahorro de combustible (σ)	2.875 %

Tabla 12: Datos sobre la WPT Ventifoil del piloto del proyecto WASP.

Usamos los mismos datos sobre la población de embarcaciones que en [CHL23]. Estos consisten en datos reales que contienen información sobre $N = 6,009$ embarcaciones extraídas de la base de datos Clarksons y se centran en todos los tipos de embarcaciones con un tonelaje de peso muerto entre 2,000 y 6,500. El precio inicial del combustible se fija en 500€/mt. Este valor se deriva tanto del estudio de Clarksons [Cla22] como de datos internos de las embarcaciones piloto del proyecto WASP.

Este precio inicial del combustible se incrementa durante la simulación bajo dos escenarios de precios. Primero, un escenario pesimista mensual en el que el precio del combustible

aumenta linealmente un 0.5 % cada mes durante 360 meses de simulación. Segundo, un escenario más optimista anual, en el que el precio también aumenta linealmente pero con una actualización del 5 % cada año. Estos dos escenarios se usaron en trabajos previos, aunque se pueden encontrar otros escenarios de precios en la literatura [KDS22, CHR23]. Se consideraron diferentes distancias de navegación (26, 000, 43, 000, 50, 000 y 60, 000 millas náuticas), ya que afectan directamente al EC de las embarcaciones en la población. Cada embarcación en la población tendrá un EC_i diferente, basado en el escenario considerado de la distancia de navegación anual. El método para estimar el EC de las embarcaciones es el descrito en [CHL23].

En cuanto a las simulaciones de ABM, para todos los experimentos ejecutamos el modelo en 30 ejecuciones independientes de Monte Carlo, cada una con semillas aleatorias distintas, promediando todos los resultados a partir de estas ejecuciones de Monte Carlo. Ejecutamos la simulación en 360 pasos, lo que equivale a 30 años de simulación. La vida útil máxima de la embarcación Y se estableció en 30 años, siguiendo trabajos previos [KPR19]. Generamos la red utilizando el algoritmo de unión preferencial de Barabási–Albert [BA99], que utiliza un parámetro m para modular la tasa de crecimiento de la red y su densidad final. Considerando diferentes valores de m , generamos cuatro densidades diferentes de SN libre de escala (SF): SF2, SF4, SF6 y SF8, correspondientes a valores de m de 2, 4, 6 y 8, respectivamente.

Establecimos los valores para el umbral de conocimiento ϕ y el peso de la influencia social α siguiendo la literatura previa debido a la falta de datos históricos sobre la WPT en la industria marítima. Específicamente, fijamos $\phi = 0.4$ y el peso de la influencia social $\alpha = 0.5$ para ser consistentes con trabajos previos y mantener un equilibrio entre los factores sociales y económicos [RMPS22]. Dada la falta de conocimiento sobre la WPT, solo aquellas s embarcaciones seleccionadas por las políticas de focalización de incentivos son conscientes de la tecnología ($a = 1$) al inicio de la simulación. Estas embarcaciones seleccionadas serán las que transmitan el conocimiento de la tecnología al resto de embarcaciones.

5.4.2. Impacto de diferentes estrategias de focalización

Esta sección presenta los resultados de un conjunto de diferentes estrategias de focalización de incentivos. Específicamente, nuestro objetivo es comparar los efectos entre las diferentes estrategias y con la estrategia de referencia de asignar uniformemente los subsidios a todas las embarcaciones, como se hizo en [CHL23]. Para todas las estrategias de focalización y la estrategia de referencia, el presupuesto total para subsidios se mantiene constante para una comparación justa.

No aplicamos solo una estrategia de focalización, sino un conjunto de ellas combinando tres criterios diferentes (medidos por pesos $[\omega_y, \omega_{EC}, \omega_{\langle k \rangle}]$) al ordenar y seleccionar las embarcaciones semilla. Específicamente, consideramos las siguientes ocho estrategias con los valores para los pesos:

- a) Por **edad**, donde las embarcaciones son elegidas solo por su atributo de edad y : $[1, 0, 0]$.

- b) Por **EC** de la embarcación: [0, 1, 0].
- c) Por su **grado**: [0, 0, 1].
- d) Por una combinación de **edad-EC**: [0.5, 0.5, 0].
- e) Por una combinación de **edad-grado**: [0.5, 0, 0.5].
- f) Por una combinación de **EC-grado**: [0, 0.5, 0.5].
- g) Por una combinación de los tres criterios **edad-EC-grado**: [0.33, 0.33, 0.33];
- h) Por una combinación no equilibrada de **0.25EC-0.75grado** para inyectar más importancia a su potencial actividad social: [0, 0.25, 0.75].

En los experimentos se considera el mismo número de semillas. Específicamente, consideramos el 10 % del total de embarcaciones ($s = 0.1N$). Además de las estrategias anteriores, se incluye una estrategia aleatoria donde las s semillas se ubican al azar sin usar los pesos mencionados anteriormente. Los resultados se obtienen para un escenario fijo con una red SF4, una distancia de navegación de 43,000 millas náuticas por año y precios actualizados mensualmente. La estrategia de referencia (*todos*) emplea el mismo presupuesto que todas las estrategias anteriores, pero se distribuye uniformemente entre todas las embarcaciones N . Como se describe en la Sección 5.3.2, las embarcaciones semilla seleccionadas s conocen la WPT al inicio de la simulación. Por tanto, en el caso de distribución uniforme para todas las embarcaciones, también se establece un conocimiento inicial de la WPT del 10 % para una comparación justa.

La Figura 2 ilustra la tasa de adopción de la WPT cuando el presupuesto global se distribuye uniformemente en toda la población (denotada como *todos*) en comparación con todas las políticas de focalización propuestas. Teniendo en cuenta que la cantidad máxima del subsidio por embarcación es de 321,151€ (equivalente a cubrir los costes de instalación completos), establecemos los siguientes escenarios presupuestarios: 193,011,751€ (subvencionando el 100 % de los costes de instalación para s semillas), 174,710,035€ (subvencionando el 90 %), 154,408,920€ (subvencionando el 80 %) y 135,107,805€ (subvencionando el 70 %). Estos presupuestos totales se transforman en las siguientes cantidades de subsidio por embarcación en el enfoque *todos*: 32,120€, 28,908€, 25,696€ y 22,484€, respectivamente.

En la Figura 2 observamos que el enfoque *todos* resulta en prácticamente cero adopciones en todos los presupuestos debido a niveles insuficientes de incentivos. Sin embargo, al utilizar el mismo presupuesto global pero dirigiendo los subsidios al conjunto seleccionado de embarcaciones, la tasa de adopción de la WPT aumenta claramente. En particular, seleccionar embarcaciones basándose en su grado (actividad social) resulta en al menos 25 % de adopción para el presupuesto más alto considerado. Como era de esperar, todas las políticas de focalización son más efectivas a medida que aumenta el presupuesto total. Resulta interesante que cuando se consideran presupuestos más bajos, la focalización por grado no es la mejor opción, sino que es superada por aquellas políticas de focalización que utilizan el EC como criterio.

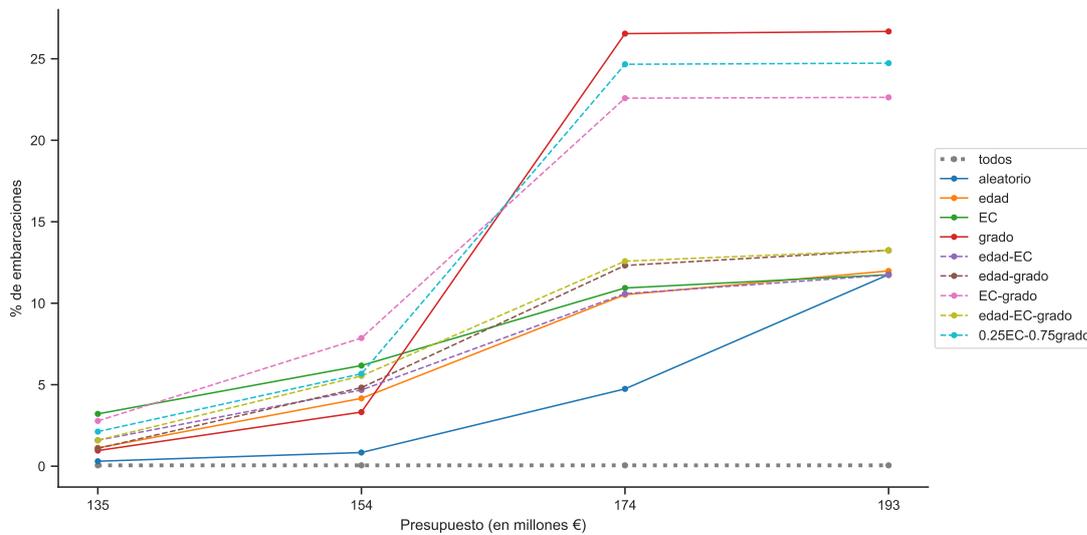


Figura 2: Gráfico de líneas que muestra las tasas de adopción de la WPT (eje Y) para diferentes presupuestos totales (eje X) al considerar alternativas de focalización y subsidios para todas las embarcaciones. La simulación se realizó considerando una distancia de navegación de 43,000 millas náuticas por año, precios de combustible actualizados mensualmente, red SF4, $\phi = 0.4$ y $\alpha = 0.5$. Fijamos el 10% como semillas s y, para la estrategia de *todos*, consideramos un 10% de conocimiento inicial.

5.4.3. Rendimiento de las políticas de focalización bajo diferentes semillas iniciales y subsidios

En esta sección, realizamos un análisis comparativo más profundo de todas las estrategias de focalización propuestas y las comparamos con la estrategia aleatoria. Para este propósito, llevamos a cabo un análisis de sensibilidad en dos parámetros clave: el número de semillas iniciales s y el subsidio para los costes de instalación (λ). Concretamente, el porcentaje de semillas seleccionadas varía del 1% al 10% y los subsidios para los costes de instalación λ van desde 200,000€ hasta 330,000€, con incrementos de 5,000€. Centramos nuestro análisis en los resultados obtenidos considerando una distancia de navegación de 43,000 millas náuticas por año, $\phi = 0.4$, $\alpha = 0.5$, red SF4 y precios de combustible actualizados mensualmente (se observaron dinámicas similares bajo un escenario de precios de combustible actualizados anualmente en experimentos preliminares), como se hizo en la subsección anterior.

Comenzamos la discusión de los resultados mostrando dos paneles diferentes de mapas de calor obtenidos a partir de los experimentos. En primer lugar, un mapa de calor en la Figura 3 que ilustra el porcentaje de embarcaciones que adoptan la WPT tras aplicar una estrategia de focalización aleatoria, sirviendo como referencia para la comparativa. En este mapa

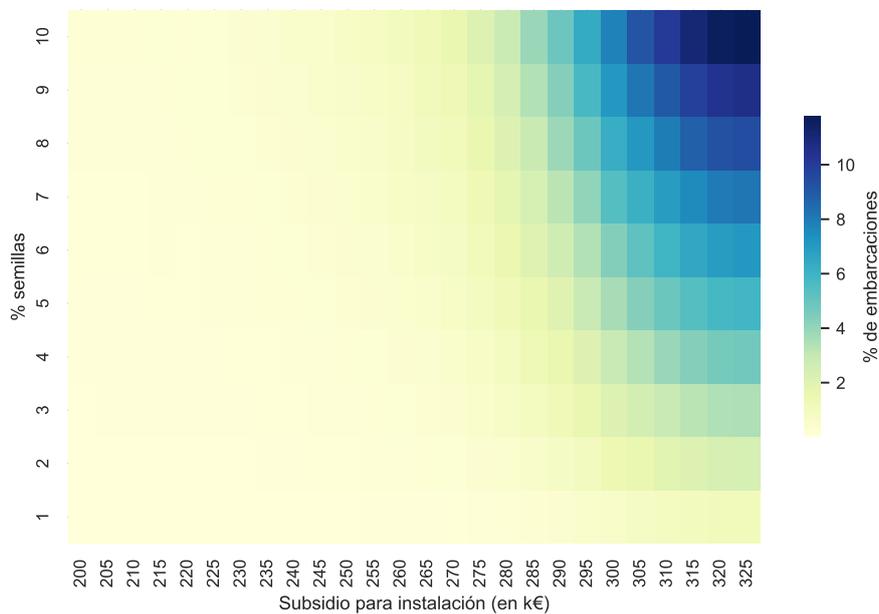


Figura 3: Mapa de calor que muestra un análisis de sensibilidad sobre el subsidio para el coste de instalación por embarcación λ y el porcentaje de semillas de la población N cuando se dirige a semillas aleatorias. Los valores representan el porcentaje de embarcaciones que adoptan la WPT.

de calor observamos que los subsidios por debajo de 300,000€ no son suficientes para iniciar la difusión de la WPT, ya que incluso aquellas embarcaciones que reciben los incentivos no están adoptando la tecnología. Cuando los subsidios superan los 300,000€, prácticamente solo aquellas embarcaciones que reciben subsidios adoptan la tecnología. Por tanto, seleccionar aleatoriamente las embarcaciones objetivo no extiende la adopción de la tecnología más allá de esas embarcaciones seleccionadas.

En segundo lugar, un panel de mapas de calor que muestra las diferencias relativas en las tasas de adopción de la WPT para todas las políticas respecto a la estrategia aleatoria (Figura 4). En este experimento, todas las políticas superan a la política aleatoria en términos de tasas de adopción, ya que las celdas de los mapas de calor tienen color azul, lo que significa un aumento positivo en la adopción. Además, aumentar el porcentaje de semillas (eje Y de los mapas de calor) incrementa las tasas de adopción en todas las políticas. Sin embargo, esta variable parece ser menos determinante que las cantidades de los subsidios, ya que, sin un subsidio adecuado, las tasas de adopción no aumentan significativamente, incluso con un mayor porcentaje de semillas.

La política basada en el grado emerge como la más efectiva cuando se consideran presu-

puestos altos, en línea con los resultados de la subsección anterior. Bajo estas condiciones presupuestarias, las estrategias de focalización basadas en el grado alcanzan diferencias en las tasas de adopción alrededor del 20 %. Las estrategias basadas en el EC parecen ser las más consistentes para todo el rango de cantidades de subsidios (eje X). Sin embargo, las políticas que utilizan la edad de la embarcación y el EC obtienen un aumento de aproximadamente el 6 %, menor que las estrategias basadas en el grado.

