



**UNIVERSIDAD
DE MÁLAGA**



**LENGUAJES Y
CIENCIAS DE LA
COMPUTACIÓN**
UNIVERSIDAD DE MÁLAGA

Tesis Doctoral

Aplicación de técnicas de aprendizaje automático y optimización a problemas reales en la industria 4.0

E.T.S.I. Informática
R.D. 99/2011
Programa de doctorado:
Tecnologías informáticas

Autor

Jesús Para Fernández

Directores

Dr. Javier Del Ser Lorente

Departamento de

Ingeniería de Comunicaciones

Universidad del País Vasco (UPV/EHU)

Dr. Antonio Jesús Nebro Urbaneja

Departamento de

Lenguajes y Ciencias de la Computación

Universidad de Málaga


Enero 2023





UNIVERSIDAD
DE MÁLAGA

AUTOR: Jesús Para Fernández

 <https://orcid.org/0009-0009-0139-8923>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): riuma.uma.es





DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD DE LA TESIS PRESENTADA PARA OBTENER EL TÍTULO DE DOCTOR

D./Dña JESÚS PARA FERNANDEZ

Estudiante del programa de doctorado TECNOLOGÍAS INFORMÁTICAS de la Universidad de Málaga, autor/a de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada: APLICACIÓN DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO Y OPTIMIZACIÓN A PROBLEMAS REALES EN LA INDUSTRIA 4.0

Realizada bajo la tutorización de ANTONIO JESÚS NEBRO URBANEJA y dirección de JAVIER DEL SER LORENTE Y ANTONIO JESÚS NEBRO URBANEJA (si tuviera varios directores deberá hacer constar el nombre de todos)

DECLARO QUE:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo.

Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 16 de FEBRERO de 2023

Fdo.: JESÚS PARA FERNÁNDEZ Doctorando/a	Fdo.: ANTONIO JESÚS NEBRO URBANEJA Tutor/a
Fdo.: JAVIER DEL SER LORENTE	ANTONIO JESÚS NEBRO URBANEJA



El Dr. **Antonio Jesús Nebro Urbaneja**, Catedrático de Universidad del Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga, y el Dr. **Javier Del Ser Lorente**, Profesor Asociado en la Universidad del País Vasco (UPV/EHU)

Certifican

que **D. Jesús Para Fernández**, Licenciado en Física por la Universidad de Valladolid, España, ha realizado en el Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga, bajo sus direcciones, el trabajo de investigación correspondiente a su Tesis Doctoral titulada

Aplicación de técnicas de aprendizaje automático y optimización a problemas reales en la industria 4.0

Revisado el presente trabajo y avalando que las publicaciones en coautoría que la avalan no han sido utilizadas en tesis anteriores, estimamos que puede ser presentado al tribunal que ha de juzgarlo, y autorizamos la presentación de esta Tesis Doctoral en la Universidad de Málaga.

En Málaga, Enero de 2023

Firmado:

Dr. Javier Del Ser Lorente

Profesor Asociado del Dpto. de Ingeniería de Comunicaciones
de la Universidad del País Vasco (UPV/EHU) y

Dr. Antonio Jesús Nebro Urbaneja

Catedrático de Universidad del Dpto. de Lenguajes y Ciencias
de la Computación de la Universidad de Málaga



UNIVERSIDAD
DE MÁLAGA

Agradecimientos

En primer lugar me gustaría agradecer a mis dos supervisores, Javi y Antonio, por todo el apoyo que me han dado durante la realización de esta tesis, superando lo puramente académico y yendo mucho más allá de lo que supone su compromiso contractual con el único fin de enseñarme. ¡Gracias por vuestro compromiso, acompañamiento y esfuerzo!

En segundo lugar, quiero agradecer a mis amigos y familiares su ayuda y atención durante todo el proyecto, pero especialmente quiero agradecer a mi padre, que hoy estaría orgulloso de lo que ha conseguido tanto académica como profesionalmente, a mi pareja, mayor sufridora de la misma y sin cuyo apoyo jamás habría llegado al final de esta etapa y a mis dos hijos, Ibai y Julen, que han venido al mundo mientras realizaba esta tesis.

Por último, quiero dar las gracias a quienes, enfrascados en guerras lingüísticas, me pidieron que abandonara la tesis para unirme a la guerra desde sus trincheras. ¡Me alegro de no haberles hecho caso!

Índice general

Índice de tablas	1
Índice de figuras	1
1. Introducción	5
1.1. Antecedentes	6
1.1.1. Mejora de los procesos de producción	7
1.1.2. Mejora de la planificación de la producción	8
1.2. Hipótesis de trabajo	9
1.3. Objetivos y fases	9
1.4. Contribuciones	10
1.5. Organización de la tesis	11
2. Fundamentos tecnológicos	13
2.1. Oportunidades de mejora en entornos industriales	13
2.1.1. Procesos productivos	13
2.1.2. Planificación de la producción	15
2.2. Inteligencia artificial	16
2.2.1. Aprendizaje automático (Machine Learning)	17
2.2.2. Optimización multiobjetivo y metaheurísticas	20
3. Estado del arte	27
3.1. Mejora de procesos productivos	27
3.1.1. Revisión de las principales metodologías	27
3.1.2. Resumen de los puntos críticos identificados	29
3.2. Mejora de la planificación de la producción	29
3.2.1. Metodología de recopilación y filtrado de bibliografía	30
3.2.2. Taxonomías y análisis bibliográfico	30
3.2.3. Resumen de los puntos críticos identificados en el análisis bibliográfico	38
4. Mejora de los procesos productivos	43
4.1. Introducción	43
4.2. Formulación del problema	44
4.3. ASPPID, una nueva metodología propuesta	46
4.3.1. Descripción general	48
4.3.2. Fases de ASPPID	48
4.4. Experimentación	55
4.5. Resultados y conclusiones	63



5. Optimización de la planificación de la producción	65
5.1. Introducción	65
5.2. Problema a resolver	66
5.3. AutoMOEA - Metodología propuesta	66
5.3.1. Enriquecimiento de instancias JSP	67
5.3.2. Diseño	68
5.3.3. Conjunto de instancias de entrenamiento	70
5.3.4. Medición de la calidad de las configuraciones	70
5.3.5. Recursos informáticos y código fuente	70
5.3.6. Configuración de AutoMOEA encontrada por irace	71
5.4. Experimentación	71
5.5. Resultados	74
5.6. Conclusiones	78
6. Conclusiones, contribuciones y líneas futuras	79
6.1. Conclusiones	79
6.2. Contribuciones	81
6.3. Líneas futuras de investigación	83
Bibliografía	85

Índice de tablas

2.1. Clasificación de las metaheurísticas en técnicas inspiradas en la naturaleza y no inspiradas en la naturaleza, junto con algunos ejemplos ilustrativos para cada una de estas categorías.	22
3.1. Algoritmos identificados en los documentos analizados.	39
4.1. Puntuaciones medias de los modelos de la primera iteración de la metodología ASP-PID.	58
4.2. Puntuaciones medias de los modelos de la segunda iteración de la metodología ASP-PID.	60
4.3. <i>NQR</i> (intervalo de confianza medio) de las reglas extraídas de los grupos de características.	62
5.1. Espacio de parámetros de AutoMOEA para resolver <i>JSP</i> . El tamaño de la población es 50.	70
5.2. Parametrización de NSGA-II y AutoMOEA para <i>JSP</i> . El tamaño de la población es de 50 soluciones.	71
5.3. Mediana y rango intercuartílico de los indicadores de calidad (a) PE y (b) VNH obtenidos por los algoritmos comparados.	73
5.4. LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .EP.	73
5.5. LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .IGD+.	73
5.6. LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .NHV.	74
5.7. Clasificaciones medias de Friedman con valores <i>p</i> ajustados de Holm (0,05) de los algoritmos comparados para los indicadores EP y NHV sobre los problemas de prueba.	76
5.8. Diferencias entre los costes de producción fijos y variables de las soluciones de energía mínima encontradas por NSGA-II y AutoMOEA para cada instancia <i>JSP</i> , suponiendo una tasa de coste fijo por hora de 10, 100 y 1.000€/hora.	78



Índice de figuras

2.1.	Proceso productivo de fundición de piezas de aluminio.	14
2.2.	Ejemplo de solución óptima (arriba) y no óptima (abajo) para la planificación de la producción de dos trabajos.	16
2.3.	Esquema de la inteligencia artificial.	17
2.4.	GD.	23
2.5.	IGD.	24
2.6.	Hipervolumen (HV).	24
3.1.	Diagrama de flujo de la metodología de búsqueda y filtrado.	30
3.2.	Número de publicaciones por año para el problema <i>JSP</i> multiobjetivo con la energía como uno de los objetivos.	31
3.3.	Taxonomía de la literatura revisada por características del problema.	32
3.4.	Taxonomía de las consideraciones relevantes encontradas en la literatura revisada.	34
3.5.	Taxonomías por optimizador multi-objetivo.	37
3.6.	Algoritmos más utilizados para la comparativa.	38
4.1.	Ejemplo de $K = 3$ ensayos de sensores dirigidos por una metodología que propone $s_K = [s_3, s_2, s_5]$ y $s_K = [A, B, A]$ para una determinada tarea de modelado predictivo (por ejemplo, detección de defectos). Se ha utilizado un doble eje vertical para reflejar los beneficios y los costes. Debido a la incertidumbre del equipo sobre la utilidad de s_2 para la tarea en cuestión, se decidió alquilarlo durante la duración del ensayo, ahorrando costes tras confirmarse su falta de relevancia predictiva.	47
4.2.	Diagrama esquemático que ilustra el flujo de trabajo iterativo de la metodología ASPPID.	49
4.3.	Duración indicativa de cada fase de ASPPID en el ejemplo de la Figura 4.1.	51
4.4.	Diagrama de Ishikawa utilizado en la fase de análisis de ASPPID.	52
4.5.	Características extraídas de la serie temporal X_t^1 capturada por el sensor seleccionado en el ensayo $k = 1$: puntos extremos $\{v_0, \dots, v_6\}$, áreas $\{A_1, \dots, A_4\}$ y retardos $\{t_1, \dots, t_5\}$, resultando en 16 características.	57
4.6.	Cálculo de las medianas tras detectar un valor atípico \bullet y sustitución de la muestra atípica utilizando el valor medio de las medianas calculadas.	58
4.7.	Puntuación media de los modelos en función de la cantidad de datos para el enfoque ADASYN + RF.	59
4.8.	Árboles de decisión más frecuentes inferidos a partir de la información recogida con diferentes subconjuntos de características grupo 1.	61
4.9.	Árboles de decisión más frecuentes inferidos a partir de la información recogida con diferentes subconjuntos de características grupo 1+2.	61



4.10. Comparación gráfica entre los costes derivados de las estrategias de alquiler (—) y compra (—) en la adquisición de sensores dentro de la metodología ASPPID. El gráfico también incluye la progresión del beneficio (—) a lo largo del ciclo ASPPID.	62
5.1. Ejemplo de la estrategia de codificación de soluciones adoptada.	69
5.2. (a)-(h): Composición del frente de referencia de cada instancia <i>JSP</i> de prueba; (i)-(p): frentes correspondientes a la mediana del valor NHV de NSGA-II y AutoMOEA.	75
5.3. Ejemplo para las dos soluciones extremas de la instancia ta12 (mejor solución energética y mejor solución energética).	76

Capítulo 1

Introducción

La historia de la humanidad es la historia del cambio y la mejora continua. El nacimiento, por ejemplo, de las técnicas de enastar (poner un mango a una herramienta o arma) durante el paleolítico superior supuso una revolución, ya a que, gracias a él, se multiplicó la eficacia de las herramientas de piedra. Desde entonces, por su propia naturaleza intrínseca, el ser humano no ha dejado de innovar y mejorar. Resultado de ello es la sociedad desarrollada en la que nos encontramos actualmente, científicamente avanzada y multidisciplinar.

La evolución no es exclusiva sólo a los avances tecnológicos, sino que también evolucionan, entre otros, los sistemas productivos. La manera en la que actualmente la industria transforma la materia prima hasta obtener productos terminados o semiterminados ha mejorado significativamente a lo largo de la historia. La primera revolución industrial, que comenzó en la Inglaterra del siglo XVIII, supuso un hito en la humanidad, ya que cambió significativamente la manera de producir, lo que alteró positivamente la economía mundial. Esta transición provocó el paso de los métodos de producción manual a las máquinas, los nuevos procesos de fabricación de productos químicos y de producción de hierro, el uso creciente de la energía de vapor y de la energía hidráulica, el desarrollo de las máquinas-herramienta y el surgimiento del sistema de fábricas mecanizadas. Esto condujo a un aumento de la población y de la tasa de crecimiento demográfico. Desde entonces se han sucedido diferentes *revoluciones* a lo largo de la historia. Entre ellas destaca la segunda revolución industrial, basada en la aplicación del principio de la producción en masa a lo largo de cadenas de montaje, permitiendo aumentar la producción con una mayor coordinación entre la mano de obra, las tareas, los procesos y las máquinas. La tercera revolución industrial, que se inició a mediados del siglo XX, se caracterizó por la automatización de los procesos, permitiendo incrementar la productividad de los mismos. La cuarta revolución industrial, en la que está inmersa actualmente la industria ahora, tiene a la robótica y el análisis de datos como principales baluartes tecnológicos. Todas estas revoluciones acontecidas a lo largo de la historia tienen, por tanto, un elemento común: la mejora de la eficiencia de los procesos productivos, es decir, el incremento de la producción mediante la reducción de los costes de fabricación, sin afectar a la calidad, o incluso, mejorándola.

Por otra parte, campos como la estadística y la probabilidad no han dejado de avanzar desde la época de Sumeria, Egipto, la antigua China, Babilonia o Asiria, donde se empezaron a elaborar las primeras tablas estadísticas. Esto, unido a los avances en el mundo de la computación y los programas informáticos, han desembocado en el desarrollo de la inteligencia artificial (IA), que se puede definir como la ciencia y la ingeniería de crear máquinas inteligentes [1]. En 1956 se acuñó por primera dicho término, en la conferencia de *Dartmouth* [2]. Fue la época en la que empezaron a aparecer los primeros ordenadores digitales en los laboratorios universitarios. Los participantes en esta conferencia eran principalmente matemáticos e informáticos, muchos de los cuales estaban interesados en demostrar teoremas y algoritmos que pudieran ser probados por estas máquinas. Hubo mucho

optimismo en la conferencia, ya que los primeros éxitos en este campo fueron un gran estímulo para la investigación en esta disciplina. Esto llevó a predicciones eufóricas sobre las capacidades de la IA que resultaron ser exageradas. Estas altas expectativas no se vieron cumplidas, en parte por la poca capacidad de cómputo de la época. Como resultado, la inteligencia artificial quedó sumida en un largo período de desinterés, ampliamente referido como el *invierno de la IA* [3]. Hoy en día, con la mejora de las capacidades de computación, la inteligencia artificial ha resurgido con fuerza y se ha posicionado como una herramienta disruptiva presente en multitud de campos con diferentes grados de madurez, como la conducción autónoma [4], la traducción automática de textos [5], los sistemas de recomendación [6, 7], la medicina [8], y como no, también en la industria.

Por tanto, una nueva cuarta revolución industrial (Industria 4.0) surge de la posibilidad de aplicar la inteligencia artificial en entornos industriales, necesitada de fabricar de forma más eficiente, reduciendo los costes de producción y asegurando la calidad. Las posibilidades de aplicación en la industria son muy extensas, como la detección por visión artificial, mejora en la logística, o la predicción de ventas, entre muchas otras. Esta tesis se centra en un objetivo concreto, la reducción de costes productivos en la industria, mediante la aplicación de técnicas automáticas de aprendizaje y optimización basadas en inteligencia artificial.

1.1. Antecedentes

Tal y como se acaba de comentar, estamos ante la cuarta revolución industrial, denominada industria 4.0. El término se acuñó por primera vez en la feria de Hannover en 2014 [9]. Desde entonces el interés de la comunidad hacia la integración de tecnologías destinadas a dotar de inteligencia a los procesos industriales ha sido creciente. Como tal, este concepto se refiere al diseño y desarrollo de fábricas *inteligentes*, donde los procesos de fabricación tradicionales evolucionan mediante la recopilación de grandes cantidades de datos operativos procedentes de sensores y otras fuentes de información. Este despliegue masivo de equipos de detección en toda la planta potencia la toma de decisiones multicriterio basada en la analítica de datos, con el objetivo de aumentar la eficiencia de las plantas de fabricación a diferentes niveles, desde el almacenamiento hasta la producción y la entrega. No en vano este desafiante paradigma ha sido identificado recientemente como uno de los principales catalizadores de la recuperación económica mundial tras la gran recesión de 2008 [10].

Para seguir siendo competitivas y aumentar la cadena de valor de sus procesos productivos, las industrias manufactureras han incluido la adaptación a este nuevo modelo productivo dentro de su hoja de ruta tecnológica, abarcando la inclusión de nuevas tecnologías y competencias dentro de sus procesos y personal que tradicionalmente habían estado vinculados a otros sectores. El cambio ha sido especialmente profundo en lo que se refiere a la monitorización de toda la cadena de producción y entrega, con nuevos habilitadores tecnológicos como el Internet de las Cosas (IoT), la ciberseguridad, la realidad aumentada y la robótica colaborativa, entre muchos otros. Sin embargo, existe un consenso común alrededor del papel crucial que desempeña la analítica de datos (ya sea por sí misma o como parte constitutiva y central de Big Data) a la hora de proporcionar la inteligencia que se busca para el proceso en cuestión. Abundan los ejemplos en la literatura que sustentan y evidencian las ganancias obtenidas por la aplicación de modelos predictivos y algoritmos de optimización en diferentes problemas industriales, como el mantenimiento predictivo o la evaluación de la calidad (véase, por ejemplo [11, 12, 13, 14] y sus referencias ahí contenidas), la mejora de la calidad, que puede utilizarse para mejorar el proceso de producción encontrando relaciones complejas entre las variables del proceso y su calidad final [15], la previsión de la demanda de ventas [16], la visión por computador [17], la optimización de cargas en hornos [18], la optimización de parámetros de producción [19] o de la configuración de simuladores industriales [20], y muchos más casos de uso por igual.

Como se puede observar, la lista de posibles aplicaciones de la inteligencia artificial dentro de los

sectores industriales es extensa, por lo que esta tesis concentra su foco en dos problemas concretos dentro de la industria: la mejora de los procesos de producción, y la mejora de la planificación de la producción.

1.1.1. Mejora de los procesos de producción

Los procesos industriales mal ejecutados pueden provocar elevados sobrecostes derivados de la necesidad de desechar o procesar de nuevo los productos terminados debido a su baja calidad. Por lo tanto, es esencial poder fabricar productos de calidad sin requerir varios ciclos de producción. Debido a la complejidad actual de muchos procesos de fabricación, encontrar la forma de producir de forma adecuada se complica por el hecho de que múltiples parámetros y las interacciones entre ellos pueden afectar a la calidad final. En consecuencia, determinar qué variables afectan al proceso de producción y en qué medida lo hacen es un trabajo sumamente complicado.

La necesidad cada vez mayor de integrar sensores y tecnologías informáticas para la recogida, el almacenamiento y el análisis de datos se enfrenta a varios problemas en la práctica. Aunque la industria destina grandes inversiones a la instalación de equipos de detección avanzados en sus procesos y maquinaria, las compras suelen estar sesgadas por el potencial de los propios equipos para captar y almacenar el mayor número posible de parámetros diversos del elemento monitorizado, sin tener en cuenta su utilidad y contribución para las etapas posteriores de generación de modelos matemáticos. Si bien aparecen nuevos roles dentro de las organizaciones (como expertos en robótica, arquitectos de datos y científicos de datos [21]), es frecuente que éstos no se involucren dentro del ciclo de decisión de compra, limitando así su contribución a un *esfuerzo* sobre los datos capturados por dichos dispositivos una vez adquiridos. Esta falta de implicación de los roles basados en datos en cuestiones de gestión implica un importante exceso de gastos y un alto grado de incertidumbre con respecto al potencial de la analítica de datos para la industria [22], [23].

Este hecho es aún más preocupante cuando se examina conjuntamente con el modelo tradicional de relación cliente-proveedor que domina la mayoría de los modelos de compra en las pequeñas y medianas industrias. Las implicaciones económicas de una determinada compra deben evaluarse no sólo desde el punto de vista puramente económico (es decir, el balance entre la inversión y la depreciación de los equipos adquiridos, junto con los gastos adicionales para las herramientas auxiliares y el mantenimiento), sino también con respecto al valor de los datos capturados. El valor del dato en este contexto se refiere a la contribución de la información capturada por el sensor adquirido a la tarea de agregación de información relevante en la generación de modelos, motivo por el que fueron adquiridos. Dicha contribución, cuantificada en términos de rendimiento predictivo, puede traducirse a términos económicos para reflejar el valor competitivo de la inversión. Sin embargo, los estudios que abordan la rentabilidad del análisis de datos dentro del ecosistema industrial son sorprendentemente escasos, a pesar del papel intuitivamente central que esta tecnología debería desempeñar en las empresas manufactureras hacia su convergencia con el paradigma de la industria 4.0.

Así, es necesario contar con un plan estructurado dentro de la organización con equipos multidisciplinarios, que incluyan expertos en el proceso productivo, expertos en analítica e ingeniería de datos, así como expertos en producto, que sean capaces de determinar qué es importante para el cliente, qué medir, cómo medirlo, cómo almacenar y explotar esta información y, como resultado de estas conclusiones, retro-alimentar el proceso productivo para evitar zonas de peligro (conjunto de parámetros que producen mala calidad) y acercarse a zonas de producción con cero defectos.

Esta tesis postula que todos los mecanismos y procesos de decisión orientados a la dotación de inteligencia basada en datos al ciclo de fabricación deben girar alrededor del valor del dato, cuantificación que sólo puede ser acometida con fiabilidad por personal cercano a la inferencia de conocimiento a partir de la información captada. Como se expondrá en el estudio del estado del arte realizado en el siguiente apartado, la mayoría de las metodologías utilizadas hasta la fecha en los flujos de decisión industriales tienen como objetivo mejorar la eficiencia productiva de la planta

atendiendo a aspectos técnicos que consideran los datos como un subproducto del proceso que podría ser explotado si estuviera disponible, en lugar de considerar este activo como una cuestión central para la decisión.

1.1.2. Mejora de la planificación de la producción

La planificación de la producción o ampliamente conocida como problema de programación de trabajos, en inglés *Jobshop Scheduling Problem* (JSP) [24, 25], se basa en ordenar de una manera óptima los trabajos de producción a realizar, minimizando su coste y garantizando su entrega en un plazo determinado. Planificar de manera incorrecta puede suponer sobrecostes en la realización de los trabajos, derivados del desperdicio de los recursos. Hacerlo de manera adecuada es una tarea complicada, ya que hay factores prácticos que deben tenerse en cuenta a la hora de planificar un conjunto de trabajos de producción, como la disponibilidad de las máquinas, las características de los trabajos a realizar, los materiales necesarios para hacerlos, la cualificación del personal o los costes de amortización de las instalaciones y maquinaria. Las dimensiones de estos factores aumentan en las fábricas más grandes, debido al número igualmente creciente de elementos instalados, la continua llegada de más órdenes de producción, y otros aspectos que hacen que los procesos de planificación de la producción subyacente sean aún más difíciles de abordar.

Por tanto, encontrar la mejor combinación para la planificación de la producción no es una tarea trivial. El número de combinaciones posibles es del orden de $(n!)^m$, siendo n el número de trabajos y m el número de máquinas [26]. Por ejemplo, asignar y programar 5 trabajos en una fábrica de sólo 5 máquinas resulta en aproximadamente $24,8 \cdot 10^9$ combinaciones diferentes. En consecuencia, el uso de técnicas de optimización exhaustiva no es factible en los escenarios industriales del mundo real, en los que el número de máquinas y trabajos puede ser mucho mayor que en el ejemplo mencionado. Por lo tanto, se han propuesto técnicas de optimización no exactas como alternativa para hacer frente a la complejidad de los problemas *JSP*. Entre estas técnicas se encuentran las metaheurísticas [27], que constituyen una amplia familia de técnicas de optimización que no garantizan el descubrimiento de soluciones óptimas pero que suelen proporcionar soluciones casi óptimas en tiempos razonables [28]. La computación evolutiva, que es posiblemente la subfamilia más conocida de las metaheurísticas, se ha aplicado también a diferentes escenarios y variantes del problema *JSP* a lo largo de los años [29].

En la formulación de un problema *JSP* se puede considerar más de un objetivo a minimizar, como el *makespan* (tiempo total para completar un plan de producción dado), la tardanza total, los cambios de máquina, etc. En consecuencia, el *JSP* puede ser formulado como un problema de optimización multiobjetivo, en el que el óptimo no es una solución única, sino un conjunto de soluciones entre los objetivos establecidos (conocido como conjunto de Pareto). Desde el punto de vista algorítmico, abordar varios objetivos y encontrar aproximaciones precisas al conjunto de Pareto que equilibra dichos objetivos de forma óptima incrementa la complejidad de diseñar una técnica de optimización eficiente y escalable.

Además de los objetivos comunes relacionados con la producción que se han mencionado anteriormente (por ejemplo, la duración de la fabricación o la tardanza total), la reducción del consumo de energía es un aspecto crucial de la sociedad actual. Hay múltiples razones para esta preocupación creciente por el consumo energético: los efectos en el cambio climático, la sostenibilidad del planeta a largo plazo [30, 31] o el impacto del coste de la energía por la crisis energética a la que nos enfrentamos en los últimos tiempos. Este objetivo ha prevalecido a lo largo de los años en los que se han abordado los problemas de *JSP* con algoritmos metaheurísticos, pero no ha sido hasta hace poco cuando la eficiencia energética ha cobrado la máxima relevancia en el ámbito industrial, especialmente en las industrias de alto consumo energético. La creciente importancia del consumo de energía como indicador clave del rendimiento y la eficiencia industrial ha calado en los procesos prácticos de planificación. En consecuencia, los intereses de la comunidad investigadora que trabaja

en metaheurísticas para problemas *JSP* se han orientado progresivamente hacia la eficiencia energética como un objetivo más, dando lugar a un aumento de las contribuciones que tratan de problemas *JSP* multiobjetivo conscientes de la energía para la programación de la producción industrial.

1.2. Hipótesis de trabajo

El objetivo principal de la tesis es abordar el uso práctico de la analítica de datos y la optimización dentro del sector industrial en el paradigma de la industria 4.0. Las hipótesis de trabajo que se plantean son las siguientes:

- **Hipótesis 1:** Los procesos productivos cuya mejora sea abordada desde el prisma de la captura, procesamiento y análisis de datos son susceptibles de mejorar significativamente.
- **Hipótesis 2:** El uso de técnicas de optimización multiobjetivo pueden dar lugar a mejoras en las planificaciones de producción cuando se tienen en cuenta la reducción del consumo energético asociado al proceso en cuestión.
- **Hipótesis 3:** La inteligencia artificial supone una herramienta disruptiva, capaz de aportar valor añadido en la generación de conocimiento y toma de decisiones dentro de las organizaciones industriales.

1.3. Objetivos y fases

Para validar las hipótesis generales planteadas, la tesis se centra en la reducción de los costes productivos en la industria mediante la aplicación de la inteligencia artificial, centrándose especialmente en los problemas de mejora de los procesos de fabricación y mejora de la planificación de la producción. Por ello, diferenciaremos entre objetivos globales, que afectan a ambos problemas, y objetivos específicos a cada uno de los problemas abordados:

- **Objetivos globales:**
 - Mostrar que es posible reducir los costes de producción en empresas industriales, derivada de la mejora en sus procesos en virtud de la aplicación de técnicas de inteligencia artificial.
 - Exponer la importancia del uso de técnicas de inteligencia artificial a bajo coste para las organizaciones.
- **Objetivos de la mejora de los procesos productivos:**
 - Evaluar el estado del arte relacionado con metodologías de implantación de sistemas de inteligencia artificial en entornos productivos.
 - Describir una nueva metodología eficiente en coste, que incorpore la analítica de datos en los proyectos de mejora de los procesos de producción.
 - Demostrar, con casos de uso reales, la reducción de costes productivos derivada de la aplicación de técnicas de inteligencia artificial a procesos de producción industriales.
- **Objetivos de mejora de la planificación de la producción:**
 - Evaluar el estado del arte relacionado con problemas de planificación de la producción, donde el consumo energético ha sido uno de los objetivos a minimizar.
 - Proponer mejoras en la generación de soluciones para problemas de planificación multiobjetivo mediante técnicas metaheurísticas de optimización.

- Demostrar experimentalmente el valor añadido de emplear dichas técnicas para la toma de decisiones a la hora de planificar trabajos de producción industrial.

Para llevar a cabo estos objetivos generales y específicos, la tesis recoge los resultados de una serie de fases de estudio e investigación, los cuales alimentan e informan las conclusiones y hallazgos que se expondrán al término de la misma:

- Exploración del estado actual de los estudios sobre la implantación de la inteligencia artificial en las organizaciones de fabricación, concretamente en el ámbito de la mejora de procesos y la planificación de la producción.
- Selección de los tipos de problemas a resolver dentro de estas áreas. En el caso de la mejora de procesos la tesis se centra en procesos de producción con datos desbalanceados/sesgados. En el caso de la mejora de la planificación de la producción, nos centramos en la planificación multiobjetivo de la producción, siendo la energía uno de sus objetivos.
- Desarrollo e implementación de una nueva metodología de mejora de procesos basada en datos, aplicada sobre un caso de uso real, donde se constata cómo debe ser un proceso de mejora basado en la analítica de datos. En el caso de la mejora en la planificación de la producción, modelizar sobre casos de uso sintéticos como debe ser aplicada la mejora en la planificación de la producción multiobjetivo, con la energía y el *makespan* como objetivos, basando la mejora algorítmica en aplicar de una manera correcta los hiper-parámetros de los algoritmos de optimización empleados.
- Análisis de los resultados obtenidos en los casos de uso considerados, y extracción de conclusiones basada en los mismos.

1.4. Contribuciones

A continuación se realiza una breve introducción de todas las contribuciones que esta tesis aporta, pero pueden ser consultadas en mayor detalle en el apartado de contribuciones 6.2.

- **Mejora de procesos mediante análisis de datos:**
 - Desarrollo de una nueva metodología (ASPPID) para la mejora de procesos productivos en entornos industriales mediante análisis de datos empleando aprendizaje automático (*machine learning*).
 - Aplicación de la metodología desarrollada sobre un caso de uso real.
- **Optimización de la planificación de la producción:**
 - Desarrollo de un módulo para el software de optimización jMetal para abordar problemas *JSP* multiobjetivo, con la energía como uno de sus objetivos.
 - Derivación de una nueva estrategia de representación de soluciones para el problema *JSP* multiobjetivo relativo a la energía, añadiendo como parámetros el coste de encendido, parado y puesta en espera de la máquina, la velocidad de máquina y los costes de producción relativos a la misma.
 - Diseño de un algoritmo multiobjetivo autoconfigurador de los hiperparámetros que gobiernan su capacidad de búsqueda.
 - Mejora de la estrategia de representación de soluciones para el problema *JSP* multiobjetivo relativo a la energía, incluyendo parámetros adicionales relacionados con el coste eléctrico y el turno.

1.5. Organización de la tesis

La tesis está organizada de la siguiente manera. El capítulo actual contiene una introducción al trabajo realizado, presentando la motivación para llevarlo a cabo, los objetivos que se han perseguido y las fases que se han seguido para conseguir dichos objetivos. El capítulo 2 realiza una breve introducción a los fundamentos tecnológicos e industriales necesarios para comprender y asimilar las contribuciones de la tesis expuestas en los siguientes capítulos. El capítulo 3 presenta un estado del arte para cada uno de los problemas que se van a considerar en esta tesis: la mejora de procesos productivos y la mejora de la planificación. En el capítulo 4 se aborda el problema de la mejora de los procesos de producción mediante técnicas de aprendizaje automático, mientras que el capítulo 5 trata la mejora de la planificación de la producción. Finalmente, el capítulo 6 recoge las conclusiones generales de esta tesis, resume las contribuciones y publicaciones derivadas de la investigación realizada, y plantea líneas futuras de trabajo motivadas por este estudio.

Capítulo 2

Fundamentos tecnológicos

Este capítulo sirve como breve introducción de los conceptos que se van a ver a lo largo de toda la tesis. Se divide en dos secciones: por un lado se introducen los conceptos meramente industriales, desglosando el tipo de problemas que se van a abordar, para, a continuación, realizar una introducción a los fundamentos algorítmicos de manera generalista, pero principalmente enfocado a detallar las técnicas a aplicar para la resolución de los problemas presentados. En el apartado 2.1 se describen los entornos dentro del sector industrial donde esta tesis pone su foco. En el apartado 2.2 se realiza una breve introducción sobre la inteligencia artificial y el tipo de técnicas que se van a usar en esta tesis.