Dos mapas de calor se muestran en la Figura 5 para comparar mejor las políticas de focalización basadas en el grado y en el EC. Estos mapas de calor comparan aquellas estrategias que combinan los criterios de grado y EC respecto a la estrategia basada únicamente en el grado. Como se sugirió en la subsección anterior y se muestra en la Figura 5, en ciertos casos ($\lambda < 250,000$), estos enfoques combinados demuestran una mejora en la adopción de hasta un 5 % sobre la política basada en el grado. Esta mejora ocurre porque, cuando los subsidios no son sustanciales, seleccionar embarcaciones basándose solo en el número de contactos no garantiza su adopción (aunque estas embarcaciones son esenciales para difundir la adopción de la tecnología más adelante). En contraste, las embarcaciones con mayor EC tienen más probabilidades de adoptar la tecnología, incluso con menores cantidades de subsidio. Si los subsidios cubren la mayor parte de los costes de instalación, usar el criterio de EC no agrega valor para una adopción considerable. Cabe destacar que hay un área de cambio con diferencias positivas máximas cuando $250,000 < \lambda < 275,000$ aproximadamente. Cuando la cantidad de subsidios se sitúa en ese rango, usar el EC como criterio es crucial para impulsar la adopción de la WPT.

5.4.4. Análisis de la mejor política de focalización en diferentes escenarios

En nuestro conjunto final de experimentos examinamos cómo diferentes escenarios de distancia de navegación, evolución del precio del combustible, topologías de SN, subsidios y semillas iniciales afectan los resultados de las políticas de focalización en la adopción final de la WPT. Para toda la experimentación, establecemos dos estrategias de focalización: la estrategia completamente basada en el grado y la estrategia aleatoria. Respecto a los escenarios a considerar, ejecutamos las simulaciones para distancias de navegación de 26,000, 43,000, 50,000 y 60,000 millas náuticas; tanto los escenarios de precios de combustible mensuales como anuales (descritos en la Sección 5.4.1); y topologías SF con diferentes densidades (de SF2 a SF8). Finalmente, como en las subsecciones anteriores, también se consideran diferentes cantidades de subsidios y semillas iniciales.

El objetivo de este experimento es extraer conocimientos que enriquezcan nuestra comprensión de la relación entre escenarios, políticas y las salidas del modelo de simulación. Para ello, ejecutamos el modelo para todas las posibles combinaciones de escenarios. Específicamente, nuestro análisis considera 4,160 configuraciones diferentes de escenarios, incluyendo las diferentes configuraciones en los escenarios de precios, densidades de red, distancias de navegación, porcentaje de semillas y subsidios para los costes de instalación. Visualizamos el impacto en la tasa de adopción de la WPT para todos los escenarios utilizando las curvas S-ICE [BPR⁺22]. Las curvas S-ICE son una modificación de las curvas ICE

adaptadas a la naturaleza estocástica del ABM. Además, mostramos los PDP [Fri01], los cuales corresponden a la media de las curvas ICE y muestran el efecto promedio que una variable tiene sobre el resultado del modelo. Los paneles 6a y 6b muestran estas curvas S-ICE con sus PDP correspondientes. Cada punto representa la tasa de adopción en cada escenario (configuración específica de parámetros), media de las 30 ejecuciones de Monte Carlo, mientras que la línea que conecta dos puntos ilustra el cambio entre escenarios cuando varía un solo parámetro.

Concretamente, mostramos los resultados para variaciones en las densidades de SN, el porcentaje de semillas y los subsidios para los costes de instalación en el eje X, mientras que el eje vertical representa el porcentaje de embarcaciones que adoptan la WPT. No mostramos variaciones en los escenarios de precios y distancias de navegación, ya que se consideran triviales. Los puntos negros gruesos en cada línea vertical representan el correspondiente PDP, es decir, la tasa de adopción media en todos los escenarios. La significación estadística de los cambios en los gráficos de las Figuras 6a y 6b se determina utilizando una prueba *t* de Student de dos muestras con un nivel de significancia del 5%. Las líneas rojas indican un cambio negativo, las líneas azules indican un cambio positivo y las grises denotan un cambio que no es estadísticamente significativo. Extraemos las siguientes observaciones de los gráficos S-ICE, divididas por cada variable:

- Densidades de SN: El análisis de las densidades de SN revela comportamientos diferentes para las políticas de focalización aleatoria y basada en el grado. Bajo la política aleatoria, predominan las líneas rojas entre SF2 y SF4, indicando una disminución significativa en las tasas de adopción. Del escenario SF4 al SF8, las diferencias no son significativas en muchos casos. La tasa media de adopción es baja, por debajo del 2%, con poca variación entre diferentes densidades. Por otro lado, bajo la política basada en el grado, la tasa media de adopción es mayor, alcanzando el 10% en SF2, y disminuye a medida que aumenta la densidad de la red. Aunque la mayoría de los escenarios siguen esta tendencia decreciente, la presencia de algunas líneas azules indica un comportamiento no monótono e interacciones con otras variables. A diferencia de la política aleatoria, las diferencias aquí son significativas en todos los escenarios, sin líneas grises. Esto es de esperar, ya que la política basada en el grado se basa en una medida de red, lo que hace que la densidad de la red sea un factor de influencia clave. En resumen, densidades más bajas corresponden a tasas de adopción más altas, ya que las políticas basadas en el grado son más importantes que en una red de alta densidad donde las embarcaciones tienen más conexiones y vecinos en general.
- Porcentaje de semillas: Bajo la política aleatoria, la tasa media de adopción aumenta a medida que aumenta el porcentaje de semillas, siguiendo una tendencia de crecimiento regular en todos los escenarios. La política basada en el grado también muestra una tendencia de aumento significativa en todos los escenarios. Sin embargo, alcanza una tasa media de adopción más alta y el crecimiento es menos lineal. También podemos observar cambios de pendiente en algunos puntos, con la pendiente haciéndose mucho más pronunciada a partir de cierto porcentaje de semillas en algunos escenarios.

Localizar estos puntos puede ser útil para encontrar el porcentaje de semillas óptimo para cada escenario.

- Subsidio para la instalación: Bajo la política aleatoria, la tasa media de adopción aumenta del 0 % a alrededor del 6 % y las diferencias son significativamente positivas en casi todos los escenarios. Observamos una pendiente más pronunciada a partir de 260,000. El comportamiento de la política basada en el grado difiere en varios aspectos. Comienza desde una tasa media similar, alrededor de cero, pero crece mucho más rápido, alcanzando casi el 20 %. En este caso, observamos una pendiente más pronunciada entre los 260,000 y 290,000, donde ocurren los mayores incrementos. Además, a partir de los 290,000 en algunos escenarios y de los 300,000 en otros, la tasa de adopción alcanza un punto de saturación. Después de ese punto, las diferencias se vuelven insignificantes. La cantidad de subsidios muestra un fuerte impacto positivo en la tasa de adopción, en la que todos los escenarios comienzan desde un valor cercano a cero y evolucionan a valores de hasta el 40 % en la política basada en el grado.

En resumen, la política aleatoria muestra un crecimiento más regular y es menos influenciada por cambios en las variables. En contraste, la política basada en el grado es altamente influenciada por los cambios y presenta un comportamiento no monótono con agrupamientos y pendientes pronunciadas. La política basada en el grado también alcanza tasas medias de adopción más altas en todas las variables, y sus valores máximos son mucho mayores. Además, identificamos puntos de inflexión en la política basada en el grado, como en el caso de los subsidios, proporcionando información valiosa para el diseño de políticas más efectivas y la optimización de recursos. Notablemente, la cantidad del subsidio se destaca como la variable más influyente, como podemos ver en el crecimiento pronunciado de su PDP y en la mayoría de los escenarios.

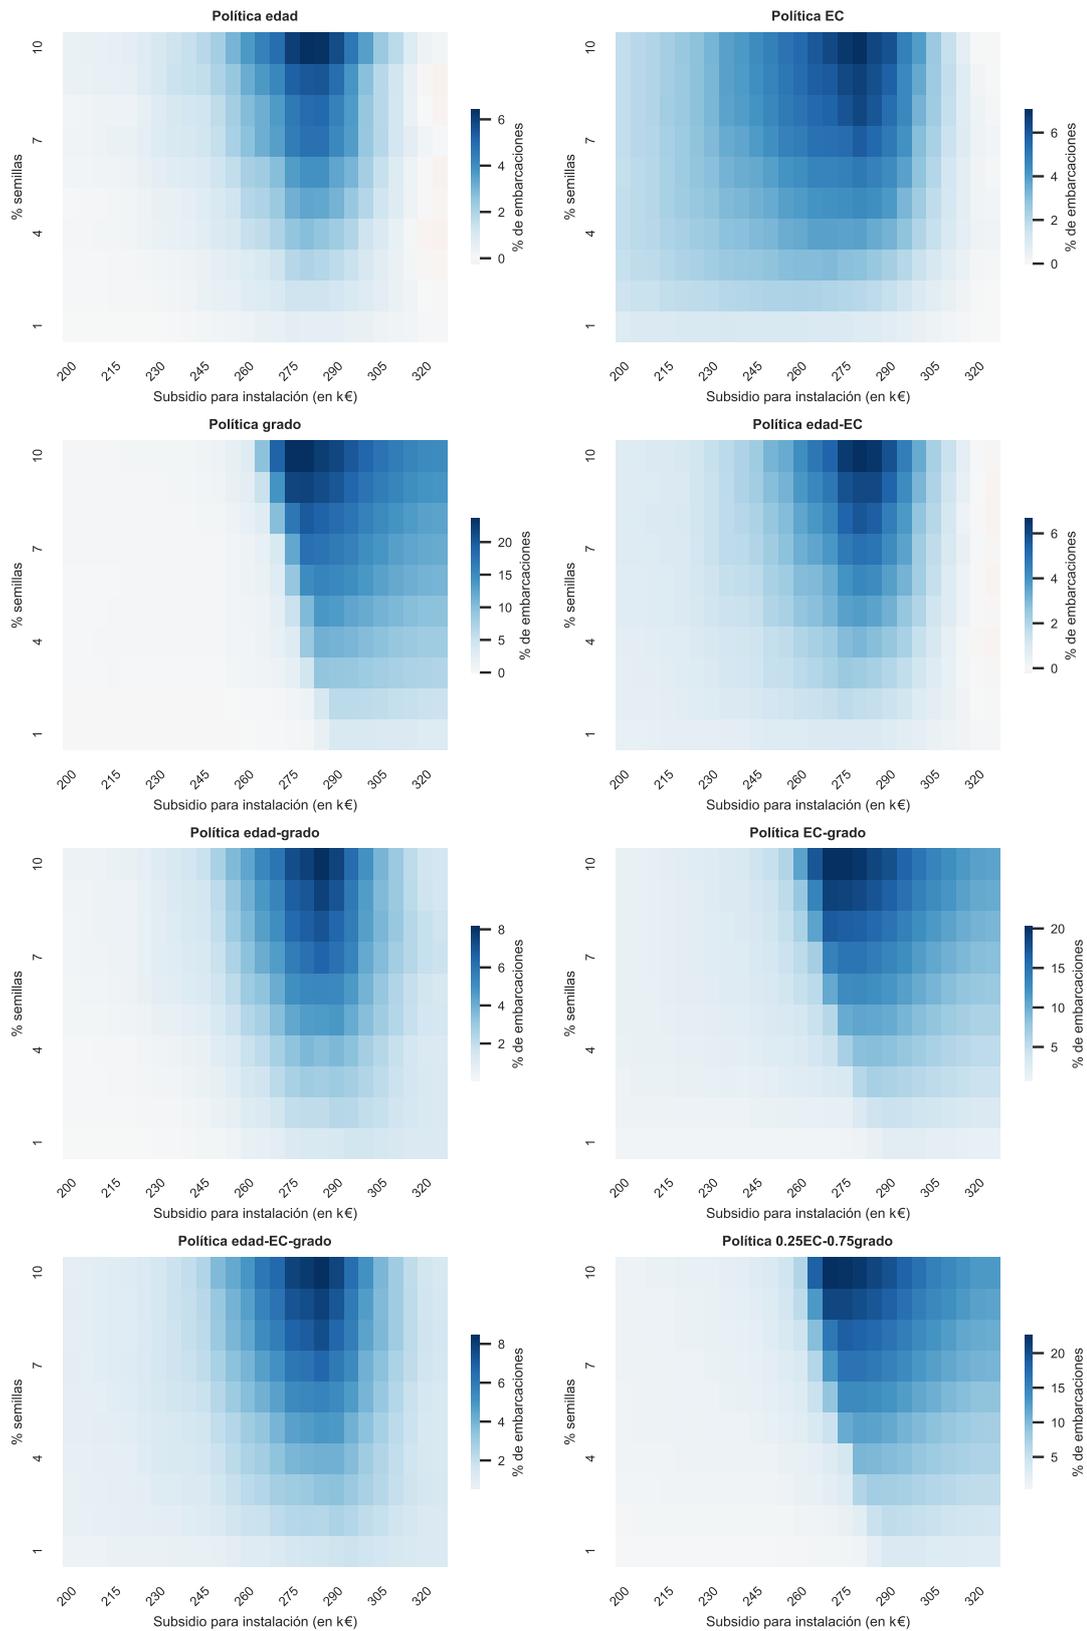


Figura 4: Panel de mapas de calor que muestra, para cada política de focalización, la diferencia relativa en la tasa de adopción de WPT con respecto a la focalización aleatoria. Cada mapa de calor representa un análisis de sensibilidad sobre el subsidio para los costes de instalación por embarcación (λ) y el porcentaje de semillas de la población (s).