2.1. Oportunidades de mejora en entornos industriales

Los entornos industriales actuales son entornos complejos donde la mejora basada en la aplicación de técnicas de aprendizaje automático (*machine learning*) y optimización dan cabida a una gran cantidad de problemas. Esta tesis se centra, de todas sus posibles aplicaciones, en la mejora de los procesos productivos y en la optimización de la planificación de la producción. Los siguientes subapartados introducen brevemente al lector a ambos tipos de problemas.

2.1.1. Procesos productivos

Un proceso productivo es el conjunto de actividades y operaciones necesarias para transformar materias primas en productos terminados o elaborados. Los procesos productivos están presentes en nuestro día a día y abarcan una gran variedad de industrias, desde la manufactura de bienes de consumo hasta la producción de energía y alimentos.

Hay varios tipos diferentes de procesos productivos, según el tipo de producto que se esté produciendo y las tecnologías utilizadas en el proceso. Algunos ejemplos de tipos de procesos productivos incluyen:

- Procesos de producción artesanal: se utilizan habilidades manuales y técnicas tradicionales para producir productos únicos y personalizados.
- Procesos de producción en serie: se utilizan máquinas y equipos especializados para producir grandes cantidades de un producto de manera rápida y eficiente.

Centrados en este tipo último tipo de producción, la producción en serie supone actualmente un reto tecnológico: se debe garantizar, mediante el control de los parámetros críticos de cada fase del proceso de producción, la calidad del producto terminado o semi-terminado, lo cual, dependiendo

del tipo de proceso productivo puede resultar complejo debido a la gran cantidad de parámetros afectando a la vez.

En esta tesis nos centramos en un tipo de proceso concreto, aunque extrapolable a otro tipo de problemas: la inyección de aluminio a baja presión. Como se puede observar en la Figura 2.1, el aluminio fundido es inyectado en los moldes a lo que se denomina baja presión, es decir, usando la gravedad sin necesidad de aplicar una presión externa. Una vez moldeadas y enfriadas, las piezas pasan por un control de calidad unitario, que determina si la calidad de las piezas es buena (piezas OK) o mala (piezas NOK). En caso de ser buenas, esas piezas serán agrupadas y enviadas a cliente. De lo contrario, pueden pasar por una fase de reprocesado, donde se solucionen problemas menores, como la mejora de la calidad visual o el limado de rebabas; o, por el contrario, ser descartadas, por lo que se fundirán de nuevo para aprovechar la materia prima.

Esta falta de calidad impacta directamente en la cuenta de explotación de las empresas, ya que procesar esas piezas defectuosas ha tenido un coste en materias primas, electricidad, coste de personas, etc, que no van a tener un retorno económico. Por ello, es crítico conseguir robustecer los procesos productivos con el fin de llegar a lo actualmente llamado *política de cero defectos*, es decir, conseguir fabricar bien a la primera.




Figura 2.1: Proceso productivo de fundición de piezas de aluminio.

En cada una de las partes del proceso se pueden registrar ingentes cantidades de datos sobre los diferentes parámetros que las propias máquinas, pero no todos los datos son relevantes para la mejora del proceso productivo, como por ejemplo los finales de carrera o las presiones y temperaturas de los aceites que accionan los grupos hidráulicos. Desde un punto de vista más cercano a intentar mejorar el proceso productivo, se puede afirmar que desde el horno de fundición se pueden registrar parámetros relevantes como la composición química, la temperatura y la densidad del aluminio. Desde la máquina de moldeo se puede registrar cada segundo la temperatura del aluminio en el interior del molde y su enfriamiento. Un 100 % pasa por el control de calidad, por lo que cada pieza OK y NOK se registra con perfecta trazabilidad respecto a sus procesos previos. Un obstáculo, desde el punto de vista analítico es que se cuenta con una producción muy desbalanceada, con muchas más piezas OK que NOK.

El objetivo de este proveedor de primer nivel es conseguir un recomendador de parámetros que ayude a los ingenieros de procesos en la toma de decisiones, de cara a incrementar el ratio de piezas Ok frente al de NOK. Para ello, es importante encontrar rápidamente los parámetros clave y sus niveles que afectan al proceso. Conseguir bajos índices de defectos dominando el proceso, identificando las variables críticas y ajustando sus niveles reduce el impacto en el rendimiento económico de producir piezas fuera de especificación. Además, no sólo es importante reducir la cantidad de piezas NOK, sino también que el apoyo de la tecnología en la toma de decisiones realmente añada valor. Esto se consigue detectando las partes realmente críticas del proceso.

La complejidad de este proceso radica en que existen una ingente cantidad de parámetros interac-

tuando en el proceso y que pueden derivar en series de producción de calidad no aceptable. Detectar qué variables son las verdaderamente significativas, y encontrar como afectan a la calidad final del producto no es una tarea trivial, pues en muchos casos ser capaces de recoger toda la información que realmente aporta valor, separándola del resto de información y determinar como ésta afecta al proceso se convierte en una tarea donde la buena gestión es clave. Es necesario tener en cuenta qué partes del proceso deben ser monitorizadas, establecer una frecuencia de recogida de datos adecuada, y poseer las habilidades necesarias para poder almacenar, procesar y extraer información relevante que ayude en el proceso de toma de decisiones.

2.1.2. Planificación de la producción

Tal y como se ha adelantado en la introducción, la planificación de la producción [32, 33] es un problema de optimización centrado en la asignación de trabajos de producción a los recursos industriales en un momento determinado. Es uno de los principales problemas en la planificación de la producción de las empresas actuales, ya que dedican recursos en un intento de encontrar eficientemente planificaciones óptimas. Dada la complejidad *NP-hard* del *JSP*, en muchos casos la asignación de tareas/trabajos a los recursos es realizada por humanos, lo que hace que las aproximaciones encontradas estén lejos de las óptimas.

El objetivo principal del *JSP* es, por tanto, encontrar una planificación de la producción óptima teniendo en cuenta las variables y restricciones que afectan a la producción en el escenario considerado. Dichos aspectos pueden ser de naturaleza variada, incluyendo la disponibilidad de máquinas, las cantidades mínimas a producir para cada tipo de producto, la calidad y disponibilidad de materiales, la cualificación del personal o la eventualidad de averías, entre muchos otros. Un objetivo que se suele considerar en toda la literatura relacionada con el *JSP* es la minimización del *makespan*. Varios estudios presentados en los años 80 y 90 abordaron el problema de minimización del *makespan* mediante algoritmos de optimización [34, 29, 35, 36]. Sin embargo, esta formulación de *JSP* sigue siendo relevante y continúa atrayendo el interés de la comunidad investigadora que trabaja en algoritmos metaheurísticos de optimización [37, 38].

Definimos matemáticamente el *JSP* adoptando la notación propuesta en [39]. Así, N trabajos de producción independientes $\{j_n\}_{n=1}^N$ deben procesarse a través de M máquinas de producción $\mathcal{M} = \{m_i\}_{i=1}^M$. Cada trabajo j_n consta de O_n tareas ordenadas $[T_1^n, \dots, T_{O_n}^n]$. La tarea T_k^n se procesa en una máquina predefinida $m_j \in \mathcal{M}$, o en cualquier máquina que esté preparada para la tarea, dada por $\mathcal{M}_j \subseteq \mathcal{M}$. La asignación de la tarea T_k^n a la máquina de producción m_j produce un coste $C_{j,n,k}$. La formulación más simplista del problema *JSP* considera que el tiempo de procesamiento global es el único objetivo de coste que debe minimizarse, mientras que otras formulaciones pueden perseguir la minimización de otros objetivos de coste en conflicto (por ejemplo, la energía) o aprovechar la flexibilidad de decidir qué máquina cualificada de \mathcal{M}_j puede servir para cada tarea. Cuando se consideran diferentes objetivos, la meta del problema *JSP* multiobjetivo es encontrar un número de programas de producción que equilibren de forma diferente los objetivos considerados, pero de una forma óptima.

De una manera gráfica, en la Figura 2.2 se puede ver el ejemplo de dos opciones diferentes de planificación para un mismo pedido consistente en dos trabajos, el *Trabajo 1*, que tiene que pasar por la máquina 3, 2 y 1, y el *Trabajo 2*, que tiene que pasar por las máquinas 1, 2 y 3. En la comparativa entre ambas planificaciones se puede observar como el tiempo necesario para completar todos los trabajos es significativamente menor en la ordenación superior que en la inferior, y esto se debe exclusivamente a una mejor ordenación de las tareas a realizar.

El problema del ejemplo descrito resulta trivial, pues el número de combinaciones es bajo, con el fin de mostrar mediante un ejemplo simplificado el problema. Pero este escenario no se da en entornos productivos reales, donde la magnitud del número de ordenes de fabricación y de máquinas disponibles es muy superior al mostrado, por lo que el uso de técnicas de optimización ayudarán

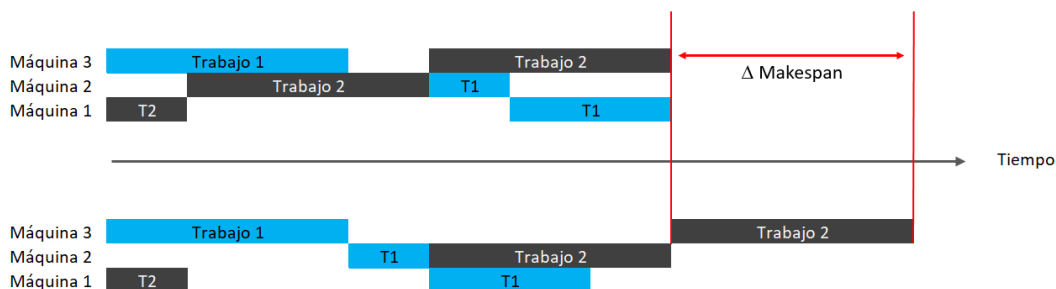


Figura 2.2: Ejemplo de solución óptima (arriba) y no óptima (abajo) para la planificación de la producción de dos trabajos.

a encontrar soluciones óptimas. Es importante remarcar, antes de proseguir, que en este tipo de problemas (*NP-hard*) no se puede garantizar encontrar las soluciones óptimas.

Además de seguir considerando el *makespan* como un objetivo central del *JSP*, el consumo de energía ha subido en el *ranking* de prioridades en los últimos años, debido a la concienciación global surgida en torno al cambio climático, la sostenibilidad de la cadena de valor industrial [30] y el impacto en los costes de producción. Existe un reto global para frenar las emisiones generadas por los países, con elevadas penalizaciones para las entidades, empresas e instituciones que los incumplan, lo que se asocia también a un mayor coste de la energía debido a las penalizaciones por el uso de métodos de producción de energía con un alto impacto ambiental, como el uso del carbón.

2.2. Inteligencia artificial

En esta segunda parte del capítulo extendemos la definición esbozada de la inteligencia artificial realizada en la introducción. Aunque en la literatura es posible hallar un sinfín de diferentes definiciones y disecciones de la inteligencia artificial, en la tesis emplearemos la distinción de subáreas y campos de esta disciplina ilustrada en la Figura 2.3. En ella podemos ver los siguientes campos:

- Aprendizaje automático o *Machine Learning*, que abarca el desarrollo de algoritmos y técnicas que permiten a las máquinas aprender a partir de los datos, sin necesidad de ser programadas explícitamente.
- *Optimización matemática*, que se centra en encontrar las soluciones óptimas para problemas de optimización, es decir, problemas que implican encontrar el máximo o el mínimo de una función sujeta a ciertas restricciones impuestas.
- *Visión por ordenador*, que permite, mediante algoritmos capaces de aprender a reconocer patrones en la información visual, extraer conocimiento de flujos de vídeos e imágenes complejas. Gracias a la inteligencia artificial, las capacidades de reconocimiento de imágenes han avanzado exponencialmente, siendo las capacidades sin precedentes de los vehículos de conducción autónoma [40] una de las aplicaciones más relevantes.
- *Procesamiento del lenguaje natural*, que abarca el conjunto de técnicas que permiten a los algoritmos entender, interpretar y procesar el lenguaje humano de manera automática, permitiendo traducir el lenguaje humano a lenguaje de programación de manera automática, y viceversa. Un ejemplo de aplicación puede ser los asistentes de programación [41] o los traductores entre idiomas automáticos[42], entre otros.

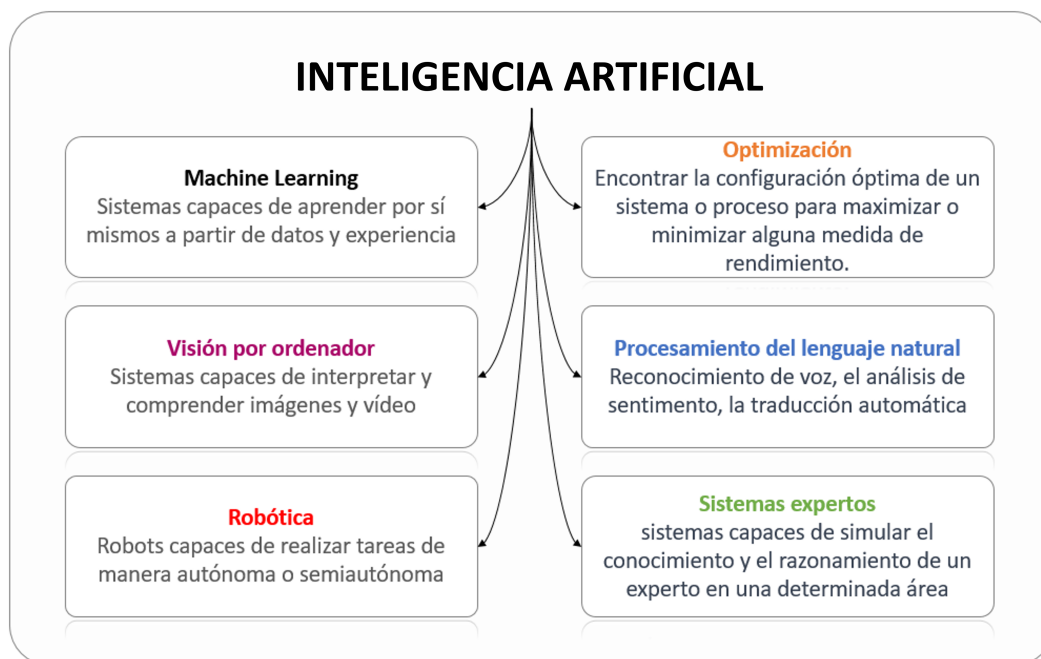


Figura 2.3: Esquema de la inteligencia artificial.

- *Robótica*, que referencia a dispositivos electromecánicos capaces de realizar tareas de manera autónoma, con la capacidad de adaptarse al entorno y conseguir la interacción hombre-máquina de una manera menos restrictiva que la actual.
- *Sistemas expertos*, los cuales ayudan a la toma de decisiones proponiendo soluciones a problemas complejos a partir del conocimiento adquirido sobre el problema en cuestión.

Como se puede observar, los campos de la inteligencia artificial arriba descritos son muy amplios, por lo que se hará hincapié sólo en los dos que son de aplicación en esta tesis. Por lo tanto, la sección 2.2.1 aborda y detalla el campo del aprendizaje automático (*machine learning*), mientras que la subsección 2.2.2 hace lo propio en lo que respecta a la optimización multiobjetivo.

2.2.1. Aprendizaje automático (Machine Learning)

El aprendizaje automático o *machine learning* [43] es un subconjunto de la inteligencia artificial que permite a los sistemas informáticos aprender de un conjunto de datos y generar soluciones que ayuden a mejorar el problema que se plantea, en base a lo aprendido y sin estar explícitamente programados para ello, siendo capaces de detectar patrones y correlaciones complejas en dicho conjunto de datos. Los algoritmos de aprendizaje automático pueden dividirse en tres categorías principales:

- Aprendizaje supervisado.
- Aprendizaje no supervisado.
- Aprendizaje semi-supervisado.

Debido a que este capítulo tiene como intención ser una introducción sobre los aspectos técnicos, haremos énfasis en el aprendizaje supervisado, que será el empleado para tratar de dar respuesta a los problemas de mejora de procesos productivos mediante una nueva metodología sensible al coste. Sobre los otros dos tipos, se hará una breve introducción.

2.2.1.1. Aprendizaje supervisado

El *aprendizaje supervisado* [44] se define como aquél que persigue descubrir las relaciones intrínsecas entre un conjunto de variables predictoras y una variable (o varias variables) objetivo, y en el que el algoritmo se entrena con un conjunto de datos previamente etiquetados.

Para usar esta técnica es necesario contar con al menos dos conjuntos de datos claramente diferenciados para su uso. A uno de ellos se le denomina conjunto de datos de entrenamiento pues, como su nombre indica, se utiliza para que el algoritmo sea capaz de aprender y descubrir las relaciones intrínsecas anteriormente mencionadas. Toda vez que el modelo ha sido entrenado, y haciendo uso del segundo conjunto de datos, normalmente llamado conjunto de test, el algoritmo realizará predicciones sobre la variable objetivo con estos datos; de la comparativa entre la variable objetivo predicha por el algoritmo y el valor real de la misma se determinará la bondad de ajuste del modelo, y por tanto, la calidad del mismo.

Dentro de los modelos de aprendizaje supervisado podemos encontrar principalmente dos subgrupos, los modelos de *clasificación* y de *regresión*. En el aprendizaje supervisado por **clasificación** [45], el algoritmo trata de etiquetar la variable respuesta entre dos o más clases, utilizando para ello la información aprendida de los datos de entrenamiento. Ejemplos de uso de aprendizaje de clasificación se pueden encontrar en la detección de *spam* [46], la presencia de tumores en imágenes médicas [47], o la prognosis industrial [14], entre otros. En los **modelos de regresión** [48], el algoritmo es entrenado para predecir una variable definida sobre un rango continuo e infinito de valores. Ejemplos de uso son, por ejemplo, la predicción del precio de la vivienda [49], del precio de las materias primas [50], la predicción de tráfico en carreteras [51], etc.

Tal y como se ha definido en la subsección 2.1.1, estamos ante un caso de clasificación, donde se necesita un sistema capaz de clasificar de manera correcta la calidad resultante de las piezas finales basado en los parámetros de máquina previamente registrados. Además el problema se vuelve más complejo al conocer, basado en históricos, que se trata de un problema desbalanceado, donde el porcentaje de piezas producidas con buena calidad es muy superior al porcentaje de las piezas de baja calidad. Para hacer frente al desbalanceo de clases es necesario utilizar técnicas de desbalanceo de datos para hacer que no influya en la calidad del modelo generado. Para ello existen tres tipos de técnicas que permiten protegernos contra esta problemática. De no hacerlo, lo más probable es que nuestro modelo sea capaz de predecir al 100 % la clase mayoritaria, y al 0 % la clase minoritaria, que en este caso es la de mayor interés. El tipo de técnicas a aplicar se pueden agrupar de la siguiente manera:

- Muestreo de datos: En el que las instancias de entrenamiento se modifican de tal forma que producen una distribución de clases más o menos equilibrada que permite a los clasificadores rendir de forma similar a la clasificación estándar, mediante técnicas de *oversampling* y *undersampling*, incrementando la clase minoritaria de manera artificial, o disminuyendo el número de muestras de la clase mayoritaria.
- Aprendizaje sensible a los costes: Este tipo de soluciones consideran mayores costes para la clasificación errónea de ejemplos de la clase positiva respecto a la clase negativa, y por tanto, tratando de minimizar los errores de mayor coste.

Respecto a las métricas, es decir, el indicador que cuantifica la bondad de un modelo, la más común para validar problemas de clasificación es la precisión (*Accuracy* o *Acc*) (2.1), pero no es la más apropiada en problemas desbalanceados, ya que no es capaz de distinguir entre el número de instancias correctamente clasificadas en la clase mayoritaria y minoritaria [52]. Esta métrica se define para problemas de clasificación binaria como:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2.1)$$

donde TP (TN) y FP (FN) son las tasas de verdaderos y falsos positivos (negativos), respectivamente. Otra métrica bastante empleada es el área debajo de la curva (*Area Under Curve* o AUC) 2.2, o área debajo de la curva:

$$AUC = \frac{1 + TPR - FPR}{2} \quad (2.2)$$

donde $TPR = TP/(TP + FN)$ y $FPR = FP/(FP + TN)$.

Desafortunadamente, la métrica AUC tiene el problema de que se ve influenciada por la clase mayoritaria. Es por ello que la métrica que tiene más sentido emplear para este tipo de problemas es la denominada F1, la cual está compuesta por una agregación de la denominada precisión y el *recall*. Por un lado, la precisión es una métrica que mide cuántos de los elementos que el modelo clasificó como positivos (es decir, pertenecientes a una determinada clase) realmente eran positivos. Se calcula como el número de elementos verdaderamente positivos dividido por el número total de elementos clasificados como positivos, i.e.:

$$Precision = \frac{TP}{TP + FP} \quad (2.3)$$

Por otro lado, el *recall* mide cuántos de los elementos que deberían haber sido clasificados como positivos (es decir, pertenecientes a una determinada clase) realmente fueron clasificados como tales. Se calcula como el número de elementos verdaderamente positivos dividido por el número total de elementos que deberían haber sido clasificados como positivos, es decir, como la tasa de verdaderos positivos anteriormente definida:

$$Recall = \frac{TP}{TP + FN} \quad (2.4)$$

Partiendo de estas definiciones, la métrica *F1* es la media armónica entre la precisión y el *recall*, i.e.:

$$F1 = \frac{(1 + \beta)Recall \cdot Precision}{\beta^2 Recall + Precision} \quad (2.5)$$

donde β es un parámetro que establece cuán de más importante es el *recall* comparado con la precisión. Para la métrica *F1*, $\beta = 1$.

2.2.1.2. Aprendizaje no supervisado

Se denomina *aprendizaje no supervisado* [53] a aquel que no necesita de datos etiquetados y, por tanto, sólo los datos de entrada están disponibles sin una variable respuesta, por lo que basado en los datos de entrada se empieza a encontrar patrones y posibles formas de agrupación. Se utilizan principalmente para descubrir estructuras y relaciones en los datos sin una guía explícita. Dentro de aprendizaje no supervisado, podemos encontrar principalmente *técnicas de clustering o agrupamiento*, *técnicas de reducción de dimensionalidad* y *reglas de asociación*.

Las *técnicas de clustering* [54] son usadas para dividir un conjunto de datos en grupos o clústers basados en la similitud entre los mismos. Dichas similitudes pueden establecerse basadas en diferentes reglas como, por ejemplo, distancias (euclídea, Manhattan, Mahalanobis, etc.), basados en densidad, etc. Un caso de uso puede ser por ejemplo la agrupación de diferentes tipos de productos de todo un catálogo, basada en el comportamiento de la demanda [55].

La *reducción de dimensionalidad* [56] se emplea como técnica de simplificación de la información, por lo que va a permitir simplificar los datos eliminando redundancias y eliminando variables irrelevantes, pero manteniendo la mayor parte de su información de variación. Esto puede ayudar

a mejorar el rendimiento de otros algoritmos y, además, hacer que los datos sean más fáciles de interpretar. Dentro de este tipo de algoritmos podemos destacar el uso de componentes principales (LCA), y, de una manera más gráfica, los gráficos bi-plot.

Las *reglas de asociación* [57] se utilizan para descubrir patrones de co-ocurrencia en los datos, como por ejemplo detectar cuándo la ocurrencia de la venta de un artículo está intrínsecamente relacionada con la venta de otros en esa misma compra. Para llevar a cabo este tipo de análisis, las reglas de asociación buscan descubrir los subconjuntos de ítems que más frecuentemente ocurren para un conjunto de transacciones, para después establecer las reglas de asociación entre los mismos. Debido a la complejidad computacional que exige el cálculo por fuerza bruta de todas las combinaciones posibles entre diferentes ítems frecuentes, se suelen adoptar diferentes tipos de estrategias que simplifiquen el cálculo: entre ellas, la reducción del número de candidatos con técnicas de poda, la reducción del número de transacciones, o la reducción del número de comparaciones, de tal manera que no sea necesario comparar a cada candidato con todas las opciones posibles.

2.2.1.3. Aprendizaje semisupervisado

El *aprendizaje semisupervisado* [58] se encuentra a medio camino entre el aprendizaje supervisado y el no supervisado. En él, el conjunto de datos no está 100% etiquetado, pues puede ser imposible o muy costoso conseguir etiquetar todos los casos. El conjunto de datos etiquetado servirá como guía para ir etiquetando el conjunto de datos no etiquetados alimentando por tanto al algoritmo para que analice los datos etiquetados según propiedades correlativas que podrían aplicarse a los datos no etiquetados. Podemos subdividir el aprendizaje semisupervisado en dos tipos:

- Clasificación semisupervisada, mejora la clasificación supervisada minimizando los errores en los ejemplos etiquetados, pero también debe ser compatible con la distribución de entrada de las instancias no etiquetadas.
- Agrupación semisupervisada: También conocido como *textitclustering restringido*, tiene como objetivo obtener *clusters* mejor definidos que los obtenidos a partir de datos no etiquetados.

2.2.2. Optimización multiobjetivo y metaheurísticas

Esta sección incluye conceptos básicos sobre la optimización multiobjetivo (subsección 2.2.2.1) y los algoritmos metaheurísticos (subsección 2.2.2.2). Los indicadores para medir la calidad de los resultados obtenidos por este tipo de algoritmos quedan detallados en la sección 2.2.2.3.

2.2.2.1. Optimización multiobjetivo

La optimización multiobjetivo es la disciplina que se ocupa de los problemas formulados en torno a dos o más funciones objetivo que tienen que ser optimizadas al mismo tiempo. Estas funciones suelen estar en conflicto, por lo que la mejora de una de ellas conlleva una degradación de las otras. Supondremos, sin pérdida de generalidad, que todas las funciones objetivo deben ser minimizadas.

A grandes rasgos, el objetivo que se busca en un problema de optimización multiobjetivo (POM) es encontrar un conjunto de soluciones que no sólo satisfagan las restricciones de igualdad y desigualdad eventualmente impuestas (según el problema a resolver), sino que también se equilibre lo mejor posible el compromiso entre los objetivos establecidos. Matemáticamente, un problema de optimización multiobjetivo se puede definir como sigue:

Definición 1. (POM) *Encontrar un vector $\vec{x}^* = [x_1^*, x_2^*, \dots, x_n^*]$ que satisfaga m restricciones de desigualdad $g_i(\vec{x}) \geq 0, i = 1, 2, \dots, m$, p restricciones de igualdad $h_i(\vec{x}) = 0, i = 1, 2, \dots, p$ y minimiza la función vectorial $\vec{f}(\vec{x}) = [f_1(\vec{x}), f_2(\vec{x}), \dots, f_k(\vec{x})]^T$, donde $\vec{x} = [x_1, x_2, \dots, x_n]^T$ es el vector de las variables de decisión.*

En esta definición todos los valores del vector de variables de decisión que satisfacen las restricciones circunscriben la *región factible* Ω , así que cada punto $\vec{x} \in \Omega$ puede ser referido como una *solución factible*.

La naturaleza opuesta de los objetivos $\vec{f}(\vec{x})$ de un POM implica la necesidad de definir qué es una solución óptima. Para ello es necesario definir el concepto de *óptimo de Pareto*:

Definición 2. (*Óptimo de Pareto*) Un punto $\vec{x}^* \in \Omega$ es un punto óptimo de Pareto si para cada $\vec{x} \in \Omega$ y $I = \{1, 2, \dots, k\}$ cualquiera $\forall i \in I$ ($f_i(\vec{x}) = f_i(\vec{x}^*)$) o hay al menos uno $i \in I$ tal que $f_i(\vec{x}) > f_i(\vec{x}^*)$.

Según esta definición, un vector (punto o solución) \vec{x}^* es óptimo de Pareto si no existe ningún vector factible \vec{x} que mejore algún criterio sin causar un empeoramiento simultáneo en al menos otro criterio.

Dados dos vectores correspondientes a soluciones de un POM dado, compararlos para determinar cuál es mejor en términos de minimización de objetivos no es tan sencillo como en la optimización de un solo objetivo. Cuando se trata de un único objetivo, se puede declarar que el vector que tiene el menor valor de función asociado es mejor que el otro. Por el contrario, cuando hay varios objetivos involucrados, se introduce el concepto de *dominancia de Pareto* para comparar entre las soluciones:

Definición 3. (*Dominancia de Pareto*) Un vector $\vec{u} = (u_1, \dots, u_k)$ se dice que domina $\vec{v} = (v_1, \dots, v_k)$ (denotado por $\vec{u} \preceq \vec{v}$) si y solo si \vec{u} es parcialmente menor que \vec{v} , por ejemplo, $\forall i \in \{1, \dots, k\}$, $u_i \leq v_i \wedge \exists i \in \{1, \dots, k\} : u_i < v_i$.

Mediante el uso de la dominancia de Pareto podemos determinar si, dadas dos soluciones, una *domina* a la otra o, por el contrario, no se dominan mutuamente. En este último caso, se trata de soluciones *igualmente no dominadas* y, por tanto, no se puede decir cuál de ellas es mejor en el sentido del compromiso entre los objetivos del POM. Un punto óptimo de Pareto es aquél que no está dominado por ningún otro punto en Ω .

La optimización de un POM puede definirse entonces como el proceso de encontrar el conjunto compuesto por todas las soluciones óptimas de Pareto. Este conjunto se denomina *conjunto óptimo de Pareto*, o simplemente conjunto de Pareto, y puede definirse como:

Definición 4. (*Conjunto óptimo de Pareto*) Para un POM dado $\vec{f}(\vec{x})$, el conjunto óptimo de Pareto $\mathcal{P}^* = \{\vec{x} \in \Omega \mid \neg \exists \vec{x}' \in \Omega, \vec{f}(\vec{x}') \preceq \vec{f}(\vec{x})\}$.

Cada vector del conjunto óptimo de Pareto tiene una correspondencia en el espacio de la función objetivo, lo que conduce al llamado *frente de Pareto*:

Definición 5. (*Frente Pareto*) Para un POM dado $\vec{f}(\vec{x})$ y su conjunto óptimo de Pareto \mathcal{P}^* , se define el frente Pareto como $\mathcal{PF}^* = \{\vec{f}(\vec{x}) \mid \vec{x} \in \mathcal{P}^*\}$.

Encontrar las soluciones óptimas de un POM es un primer paso en el proceso completo de optimización, ya que le sigue la etapa de toma de decisiones, en la que un experto en el dominio del problema tiene que elegir una de ellas que satisfaga algunos criterios [59]. En consecuencia, los algoritmos utilizados para la resolución de POMs tienen como objetivo encontrar una aproximación del conjunto de Pareto que tenga un número relativamente bajo de soluciones diversas, en base a las cuales el usuario de la aplicación en cuestión (en nuestro caso, la persona responsable de la planificación de la producción) pueda finalmente tomar decisiones informadas.

2.2.2.2. Metaheurísticas y algoritmos evolutivos

La búsqueda del conjunto de Pareto completo de un POM dado puede ser poco práctica por dos razones. Por un lado, proporcionar un gran número de soluciones puede complicar el proceso de

toma de decisiones; en general, los algoritmos utilizados para la resolución de POMs tienen como objetivo obtener una aproximación del conjunto de Pareto con un número relativamente bajo de soluciones. Por otro lado, los POMs pueden caracterizarse por una serie de características que los hacen muy difíciles de resolver, como la complejidad NP-hard, las funciones no lineales, varios objetivos o un gran número de variables de decisión, por mencionar algunas [60].

Como consecuencia, el uso de técnicas de optimización exactas es a menudo inviable en la práctica. La alternativa es recurrir a otro tipo de algoritmos. En este contexto, las metaheurísticas aparecen como una familia de técnicas no exactas que han ganado mucha popularidad desde los años 90. Pueden definirse como estrategias iterativas que guían y gestionan las operaciones de las heurísticas subordinadas para encontrar eficientemente soluciones de alta calidad [28]. Las metaheurísticas suelen ser no deterministas y no son específicas del problema, aunque pueden incorporar conocimientos del dominio en virtud de la flexibilidad de su diseño algorítmico.

Tabla 2.1: Clasificación de las metaheurísticas en técnicas inspiradas en la naturaleza y no inspiradas en la naturaleza, junto con algunos ejemplos ilustrativos para cada una de estas categorías.