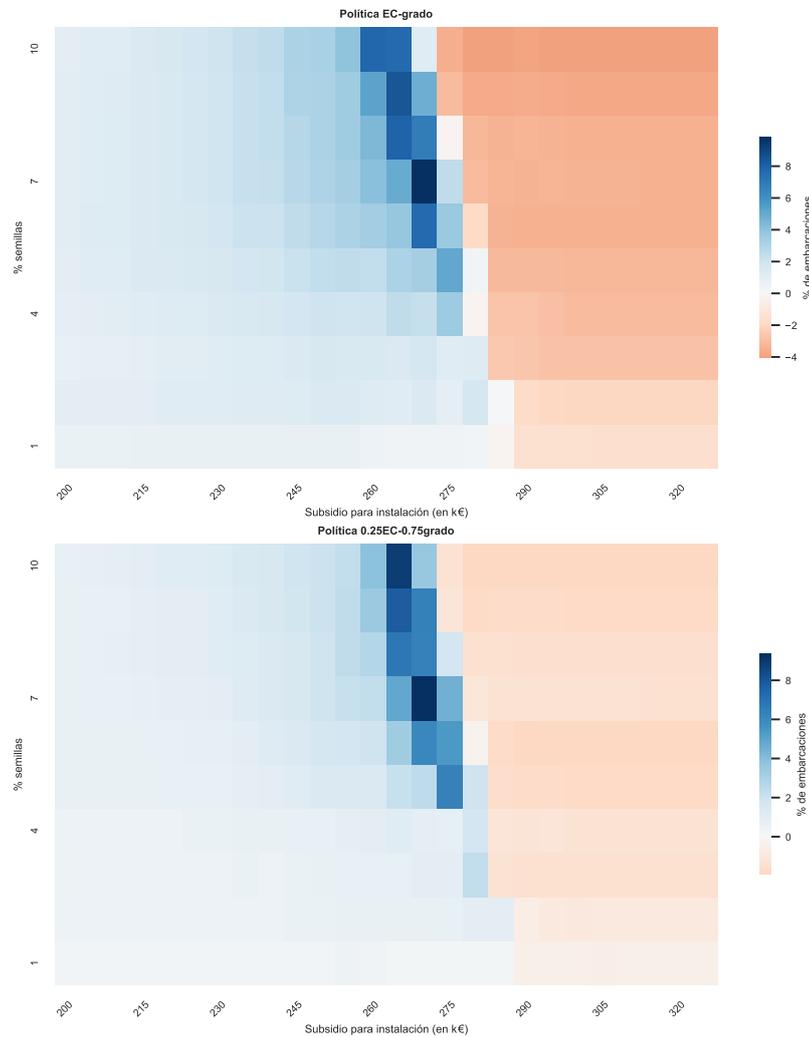


Figura 5: Panel de dos mapas de calor que muestra el aumento relativo en las tasas de adopción de WPT al combinar EC y grado en comparación con una estrategia de focalización que solo considera el grado. Cada mapa de calor representa un análisis de sensibilidad sobre el subsidio para los costes de instalación por embarcación (λ) y el porcentaje de semillas de la población (s). Los resultados de una combinación proporcional de EC y grado (gráfico superior) son más significativos tanto para aumentos positivos como negativos. Se observan tres áreas principales (aumento bajo, aumento alto, disminución baja), que describen cuándo EC es útil para focalización de semillas de embarcaciones.

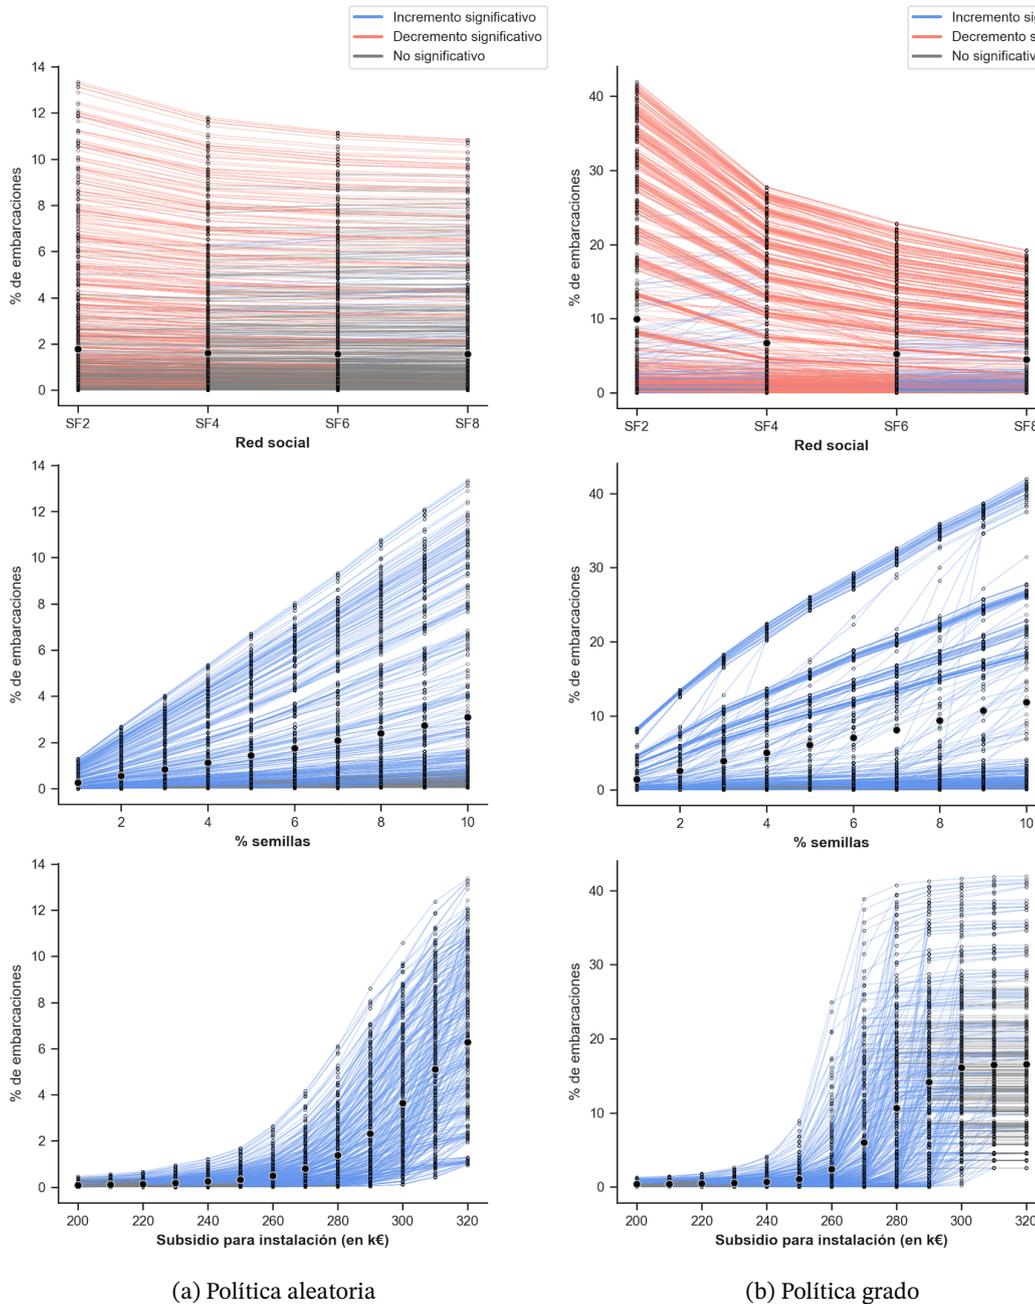


Figura 6: Curvas S-ICE para la adopción de WPT bajo políticas de focalización aleatoria (columna izquierda) y por grado (columna derecha). Cada fila del panel muestra variaciones en las densidades de la red social, el porcentaje de semillas, y los subsidios para la instalación en el eje X. Cada punto en el gráfico representa un escenario único, mientras que la línea que conecta dos puntos ilustra el cambio entre escenarios cuando varía un solo parámetro. El color de la línea indica la naturaleza de los cambios: azul para cambios significativamente positivos, rojo para cambios significativamente negativos y gris para cambios no significativos. Los PDP están representados por los puntos gruesos. Las simulaciones se llevaron a cabo considerando $\phi = 0.4$ y $\alpha = 0.5$.

5.5. Discusión

Desde un punto de vista práctico, las principales conclusiones que observamos son las siguientes. Primero, sin intervenciones, la adopción de la WPT es prácticamente inexistente, en línea con los hallazgos de [CHL23]. Segundo, con el mismo presupuesto global, es más efectivo asignar una mayor cantidad de subsidios para los costes de instalación a un conjunto de embarcaciones en lugar de distribuir una cantidad menor a toda la población. Además, es esencial seleccionar estratégicamente qué embarcaciones serán las que reciban los subsidios. La tasa de adopción más alta se alcanza cuando la política de focalización consiste en seleccionar las embarcaciones con el mayor número de contactos, ya que estas embarcaciones influirán positivamente en sus vecinos para que adopten la tecnología. Este hecho destaca el importante papel de la influencia social, ya que las embarcaciones influyentes pueden acelerar la difusión y adopción de innovaciones.

Es importante señalar que, para un nivel medio de subsidios, es más beneficioso considerar no solo el número de contactos, sino también el EC de la embarcación. Esta política combinada mejora la efectividad, especialmente cuando los subsidios aún no son sustanciales. Al seleccionar embarcaciones con alto EC, nos aseguramos de que las embarcaciones elegidas tengan más probabilidades de adoptar la tecnología. También observamos que cada política exhibe un comportamiento diferente en los distintos escenarios, siendo más o menos influenciada por ciertas variables o mostrando mayor o menor regularidad. En general, parece que la variable más influyente es el subsidio para los costes de instalación. Además, observamos la presencia de puntos de saturación, que nos permiten identificar niveles de subsidios a partir de los cuales el crecimiento en la tasa de adopción se vuelve insignificante. Identificar estos puntos garantiza que los subsidios no sean demasiado bajos para ser ineficaces ni demasiado altos para desperdiciar recursos. En resumen, estas conclusiones resaltan la importancia de la asignación estratégica de subsidios y el papel significativo de la influencia social y la cantidad de subsidios en promover la adopción de la WPT.

Los subsidios como política para mejorar la adopción de tecnologías marítimas sostenibles son fundamentales, como demuestran nuestras conclusiones y corrobora la literatura existente [CC19, CZS23, ZTWZ24]. En [HLZ23] se demuestra que los subsidios pueden estabilizar y aumentar la rentabilidad y sostenibilidad de las operaciones marítimas, aunque es necesario gestionar cuidadosamente los subsidios excesivos para evitar el caos en el mercado. Otros estudios [WGD⁺22, WCZ23] proporcionan conocimiento sobre la optimización de la eficiencia de los subsidios, mostrando que los subsidios dirigidos a operaciones portuarias y a la readaptación de embarcaciones específicas pueden maximizar los beneficios ambientales. Nuestra investigación corrobora estos hallazgos, demostrando que la asignación estratégica de subsidios basada en métricas de red y características de las embarcaciones puede llevar a tasas de adopción más altas y un uso más efectivo de los recursos. Este enfoque garantiza que los subsidios no sean ni demasiado bajos para ser ineficaces ni demasiado altos como para desperdiciar recursos, optimizando así la transición ecológica en la industria marítima. Por lo tanto, la integración de subsidios con ABM basada en la focalización de incentivos podría ser esencial para promover la tecnología verde y lograr reducciones sustanciales de emisiones en la industria marítima.

Teóricamente, nuestro estudio también enriquece la literatura estratégica sobre transi-

ciones sostenibles, ofreciendo lecciones aplicables más allá del sector marítimo. Aunque la literatura sobre transiciones sociotécnicas ha analizado ampliamente el papel de la gestión estratégica de nichos a través de políticas dirigidas a apoyar la difusión de determinadas tecnologías [SG08], se sabía menos sobre cómo dirigirse a organizaciones concretas que buscan ser alimentadas por las políticas públicas. Con esta contribución, nos adentramos en este debate que interrelaciona las transiciones sociotécnicas sostenibles y el papel de las políticas públicas [KPR19, CHL23, MSK24]. Reconocemos que este sector se encuentra en una fase de transición crítica y que múltiples tecnologías compiten en paralelo para convertirse en dominantes en determinados segmentos [UNHM24]. Nuestros hallazgos abren un debate clave en el que un análisis más detallado de las políticas públicas debe participar en la comprensión de las micro-dinámicas de la transición verde; de esta manera, respondemos a las llamadas de la comunidad de transición sociotécnica para ampliar las herramientas metodológicas para incluir técnicas de simulación de sistemas complejos [Köh19].

Desde un punto de vista metodológico, podemos destacar los siguientes hechos. Comparando nuestro trabajo con otros estudios sobre focalización en tecnologías verdes dentro de la literatura de ABM, donde la investigación sigue siendo escasa, nuestro enfoque difiere. Mientras que otros estudios utilizan la focalización para informar sobre la nueva tecnología [RMPS22] o para la adopción inicial [BLS19], nuestro trabajo utiliza la focalización para proporcionar incentivos que faciliten la adopción de la tecnología. Hasta donde sabemos, este enfoque no ha sido explorado en la literatura sobre tecnologías verdes en ABM. Además, mientras que en [RMPS22] se realizan experimentos con empresas y en [BLS19] con agricultores, nuestro estudio utiliza datos reales de embarcaciones en la industria marítima. Respecto a la industria marítima, y concretamente en relación con [CHL23], incorporamos un modelo con mayor énfasis en la influencia social y proporcionamos incentivos solamente a un subconjunto de la población en lugar de a toda la población. Además, nuestro trabajo propone el diseño de políticas de focalización que tengan en cuenta tanto las características sociales de la red como las características específicas de las embarcaciones.

5.6. Conclusiones

En este estudio, desarrollamos un modelo basado en agentes enriquecido con datos reales de propietarios de embarcaciones y prototipos piloto de WPT para simular la adopción de la tecnología. Antes de las fases de conocimiento y adopción del modelo, se aplica focalización de incentivos. Estas micro-políticas son el ingrediente clave de nuestra propuesta, ya que proporcionamos subsidios a un subconjunto de agentes basado en diferentes criterios, en lugar de distribuirlos uniformemente a toda la población, como se ha hecho en estudios relacionados para tecnologías verdes en la industria marítima. Así, nuestro estudio contribuye significativamente a la literatura de ABM sobre tecnologías verdes utilizando focalización para proporcionar incentivos para la adopción de tecnología, a diferencia de otros estudios que se centran en informar sobre nuevas tecnologías o en la adopción basada principalmente en factores económicos.

Los principales resultados de los experimentos son los siguientes. En primer lugar, observamos que dirigir los subsidios a un subconjunto de embarcaciones estratégicamente elegido

alcanza tasas de adopción más altas que repartir subsidios menores a toda la población. Dependiendo del presupuesto total, los criterios para elegir las embarcaciones cambian, siendo el grado y el EC los criterios más valiosos para usar en la selección de semillas. En concreto, las políticas basadas en el grado de las embarcaciones en la SN son efectivas, destacando que la influencia social y la red de contactos juegan roles fundamentales en la adopción de tecnologías verdes. Todas las estrategias de focalización consiguen tasas de adopción superiores a las obtenidas al subvencionar a todas las embarcaciones o al considerar una selección aleatoria de las semillas. Bajo diferentes condiciones de presupuesto, también se recomienda el uso de criterios no sociales, como el EC de la embarcación. Esto destaca la importancia de seleccionar cuidadosamente qué embarcaciones van a recibir incentivos y no usar un enfoque general. Analizamos las políticas aleatoria y basada en el grado en más de 4,000 escenarios usando PDP y curvas S-ICE. Nuestro análisis revela las dinámicas de salida esperadas bajo diferentes escenarios, mientras que la estrategia aleatoria y basada en el grado exhiben comportamientos diferentes, lo cual resalta la complejidad del sistema y la necesidad de un diseño de políticas estratégicas adecuado. Además, este análisis nos proporciona conocimiento significativo que nos permite optimizar la efectividad de las políticas diseñadas.

Este estudio presenta algunas limitaciones que son una oportunidad para desarrollar trabajos futuros. La primera limitación es el hecho de centrar el estudio en un solo tipo de tecnología limpia, mientras que el sector marítimo está experimentando con múltiples tecnologías compitiendo por ser la solución preferida. Aunque nuestro fin no es promover esta tecnología específica frente a otras tecnologías competidoras, nuestro objetivo es destacar las posibilidades de subsidios dirigidos para ayudar a impulsar la actualización de tecnologías verdes. Esta limitación debe tenerse en cuenta al extrapolar los hallazgos sobre la difusión de tecnología verde en el sector marítimo.

También podemos señalar una limitación adicional del modelado: dado que el conocimiento de la WPT es bajo y la tasa de adopción actual es insignificante según la base de datos de Clarksons, aquellas embarcaciones que conocen la tecnología con antelación son solamente las embarcaciones seleccionadas. Entonces si no se aplica la focalización, no hay otras formas externas para que los propietarios de embarcaciones conozcan la tecnología y, por tanto, puedan adoptarla. Este diseño se justifica ya que el modelo se centra en evaluar la focalización de incentivos, pero se necesitaría un rediseño del modelo si se desean aplicar escenarios más generales. Además, no se recogió información sobre actividades de *networking*, y esta es la razón por la cual se utilizó una red artificial libre de escala y los valores para los parámetros sociales se establecieron teniendo en cuenta estudios previos. En caso de disponer de este tipo de datos, se podría inyectar más información en el modelo.

Capítulo 6

Conclusiones

Las contribuciones de los capítulos 3, 4 y 5 suponen la consecución del objetivo principal marcado al inicio de esta tesis así como de los distintos subobjetivos. En este capítulo exponemos las conclusiones obtenidas a partir del desarrollo de esta tesis. Tras esto, se presentan las nuevas vías de trabajo futuro que se abren a partir de esta investigación. Finalmente, se enumeran las publicaciones científicas realizadas durante el transcurso de la tesis.

6.1. Conclusiones

En esta sección mostraremos en primer lugar las principales conclusiones extraídas a lo largo del desarrollo de las distintas contribuciones de esta tesis. Posteriormente, en la Sección 6.2 mencionaremos posibles trabajos futuros que surgen a partir de nuestras contribuciones. Finalmente, en la Sección 6.3 enumeraremos las publicaciones científicas realizadas en el curso de la tesis.

Como ya se ha destacado a lo largo de esta tesis, los modelos basados en agentes y los sistemas de soporte a la decisión en general, requieren el desarrollo de nuevos enfoques que los hagan más interpretables y transparentes con el fin de apoyar de una forma justificada la toma de decisiones a partir del conocimiento aportado por estos sistemas. En esta tesis nos planteamos el objetivo principal de desarrollar y aplicar un enfoque multidisciplinar que integre ABM y técnicas de XAI con el fin de extraer información explicable de las simulaciones de ABM, logrando así una comprensión más profunda del comportamiento de los agentes y mejorar la toma de decisiones en el ámbito del marketing. A partir del desarrollo de esta tesis y las contribuciones realizadas en los capítulos 3, 4 y 5, se han obtenido las siguientes conclusiones:

- La primera contribución se centra en la revisión de la literatura y análisis bibliométrico sobre el uso del ABM en marketing desde el año 2000 hasta la actualidad. Nuestro análisis revela una tendencia creciente de publicaciones en el área y la contribución destacada de países como Estados Unidos, y más recientemente España y Australia. Los resultados también indican que existe una colaboración limitada entre grupos de coautoría; el campo podría beneficiarse de una mayor colaboración. Además, esta contribución ofrece una caracterización detallada de los modelos que permite comprender cómo se han integrado y aplicado los distintos elementos de los modelos basados en agentes en el ámbito del marketing, identificando las características más populares, como el uso de modelos de difusión y SN. Observamos una amplia variedad en los objetivos de los estudios analizados, destacando la considerable cantidad de investigaciones enfocadas en estudiar los efectos de la topología y la heterogeneidad del consumidor en la difusión de innovaciones o las centradas en la difusión de eco-innovaciones.
- La segunda contribución propone una metodología genérica de XAI para aplicar SD y extraer reglas interesantes e interpretables a partir de los resultados micro de las simulaciones basadas en agentes. La metodología es fácil de aplicar sobre la salida de cualquier modelo basado en agentes correctamente calibrado y validado. El paso de filtrado funciona adecuadamente, asegurando la retención de las reglas más significativas y fiables, a la vez que se reduce el conjunto de reglas facilitando su interpretación. El paso de visualización a su vez contribuye a la interpretación, facilitando el análisis del experto. Se demuestra la efectividad de la metodología a través de un caso de estudio en el área de marketing, confirmando su utilidad práctica. Aunque en este caso concreto, el algoritmo SDMap resulta el más ventajoso, no necesariamente será el mejor en todos los casos; otros problemas podrían beneficiarse más de algoritmos como FuGePSD o NMEEFSD. Se obtienen reglas interesantes, interpretables y con un buen balance entre generalidad y precisión. Desde la perspectiva de marketing, se refuerza

la importancia de la interacción WOM en el comportamiento de compra y proporciona conocimiento estratégico clave para ajustar estrategias de marketing dirigidas a determinados grupos de consumidores.

- Finalmente, con la tercera contribución se aborda un problema práctico y relevante en el área de adopción de tecnologías sostenibles a través del diseño de políticas de focalización con ABM para la asignación de subsidios que incentiven la adopción de tecnologías verdes. Nuestro estudio contribuye a la literatura de ABM sobre tecnologías verdes utilizando focalización para proporcionar incentivos, en lugar de limitarse a usarlo para informar. Se demuestra que dirigir incentivos a un subgrupo específico de embarcaciones es más efectivo que dirigirlos a toda la población y que además es fundamental elegir estratégicamente quiénes serán los destinatarios, destacando la importancia de la influencia social. Los criterios más efectivos para la selección son el grado y el EC, variando según el presupuesto total. Además, se ofrece una comprensión más profunda de la relación entre las políticas, escenarios y salidas del modelo, lo cual proporciona conocimiento útil para optimizar la efectividad de las políticas diseñadas, como la identificación de puntos de saturación, garantizando que los subsidios no sean ni demasiado bajos para ser ineficaces ni demasiado altos como para desperdiciar recursos.

En base a los resultados obtenidos en cada una de las contribuciones mencionadas anteriormente, podemos concluir que los resultados del trabajo realizado cumplen con los objetivos definidos en la presente tesis doctoral. Además, las contribuciones realizadas han supuesto una aportación notable al estado del arte de distintas disciplinas como el ABM, XAI, marketing y adopción de tecnologías sostenibles.

6.2. Trabajos futuros

Además de cumplir los objetivos propuestos al inicio de esta tesis, el desarrollo de la misma abre puertas a otros desafíos que pueden mejorar nuestras contribuciones:

- Asociados a nuestra primera contribución, identificamos varias líneas para trabajos futuros que podrían abordar algunas de las limitaciones del ABM. Dado que una de las principales limitaciones del ABM es su rendimiento al manejar un gran número de agentes, se sugiere la integración de técnicas de *big data* con simulaciones a gran escala para ayudar a mejorar esta limitación de rendimiento. Adicionalmente, se necesitan más estándares y mecanismos de validación en ABM para marketing, así como la publicación de código abierto y prototipos funcionales. En cuanto a las aplicaciones en marketing, el ABM ofrece un gran potencial para analizar la emergencia de productos inteligentes [ZDZJ22], los nuevos patrones de consumo como las aplicaciones de entrega a domicilio [HHC⁺19] o la difusión de productos a través de SN *online* dinámicas [WGS23].
- En cuanto a la segunda contribución, la metodología propuesta se podría aplicar a modelos basados en agentes en otras áreas. Por ejemplo, se podría aplicar a las salidas

de un modelo basado en agentes de adopción de tecnologías sostenibles (como el de nuestra tercera contribución) para identificar subgrupos de embarcaciones y dirigir estrategias de incentivos adecuadas a cada grupo según su comportamiento. Otra línea de investigación podría consistir en cambiar la tarea de aprendizaje automático, por ejemplo, buscar descubrir relaciones causales a través de diagramas causales [JSCL19] a partir de los resultados de las simulaciones en lugar de reglas. Además, también se podría explorar la aplicación de otros algoritmos de XAI a los resultados de las simulaciones.

- En relación con la tercera contribución, futuras investigaciones podrían explorar el impacto de utilizar diferentes niveles de subsidios para distintos grupos dentro de la misma población. Además, se podría estudiar el uso de algoritmos de optimización para identificar a los individuos que maximicen la tasa de adopción de la WPT en la industria marítima.

6.3. Publicaciones

Por último, esta sección presenta las publicaciones científicas realizadas en el curso de esta tesis doctoral, incluyendo un artículo aceptado en una revista indexada en el JCR-SCI y otros dos que actualmente se encuentran en proceso de revisión.

Artículos publicados en revistas indexadas en el JCR-SCI (1):

1. Romero, E., Chica, M., Damas, S., & Rand, W. (2023). Two decades of agent-based modeling in marketing: A bibliometric analysis. *Progress in Artificial Intelligence* 12: 213-229. DOI: <https://doi.org/10.1007/s13748-023-00303-y> (JCR 2023; Factor de impacto: 2.0; Cat.: COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE; Pos.: 130/197; Q3). Relacionado con el Capítulo 3.

Artículos en proceso de revisión en revistas indexadas en el JCR-SCI (2):

1. Romero, E., Carmona, C.J., Córdón, O., Del Jesus, M.J., Damas, S., & Chica, M. (2024). Explaining Agent-based Modeling Outputs Using Subgroup Discovery: A Case Study in Marketing. En revisión en *Complex & Intelligent Systems*.¹ (JCR 2023; Factor de impacto: 5.0; Cat.: COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE; Pos.: 45/197; Q1). Relacionado con el Capítulo 4.
2. Romero, E., Chica, M., Hermann, R.R., & Damas, S. (2024). Targeting incentives to adopt wind-assisted technologies in shipping by agent-based simulations. En revisión en *Transportation Research Part D*. (JCR 2023; Factor de impacto: 7.3; Cat.: TRANSPORTATION; Pos.: 5/57; Q1, D1). Disponible en repositorio abierto: <https://ssrn.com/abstract=4901495>. Relacionado con el Capítulo 5.

¹No disponible en repositorio abierto porque la revista sigue un proceso de revisión doble ciego.

Bibliografía

- [AAES⁺23] Ali S., Abuhmed T., El-Sappagh S., Muhammad K., Alonso-Moral J. M., Confalonieri R., Guidotti R., Del Ser J., Díaz-Rodríguez N., and Herrera F. (2023) Explainable artificial intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence. *Information fusion* 99: 101805.
- [AB18] Adadi A. and Berrada M. (2018) Peeking inside the black-box: a survey on explainable artificial intelligence (XAI). *IEEE access* 6: 52138–52160.
- [ADR23] Angelotti G. and Díaz-Rodríguez N. (2023) Towards a more efficient computation of individual attribute and policy contribution for post-hoc explanation of cooperative multi-agent systems using myerson values. *Knowledge-Based Systems* 260: 110189.
- [AIS93] Agrawal R., Imieliński T., and Swami A. (1993) Mining association rules between sets of items in large databases. In *Proceedings of the 1993 ACM SIGMOD international conference on Management of data*, pp. 207–216.
- [AM20] Angeli F. and Montefusco A. (2020) Sensemaking and learning during the COVID-19 pandemic: A complex adaptive systems perspective on policy decision-making. *World Development* 136: 105106.
- [AMS⁺96] Agrawal R., Mannila H., Srikant R., Toivonen H., and Verkamo A. (1996) Fast discovery of association rules. In Fayyad U., Piatetsky-Shapiro G., Smyth P., and Uthurusamy R. (Eds.) *Advances in Knowledge Discovery and Data Mining*, pp. 307–328. AAAI Press.
- [AP06] Atzmueller M. and Puppe F. (2006) SD-Map - A fast algorithm for exhaustive subgroup discovery. In *Proceedings of the 17th European Conference on Machine Learning and 10th European Conference on Principles and Practice of Knowledge Discovery in Databases*, volumen 4213 of LNCS, pp. 6–17. Springer.
- [Art94] Arthur W. B. (1994) Inductive reasoning and bounded rationality. *The American economic review* 84(2): 406–411.

- [Art09] Arthur W. B. (2009) Complexity and the economy. In *Handbook of Research on Complexity*. Edward Elgar Publishing.
- [AWRN12] Amini M., Wakolbinger T., Racer M., and Nejad M. G. (2012) Alternative supply chain production–sales policies for new product diffusion: An agent-based modeling and simulation approach. *European Journal of Operational Research* 216(2): 301–311.
- [BA99] Barabási A.-L. and Albert R. (1999) Emergence of scaling in random networks. *Science* 286(5439): 509–512.
- [BADRD⁺20] Barredo-Arrieta A., Díaz-Rodríguez N., Del Ser J., Bennetot A., Tabik S., Barbado A., García S., Gil-Lopez S., Molina D., Benjamins R., Chatila R., and Herrera F. (2020) Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion* 58: 82–115.
- [Bal94] Balci O. (1994) Validation, verification, and testing techniques throughout the life cycle of a simulation study. *Annals of Operations Research* 53: 121–173.
- [BAM22] Bigdellou S., Aslani S., and Modarres M. (2022) Optimal promotion planning for a product launch in the presence of word-of-mouth. *Journal of Retailing and Consumer Services* 64: 102821.
- [Bas69] Bass F. M. (1969) A new product growth for model consumer durables. *Management Science* 15(5): 215–227.
- [BB06] Bassett D. S. and Bullmore E. (2006) Small-world brain networks. *The Neuroscientist* 12(6): 512–523.
- [BCZ10] Bohlmann J. D., Calantone R. J., and Zhao M. (2010) The effects of market network heterogeneity on innovation diffusion: An agent-based modeling approach. *Journal of Product Innovation Management* 27(5): 741–760.
- [BDEQEH⁺24] Bennetot A., Donadello I., El Qadi El Haouari A., Dragoni M., Frossard T., Wagner B., Sarranti A., Tulli S., Trocan M., Chatila R., *et al.* (2024) A practical tutorial on explainable AI techniques. *ACM Computing Surveys* .
- [BDGP22] Borrego-Díaz J. and Galán Páez J. (2022) Knowledge representation for explainable artificial intelligence: Modeling foundations from complex systems. *Complex & Intelligent Systems* 8(2): 1579–1601.
- [BJL⁺21] Backs S., Jahnke H., Lüpke L., Stücken M., and Stummer C. (2021) Traditional versus fast fashion supply chains in the apparel industry: an agent-based simulation approach. *Annals of Operations Research* 305: 487–512.