Inspiradas en la naturaleza	No inspiradas en la naturaleza
<ul style="list-style-type: none"> • Recalentamiento simulado (SA) • Inteligencia de enjambre <ul style="list-style-type: none"> – Optimización por enjambre de partículas (PSO) – Optimización de colonias de hormigas (ACO) • Computación evolutiva (EC) <ul style="list-style-type: none"> – Algoritmos genéticos (GA) – Estrategia de evolución (ES) – Programación genética (GP) • Sistemas inmunes artificiales (AIS) 	<ul style="list-style-type: none"> • Búsqueda tabú (TS) • Búsqueda de vecindades variables (VNS) • Búsqueda por dispersión (SS) • Búsqueda local iterada (ILS) • Búsqueda local guiada (GLS) • Reenlace de ruta (PR) • Codicioso Aleatorio Adaptativo Procedimientos de búsqueda (GRASP)

Las subclases de metaheurísticas incluyen los algoritmos evolutivos (con mucho, la metaheurística más conocida), la optimización de colonias de hormigas, el recocido simulado y la optimización con enjambre de partículas. De hecho, se han diseñado muchas metaheurísticas, por lo que se han propuesto varios enfoques para clasificarlas. La taxonomía más aceptada distingue entre metaheurísticas inspiradas en la naturaleza y metaheurísticas no inspiradas en la naturaleza. La tabla 2.1 contiene una lista de algoritmos metaheurísticos representativos según esta clasificación. Un compendio más exhaustivo de las metaheurísticas inspiradas en la naturaleza puede encontrarse en cualquiera de los estudios taxonómicos aportados recientemente por la comunidad (véase, por ejemplo, [61] y las referencias incluidas en él).

Entre las metaheurísticas inspiradas en la naturaleza, los algoritmos evolutivos son técnicas inspiradas en la evolución biológica, en las que las soluciones se denominan individuos y se agrupan en poblaciones que se van refinando a lo largo del proceso de búsqueda. Los individuos evolucionan mediante la aplicación iterativa de operadores de selección, reproducción y reemplazo sobre la población, que imitan la evolución de los seres en un ecosistema. Dentro de la computación evolutiva destacan los algoritmos genéticos, que aplican la recombinación y la mutación en el paso de reproducción. Al igual que en la optimización tradicional de un solo objetivo, las metaheurísticas han sido ampliamente utilizadas para resolver POMs [62, 63]. Algunos de los algoritmos más empleados son NSGA-II [64], MOEA/D [65] y SMS-EMOA [66]. Estas tres metaheurísticas POM ejemplificadas son, respectivamente, representantes de las tres categorías comúnmente aceptadas de metaheurísticas multiobjetivo: dominancia de Pareto, descomposición y basada en indicadores.

2.2.2.3. Indicadores de calidad

Para medir la calidad de la aproximación al frente de Pareto producida por metaheurísticas multiobjetivo, se suelen tener en cuenta dos aspectos: minimizar la distancia del frente obtenido al frente de Pareto del problema (convergencia) y maximizar la extensión de las soluciones en el frente para que la distribución sea lo más uniforme posible (diversidad). Existen diferentes formas de medir estas propiedades, por lo que se han definido indicadores de calidad. A continuación se describen brevemente algunos de los más usados:

- *EP (Epsilon)*, [67]: Dado un frente calculado para un problema, A , este indicador es una medida de la distancia más pequeña que se necesitaría para trasladar cada solución de A de modo que domine el frente óptimo de Pareto de este problema. Más formalmente, dado $\vec{z}^1 = (z_1^1, \dots, z_n^1)$ y $\vec{z}^2 = (z_1^2, \dots, z_n^2)$, donde n es el número de objetivos

$$I_{\epsilon+}^1(A) = \inf_{\epsilon \in \mathbb{R}} \left\{ \forall \vec{z}^2 \in \mathcal{PF}^* \exists \vec{z}^1 \in A : \vec{z}^1 \prec_{\epsilon} \vec{z}^2 \right\}$$

donde, $\vec{z}^1 \prec_{\epsilon} \vec{z}^2$ si y solo si $\forall 1 \leq i \leq n : z_i^1 < \epsilon + z_i^2$. En este caso, los frentes de solución con valores más bajos de $I_{\epsilon+}$ son deseables.

- *GD (Generational Distance)*: Es la distancia promedio entre el conjunto de soluciones no dominadas obtenidas por el algoritmo y el conjunto de soluciones óptimas (ver Figura 2.4). Más formalmente, dado un conjunto A se define como la distancia entre cada punto $a \in A$ y el punto r más cercano de un conjunto de referencia R , promediada sobre el tamaño de A .

$$GD(A) = \frac{1}{n} \sum_{1..n} d$$




Figura 2.4: GD.

- *IGD (Inverted Generational Distance)*, [68]: Distancia media de cada solución de los puntos de frente de Pareto a un frente A (ver Figura 2.5). Convergencia al verdadero frente de Pareto. Viene dado por:

$$IGD(A) = \frac{1}{n} \sum_{1..n} ld$$




Figura 2.5: IGD.

- *HV (Hypervolume)*, [69]: El hipervolumen es una métrica combinada de convergencia y diversidad que mide la región dominada por la fuente obtenida (ver Figura 2.6. Matemáticamente, para cada solución $i \in Q$, se construye un hipercubo v_i utilizando un punto de referencia W (que puede estar compuesto por la peor solución para cada objetivo, por ejemplo) y la solución i como las esquinas de la diagonal del hipercubo. El punto de referencia puede obtenerse simplemente construyendo un vector de los peores valores de las funciones. Así, *HV* se calcula como el volumen de la unión de todos los hipercubos:

$$HV = \text{volume} \left(\bigcup_{i=1}^{|Q|} v_i \right)$$

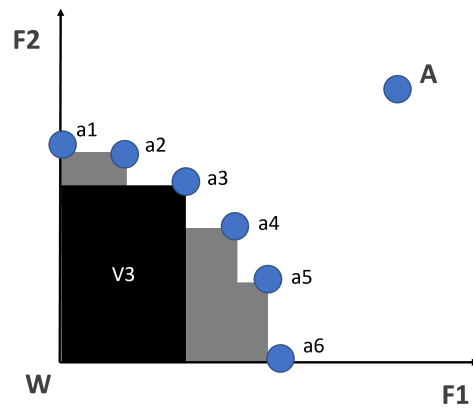


Figura 2.6: Hipervolumen (HV).

El cálculo de los indicadores de calidad requiere obtener un frente de referencia. En algunos casos, el frente de Pareto de los problemas es desconocido, por lo que será necesario construir un

frente pareto de referencia, para lo que se puede usar las soluciones no dominadas de todas las ejecuciones de todos los algoritmos que se vayan a ejecutar por problema.

Capítulo 3

Estado del arte

Este capítulo tiene como objeto hacer una revisión de las metodologías y tipo de soluciones propuestas para la mejora, en los entornos industriales, enfocada en los dos tipos de problemas que se han descrito anteriormente, la mejora de procesos productivos y la mejora de la planificación de la producción con la energía como uno de sus objetivos, tal y como se describe en la Introducción.

3.1. Mejora de procesos productivos

En esta sección se van a describir las principales herramientas y metodologías que se pueden encontrar implementadas en las organizaciones industriales para abordar la mejora de procesos productivos desde el punto de vista económico y de proceso. Además, se realiza un análisis crítico de las mismas, detectando además los puntos débiles de las mismas.

3.1.1. Revisión de las principales metodologías

Tradicionalmente, para hacer frente a una competitividad cada vez mayor en sus respectivos mercados, las industrias se han visto obligadas a mejorar constantemente sus procesos. Para ello, se pueden adoptar varias metodologías, entre las cuales *SPC* (*Statistical Process Control*), *TQM* (*Total Quality Management*), *LEAN* y *6SIGMA* pueden considerarse las más adoptadas:

- *SPC* [70] fue la primera metodología que adoptó técnicas de control estadístico a principios del siglo XX, utilizadas años más tarde por Estados Unidos en la Segunda Guerra Mundial para mejorar el proceso de fabricación de armas. El *SPC* se basa en el uso de gráficos de control donde se monitorizan variables importantes, para evidenciar cambios en el comportamiento normal de los procesos de producción, permitiendo a los operarios actuar y corregir la deriva de los procesos. Más recientemente se han aportado a la comunidad revisiones, como [71], donde se hace un repaso de la aplicación y las experiencias del *SPC* en la industria alimentaria a lo largo de 30 años. La mayoría de estos informes concluyen que la motivación general que subyace a la adopción del *SPC* es la reducción de la producción de defectos, pero que subsisten algunas barreras, como la resistencia al cambio del personal implicado y la falta de conocimientos estadísticos suficientes. El estudio [72] se centra en la mejora de la calidad y la rentabilidad. Entre los beneficios de la aplicación del *SPC* se incluyen la resolución de problemas y el diagnóstico en plazos más cortos con costes de producción reducidos. Sin embargo, el *SPC* sufre problemas prácticos en su aplicación, ya que hay que formar previamente a los operarios y elaborar nueva documentación, lo que requiere un exceso de trabajo para su preparación.

- **TQM** [73] es una estrategia de gestión destinada a crear conciencia de calidad en todos los procesos organizativos. La *TQM* se ha utilizado ampliamente en diferentes áreas, como la industria, la educación y el sector servicios entre otros. Se denomina *total* porque se ocupa de la organización de la empresa en su conjunto, incluido su personal. *TQM* comprende tres paradigmas generales: 1) gestión, con pasos y objetivos compuestos específicos como planificación, organización, control y liderazgo; 2) total, que representa la cobertura de la metodología en toda la organización; y 3) calidad, que denota la cuantificación de la metodología mediante las definiciones habituales de indicadores y todos los derivados posteriores. Por poner dos ejemplos, en [74] se aplica la metodología *TQM* a un hotel de Grecia, identificando como resultado factores *TQM* influyentes como las prácticas de calidad de la alta dirección, la planificación estratégica de la calidad, la gestión de la calidad de los empleados, la orientación al cliente y el conocimiento y la formación de los empleados. Asimismo, [75] estudia, a través de la *TQM*, el impacto de la Cultura Organizativa en pequeñas y medianas empresas de automoción indias. Se descubrió que los principales factores son la apertura, la confrontación, la confianza, la autenticidad, la proactividad, la autonomía, la colaboración y la experimentación.
- **LEAN** [76] tiene su origen directo en el sistema de producción de Toyota desarrollado entre 1950 y 1980. Tras producir un gran lote de culatas y montarlas en los motores correspondientes, los ingenieros de producción de Toyota descubrieron finalmente que no se alcanzaba la potencia requerida porque las culatas producidas eran defectuosas. Los enormes costes ocasionados por este problema enseñaron a Sakichi Toyoda una de las lecciones que se han mantenido en la cultura de la empresa: la adquisición y verificación de la calidad de los componentes en cada fase del proceso de producción, antes de pasar a la siguiente, conformando el llamado concepto *Jidoka*. Esta fue la primera motivación para crear una nueva metodología para eliminar los residuos, mejorar la calidad y reducir los tiempos y costes de producción, basada en un conjunto de áreas operativas objetivo: sobreproducción, tiempo de permanencia, transporte, procedimientos excesivos, inventario, movimientos y defectos.
- **6SIGMA** [77] se define como un proceso empresarial que permite a las empresas mejorar sus resultados finales. Creada originalmente por Motorola en los años 80 y consolidada por General Electric, *6SIGMA* es una metodología que utiliza datos rigurosamente medidos y analizados para identificar las causas de un problema y las formas de eliminarlas, generando una mayor satisfacción del cliente y ahorros financieros sustanciales. Se apoya en herramientas estadísticas y analíticas y propone el desarrollo de grupos de trabajo dinámicos, trabajando con datos en su búsqueda de la causa raíz del problema estudiado. Esto se logra mediante un conjunto de 5 pasos: Definir, Medir, Analizar, Mejorar y Controlar. Abundan las experiencias recientes con *6SIGMA*: Shokri *et al* en [78] reportaron una buena práctica de la aplicación de *6SIGMA* para reducir defectos en una planta de fabricación de airbags, obteniendo una reducción de rechazo en el primer año del 0,63 %. Del mismo modo, [79] aplicó *6SIGMA* para reducir el defecto en la fabricación de envases de vidrio para una empresa de cosméticos, utilizando para ello herramientas como Pareto, Mapa de Procesos y *AMFE* (Análisis Modal de Fallos y Efectos).

Las metodologías examinadas anteriormente se aplican hoy en día a un gran número de industrias diversas; sin embargo, el advenimiento y la proliferación de sensores industriales capaces de registrar grandes volúmenes de datos estimularon la derivación de nuevas metodologías basadas en el análisis de la información recopilada. Algunos ejemplos los encontramos en trabajos recientes como [80], donde se explotan datos en tiempo real para aumentar la eficiencia de un proceso productivo; [81], que se centra en el uso de técnicas de minería de datos a casos reales de la industria; o [82], que propone una metodología de minería de datos de fabricación para entornos industriales, que abarca desde el análisis de la unidad de fabricación de industrias de la confección hasta la implementación y evaluación del modelo.

3.1.2. Resumen de los puntos críticos identificados

Una vez descritas las principales metodologías existentes en el sector industrial para la mejora de los procesos productivos, en la que se han incluido las principales referencias, se procede en este punto a resumir las principales observaciones que surgen de las mismas: *SPC* se centra en la monitorización de las variables por separado de los procesos productivos. Es de gran importancia siempre y cuando la relación sea directa e independiente del resto de variables respecto a la variable respuesta. Sin embargo, en muchas ocasiones esta variable es usada para ver la evolución de parámetros en la fabricación pero sin tener en cuenta el resto de parámetros, lo que puede llevar a una toma de decisiones errónea.

El *TQM* no tiene un proceso específico, sino que se basa en principios generales de mejora continua y participación activa de todos los empleados. El 6 Sigma tiene un proceso más detallado y estructurado: *DMAIC*. Cada una de estas partes tiene varias etapas y se utilizan herramientas y técnicas específicas para cada una de ellas. Respecto al enfoque, *TQM* se centra en la mejora continua de la calidad de los productos y servicios de una empresa y en la satisfacción del cliente. El 6 Sigma se centra más específicamente en la eliminación de errores y la variabilidad en los procesos de negocio y utiliza un sistema de roles y responsabilidades especializado para asegurar la implementación y el seguimiento de las mejoras. Podemos por tanto decir que *6Sigma* hereda conceptos de *TQM*, pero siendo esta última un enfoque más detallado y estructurado. *6Sigma* es principalmente reactiva a los problemas, es decir, los equipos de mejora se montan una vez se ha descubierto el problema dentro del proceso productivo y la fase de análisis de datos, debido al sobrecoste, se centra en el análisis de datos ya existentes o registrados por los sensores ya existentes. Además, en innumerables ocasiones, llevar a cabo un proyecto *6Sigma* conlleva un gran esfuerzo en las fases iniciales, debido a que las fuentes de datos no son fiables.

Mientras tanto, *LEAN* se centra en reducir el desperdicio de los procesos productivos, sin importar si lleva dicha mejora asociada una mejora en el proceso productivo o en el coste de los mismos, por lo cual no tiene por qué ser una mejora respecto a la calidad final del producto. Un ejemplo de esto es, por ejemplo, la organización de los utillajes en una máquina, colocando los de uso más frecuente más cerca, en lugar de en un almacén, lo cual puede suponer un ahorro en costes o tiempo, evitando desplazamientos innecesarios y optimizando el tiempo asociado, pero no una mejora ligada a la mejora en la calidad final del producto.

Es por ello por lo que se hace necesario definir una nueva metodología que, heredando todas las bondades de las metodologías descritas, sea capaz de definir las partes del proceso a sensorizar, de qué forma sensorizarlas, teniendo en cuenta sus costes; de cómo recolectar, cruzar y procesar en tiempo real dicha información, y, basados en el resultado del análisis de datos, prescribir en tiempo real o de manera estática, con una frecuencia de revisión dada por el especialista, la mejor configuración de parámetros del proceso productivo, que garantice el óptimo del mismo para las variables consideradas dentro de los ciclos habituales de producción. La metodología propuesta se detalla en el capítulo 4

3.2. Mejora de la planificación de la producción

Respecto a la mejora de la planificación de la producción existe una vasta cantidad de publicaciones al respecto. Como se ha explicado en la Introducción, nos vamos a centrar en el problema de la planificación de la producción con la energía como uno de sus objetivos. Para ello, se divide la sección en tres apartados. En primer lugar, la subsección 3.2.1 detalla los pasos metodológicos seguidos para recopilar la literatura relacionada y acabar con el corpus seleccionado de contribuciones consideradas. La subsección 3.2.2 sigue con el análisis de la literatura basado en tres taxonomías: características del problema, restricciones y consideraciones, y optimizador multiobjetivo en uso. Por

último, la sección se completa con un resumen de nuestras principales conclusiones tras el análisis de la literatura: como tal, la subsección 3.2.3 hace hincapié en las lecciones aprendidas, las buenas y malas prácticas y las oportunidades para futuras investigaciones en el área examinada.

3.2.1. Metodología de recopilación y filtrado de bibliografía

El proceso de búsqueda llevado a cabo se representa esquemáticamente en la Figura 3.1. La fuente de la búsqueda bibliográfica es *SCOPUS* [83], utilizando como términos de búsqueda “multi-objective job shop scheduling”, sin ningún tipo de limitación. La consulta de búsqueda utilizando estos términos devolvió un total de 772 resultados, sobre los que se aplicó un primer filtro: se eliminaron los trabajos duplicados, así como aquellas contribuciones que no se relacionaban en absoluto con procesos industriales y/o de fabricación. Asimismo, se excluyeron de los resultados de la búsqueda los trabajos que no habían sido revisados por pares, con el fin de conservar únicamente artículos de revistas y ponencias de congresos. Este primer ejercicio de filtrado redujo la cantidad de documentos devueltos a 420 resultados.

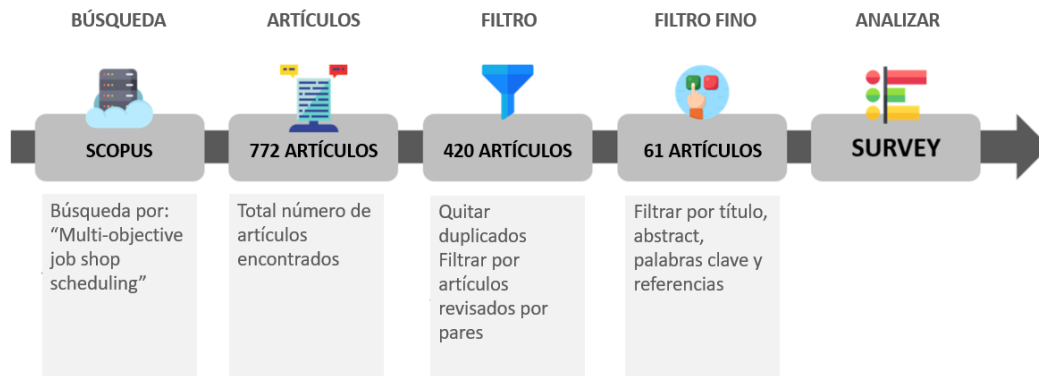


Figura 3.1: Diagrama de flujo de la metodología de búsqueda y filtrado.

Un segundo filtro seleccionó aquellos trabajos que tenían términos como *job*, *shop*, *job shop*, *flow shop*, *jobshop*, *job-shop*, centrados en la industria y con al menos dos objetivos, uno de ellos centrado en la energía. Tras este filtrado, nos quedamos con 61 referencias.

La Figura 3.2 muestra el número de artículos publicados por año hasta 2020. Podemos observar un crecimiento casi lineal desde 2017, lo que indica que el campo del *JSP* multiobjetivo que tienen en cuenta la energía está ganando impulso en los últimos años.

3.2.2. Taxonomías y análisis bibliográfico

Una vez que la búsqueda y el filtrado de artículos han producido una lista de los trabajos más relevantes, procedemos a analizarlos. Para ello, definimos tres taxonomías que abarcan diferentes aspectos que merecen ser estudiados:

- *Características del problema*: tipo de problema, número de objetivos, objetivo energético y objetivos secundarios.
- *Restricciones* y otras consideraciones que se han tenido en cuenta en los trabajos analizados.
- *Optimizador multiobjetivo*, incluyendo el algoritmo utilizado, algoritmos comparados y valores de los principales parámetros.




Figura 3.2: Número de publicaciones por año para el problema *JSP* multiobjetivo con la energía como uno de los objetivos.

A continuación se describen y analizan detalladamente las tres taxonomías.

3.2.2.1. Taxonomía 1: Características del problema

Desde el punto de vista de las características del problema, se han considerado cuatro características taxonómicas de interés: 1) el número de objetivos, 2) el objetivo energético, 3) los objetivos secundarios, y 4) el tipo de formulación *JSP*. La clasificación de los trabajos según estos criterios taxonómicos se muestra en la Figura 3.3.

Comenzamos nuestro análisis de la literatura a través de esta primera taxonomía analizando la primera de las características del problema: el **número de objetivos**. Esta característica se refiere a la formulación del problema de optimización en términos del número de objetivos. Cuanto mayor sea este número, más complejo se puede considerar el problema, ya que el espacio de búsqueda crece (la maldición de la dimensionalidad) y la toma de decisiones se hace más difícil de manejar en la práctica. Podemos observar en la Figura 3.5 que el 75,44 % de las referencias revisadas consideran dos objetivos, más del 22 % tienen 3 objetivos y sólo un trabajo se centra en un problema con más de tres objetivos. Como se verá más adelante, este predominio de referencias con 2 ó 3 referencias se alinea con las características de los problemas del mundo real, en los que raramente encontramos *JSP* que se rijan por más de 3 objetivos en conflicto.

Pasamos ahora a centrar el análisis en el **objetivo energético** específico definido. El objetivo genérico de reducir el consumo de energía puede definirse mediante distintos indicadores. Consideramos cuatro criterios: consumo de energía, costes de energía eléctrica, energía no usada en producción y energía mientras la máquina está en espera. A partir de estos criterios, hemos constatado que el 81,97 % de los trabajos analizados se basan en el punto de vista del consumo, expresado en KWh. Por el contrario, el 11,48 % de las aportaciones se refieren al coste del consumo energético, que no tiene por qué coincidir con el consumo debido a las diferentes políticas energéticas aplicadas en cada región, como por ejemplo la discriminación horaria. En este sentido, un algoritmo podría encontrar, por ejemplo, que es mejor producir por la noche a ritmos altos, con el consiguiente aumento del consumo de energía, pero con un bajo impacto en el coste energético, frente a producir a

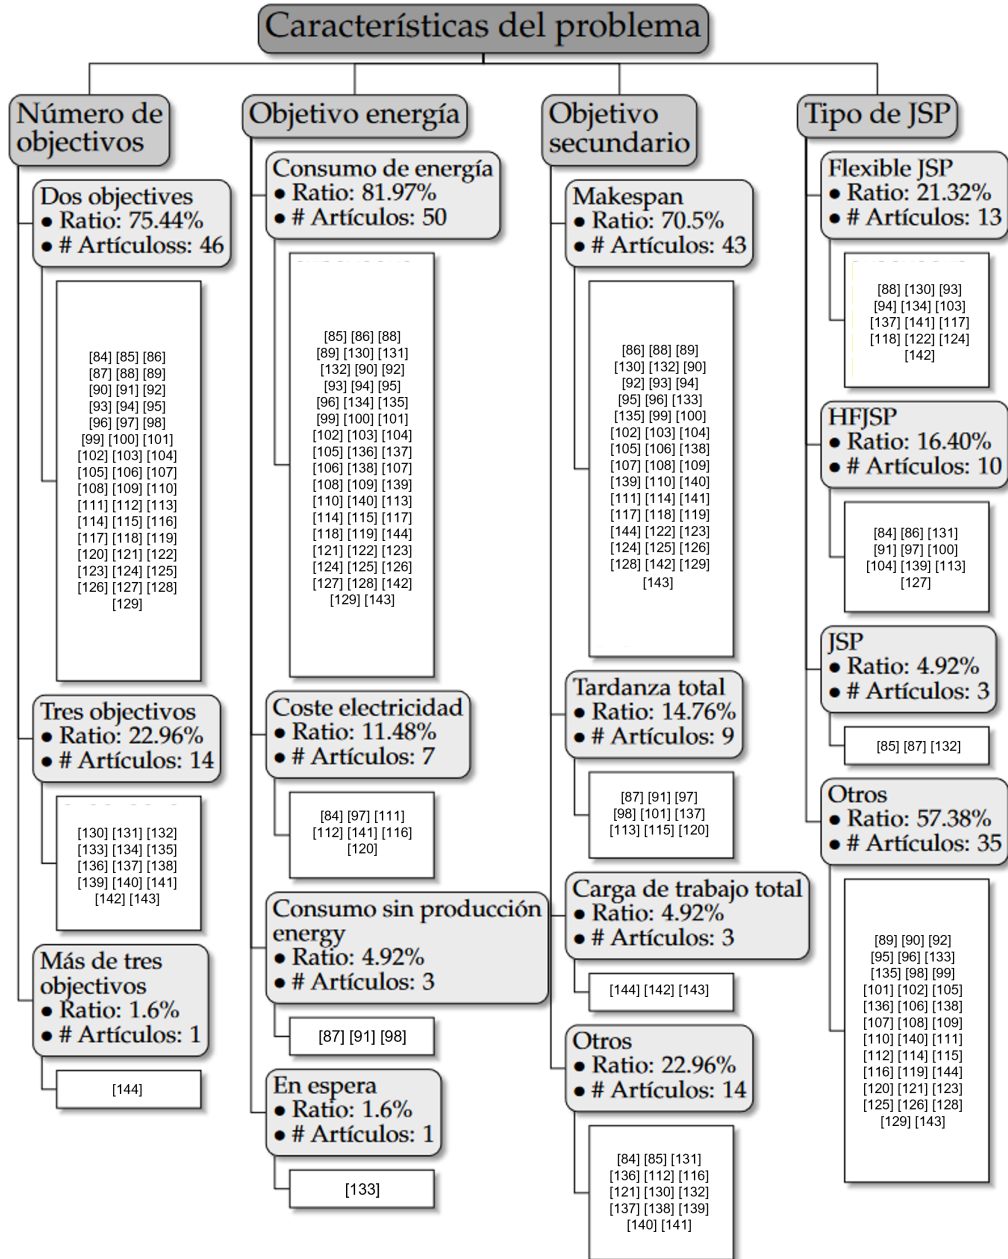


Figura 3.3: Taxonomía de la literatura revisada por características del problema.

rítmos más bajos por la tarde (mayor consumo, menor coste). El consumo de energía no utilizada en la producción y la energía consumida en los tiempos de espera de las máquinas se tienen en cuenta en el 4,92 % y el 1,6 % de la bibliografía revisada, respectivamente.

Por tanto, menos del 10 % de los trabajos analizados estudian el consumo de la energía cuando no se está estrictamente en producción. Dado que la reducción del tiempo de fabricación se ve directamente afectada por los tiempos de espera, el consumo de las máquinas durante los tiempos de espera puede ser de gran importancia, por ejemplo, en sectores como la siderurgia o las fundiciones, donde el consumo de energía durante el tiempo de espera de los activos de producción es crítico. Ignorar esta parte del comportamiento puede suponer un sobrecoste relativo al consumo de energía.

Dado que la revisión realizada aborda trabajos que tratan formulaciones multiobjetivo del *JSP* en las que el consumo de energía se minimiza conjuntamente con otros **objetivos secundarios**, continuamos nuestro examen de la primera taxonomía evaluando qué otros objetivos no relacionados con la energía se han utilizado. El objetivo secundario que aparece con más frecuencia es, como era de esperar (ya que la investigación se ha realizado en entornos industriales), el *makespan*, con un 70,5 % de los artículos revisados. Cuanto menor es el *makespan*, más eficiente es la producción o mayor es la capacidad de producción de una planta. Por lo tanto, el *makespan* es un objetivo a minimizar. Este objetivo puede entrar en conflicto con el objetivo energético, ya que un menor tiempo de producción puede requerir mayores velocidades de producción o el uso de más máquinas, consumiendo así más energía. Este es el caso más abordado, aunque es posible encontrar un óptimo global que garantice el mínimo *makespan* y la mínima energía, siempre que los tiempos de espera entre operaciones sean el único aspecto de la planta que permita minimizar la energía. Sin embargo, esto no suele ser lo habitual, lo que allana el camino para la adopción de soluciones basadas en la optimización multiobjetivo.

El siguiente objetivo secundario más importante es la tardanza total, que se contabiliza en el 14,76 % de los trabajos organizados en la taxonomía. La tardanza total se refiere al tiempo de retraso y es crítica para la producción, ya que puede provocar graves sobrecostes de producción debido a las entregas tardías. Este objetivo está relacionado con el *makespan* y, si consideramos ambos conjuntamente, alrededor del 90 % de los trabajos incluyen la eficiencia de la producción de un tipo u otro como objetivo secundario. La carga total de trabajo aparece como el siguiente objetivo secundario más abordado, apareciendo en el 4,92 % de los trabajos. Por último, el 22,96 % restante incluye otras métricas clave de rendimiento no necesariamente relacionadas con la eficiencia de la producción, como el ruido, los costes de los trabajadores y la calidad del producto (entre otros), que tienen un menor impacto en la producción a la hora de buscar un plan de programación óptimo.

Terminamos el análisis de nuestra primera taxonomía propuesta deteniéndonos en el **tipo de *JSP*** formulado en cada trabajo. En la mayoría de las contribuciones, los autores definen cada caso de uso asignándolo a un tipo específico de problema. Aunque todos ellos están relacionados con problemas de *JSP*, en muchos casos muestran tipos de problemas demasiado específicos como para generalizarlos a otros casos de uso prácticos. Esto implica que muchos de los casos descritos por los autores sólo son aplicables bajo las condiciones de la configuración particular que consideran en su trabajo. Esto se observa en el 57,38 % de los trabajos revisados, en los que el tipo de problema es único para ese estudio y se define bajo siglas que no aportan ninguna información relevante al lector. El siguiente grupo más numeroso se refiere a las *JSP* flexibles (*FJSP*), que se describen en el 21,32 % de las contribuciones. Del mismo modo, el 16,40 % de los casos se refieren al problema de programación *Flow-shop* híbrido (*HFSP*), mientras que el 4,92 % son sobre un problema *JSP*, sin más especificaciones de formulación de ningún tipo.

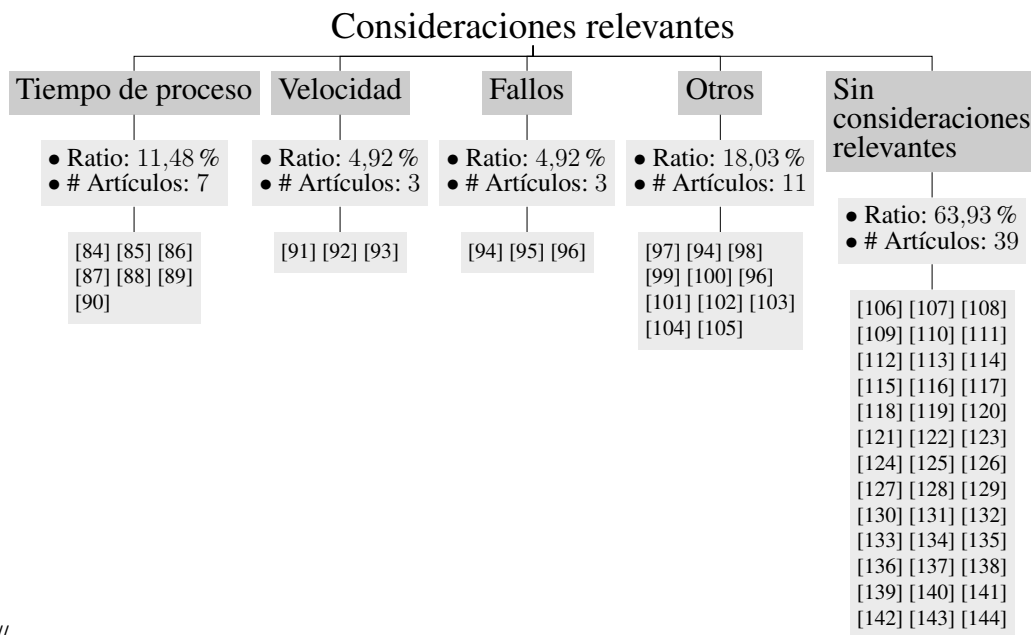
3.2.2.2. Taxonomía 2: restricciones y consideraciones

Continuamos nuestro examen de la bibliografía analizando las contribuciones a través de las restricciones y los aspectos prácticos considerados, más allá de los propios objetivos. La variabilidad

de las restricciones y los aspectos es elevada, por lo que resulta difícil ordenarlos de forma coherente. No obstante, se han identificado varias pautas y tendencias.