- [BJSWW16] Byrka K., Jędrzejewski A., Sznajd-Weron K., and Weron R. (2016) Difficulty is critical: The importance of social factors in modeling diffusion of green products and practices. *Renewable and Sustainable Energy Reviews* 62: 723–735.
- [BLS19] Barbuto A., Lopolito A., and Santeramo F. (2019) Improving diffusion in agriculture: an agent-based model to find the predictors for efficient early adopters. *Agricultural and Food Economics* 7(1).
- [BM18] Bell D. and Mgbemena C. (2018) Data-driven agent-based exploration of customer behavior. *Simulation* 94(3): 195–212.
- [BMWG19] Bhattacharjee S., MacPherson B., Wang R. F., and Gras R. (2019) Animal communication of fear and safety related to foraging behavior and fitness: An individual-based modeling approach. *Ecological Informatics* 54: 101011.
- [BÖBN17] Ballini F., Ölçer A. I., Brandt J., and Neumann D. (2017) Health costs and economic impact of wind assisted ship propulsion. *Ocean Engineering* 146: 477–485.
- [Bon01] Bonabeau E. (2001) Control mechanisms for distributed autonomous systems: Insights from social insects. *Design principles for the immune system and other distributed autonomous systems* pp. 281–292.
- [Bon02] Bonabeau E. (2002) Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the National Academy of Sciences of the United States of America* 99(Suppl 3): 7280–7287.
- [BP01] Bay S. D. and Pazzani M. J. (2001) Detecting group differences: Mining contrast sets. *Data Mining and Knowledge Discovery* 5(3): 213–246.
- [BPR⁺22] Borgonovo E., Pangallo M., Rivkin J., Rizzo L., and Siggelkow N. (2022) Sensitivity analysis of agent-based models: a new protocol. *Computational and Mathematical Organization Theory* 28: 52–94.
- [Bre01] Breiman L. (2001) Random forests. *Machine learning* 45: 5–32.
- [BRR⁺05] Brown D. G., Riolo R., Robinson D. T., North M., and Rand W. (2005) Spatial process and data models: Toward integration of agent-based models and GIS. *Journal of Geographical Systems* 7(1): 25–47.
- [CA19] Can U. and Alatas B. (2019) A new direction in social network analysis: Online social network analysis problems and applications. *Physica A: Statistical Mechanics and its Applications* 535: 122372.
- [Cas94] Casti J. L. (1994) *Complexification: Explaining a paradoxical world through the science of surprise*. HarperCollins.

- [Cas00] Casti J. L. (2000) BizSim: The world of business—in a box. *Artificial Life and Robotics* 4(3): 125–129.
- [CC19] Cheaitou A. and Cariou P. (2019) Greening of maritime transportation: A multi-objective optimization approach. *Annals of Operations Research* 273(1-2): 501–525.
- [CCGJ02] Chen Q., Chang H., Govindan R., and Jamin S. (2002) The origin of power laws in internet topologies revisited. In *Proceedings of the Twenty-First Annual Joint Conference of the IEEE Computer and Communications Societies*, volumen 2, pp. 608–617. IEEE.
- [CCR⁺23] Chica M., Cerdón O., Robles J. F., Garrido A., Mingot J., and Damas S. (2023) Zio: An artificial intelligence digital twin to build virtual markets. In *Proceedings of the 2023 IEEE Conference on Artificial Intelligence (CAI)*, pp. 173–174.
- [CCSdJ13] Carmona C. J., Chrysostomou C., Seker H., and del Jesus M. J. (2013) Fuzzy rules for describing subgroups from influenza A virus using a multi-objective evolutionary algorithm. *Applied Soft Computing* 13(8): 3439–3448.
- [CdJH18] Carmona C. J., del Jesus M. J., and Herrera F. (2018) A unifying analysis for the supervised descriptive rule discovery via the weighted relative accuracy. *Knowledge-Based Systems* 139: 89–100.
- [CDM⁺23] Cofas L.-A., Delcea C., Mancini S., Ponsiglione C., and Vitiello L. (2023) An agent-based model for cruise ship evacuation considering the presence of smart technologies on board. *Expert Systems with Applications* 214: 119124.
- [CGdJ⁺11] Carmona C. J., González P., del Jesus M. J., Navío M., and Jiménez L. (2011) Evolutionary fuzzy rule extraction for subgroup discovery in a psychiatric emergency department. *Soft Computing* 15(12): 2435–2448.
- [CGdJH10] Carmona C. J., González P., del Jesus M. J., and Herrera F. (2010) NMEEFSD: Non-dominated multi-objective evolutionary algorithm for extracting fuzzy rules in subgroup discovery. *IEEE Transactions on Fuzzy Systems* 18(5): 958–970.
- [CGdJH14] Carmona C. J., González P., del Jesus M. J., and Herrera F. (2014) Overview on evolutionary subgroup discovery: analysis of the suitability and potential of the search performed by evolutionary algorithms. *WIREs Data Mining and Knowledge Discovery* 4(2): 87–103.
- [CGdJV11] Carmona C. J., González P., del Jesus M. J., and Ventura S. (2011) Subgroup discovery in an e-learning usage study based on Moodle. In *Proceedings*

- of the *International Conference of European Transnational Education*, pp. 446–451.
- [CGGD⁺13] Carmona C. J., González P., García-Domingo B., del Jesus M. J., and Aguilera J. (2013) MEFES: An evolutionary proposal for the detection of exceptions in subgroup discovery. An application to Concentrating Photovoltaic Technology. *Knowledge-Based Systems* 54: 73–85.
- [CGL08] Crespi V., Galstyan A., and Lerman K. (2008) Top-down vs bottom-up methodologies in multi-agent system design. *Autonomous Robots* 24: 303–313.
- [CH16] Christian J. and Hansun S. (2016) Simulating shopper behavior using fuzzy logic in shopping center simulation. *Journal of ICT Research and Applications* 10(3): 277–295.
- [CHL23] Chica M., Hermann R. R., and Lin N. (2023) Adopting different wind-assisted ship propulsion technologies as fleet retrofit: An agent-based modeling approach. *Technological Forecasting and Social Change* 192: 122559.
- [CHP22] Chica M., Hernández J. M., and Perc M. (2022) Sustainability in tourism determined by an asymmetric game with mobility. *Journal of Cleaner Production* 355: 131662.
- [CHR23] Cariou P., Halim R. A., and Rickard B. J. (2023) Ship-owner response to carbon taxes: Industry and environmental implications. *Ecological Economics* 212: 107917.
- [CI06] Churchill G. A. and Iacobucci D. (2006) *Marketing research: methodological foundations*, volumen 199. Dryden Press New York.
- [CKWZ21] Chen J., Kou G., Wang H., and Zhao Y. (2021) Influence identification of opinion leaders in social networks: an agent-based simulation on competing advertisements. *Information Fusion* 76: 227–242.
- [Cla22] Clarksons Research (2022) Fuelling Transition: Tracking the economic impact of emission reductions & fuel changes. Technical report, Clarksons, London.
- [CLHHVH12] Cobo M. J., López-Herrera A. G., Herrera-Viedma E., and Herrera F. (2012) SciMAT: A new science mapping analysis software tool. *Journal of the American Society for Information Science and Technology* 63(8): 1609–1630.
- [CM07] Centola D. and Macy M. (2007) Complex contagions and the weakness of long ties. *American Journal of Sociology* 113(3): 702–734.

- [CR17] Chica M. and Rand W. (2017) Building agent-based decision support systems for word-of-mouth programs. A freemium application. *Journal of Marketing Research* 54: 752–767.
- [CRRdJ⁺15] Carmona C. J., Ruiz-Rodado V., del Jesus M. J., Weber A., Grootveld M., González P., and Elizondo D. (2015) A fuzzy genetic programming-based algorithm for subgroup discovery and the application to one problem of pathogenesis of acute sore throat conditions in humans. *Information Sciences* 298: 180–197.
- [CS23] Chica M. and Santos F. C. (2023) Seeding leading cooperators and institutions in networked climate dilemmas. *Chaos, Solitons & Fractals* 167: 112987.
- [Cue20] Cuevas E. (2020) An agent-based model to evaluate the COVID-19 transmission risks in facilities. *Computers in Biology and Medicine* 121: 103827.
- [CZS23] Chen S., Zheng S., and Sys C. (2023) Policies focusing on market-based measures towards shipping decarbonization: Designs, impacts and avenues for future research. *Transport Policy* 137: 109–124.
- [DBB16] Delre S. A., Broekhuizen T. L., and Bijmolt T. H. (2016) The effects of shared consumption on product life cycles and advertising effectiveness: the case of the motion picture market. *Journal of Marketing Research* 53(4): 608–627.
- [DBZS23] De Bosscher B. C., Ziabari S. S. M., and Sharpanskykh A. (2023) A comprehensive study of agent-based airport terminal operations using surrogate modeling and simulation. *Simulation Modelling Practice and Theory* 128: 102811.
- [DCCM20] Dhakal S., Chiong R., Chica M., and Middleton R. H. (2020) Climate change induced migration and the evolution of cooperation. *Applied Mathematics and Computation* 377: 125090.
- [DCSM17] Du E., Cai X., Sun Z., and Minsker B. (2017) Exploring the role of social media and individual behaviors in flood evacuation processes: An agent-based modeling approach. *Water Resources Research* 53(11): 9164–9180.
- [DF16] Desmarchelier B. and Fang E. S. (2016) National culture and innovation diffusion. Exploratory insights from agent-based modeling. *Technological Forecasting and Social Change* 105: 121–128.
- [DFK21] Dulam R., Furuta K., and Kanno T. (2021) Quantitative decision-making model to analyze the post-disaster consumer behavior. *International Journal of Disaster Risk Reduction* 61: 102329.

- [DJBJ07] Delre S. A., Jager W., Bijmolt T. H., and Janssen M. A. (2007) Targeting and timing promotional activities: An agent-based model for the takeoff of new products. *Journal of business research* 60(8): 826–835.
- [DJBJ10] Delre S. A., Jager W., Bijmolt T. H., and Janssen M. A. (2010) Will it spread or not? The effects of social influences and network topology on innovation diffusion. *Journal of Product Innovation Management* 27(2): 267–282.
- [DJGHM07] Del Jesus M. J., González P., Herrera F., and Mesonero M. (2007) Evolutionary fuzzy rule induction process for subgroup discovery: a case study in marketing. *IEEE Transactions on Fuzzy Systems* 15(4): 578–592.
- [DJJ07] Delre S. A., Jager W., and Janssen M. A. (2007) Diffusion dynamics in small-world networks with heterogeneous consumers. *Computational and Mathematical Organization Theory* 13(2): 185–202.
- [DKM⁺21] Donthu N., Kumar S., Mukherjee D., Pandey N., and Lim W. M. (2021) How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research* 133: 285–296.
- [DL99] Dong G. and Li J. (1999) Efficient mining of emerging patterns: Discovering trends and differences. In *Proceedings of the 5th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 43–52. ACM Press.
- [DLG⁺23] Dehkordi M. A. E., Lechner J., Ghorbani A., Nikolic I., Chappin E., and Herder P. (2023) Using machine learning for agent specifications in agent-based models and simulations: A critical review and guidelines. *Journal of Artificial Societies and Social Simulation* 26(1): 9.
- [DLMS20] Doniec A., Lecoeuche S., Mandiau R., and Sylvain A. (2020) Purchase intention-based agent for customer behaviours. *Information Sciences* 521: 380–397.
- [dLvZvBK22] de Leeuw A. W., van der Zwaard S., van Baar R., and Knobbe A. (2022) Personalized machine learning approach to injury monitoring in elite volleyball players. *European Journal of Sport Science* 22(4): 511–520.
- [DPAM02] Deb K., Pratap A., Agarwal S., and Meyarivan T. (2002) A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation* 6(2): 182–197.
- [DPW17] Delre S. A., Panico C., and Wierenga B. (2017) Competitive strategies in the motion picture industry: An ABM to study investment decisions. *International Journal of Research in Marketing* 34(1): 69–99.

- [DRDSC⁺23] Díaz-Rodríguez N., Del Ser J., Coeckelbergh M., de Prado M. L., Herrera-Viedma E., and Herrera F. (2023) Connecting the dots in trustworthy artificial intelligence: From AI principles, ethics, and key requirements to responsible AI systems and regulation. *Information Fusion* 99: 101896.
- [DRR22] Doshi R., Ramesh A., and Rao S. (2022) Modeling influencer marketing campaigns in social networks. *IEEE Transactions on Computational Social Systems* pp. 1–13.
- [EA96] Epstein J. M. and Axtell R. (1996) *Growing artificial societies: social science from the bottom up*. Brookings Institution Press.
- [EB17] Ernst A. and Briegel R. (2017) A dynamic and spatially explicit psychological model of the diffusion of green electricity across Germany. *Journal of Environmental Psychology* 52: 183–193.
- [EGMR11] Eppstein M. J., Grover D. K., Marshall J. S., and Rizzo D. M. (2011) An agent-based model to study market penetration of plug-in hybrid electric vehicles. *Energy Policy* 39(6): 3789–3802.
- [EOW22] England R., Owadally I., and Wright D. (2022) An agent-based model of motor insurance customer behaviour in the UK with word of mouth. *Journal of Artificial Societies and Social Simulation* 25(2): 2.
- [Eps06] Epstein J. M. (2006) *Generative social science: Studies in agent-based computational modeling*. Princeton University Press.
- [ER59] Erdős P. and Rényi A. (1959) On random graphs I. *Publ. Math. debrecen* 6: 290–297.
- [EY19] Edali M. and Yücel G. (2019) Exploring the behavior space of agent-based simulation models using random forest metamodels and sequential sampling. *Simulation Modelling Practice and Theory* 92: 62–81.
- [FA01] Friedman S. R. and Aral S. (2001) Social networks, risk-potential networks, health, and disease. *Journal of Urban Health* 78: 411–418.
- [FG01] Flach P. and Gamberger D. (2001) Subgroup evaluation and decision support for a direct mailing marketing problem. In *Proceedings of the 12th European conference on machine learning and 5th European conference on principles and practice of knowledge discovery in databases*, pp. 45 – 56.
- [FGL⁺22] Fisher A., Gajderowicz B., Latimer E., Aubry T., and Mago V. (2022) BEAUT: An explainable deep learning model for agent-based populations with poor data. *Knowledge-Based Systems* 248: 108836.

- [FI93] Fayyad U. M. and Irani K. B. (1993) Multi-interval discretization of continuous-valued attributes for classification learning. In *Proceedings of the 13th International Joint Conference on Artificial Intelligence*, pp. 1022–1029.
- [FKP20] Fürnkranz J., Kliegr T., and Paulheim H. (2020) On cognitive preferences and the plausibility of rule-based models. *Machine Learning* 109(4): 853–898.
- [FPSS96] Fayyad U., Piatetsky-Shapiro G., and Smyth P. (1996) From data mining to knowledge discovery in databases. *AI magazine* 17(3): 37–37.
- [Fri40] Friedman M. (1940) A Comparison of alternative tests of significance for the problem of m rankings. *The Annals of Mathematical Statistics* 11(1): 86 – 92.
- [Fri01] Friedman J. H. (2001) Greedy function approximation: a gradient boosting machine. *Annals of statistics* pp. 1189–1232.
- [GACK⁺07] González-Avella J., Cosenza M., Klemm K., Eguíluz V., and Miguel M. (2007) Information feedback and mass media effects in cultural dynamics. *Journal of Artificial Societies and Social Simulation* 10: 9.
- [GAK15] Golkar Amnieh I. and Kaedi M. (2015) Using estimated personality of social network members for finding influential nodes in viral marketing. *Cybernetics and Systems* 46(5): 355–378.
- [Gar05] Garcia R. (2005) Uses of agent-based modeling in innovation/new product development research. *Journal of Product Innovation Management* 22(5): 380–398.
- [GC23] Grigoryan G. and Collins A. J. (2023) Feature importance for uncertainty quantification in agent-based modeling. In *Proceedings of the 2023 Winter Simulation Conference (WSC)*, pp. 233–242. IEEE.
- [GCC23] Giráldez J., Chica M., and Córdón O. (2023) An integrative decision-making mechanism for consumers’ brand selection using 2-tuple fuzzy linguistic perceptions and decision heuristics. *International Journal of Fuzzy Systems* 25: 59–79.
- [GCCCH20] Giráldez-Cru J., Chica M., Córdón O., and Herrera F. (2020) Modeling agent-based consumers decision-making with 2-tuple fuzzy linguistic perceptions. *International Journal of Intelligent Systems* 35(2): 283–299.
- [GHLH09] Goldenberg J., Han S., Lehmann D. R., and Hong J. W. (2009) The role of hubs in the adoption process. *Journal of Marketing* 73(2): 1–13.

- [GKBP15] Goldstein A., Kapelner A., Bleich J., and Pitkin E. (2015) Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation. *Journal of Computational and Graphical Statistics* 24(1): 44–65.
- [GL02] Gamberger D. and Lavrac N. (2002) Expert-guided subgroup discovery: Methodology and application. *Journal of Artificial Intelligence Research* 17: 501–527.
- [GLH15] García S., Luengo J., and Herrera F. (2015) *Data Preprocessing in Data Mining*. Springer.
- [GLM01] Goldenberg J., Libai B., and Muller E. (2001) Talk of the network: A complex systems look at the underlying process of word-of-mouth. *Marketing letters* 12: 211–223.
- [GLM10] Goldenberg J., Libai B., and Muller E. (2010) The chilling effects of network externalities. *International Journal of Research in Marketing* 27(1): 4–15.
- [GLMM07] Goldenberg J., Libai B., Moldovan S., and Muller E. (2007) The NPV of bad news. *International Journal of Research in Marketing* 24(3): 186–200.
- [GR13] Grimm V. and Railsback S. F. (2013) Individual-based modeling and ecology. In *Individual-based modeling and ecology*. Princeton university press.
- [Gra78] Granovetter M. (1978) Threshold models of collective behavior. *American journal of sociology* 83(6): 1420–1443.
- [GRH07] Garcia R., Rummel P., and Hauser J. (2007) Validating agent-based marketing models through conjoint analysis. *Journal of Business Research* 60(8): 848–857.
- [GSC⁺19] Gunning D., Stefik M., Choi J., Miller T., Stumpf S., and Yang G.-Z. (2019) XAI—Explainable artificial intelligence. *Science robotics* 4(37): eaay7120.
- [GSS⁺22] Gnann T., Speth D., Seddig K., Stich M., Schade W., and Gómez Vilchez J. (2022) How to integrate real-world user behavior into models of the market diffusion of alternative fuels in passenger cars - An in-depth comparison of three models for Germany. *Renewable and Sustainable Energy Reviews* 158: 112103.
- [GSWW11] Günther M., Stummer C., Wakolbinger L., and Wildpaner M. (2011) An agent-based simulation approach for the new product diffusion of a novel biomass fuel. *The Journal of the Operational Research Society* 62(1): 12–20.

- [HC19] Hesselink L. X. W. and Chappin E. J. L. (2019) Adoption of energy efficient technologies by households – barriers, policies and agent-based modelling studies. *Renewable and Sustainable Energy Reviews* 99: 29–41.
- [HCGdJ11] Herrera F., Carmona C. J., González P., and del Jesus M. J. (2011) An overview on subgroup discovery: Foundations and applications. *Knowledge and Information Systems* 29(3): 495–525.
- [HEB07] Heppenstall A. J., Evans A. J., and Birkin M. H. (2007) Genetic algorithm optimisation of an agent-based model for simulating a retail market. *Environment and Planning B: Planning and Design* 34(6): 1051–1070.
- [HHC⁺19] He Z., Han G., Cheng T., Fan B., and Dong J. (2019) Evolutionary food quality and location strategies for restaurants in competitive online-to-offline food ordering and delivery markets: An agent-based approach. *International Journal of Production Economics* 215: 61–72.
- [HHRO13] Heppenstall A. J., Harland K., Ross A. N., and Olnier D. (2013) Simulating spatial dynamics and processes in a retail gasoline market: An agent-based modeling approach. *Transactions in GIS* 17(5): 661–682.
- [HIHS13] Hui S. K., Inman J. J., Huang Y., and Suher J. (2013) The effect of in-store travel distance on unplanned spending: Applications to mobile promotion strategies. *Journal of Marketing* 77(2): 1–16.
- [HL13] Haenlein M. and Libai B. (2013) Targeting revenue leaders for a new product. *Journal of Marketing* 77(3): 65–80.
- [HL20] He M. and Lee J. (2020) Social culture and innovation diffusion: a theoretically founded agent-based model. *Journal of Evolutionary Economics* 30(4): 1109–1149.
- [HLL⁺19] Helal S., Li J., Liu L., Ebrahimie E., Dawson S., and Murray D. J. (2019) Identifying key factors of student academic performance by subgroup discovery. *International Journal of Data Science and Analytics* 7(3): 227–245.
- [HLQS18] Hu H.-h., Lin J., Qian Y., and Sun J. (2018) Strategies for new product diffusion: Whom and how to target? *Journal of Business Research* 83: 111–119.
- [HLZ⁺21] Huang X., Lin Y., Zhou F., Lim M. K., and Chen S. (2021) Agent-based modelling for market acceptance of electric vehicles: Evidence from China. *Sustainable Production and Consumption* 28: 206–217.
- [HLZ23] Huang X., Liu G., and Zheng P. (2023) Dynamic analysis of a low-carbon maritime supply chain considering government policies and social preferences. *Ocean & Coastal Management* 239: 106564.

- [Hol00] Holland J. H. (2000) *Emergence: From chaos to order*. OUP Oxford.
- [Hol14] Holland J. H. (2014) *Complexity: A very short introduction*. OUP Oxford.
- [HPY00] Han J., Pei J., and Yin Y. (2000) Mining frequent patterns without candidate generation. *ACM sigmod record* 29(2): 1–12.
- [HS08] Hauser F. and Schredelseker K. (2008) *Complexity and artificial markets*. Springer.
- [HWC13] He Z., Wang S., and Cheng T. (2013) Competition and evolution in multi-product supply chains: An agent-based retailer model. *International Journal of Production Economics* 146(1): 325–336.
- [HWJY19] Hu H.-h., Wang L., Jiang L., and Yang W. (2019) Strong ties versus weak ties in word-of-mouth marketing. *BRQ Business Research Quarterly* 22(4): 245–256.
- [ID80] Iman R. and Davenport J. (1980) Approximations of the critical region of the Friedman statistic. *Communications in Statistics-Theory and Methods* 9: 571–595.
- [Jag00] Jager W. (2000) *Modelling consumer behaviour*. Universal Press The Netherlands.
- [Jag07] Jager W. (2007) The four P's in social simulation, a perspective on how marketing could benefit from the use of social simulation. *Journal of Business Research* 60(8): 868–875.
- [JFW⁺14] Jin N., Flach P. A., Wilcox T., Sellman R., Thumim J., and Knobbe A. J. (2014) Subgroup discovery in smart electricity meter data. *IEEE Transactions on Industrial Informatics* 10(2): 1327–1336.
- [JHA⁺17] Jalalimanesh A., Haghighi H. S., Ahmadi A., Hejazian H., and Soltani M. (2017) Multi-objective optimization of radiotherapy: distributed q-learning and agent-based simulation. *Journal of Experimental & Theoretical Artificial Intelligence* 29(5): 1071–1086.
- [JJ00] Janssen M. A. and Jager W. (2000) Psychological factors affecting market dynamics: the role of uncertainty and need satisfaction. *Advances in Complex Systems* 03(01n04): 323–334.
- [JJ01] Janssen M. A. and Jager W. (2001) Fashions, habits and changing preferences: Simulation of psychological factors affecting market dynamics. *Journal of economic psychology* 22(6): 745–772.
- [JJ02] Janssen M. A. and Jager W. (2002) Stimulating diffusion of green products. *Journal of Evolutionary Economics* 12(3): 283–306.

- [JJ03] Janssen M. A. and Jager W. (2003) Simulating market dynamics: Interactions between consumer psychology and social networks. *Artificial Life* 9(4): 343–356.
- [JPM⁺17] Jansson J., Pettersson T., Mannberg A., Brännlund R., and Lindgren U. (2017) Adoption of alternative fuel vehicles: Influence from neighbors, family and coworkers. *Transportation Research Part D: Transport and Environment* 54: 61–73.
- [JSCL19] Janssen S., Sharpanskykh A., Curran R., and Langendoen K. (2019) Using causal discovery to analyze emergence in agent-based models. *Simulation Modelling Practice and Theory* 96: 101940.
- [KDS22] Köhler J., Dönitz E., and Schätter F. (2022) Transitions for ship propulsion to 2050: The ahoy combined qualitative and quantitative scenarios. *Marine Policy* 140: 105049.
- [KGSW12] Kiesling E., Günther M., Stummer C., and Wakolbinger L. M. (2012) Agent-based simulation of innovation diffusion: a review. *Central European Journal of Operations Research* 20(2): 183–230.
- [KH22] Kotthoff F. and Hamacher T. (2022) Calibrating agent-based models of innovation diffusion with gradients. *Journal of Artificial Societies and Social Simulation* 25(3): 4.
- [KHK14] Kim S., Hong S., and Kim C. O. (2014) Product attribute design using an agent-based simulation of an artificial market. *International journal of simulation modelling* 13(3): 288–299.
- [KIKK14] Karsai M., Iniguez G., Kaski K., and Kertész J. (2014) Complex contagion process in spreading of online innovation. *Journal of The Royal Society Interface* 11(101).
- [KK08] Kocsis G. and Kun F. (2008) The effect of network topologies on the spreading of technological developments. *Journal of Statistical Mechanics: Theory and Experiment* 2008(10): P10014.
- [KKT03] Kempe D., Kleinberg J., and Tardos É. (2003) Maximizing the spread of influence through a social network. In *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 137–146.
- [KL06] Kavšek B. and Lavrač N. (2006) APRIORI-SD: Adapting association rule learning to subgroup discovery. *Applied Artificial Intelligence* 20(7): 543–583.

- [Kl696] Klöesgen W. (1996) Explora: A multipattern and multistrategy discovery assistant. In *Advances in Knowledge Discovery and Data Mining*, pp. 249–271. American Association for Artificial Intelligence.
- [KNLGK09] Kralj-Novak P., Lavrac N., Gamberger D., and Krstacic A. (2009) CSM-SD: Methodology for contrast set mining through subgroup discovery. *Journal of Biomedical Informatics* 42(1): 113–122.
- [Köh19] Köhler J. (2019) Chapter 18: Advances in modelling sustainable innovation: From technology bias to system theories and behavioural dynamics. In Boons F. and McMeeking A. (Eds.) *Handbook of Sustainable Innovation*, pp. 310–330. Edward Elgar Publishing.
- [KP21] Khodabandelu A. and Park J. (2021) Agent-based modeling and simulation in construction. *Automation in Construction* 131: 103882.
- [KPMS+14] Kowalska-Pyzalska A., Maciejowska K., Suszczyński K., Sznajd-Weron K., and Weron R. (2014) Turning green: Agent-based modeling of the adoption of dynamic electricity tariffs. *Energy Policy* 72: 164–174.
- [KPR19] Karslen R., Papachristos G., and Rehmatulla N. (2019) An agent-based model of climate-energy policies to promote wind propulsion technology in shipping. *Environmental Innovation and Societal Transitions* 31: 33–53.
- [KS19] Keller K. L. and Swaminathan V. (2019) *Strategic brand management: building, measuring, and managing brand equity*. Pearson.
- [KSSW12] Kowalska-Styczeń A. and Sznajd-Weron K. (2012) Access to information in word of mouth marketing within a cellular automata model. *Advances in Complex Systems* 15(08): 1250080.
- [KSV+22] Krivorotko O., Sosnovskaia M., Vashchenko I., Kerr C., and Lesnic D. (2022) Agent-based modeling of COVID-19 outbreaks for New York state and UK: parameter identification algorithm. *Infectious Disease Modelling* 7(1): 30–44.
- [LAH07] Leskovec J., Adamic L. A., and Huberman B. A. (2007) The dynamics of viral marketing. *ACM Transactions on the Web (TWEB)* 1(1): 228–237.
- [LCGF04] Lavrač N., Cestnik B., Gamberger D., and Flach P. (2004) Decision support through subgroup discovery: three case studies and the lessons learned. *Machine Learning* 57: 115–143.
- [LDRW04] Li J., Dong G., Ramamohanarao K., and Wong L. (2004) DeEPs: A new instance-based lazy discovery and classification system. *Machine Learning* 54: 99–124.