Para empezar, la mayoría de los trabajos revisados consideran **restricciones** similares que se plantean para saber cuándo es factible una buena solución según los objetivos definidos para el *JSP* en cuestión. Estas restricciones que son comunes en la mayoría de la literatura estudiada incluyen:

- Un trabajo sólo puede asignarse a una máquina.
- El número de trabajos asignados a una máquina no puede exceder la capacidad neta de producción de la máquina.
- El tiempo de procesamiento de un lote es igual al tiempo más largo de los trabajos en la máquina.
- Un trabajo no puede empezar antes de que el trabajo anterior haya terminado en la máquina.
- Ninguna máquina puede realizar más de un trabajo a la vez.
- Cada operario sólo puede manejar una máquina a la vez.
- Los trabajos son independientes entre sí.



////

Figura 3.4: Taxonomía de las consideraciones relevantes encontradas en la literatura revisada.

Sin embargo, existen otras restricciones y consideraciones que plantean diferencias en la forma en que los autores abordan el problema. Así, algunos trabajos asumen entornos de producción excesivamente idealistas, insertando diversas restricciones que pueden considerarse alejadas de la realidad. Éstas se muestran en la Figura 3.4:

- Las máquinas siempre están disponibles desde el principio: esta primera suposición no se cumple en muchas circunstancias prácticas, porque no siempre todas las máquinas están disponibles en entornos reales. Esto puede ocurrir por múltiples razones. Por ejemplo, una máquina

puede estar averiada, en mantenimiento (programado o no), puede estar bloqueada para producir sólo un tipo de unidades, etc. Sorprendentemente, todos los trabajos revisados asumen este punto de partida.

- Una vez iniciado un trabajo en una máquina, éste no puede detenerse: esta segunda suposición no siempre es posible debido a averías, prioridades de producción que surgen durante el ciclo de producción y otras razones diversas. Por lo tanto, en algunos casos (especialmente cuando hay muchos subprocesos fluyendo dentro de la misma máquina), la producción de una unidad debe detenerse y no necesariamente reanudarse en la misma unidad. Los posibles problemas derivados de estas circunstancias durante el proceso de fabricación se consideran en [96].
- Cada operación debe comenzar inmediatamente después de que la anterior haya finalizado: este tercer supuesto no siempre es la mejor práctica debido a los cuellos de botella en la producción: si una máquina tiene un tiempo de ciclo superior al de otros activos, es una buena práctica poner en marcha la siguiente/anterior máquina antes de que finalice la otra. Todos los documentos revisados parten de este supuesto.
- El *buffer* de producción entre máquinas es ilimitado: esta suposición puede cumplirse a veces, pero no siempre es cierta. Ahora que el *lean manufacturing* se está implantando de manera generalizada en la industria, y que uno de sus pilares se basa en producir sólo lo imprescindible. reduciendo el tamaño de los lotes de fabricación, suponer *buffers* ilimitados violará este principio [97].
- El tiempo de transporte dentro de la planta y la cadena de producción es despreciable: esto no siempre es factible, ya que el tiempo necesario para transportar un producto semi acabado de una zona donde se realiza una parte del proceso productivo a otra puede ser incluso mayor que el del propio proceso productivo. La fabricación ajustada se esfuerza por reducir el despilfarro, por lo que es importante mejorar el encaminamiento de los productos dentro de la fábrica. Esta restricción será opuesta a la optimización de rutas y transportes, y su influencia en el *makespan* se considera en la mayoría de los casos despreciable. Sin embargo, algunos trabajos han dejado de lado esta tendencia y han considerado este aspecto en la formulación del problema [122].
- El tiempo de cambio es despreciable: esta sexta restricción puede asumirse principalmente en la producción de grandes lotes, pero hoy en día la mayoría de las fábricas están obligadas a trabajar en lotes pequeños. Esto implica que los cambios de utillaje, por ejemplo, se producen con más frecuencia, por lo que ya no se puede despreciar su impacto agregado en los plazos de producción [120, 122, 87, 123].

Otro aspecto importante que no siempre se tiene en cuenta es el impacto en el consumo de energía de los tiempos de inactividad y espera. El tiempo de inactividad es un periodo de tiempo en el que un activo (máquina o empleado) está listo y disponible, pero no está dedicado a las labores de producción. El tiempo de espera es el tiempo durante el cual una parte del proceso está esperando a que termine una operación anterior. El consumo energético y el coste derivado de estos estados de los activos industriales puede llegar a ser relevante, y ha sido tenido en consideración en los siguientes trabajos [84, 85, 86, 87, 88, 89, 90].

Por último, nos detenemos en una causa importante y con un importante impacto en el consumo de energía: la velocidad de procesamiento de las máquinas dotadas de capacidad para producir a diferentes ritmos de fabricación. Una mayor velocidad de producción suele implicar un mayor consumo de energía. Dado que esta capacidad de las máquinas es específica del sector industrial y del tipo de producto, sólo unos pocos trabajos han prestado atención a esta cuestión [91, 92, 93].

3.2.2.3. Taxonomía 3: Optimizador multiobjetivo

La tercera taxonomía aborda el procedimiento algorítmico por el que se ha optimizado cada *JSP* considerado. En este sentido, utilizamos cuatro criterios para ordenar la literatura en la taxonomía que se muestra en la Figura 3.5: 1) algoritmo específico utilizado; 2) algoritmo(s) con el que se ha comparado la propuesta; 3) parámetros de cruce; y 4) parámetros de mutación. A continuación se discuten las pautas generales de diseño y metodología derivadas de este tercer análisis sistemático.

Comenzamos la discusión considerando el algoritmo usado, que hace referencia al algoritmo multiobjetivo específico central utilizado en cada contribución. A priori, aquí esperábamos encontrar el uso de algoritmos evolutivos multiobjetivo ampliamente conocidos, como NSGA-II, MOEA/D, o SPEA-2. Sin embargo, tras realizar la revisión, la mayoría de los trabajos analizados hacen referencia a desarrollo de nuevos algoritmos que intentan mejorar las prestaciones de los algoritmos anteriormente mencionados. Por ello, en esta categoría de la taxonomía se determina si el autor ha empleado un algoritmo ya existente como algoritmo de referencia o, si por el contrario, se ha desarrollado un nuevo algoritmo para el estudio o no. Sorprendentemente, descubrimos que el 88,5 % de los artículos incluidos en la revisión desarrollan nuevos algoritmos o mejoras de los existentes, mientras que sólo en el 9,8 % de los casos no se propone ningún algoritmo nuevo.

Respecto al **algoritmo de comparación** incluido en las comparativas, en este criterio consideramos aquellas técnicas que los autores de cada contribución utilizan para comparar su rendimiento con el obtenido por sus propios algoritmos propuestos. Como era de esperar, NSGA-II prevalece en el área como contrapartida de comparación, con un 32,47 % de los trabajos que lo incluyen en sus *benchmarks*. A este algoritmo evolutivo multiobjetivo le sigue SPEA-2, que se utiliza en el 10,39 % de los casos. MOEA/D, otro popular algoritmo evolutivo multiobjetivo, aparece en el 9,09 % de la literatura analizada, mientras que el resto incluye comparaciones con otros algoritmos como NSGA-III, MOGWO, SPEAR, etc.

Otro hecho a tener en cuenta en esta categoría es que el software comercial de optimización como CPLEX se emplea con bastante frecuencia en esta área, sin profundizar en la parte algorítmica. Esta afirmación queda refrendada por la Figura 3.6, donde podemos observar que los tres algoritmos mencionados predominan sobre el resto.

La tabla 3.1 ofrece una lista completa, ordenada por año de publicación, de los algoritmos utilizados, el algoritmo tomado como punto de partida para desarrollar el nuevo enfoque propuesto y los algoritmos con los que se compara. Podemos observar claramente que la mayoría de los artículos centran sus esfuerzos en desarrollar su propio algoritmo. También cabe destacar que ninguna de las metaheurísticas desarrolladas recientemente a lo largo de los años establece una comparación con los optimizadores definidos previamente en la tabla. Esto indica que los trabajos de investigación reportados en esta área intentan principalmente superar algoritmos genéricos (por ejemplo, NSGA-II, ILS, MOGA), y no incluyen en la comparación algoritmos específicamente diseñados para resolver instancias *JSP*.

Dado que la mayoría de las metaheurísticas utilizadas para resolver formulaciones multiobjetivo del *JSP* son algoritmos genéticos, analizamos a continuación los **operadores de cruce** utilizados y, en particular, el valor del parámetro de probabilidad de cruce (véase de nuevo la Figura 3.5). En la fase experimental, los autores de los trabajos han realizado diferentes experimentos variando los valores de cruce y mutación, por lo que en muchos casos se proporciona más de un valor para estos operadores. Así, hemos decidido agruparlos por cuartiles, siendo el primer cuartil Q1 la probabilidad de cruce fijada entre [0, 0.25), Q2 entre [0.25, 0.5), Q3 entre [0.5, 0.75) y Q4 entre [0.75, 1].

El operador de cruce no siempre se indica, a veces porque el algoritmo no hace uso de él (como en las propuestas basadas en *PSO*, por ejemplo). Sin embargo, cuando se utiliza hay un elevado número de trabajos que no proporcionan información detallada: en el 39,34 % de los casos no se especifica el operador de cruce. En el 24,59 % de los casos la probabilidad de cruce es alta, perteneciente al Q4; en el 16,39 % de los casos los parámetros de cruce están en el tercer cuartil, y el 1,6 % y el 4,92 %

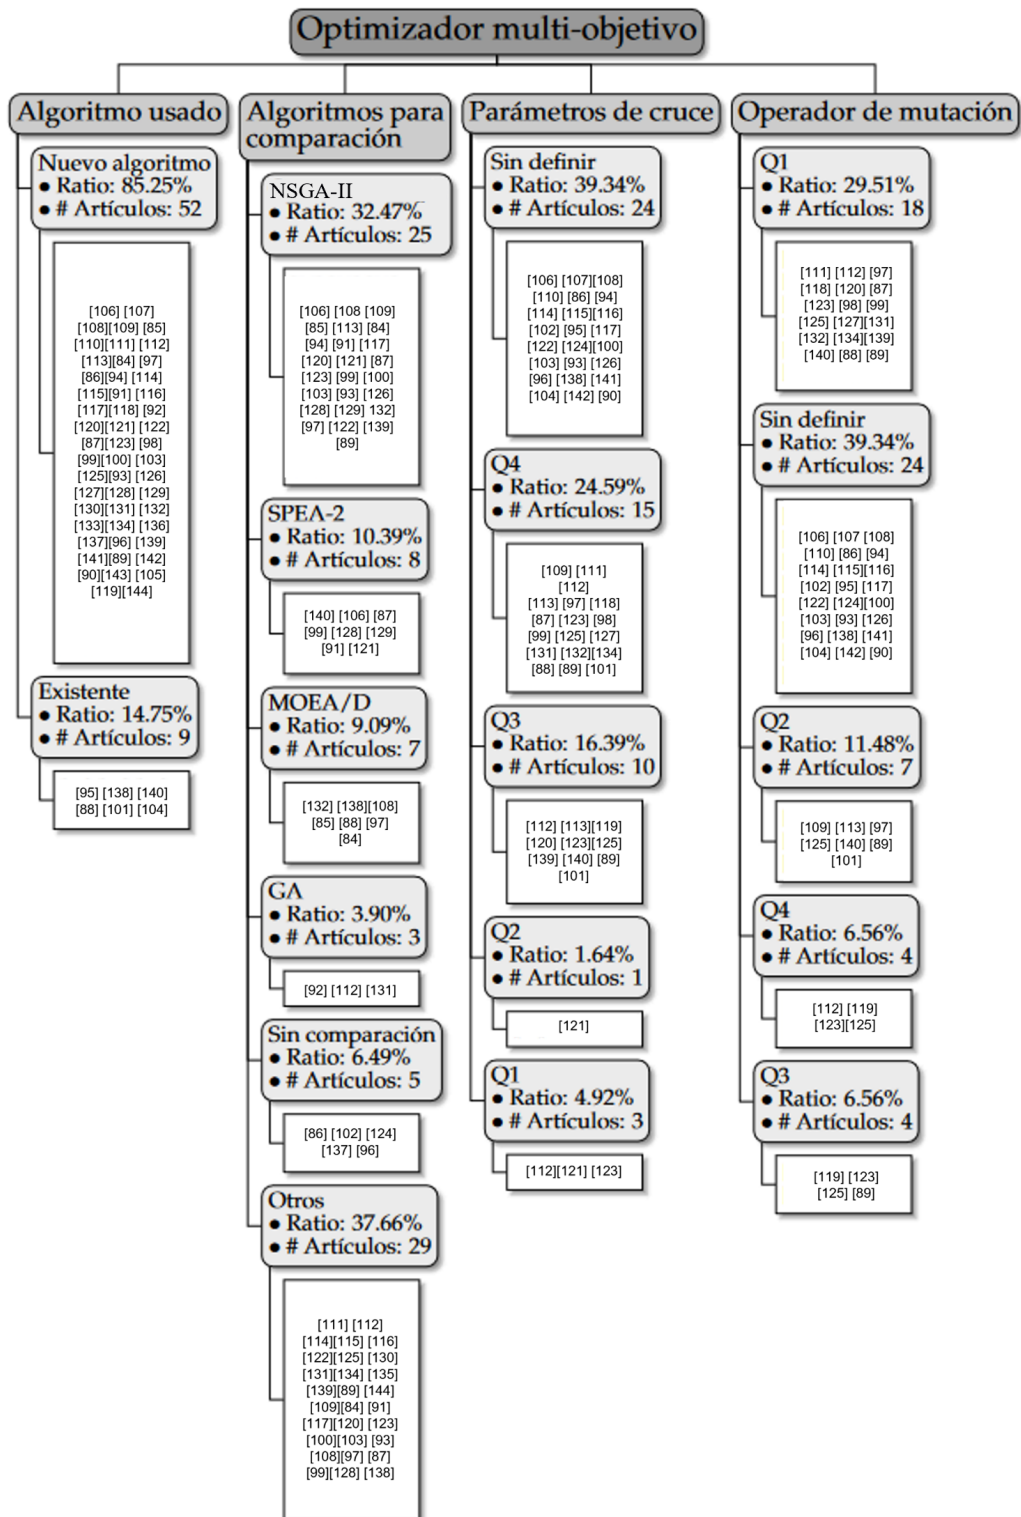


Figura 3.5: Taxonomías por optimizador multi-objetivo.




Figura 3.6: Algoritmos más utilizados para la comparativa.

tienen probabilidades de cruce pertenecientes al segundo cuartil y al primer cuartil, respectivamente.

Llama la atención que un gran número de artículos no facilitan los ajustes de los parámetros de cruce, por lo que no pueden reproducirse en nuevos estudios. Esta práctica resta valor científico a las publicaciones porque las afirmaciones y conclusiones no pueden ser validadas por la comunidad. Un estudio bien realizado debería informar de forma transparente sobre los operadores y algoritmos en uso, para que los investigadores interesados puedan replicarlos y avanzar sobre el conocimiento general en el campo. Además, llama la atención que este tipo de información no aparezca cuando en muchos casos el problema estudiado es sintético y no hay compromiso de confidencialidad. Por lo demás, los valores de probabilidad más utilizados son los más altos (es decir, en el rango Q4), como era de esperar.

Finalizamos el análisis de la literatura a través de la tercera taxonomía evaluando el **operador de mutación** adoptado por las contribuciones seleccionadas. Para analizar el operador de mutación, definimos, al igual que en el operador de cruce, cuartiles, siendo el primer cuartil Q1 la probabilidad de mutación fijada entre $[0, 0.25)$, Q2 entre $[0.25, 0.5)$, Q3 entre $[0.5, 0.75)$ y Q4 entre $[0.75, 1]$. En general, las probabilidades de mutación son bajas, como se desprende del cuartil más utilizado para este parámetro (34,2 % en el primer cuartil y 15,8 % en el segundo). Al igual que en el cruce, una fracción significativa de los trabajos (39,34 %) no indica claramente los parámetros de mutación elegidos para la parte experimental del estudio, lo que agrava aún más los problemas de reproducibilidad expuestos anteriormente.