- [Lew11] Lewis T. G. (2011) *Network science: Theory and applications*. John Wiley & Sons.
- [LFKT02] Lavrač N., Flach P., Kavsek B., and Todorovski L. (2002) Rule induction for subgroup discovery with CN2-SD. In *Proceedings of the 2nd International Workshop on Integration and Collaboration Aspects of Data Mining, Decision Support and Meta-Learning*, pp. 77–87.
- [LFLZ⁺15] Lee J. S., Filatova T., Ligmann-Zielinska A., Hassani-Mahmooei B., Stone-dahl F., Lorscheid I., Voinov A., Polhill G., Sun Z., and Parker D. C. (2015) The complexities of agent-based modeling output analysis. *Journal of Artificial Societies and Social Simulation* 18(4): 4.
- [LFP⁺22] Luna J. M., Fardoun H. M., Padillo F., Romero C., and Ventura S. (2022) Subgroup discovery in MOOCs: a big data application for describing different types of learners. *Interactive Learning Environments* 30(1): 127–145.
- [LFZ99] Lavrač N., Flach P. A., and Zupan B. (1999) Rule evaluation measures: A unifying view. In *Proceedings of the 9th International Workshop on Inductive Logic Programming*, volumen 1634 of *LNCS*, pp. 174–185. Springer.
- [LHJ⁺23] Li W., Hu Y., Jiang C., Wu S., Bai Q., and Lai E. (2023) ABEM: An adaptive agent-based evolutionary approach for influence maximization in dynamic social networks. *Applied Soft Computing* 136: 110062.
- [Lis15] Lister J. (2015) Green shipping: Governing sustainable maritime transport. *Global Policy* 6(2): 118–129.
- [LKKP13] Lee K., Kim S., Kim C. O., and Park T. (2013) An agent-based competitive product diffusion model for the estimation and sensitivity analysis of social network structure and purchase time distribution. *Journal of Artificial Societies and Social Simulation* 16(1): 3.
- [LL17] Lundberg S. M. and Lee S.-I. (2017) A unified approach to interpreting model predictions. *Advances in neural information processing systems* 30.
- [LLK14] Lee K., Lee H., and Kim C. O. (2014) Pricing and timing strategies for new product using agent-based simulation of behavioural consumers. *Journal of Artificial Societies and Social Simulation* 17(2): 1–21.
- [LLWC13] Lai K. H., Lun Y. V., Wong C. W., and Cheng T. (2013) Measures for evaluating green shipping practices implementation. *International Journal of Shipping and Transport Logistics* 5(2): 217.
- [LMCLH21] López M., Martínez-Camara E., Luzón M., and Herrera F. (2021) ADOPS: Aspect discovery opinion summarisation methodology based on deep learning and subgroup discovery for generating explainable opinion summaries. *Knowledge-Based Systems* 231: 511–520.

- [LMP13] Libai B., Muller E., and Peres R. (2013) Decomposing the value of word-of-mouth seeding programs: Acceleration versus expansion. *Journal of Marketing Research* 50(2): 161–176.
- [LMR22] Lopez-Merino P. and Rouchier J. (2022) The diffusion of goods with multiple characteristics and price premiums: an agent-based model. *Applied Network Science* 7(1): 11.
- [LMT13] Lopolito A., Morone P., and Taylor R. (2013) Emerging innovation niches: An agent based model. *Research Policy* 42(6-7): 1225–1238.
- [LRP⁺20] Lonjarret C., Robardet C., Plantevit M., Auburtin R., and Atzmueller M. (2020) Why should i trust this item? explaining the recommendations of any model. In *Proceedings of the 2020 IEEE 7th international conference on data science and advanced analytics (DSAA)*, pp. 526–535. IEEE.
- [Mac16] Macal C. M. (2016) Everything you need to know about agent-based modelling and simulation. *Journal of Simulation* 10: 144–156.
- [MB17] Mbaru E. K. and Barnes M. L. (2017) Key players in conservation diffusion: Using social network analysis to identify critical injection points. *Biological Conservation* 210: 222–232.
- [MBA14] Morosan C., Bowen J. T., and Atwood M. (2014) The evolution of marketing research. *International Journal of Contemporary Hospitality Management* 26(5): 706–726.
- [MBCC21] Moya I., Bermejo E., Chica M., and Cerdón O. (2021) Coral reefs optimization algorithms for agent-based model calibration. *Engineering Applications of Artificial Intelligence* 100: 104170.
- [MBTT22] Masuda S., Bahr K., Tsuchiya N., and Takemori T. (2022) Agent based simulation with data driven parameterization for evaluation of social acceptance of a geothermal development: a case study in Tsuchiyu, Fukushima, Japan. *Scientific reports* 12(1): 3314.
- [MCC19] Moya I., Chica M., and Cerdón O. (2019) A multicriteria integral framework for agent-based model calibration using evolutionary multiobjective optimization and network-based visualization. *Decision Support Systems* 124: 113111.
- [MCC21] Moya I., Chica M., and Cerdón O. (2021) Evolutionary multiobjective optimization for automatic agent-based model calibration: A comparative study. *Ieee Access* 9: 55284–55299.
- [MCSLC17] Moya I., Chica M., Sáez-Lozano J. L., and Cerdón O. (2017) An agent-based model for understanding the influence of the 11-M terrorist attacks on the 2004 Spanish elections. *Knowledge-Based Systems* 123: 200–216.

- [MCSLC21] Moya I., Chica M., Saez-Lozano J. L., and Cerdón O. (2021) Simulating the influence of terror management strategies on the voter ideological distance using agent-based modeling. *Telematics and Informatics* 63: 101656.
- [MdH09] Mueller M. and de Haan P. (2009) How much do incentives affect car purchase? Agent-based microsimulation of consumer choice of new cars - Part I: model structure, simulation and bounded rationality, and model validation. *Energy Policy* 37: 1072–1082.
- [MHL⁺19] Ma P., Han X.-H., Lin Y., Moore J., Guo Y.-X., and Yue M. (2019) Exploring the relative importance of biotic and abiotic factors that alter the self-thinning rule: insights from individual-based modelling and machine-learning. *Ecological modelling* 397: 16–24.
- [MHLGHV14] Martínez M. A., Herrera M., López-Gijón J., and Herrera-Viedma E. (2014) H-Classics: characterizing the concept of citation classics through H-index. *Scientometrics* 98: 1971–1983.
- [Mil67] Milgram S. (1967) The small world problem. *Psychology today* 2(1): 60–67.
- [Mit09] Mitchell M. (2009) *Complexity: A guided tour*. Oxford university press.
- [ML14] McCoy D. and Lyons S. (2014) Consumer preferences and the influence of networks in electric vehicle diffusion: An agent-based microsimulation in Ireland. *Energy Research & Social Science* 3: 89–101.
- [MN05a] Ma T. and Nakamori Y. (2005) Agent-based modeling on technological innovation as an evolutionary process. *European Journal of Operational Research* 166(3): 741–755.
- [MN05b] Macal C. M. and North M. J. (2005) Tutorial on agent-based modeling and simulation. In *Proceedings of the Winter Simulation Conference, 2005.*, pp. 14–pp. IEEE.
- [MN10] Macal C. M. and North M. J. (2010) Tutorial on agent-based modelling and simulation. *Journal of Simulation* 4: 151–162.
- [Mol22] Molnar C. (2022) *Interpretable Machine Learning*. 2 edition.
- [Mom22] Momennejad I. (2022) Collective minds: social network topology shapes collective cognition. *Philosophical Transactions of the Royal Society B* 377(1843): 20200315.
- [MP09] Miller J. H. and Page S. E. (2009) *Complex adaptive systems: an introduction to computational models of social life*. Princeton university press.

- [MSK24] Mahmoudi M., Saboohi Y., and Köhler J. (2024) Facilitating the transition to sustainable propulsion in the shipping industry: An agent-based modelling analysis of retrofitting. *Environmental Innovation and Societal Transitions* 51: 100838.
- [MW02] Macy M. W. and Willer R. (2002) From factors to actors: Computational sociology and agent-based modeling. *Annual review of sociology* 28(1): 143–166.
- [NAB15] Nejad M. G., Amini M., and Babakus E. (2015) Success factors in product seeding: The role of homophily. *Journal of Retailing* 91(1): 68–88.
- [NBW06] Newman M., Barabási A.-L., and Watts D. J. (2006) *The structure and dynamics of networks*. Princeton university press.
- [NC16] Namatame A. and Chen S.-H. (2016) *Agent-based modeling and network dynamics*. Oxford University Press.
- [NKZ23] Neshat N., Kaya M., and Zare S. G. (2023) Exploratory policy analysis for electric vehicle adoption in european countries: A multi-agent-based modelling approach. *Journal of Cleaner Production* 414: 137401.
- [NLW09] Novak P. K., Lavrač N., and Webb G. I. (2009) Supervised descriptive rule discovery: A unifying survey of contrast set, emerging pattern and subgroup mining. *Journal of Machine Learning Research* 10: 377–403.
- [NMA⁺10] North M. J., Macal C. M., Aubin J. S., Thimmapuram P., Bragen M., Hahn J., Karr J., Brigham N., Lacy M. E., and Hampton D. (2010) Multiscale agent-based consumer market modeling. *Complexity* 15(5): 37–47.
- [NS18] Negahban A. and Smith J. S. (2018) A joint analysis of production and seeding strategies for new products: an agent-based simulation approach. *Annals of Operations Research* 268(1-2): 41–62.
- [NWG20] Nöldeke B., Winter E., and Grote U. (2020) Seed selection strategies for information diffusion in social networks: An agent-based model applied to rural Zambia. *Journal of Artificial Societies and Social Simulation* 23(4): 9.
- [NY14] Negahban A. and Yilmaz L. (2014) Agent-based simulation applications in marketing research: an integrated review. *Journal of Simulation* 8(2): 129–142.
- [NYN14] Negahban A., Yilmaz L., and Nall T. (2014) Managing production level in new product diffusion: an agent-based simulation approach. *International Journal of Production Research* 52(17): 4950–4966.

- [Oli03] Oliva R. (2003) Model calibration as a testing strategy for system dynamics models. *European Journal of Operational Research* 151(3): 552–568.
- [PASA18] Patel M., Abbasi M., Saeed M., and Alam S. J. (2018) A scheme to analyze agent-based social simulations using exploratory data mining techniques. *Complex Adaptive Systems Modeling* 6: 1.
- [PG18] Phan T. Q. and Godes D. (2018) The evolution of influence through endogenous link formation. *Marketing Science* 37(2): 259–278.
- [PLGHQCCR23] Platas-López A., Guerra-Hernández A., Quiroz-Castellanos M., and Cruz-Ramirez N. (2023) A survey on agent-based modelling assisted by machine learning. *Expert Systems* page e13325.
- [PM20] Pakravan M. H. and MacCarty N. A. (2020) Design for clean technology adoption: Integration of usage context, user behavior, and technology performance in design. *Journal of Mechanical Design, Transactions of the ASME* 142(9): 1–10.
- [PMHR23] Poledna S., Miess M. G., Hommes C., and Rabitsch K. (2023) Economic forecasting with an agent-based model. *European Economic Review* 151: 104306.
- [PPBP21] Pantano E., Pizzi G., Bilotta E., and Pantano P. (2021) Enhancing store layout decision with agent-based simulations of consumers' density. *Expert Systems with Applications* 182: 115231.
- [PPY19] Park J. V., Park S. J., and Yoo J. S. (2019) Finding characteristics of exceptional breast cancer subpopulations using subgroup mining and statistical test. *Expert Systems with Applications* 118: 553–562.
- [PSWW14] Przybyła P., Sznajd-Weron K., and Weron R. (2014) Diffusion of innovation within an agent-based model: Spinsons, independence and advertising. *Advances in Complex Systems* 17(01): 1450004.
- [RA03] Rossi P. E. and Allenby G. M. (2003) Bayesian statistics and marketing. *Marketing Science* 22(3): 304–328.
- [Ran06] Rand W. (2006) Machine learning meets agent-based modeling: when not to go to a bar. In *Proceedings of the Conference on Social Agents: Results and Prospects*. Citeseer.
- [Ran15] Rand W. (2015) Complex systems: concepts, literature, possibilities and limitations. *Modeling complex systems for public policies. Brasília: IPEA* pp. 37–54.
- [RBCC21] Robles J. F., Bermejo E., Chica M., and Cerdón O. (2021) Multimodal evolutionary algorithms for easing the complexity of agent-based model calibration. *Journal of Artificial Societies and Social Simulation* 23(3): 4.

- [RC06] Remondino M. and Correndo G. (2006) MABS validation through repeated execution and data mining analysis. *International Journal of Simulation: Systems, Science and Technology* 7(6): 10–21.
- [RCC20] Robles J. F., Chica M., and Cordón O. (2020) Evolutionary multiobjective optimization to target social network influentials in viral marketing. *Expert Systems with Applications* 9: 113183.
- [Res97] Resnick M. (1997) *Turtles, termites, and traffic jams: Explorations in massively parallel microworlds*. Mit Press.
- [RGAH⁺11] Roozmand O., Ghasem-Aghaee N., Hofstede G. J., Nematbakhsh M. A., Baraani A., and Verwaart T. (2011) Agent-based modeling of consumer decision making process based on power distance and personality. *Knowledge-Based Systems* 24(7): 1075–1095.
- [RH16] Rai V. and Henry A. D. (2016) Agent-based modelling of consumer energy choices. *Nature Climate Change* 6(6): 556–562.
- [RMPS22] Ramkumar S., Mueller M., Pyka A., and Squazzoni F. (2022) Diffusion of eco-innovation through inter-firm network targeting: An agent-based model. *Journal of Cleaner Production* 335: 130298.
- [Rog10] Rogers E. (2010) *Diffusion of innovations*. Simon and Schuster.
- [Rot88] Roth A. E. (1988) *The Shapley value: essays in honor of Lloyd S. Shapley*. Cambridge University Press.
- [RR11] Rand W. and Rust R. T. (2011) Agent-based modeling in marketing: Guidelines for rigor. *International Journal of Research in Marketing* 28(3): 181–193.
- [RRB24] Ribeiro-Rodrigues E. and Bortoleto A. P. (2024) A systematic review of agent-based modeling and simulation applications for analyzing pro-environmental behaviors. *Sustainable Production and Consumption* .
- [RRK18] Rand W., Rust R. T., and Kim M. (2018) Complex systems: Marketing's new frontier. *AMS Review* 8(3-4): 111–127.
- [RS21] Rand W. and Stummer C. (2021) Agent-based modeling of new product market diffusion: An overview of strengths and criticisms. *Annals of Operations Research* 305.
- [RSG16] Ribeiro M. T., Singh S., and Guestrin C. (2016) “Why should i trust you?” Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 1135–1144.

- [RWT⁺19] R. Vahdati A., Weissmann J. D., Timmermann A., Ponce de León M. S., and Zollikofer C. P. (2019) Drivers of late pleistocene human survival and dispersal: an agent-based modeling and machine learning approach. *Quaternary Science Reviews* 221: 105867.
- [SABA21] Serré L., Amyot-Bourgeois M., and Astles B. (2021) Use of Shapley additive explanations in interpreting agent-based simulations of military operational scenarios. In *Proceedings of the 2021 Annual Modeling and Simulation Conference (ANNSIM)*, pp. 1–12.
- [Saw05] Sawyer R. K. (2005) *Social emergence: Societies as complex systems*. Cambridge University Press.
- [SB01] Said L. B. and Bouron T. (2001) Multi-agent simulation of virtual consumer populations in a competitive market. *Proceedings of the Seventh Scandinavian Conference on Artificial Intelligence* pp. 31–43.
- [SBL⁺20] Silva P. C., Batista P. V., Lima H. S., Alves M. A., Guimarães F. G., and Silva R. C. (2020) COVID-ABS: An agent-based model of COVID-19 epidemic to simulate health and economic effects of social distancing interventions. *Chaos, Solitons & Fractals* 139: 110088.
- [SBST13] Schlereth C., Barrot C., Skiera B., and Takac C. (2013) Optimal product-sampling strategies in social networks: How many and whom to target? *International Journal of Electronic Commerce* 18(1): 45–72.
- [Sch22] Schinas O. (2022) Financing of low-carbon technology projects. In *Sustainable Energy Systems on Ships*, pp. 431–450. Elsevier.
- [SDB01] Said L. B., Drogoul A., and Bouron T. (2001) Multi-agent based simulation of consumer behaviour: Towards a new marketing approach. *Proceedings of the International Congress on Modelling and Simulation* .
- [SE09] Schwarz N. and Ernst A. (2009) Agent-based modeling of the diffusion of environmental innovations - An empirical approach. *Technological Forecasting and Social Change* 76(4): 497–511.
- [SG08] Schot J. and Geels F. W. (2008) Strategic niche management and sustainable innovation journeys: Theory, findings, research agenda, and policy. *Technology Analysis and Strategic Management* 20(5): 537–554.
- [SHP⁺22] Sarstedt M., Hair J. F., Pick M., Liengaard B. D., Radomir L., and Ringle C. M. (2022) Progress in partial least squares structural equation modeling use in marketing research in the last decade. *Psychology & Marketing* 39(5): 1035–1064.

- [SI16] Serrano E. and Iglesias C. A. (2016) Validating viral marketing strategies in Twitter via agent-based social simulation. *Expert Systems with Applications* 50: 140–150.
- [Sie95] Siebes A. (1995) Data surveying: Foundations of an inductive query language. In *Proceedings of the 1st International Conference on Knowledge Discovery and Data Mining*, pp. 269–274.
- [SK21] Stummer C. and Kiesling E. (2021) An agent-based market simulation for enriching innovation management education. *Central European Journal of Operations Research* 29: 143–161.
- [SKGV15] Stummer C., Kiesling E., Günther M., and Vetschera R. (2015) Innovation diffusion of repeat purchase products in a competitive market: an agent-based simulation approach. *European Journal of Operational Research* 245(1): 157–167.
- [SL16] Stephen A. T. and Lehmann D. R. (2016) How word-of-mouth transmission encouragement affects consumers’ transmission decisions, receiver selection, and diffusion speed. *International Journal of Research in Marketing* 33(4): 755–766.
- [SLR07] Schenk T. A., Löffler G., and Rauh J. (2007) Agent-based simulation of consumer behavior in grocery shopping on a regional level. *Journal of Business research* 60(8): 894–903.
- [SNH18] Sturley C., Newing A., and Heppenstall A. (2018) Evaluating the potential of agent-based modelling to capture consumer grocery retail store choice behaviours. *The International Review of Retail, Distribution and Consumer Research* 28(1): 27–46.
- [SPF19] Stavrakas V., Papadelis S., and Flamos A. (2019) An agent-based model to simulate technology adoption quantifying behavioural uncertainty of consumers. *Applied Energy* 255: 113795.
- [SRE22] Sánchez J. M., Rodríguez J. P., and Espitia H. E. (2022) Bibliometric analysis of publications discussing the use of the artificial intelligence technique agent-based models in sustainable agriculture. *Heliyon* page e12005.
- [SRW10] Stonedahl F., Rand W., and Wilensky U. (2010) Evolving viral marketing strategies. In *Proceedings of the 12th annual conference on Genetic and evolutionary computation*, pp. 1195–1202. ACM.
- [SS03] Schwaiger A. and Stahmer B. (2003) SimMarket: Multiagent-based customer simulation and decision support for category management. *Proceedings of the German Conference on Multiagent System Technologies* pp. 74–84.

- [STÁ⁺12] Shafiei E., Thorkelsson H., Ásgeirsson E. I., Davidsdottir B., Raberto M., and Stefansson H. (2012) An agent-based modeling approach to predict the evolution of market share of electric vehicles: A case study from Iceland. *Technological Forecasting and Social Change* 79(9): 1638–1653.
- [STSH10] Schramm M. E., Trainor K. J., Shanker M., and Hu M. Y. (2010) An agent-based diffusion model with consumer and brand agents. *Decision Support Systems* 50(1): 234–242.
- [SV18] Sharma S. and Verma H. V. (2018) Social media marketing: Evolution and change. *Social media marketing: Emerging concepts and applications* pp. 19–36.
- [SWM17] Samek W., Wiegand T., and Müller K. R. (2017) Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *ITU Journal: ICT Discoveries - Special Issue 1 - The Impact of Artificial Intelligence (AI) on Communication Networks and Services* 1: 1–10.
- [SZE⁺20] Shi Y., Zeng Y., Engo J., Han B., Li Y., and Muehleisen R. T. (2020) Leveraging inter-firm influence in the diffusion of energy efficiency technologies: An agent-based model. *Applied Energy* 263: 114641.
- [tBvVLM21] ten Broeke G., van Voorn G., Ligtenberg A., and Molenaar J. (2021) The use of surrogate models to analyse agent-based models. *Journal of Artificial Societies and Social Simulation* 24(2): 3.
- [TKT⁺09] Terano T., Kishimoto A., Takahashi T., Yamada T., and Takahashi M. (2009) Agent-based in-store simulator for analyzing customer behaviors in a super-market. *Proceedings of the International Conference on Knowledge-Based and Intelligent Information and Engineering Systems* pp. 244–251.
- [TR18] Trivedi A. and Rao S. (2018) Agent-based modeling of emergency evacuations considering human panic behavior. *IEEE Transactions on Computational Social Systems* 5(1): 277–288.
- [TR23] Thies F. and Ringsberg J. W. (2023) Wind-assisted, electric, and pure wind propulsion—the path towards zero-emission roro ships. *Ships and Offshore Structures* 18(8): 1229–1236.
- [Tra12] Tran M. (2012) Agent-behaviour and network influence on energy innovation diffusion. *Communications in Nonlinear Science and Numerical Simulation* 17(9): 3682–3695.
- [TRJ13] Trusov M., Rand W., and Joshi Y. V. (2013) Improving prelaunch diffusion forecasts: Using synthetic networks as simulated priors. *Journal of Marketing Research* 50(6): 675–690.

- [TSB⁺11] Telesford Q. K., Simpson S. L., Burdette J. H., Hayasaka S., and Laurienti P. J. (2011) The brain as a complex system: using network science as a tool for understanding the brain. *Brain connectivity* 1(4): 295–308.
- [TXS22] Tian C., Xiao T., and Shang J. (2022) Channel differentiation strategy in a dual-channel supply chain considering free riding behavior. *European Journal of Operational Research* 301(2): 473–485.
- [UNHM24] Urban F., Nurdiawati A., Harahap F., and Morozovska K. (2024) Decarbonizing maritime shipping and aviation: Disruption, regime resistance and breaking through carbon lock-in and path dependency in hard-to-abate transport sectors. *Environmental Innovation and Societal Transitions* 52: 100854.
- [vdH19] van der Hoog S. (2019) Surrogate modelling in (and of) agent-based models: A prospectus. *Computational Economics* 53(3): 1245–1263.
- [VEJL11] Van Eck P. S., Jager W., and Leeflang P. S. H. (2011) Opinion leaders' role in innovation diffusion: A simulation study. *Journal of Product Innovation Management* 28: 187–203.
- [VEW10] Van Eck N. J. and Waltman L. (2010) Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics* 84(2): 523–538.
- [VM11] Vanhaverbeke L. and Macharis C. (2011) An agent-based model of consumer mobility in a retail environment. *Procedia-Social and Behavioral Sciences* 20: 186–196.
- [VPMCC23] Vargas-Pérez V. A., Mesejo P., Chica M., and Cerdón O. (2023) Deep reinforcement learning in agent-based simulations for optimal media planning. *Information Fusion* 91: 644–664.
- [VRRC06] Viamonte M. J., Ramos C., Rodrigues F., and Cardoso J. C. (2006) ISEM: a multiagent simulator for testing agent market strategies. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 36(1): 107–113.
- [Wal93] Waldrop M. M. (1993) *Complexity: The emerging science at the edge of order and chaos*. Simon and Schuster.
- [Wat02] Watts D. J. (2002) A simple model of global cascades on random networks. *Proceedings of the National Academy of Sciences* 99(9): 5766–5771.
- [WC02] Wei C.-P. and Chiu I.-T. (2002) Turning telecommunications call details to churn prediction: a data mining approach. *Expert systems with applications* 23(2): 103–112.

- [WCZ23] Wang T., Cheng P., and Zhen L. (2023) Green development of the maritime industry: Overview, perspectives, and future research opportunities. *Transportation Research Part E: Logistics and Transportation Review* 179: 103322.
- [WD07] Watts D. J. and Dodds P. S. (2007) Influentials, networks, and public opinion formation. *Journal of Consumer Research* 34(4): 441–458.
- [WF94] Wasserman S. and Faust K. (1994) *Social network analysis: Methods and applications*. Cambridge university press.
- [WGD⁺22] Wang Y., Guo S., Dai L., Zhang Z., and Hu H. (2022) Shore side electricity subsidy policy efficiency optimization: From the game theory perspective. *Ocean & Coastal Management* 228: 106324.
- [WGF20] Will M., Groeneveld J., Frank K., and Muller B. (2020) Combining social network analysis and agent-based modelling to explore dynamics of human interaction: A review. *Socio-Environmental Systems Modelling* 2: 16325–16325.
- [WGS23] Wei X., Gong H., and Song L. (2023) Product diffusion in dynamic online social networks: A multi-agent simulation based on gravity theory. *Expert Systems with Applications* 213: 119008.
- [WR15] Wilensky U. and Rand W. (2015) *An introduction to agent-based modeling: modeling natural, social, and engineered complex systems with NetLogo*. Mit Press.
- [Wro97] Wrobel S. (1997) An algorithm for multi-relational discovery of subgroups. In *Proceedings of the 1st European Symposium on Principles of Data Mining and Knowledge Discovery*, pp. 78–87. Springer.
- [WS98] Watts D. J. and Strogatz S. H. (1998) Collective dynamics of ‘small-world’ networks. *Nature* 393(6684): 440–442.
- [WvEvL⁺11] Waltman L., van Eck N. J., van Leeuwen T. N., Visser M. S., and van Raan A. F. (2011) Towards a new crown indicator: Some theoretical considerations. *Journal of informetrics* 5(1): 37–47.
- [XH16] Xiao Y. and Han J. (2016) Forecasting new product diffusion with agent-based models. *Technological Forecasting and Social Change* 105: 167–178.
- [XMSZ21] Xu X., Mei Y., Sun Y., and Zhu X. (2021) Analysis of the effectiveness of promotion strategies of social platforms for the elderly with different levels of digital literacy. *Applied Sciences* 11(9): 4312.
- [Yan22] Yang L. (2022) Double-edged effects of pricing on diffusion of green products. *Journal of Cleaner Production* 359: 132109.

- [YYF⁺18] Yousefi M., Yousefi M., Ferreira R. P. M., Kim J. H., and Fogliatto F. S. (2018) Chaotic genetic algorithm and adaboost ensemble metamodeling approach for optimum resource planning in emergency departments. *Artificial Intelligence in Medicine* 84: 23–33.
- [ZDZJ22] Zhang T., Dong P., Zeng Y., and Ju Y. (2022) Analyzing the diffusion of competitive smart wearable devices: An agent-based multi-dimensional relative agreement model. *Journal of Business Research* 139: 90–105.
- [ZGBL23] Zhang Y., Gao J., Bilgihan A., and Lorenz M. (2023) A holistic assessment of eWOM management effectiveness with agent-based modeling. *International Journal of Contemporary Hospitality Management* 35(3): 785–827.
- [ZGCR21] Zhang Y., Gao J., Cole S., and Ricci P. (2021) How the spread of user-generated contents (UGC) shapes international tourism distribution: Using agent-based modeling to inform strategic ugc marketing. *Journal of Travel Research* 60(7): 1469–1491.
- [ZGG11] Zhang T., Gensler S., and Garcia R. (2011) A study of the diffusion of alternative fuel vehicles: An agent-based modeling approach. *Journal of Product Innovation Management* 28(2): 152–168.
- [ZGN⁺18] Zutshi A., Grilo A., Nodehi T., Mehrbod A., and Jardim-Goncalves R. (2018) Simulation and forecasting of digital pricing models for an e-procurement platform using an agent-based simulation model. *Journal of Simulation* 12(3): 211–224.
- [ZH22] Zadbood A. and Hoffenson S. (2022) Social network word-of-mouth integrated into agent-based design for market systems modeling. *Journal of Mechanical Design* 144(7): 071701.
- [ZLLZ20] Zhou L., Lin J., Li Y., and Zhang Z. (2020) Innovation diffusion of mobile applications in social networks: A multi-agent system. *Sustainability* 12(7): 2884.
- [ZTWZ24] Zhang Q., Tan Z., Wang S., and Zhen L. (2024) Shore hydrogen deployment problem in green ports. *Computers & Operations Research* 165: 106585.
- [ZU22] Zehra A. and Urooj A. (2022) A bibliometric analysis of the developments and research frontiers of agent-based modelling in economics. *Economies* 10(7): 171.
- [ZV19] Zhang H. and Vorobeychik Y. (2019) Empirically grounded agent-based models of innovation diffusion: a critical review. *Artificial Intelligence Review* pp. 1–35.

- [ZVC21] Zhang W., Valencia A., and Chang N. B. (2021) Synergistic integration between machine learning and agent-based modeling: A multidisciplinary review. *IEEE Transactions on Neural Networks and Learning Systems* 34(5): 2170–2190.
- [ZWD09] Zenobia B., Weber C., and Daim T. (2009) Artificial markets: A review and assessment of a new venue for innovation research. *Technovation* 29(5): 338–350.
- [ZZ07] Zhang T. and Zhang D. (2007) Agent-based simulation of consumer purchase decision-making and the decoy effect. *Journal of business research* 60(8): 912–922.
- [ZZ19] Zhang N. and Zheng X. (2019) Agent-based simulation of consumer purchase behaviour based on quality, price and promotion. *Enterprise Information Systems* 13(10): 1427–1441.
- [ZZZL21] Zhang Z., Zhang H., Zhou L., and Li Y. (2021) Analyzing the coevolution of mobile application diffusion and social network: A multi-agent model. *Entropy* 23(5): 521.