3.2.3. Resumen de los puntos críticos identificados en el análisis bibliográfico

Una vez descrita la literatura sobre la optimización de la planificación de la producción con conciencia energética y la metaheurística multiobjetivo, resumimos ahora las principales observaciones que surgen del análisis crítico de dichos trabajos. Antes de proseguir, afirmamos que con esta crítica no pretendemos disuadir a los lectores de realizar investigaciones en esta encrucijada, sino más bien 1) subrayar aspectos realistas y suposiciones que están estrechamente vinculadas a entornos del mundo real, 2) señalar malas prácticas que deberían evitarse en estudios prospectivos, y 3) solicitar esfuerzos de investigación en direcciones de valor inherente para el campo. Estas observaciones se

Tabla 3.1: Algoritmos identificados en los documentos analizados.

Año	Referencia	Algoritmo usado	Algoritmo inicial	Algoritmos empleados en la comparativa
2011	[144]	SPNE	Dynamic game theory	AL+CGA; PSO+TS; HSISAT
2013	[106] [137]	MOACO IGSAA	ACO SA	NSGA-II; SPEA-2 -
2014	[111] [95]	BVNSGA-II NSGA-II	NSGA-II NSGA-II	- -
2015	[110] [136] [134] [135]	SAA Continuous-time MILP GD-MOCDE ABC	GA - MOCDE, Gradient Descend (DC), ABC	- - MODE; IGAMU; CSO; SAGA
2016	[107] [109]	MILMO GAEJP	- NSGA-II	- NSGA-II; LEKING
2017	[113] [98] [132] [133] [144]	MOGA GA-based HMOBSA Enhanced GA SPNE	Simplex lattice design GA MOEAs Standard GA DGT	NSGA-II; - NSGA-II; MOEA/D; - AL+CGA; PSO+TS; HSISAT
2018	[108] [86] [114] [118] [123] [124] [128] [129] [130] [131] [138]	EA-MOA IGALL SFLA MCEAs Multi-objective DE Bee Colony HMOGWO TEPSO NBI TTLBO NSGA-III	- IG SFLA - - Artificial bee colony (ABC) GWO; GA PSO; TABOO Normal Boundary Intersection - NSGA-III	NSGA-II; MOEA/D; DBEA; EADD - BVNSGA-II NSGA; NSGA-II; AMGA - NSGA-II; SPEA2 ; MOGWO; MOGWO1; MOGWO2 NSGA-II;SPEA2 - IGSA; GA NSGA-III-NIG; EFR-RR ; crEA
2019	[85] [84] [97] [94] [116] [96] [143] [87] [122] [87] [99] [93] [126] [121] [90]	MOBSO MDABC EOMO MOHPIOSA IMOMVO MOGSA DCRO MOCGWO iMOEA/D MOCGWO MOWSA COA ILS New MOGA MOGA-LS	Basic BSO MOEA (MOEA/D). PIO MOGA CRO MOG MOEA/d GWO & CA Whale Swarm Algorithm ILS MOGA ILS; VILS	NSGA-II; MOEA/D NSGAII;EAMOA;CMFOA;MOEA/D;iMOEA/D SPGA-II; NSGA-II;MOEA/D NSGA-II; MOMVO; MOPSO; MOALO; NSGA-II - - NSGA-II; NSGA-II + NDM; SPEA2; SPEA2 + NDM; MOCGWO HMOBSA; NSGA-II NSGA-II;SPEA2; MOCGWO NSGA-II;SPEA2;PAES NSGA-II; IMEA/D NSGA-II; - -
2020	[112] [115] [91] [102] [117] [92] [119] [120] [100] [103] [125] [140] [88] [141] [89] [101] [104] [105]	PH-MOEAD DEMO MHACO CPLEX (Not provided) EMA EDA Own algorithm 2-echelon iMOEA/D HEA iMOALO NMA NSGA-II NSGA-II EE-VBIH; EE-IG; IG-ALL MDSS-MOGA-DE NSGA-II; SPEA-2; NSGA-II PSO _S WS; PSO _L WR	MOEAD - - - - - MOEA/D - ALO MA NSGA-II NSGA-II - - NSGA-II; SPEA-II NSGA-II	EMBO;GA;GAR;DPSO;DABC MODWWO; MPVNS; MOMBO NSGA-II;MODEA;SPEA-II - NSGA-II; NNIA; NSGA-III GA - NSGA-II;MOGLS NSGA-II;NNIA; NSGA-II; MOPSO; MA SPEA2 - - MOABC; MOACO; MOCS NSGA-II; SPEA-2 NSGA-II PSO _S WS; PSO _L WR; PSO
2021	[139]	HPSO	PSO i	NSGA-II; HPSO-LS

exponen a continuación:

- La primera taxonomía dada en la subsección 3.2.2.1 descubrió que la mayoría de las *JSP* resueltas en el corpus bibliográfico analizado abordan dos o tres objetivos. Esto se ajusta a los escenarios del mundo real, donde la programación de la producción a menudo se rige por

unos pocos indicadores clave de rendimiento. No obstante, insistimos en que el potencial de las metaheurísticas multiobjetivo para hacer frente sin problemas a problemas que comprenden varios objetivos debe estar impulsado por la necesidad de tenerlos en cuenta en el mundo real. En este sentido, la mayoría de los casos descritos en la bibliografía plantean sofisticados enunciados matemáticos de problemas sin ofrecer una justificación explícita que conecte el propio enunciado del problema con las circunstancias, los *KPI (Key Performance Indicator)* y las restricciones del mundo real. Esto no sólo dificulta la generalización de los estudios, sino que también cuestiona que la investigación esté realmente motivada por problemas del mundo real.

- La formulación del *JSP* multiobjetivo se basa principalmente en el consumo de energía y el tiempo de ciclo. Esto no es un problema, sino más bien una consecuencia del hecho de que, en la mayoría de los entornos prácticos, la programación en las plantas industriales se rige principalmente por la eficiencia de la producción, es decir, la producción de la mayor cantidad de producto posible. El número relativamente bajo de trabajos científicos relacionados con la programación de la producción teniendo en cuenta la energía (algo más de 60 referencias) es también sintomático del hecho de que no ha sido hasta hace poco cuando la eficiencia energética se ha convertido en un tema preocupante en las industrias del mundo real. Varias razones de esta creciente preocupación pueden especular en torno al fuerte aumento de los costes de la energía, especialmente notable en ciertos países. Este hecho es alentador y debe catalizar los esfuerzos llevados a la zona estudiada en este trabajo
- En el lado negativo, y coincidiendo con afirmaciones anteriores, nos encontramos con que la mayoría de los tipos de *JSP* abordados en los estudios analizados son en gran medida específicos para el caso de uso objeto del trabajo, lo que lleva a una escasa generalización de los resultados a nuevas configuraciones del mundo real. De nuevo, esto no debería considerarse un problema si el trabajo en cuestión limitara las conclusiones de sus experimentos a la variante de *JSP* considerada. Sin embargo, este no es el caso en un subconjunto de las referencias examinadas, en las que la novedad del problema *JSP* se enreda con la propuesta de un algoritmo metaheurístico novedoso sin ninguna razón sólida. Esto se hace eco de la antigua controversia sobre el papel de la metáfora en el diseño de metaheurísticas inspiradas en la naturaleza. También hemos observado esta práctica en varios trabajos que recurren a nuevos optimizadores de inspiración biológica sobre formulaciones *JSP* a medida, evitando 1) la inclusión de algoritmos multiobjetivo bien establecidos en las comparaciones; y 2) la reproducibilidad de los resultados de la comparativa que conduce a las afirmaciones sobre el rendimiento del nuevo optimizador. Deberían realizarse estudios de rendimiento rigurosos y exhaustivos en trabajos futuros para aclarar si el rendimiento de tales optimizadores se corresponde con una capacidad de búsqueda realmente mejor de sus operadores bioinspirados.
- En cuanto al realismo del problema formulado, muy pocos trabajos tienen en cuenta aspectos que prevalecen en las plantas de producción de diversas industrias, como los tiempos de espera, los ciclos de mantenimiento, los tiempos de inactividad de las máquinas y otros aspectos que repercuten en el cómputo global del makespan. La intensidad con la que puede verse afectada la duración de la fabricación si no se tienen en cuenta estos aspectos depende del caso de uso que se esté considerando. Sin embargo, la creciente capacidad de los modernos sistemas de ejecución de fabricación (*MES*) para integrar y manejar todas las fuentes de información relacionadas con el proceso de producción debería conllevar formulaciones *JSP* más realistas, que demuestren que el cálculo de la duración de la fabricación y el conjunto de restricciones impuestas pueden aprovechar la disponibilidad de fuentes externas de información. Además, podrían surgir nuevas oportunidades de programación dinámica de la producción, en función del ritmo de actualización de la información en el *MES*.

- Las comparaciones de rendimiento entre algoritmos deben ser incrementales. Si se proponen algoritmos, deben evaluarse sobre instancias *JSP* sintéticas (es decir, dejando de lado las condiciones/restricciones impuestas por los escenarios reales), de modo que los avances puedan ser validados por la comunidad y mejorados. Nuestro análisis de la literatura reveló que reproducir un artículo que trate un escenario del mundo real con una *JSP* como núcleo es difícil de conseguir. No se facilita información clave (en algunos casos, debido a cláusulas de confidencialidad) y los códigos fuente no están disponibles. Por lo tanto, se puede cuestionar fácilmente si se desarrollan nuevos algoritmos *ex professo* para el caso de uso analizado, mostrando un rendimiento superior sobre una *JSP* escasamente extrapolable. Esta podría ser la razón por la que la Tabla 3.1 evidencia que casi ningún algoritmo multiobjetivo que se salga de la corriente principal de las metaheurísticas se utiliza en estudios publicados después de su primera presentación. En definitiva, creemos que la comunidad debería realizar una comparación de rendimiento justa y basada en principios metodológicos entre algoritmos bien conocidos en diversas instancias de problemas *JSP* conscientes de la energía generados sintéticamente. Este estudio podría informar sobre si existe algún valor en el conjunto de enfoques metaheurísticos modernos que se encuentran dentro de los límites de la controversia antes mencionada. Y lo que es más importante: al incluir algoritmos personalizados/meméticos/híbridos en la prueba comparativa, el estudio revelaría si la personalización de los algoritmos metaheurísticos proporciona algún valor adicional más allá de resolver mejor formulaciones específicas del *JSP* con conciencia energética.

Capítulo 4

Mejora de los procesos productivos

Este capítulo se centra en describir la mejora de procesos productivos haciendo uso de la inteligencia artificial como soporte de la mejora. El capítulo queda organizado de la siguiente manera: la sección 4.1 introduce el tipo de problema que se pretende resolver y por qué es crítico para las organizaciones. A continuación, la sección 4.2 detalla el caso de uso que se va a resolver. La sección 4.3 describe la metodología aplicada para alcanzar los objetivos, y que se aplicará en la sección 4.4. La sección 4.5 expone los resultados y conclusiones generales para este problema.

4.1. Introducción

Como se describe en la introducción de la tesis, uno de los principales temas para la reducción de costes industriales es la mejora de los procesos, haciéndolos más robustos, lo que minimiza las pérdidas por reprocesos o desechos. En la actualidad, la industria 4.0 tiene en la ciencia de datos uno de sus principales baluartes, a través de la extracción de conocimiento mediante el procesamiento y análisis de los datos. Estos procesos permiten encontrar relaciones entre variables (por ejemplo, variables de producción) que a primera vista no son directas. Campos como la Computación Visual [145], la Toma de Decisiones [146], y la Logística [147], entre otros, están aprovechando las ventajas que proporciona la ciencia de datos.

Existen numerosas publicaciones referenciadas a datos en los entornos industriales, bajo el pseudónimo de *smart factories* [148]. Este tipo de publicaciones se pueden agrupar en dos ramas principales, infraestructura y análisis de datos. Por un lado, los estudios de infraestructura se centran en establecer el tipo de soluciones de comunicaciones, hardware y software necesarias para satisfacer la demanda de ingesta, almacenamiento y seguridad de grandes volúmenes de datos. Ejemplos de este tipo de estudios se describen en [149],[150]. Por otro lado, el núcleo del análisis de datos es obtener valor de los datos de proceso, obteniendo mediante el preprocesamiento y análisis de datos valor añadido. Ejemplos de ello son: extracción de parámetros relevantes y sus valores óptimos para la mejora del proceso, como en [151], estudios donde se establece una comparativa de algoritmos para descubrir parámetros relevantes sobre imágenes de defectos de madera, o [152], otro centrado en el análisis de series temporales para el descubrimiento de características y uso de las mismas en un proceso repetible, [153], donde se describe un algoritmo híbrido de aprendizaje automático para la recomendación de características de diseño de fabricación aditiva (*AM*) en la fase de diseño conceptual, [154, 155] para la reducción del consumo energético en procesos industriales, y mantenimiento predictivo [156].

Los pasos a seguir en este segundo tipo de estudios suelen ser los mismos. Partiendo de un problema dado, es necesario preprocesar la información, [157]. Una vez que la información tiene

la forma adecuada, realizar una comparativa entre modelos matemáticos, como el realizado sobre el estudio de predicción de desgaste de una herramienta [158], finalizando con la generación de modelos matemáticos y extracción de parámetros relevantes para establecer las conclusiones.

El problema de la industria 4.0 y el análisis de datos aplicado sobre datos masivos es que esta nueva revolución irrumpe bruscamente sobre las metodologías existentes, con la fama de poder revolucionar la forma de mejorar los procesos, pero sin una implementación muy clara que no incurra en un sobrecoste por una mala planificación. Por tanto, implantar una nueva metodología que herede los buenos conceptos de sus predecesoras y los actualice para tener en cuenta las capacidades informáticas y de captura de datos actuales, pero que también tenga en cuenta qué, cómo y cuándo sensorizar partes de los procesos productivos es necesario para evitar incurrir en sobrecostes derivados de la captura masiva de información no relevante y problemas en la explotación de dicha información.

4.2. Formulación del problema

Tal y como se ha definido en la sección 2.1 el problema a resolver es reducir la cantidad de piezas defectuosas (NOK) producidas en un proceso industrial aplicando técnicas de machine learning, pero sin desperdiciar recursos, es decir, sensorizando en exceso los procesos de producción. Este problema viene dado por el equilibrio entre los costes derivados de la adquisición e instalación de la sensórica y los sistemas auxiliares, la recogida y análisis de los datos captados y los beneficios derivados de los resultados del análisis.

Para plantear formalmente el problema, primero modelamos matemáticamente el coste en que se incurre al adquirir e instalar un equipo sensor s de entre una cartera de S posibles elecciones $\mathcal{S} \doteq \{s_1, \dots, s_S\}$ destinadas a capturar datos de una máquina con vistas a una determinada tarea de modelado predictivo (por ejemplo, caracterización y minimización del consumo energético, mantenimiento predictivo o detección de defectos). El coste por tanto de la sensórica viene dado por el precio neto del sensor o sensores como $C_{sens}(s)$ (en unidades monetarias), a lo que habría que añadir la instalación, calibración (ambas cantidades fijas, $C_{cal}(s) + C_{inst}(s)$, incluidos los ajustes en máquina y la mano de obra) y mantenimiento (coste imputado de forma recurrente $C_{mnt}(s)$ con periodicidad $T_{mnt}(s)$ [unidades de tiempo]) para un despliegue de sensores plenamente operativo. Una vez instalados, los datos deben recuperarse de la máquina y almacenarse para su posterior análisis (ya sea en el *Manufacturing Execution Server* – MES – o en la nube). Dicha recogida debe abarcar un período de tiempo mínimo $T_{col}^{min}(s)$ de forma que proporcione a los modelos predictivos un sustrato de datos suficiente para caracterizar el patrón entre la información recogida y la variable a predecir (siguiendo con los ejemplos anteriores, defecto o energía consumida). Esta duración mínima depende no sólo de las especificaciones de muestreo de los sensores desplegados, sino también de la estacionalidad de los datos y de los requisitos temporales de la tarea de modelado predictivo considerada.

En cualquier caso, surgen costes adicionales durante el período de captura de datos, como el almacenamiento de datos $C_{almc}(s, t)$, que depende tanto del sensor –a través de sus especificaciones de muestreo de datos– como del tiempo t durante el que se utiliza. Dependiendo de los requisitos del caso de uso en cuestión, podría darse el caso de que la máquina en cuestión se mantuviera apartada de la línea de producción durante el periodo de captura de datos con fines de experimentación, causando costes adicionales debido, por ejemplo, al cese de la producción y a los gastos en materias primas utilizadas para construir muestras para la experimentación. Todos estos posibles costes se denotarán como $C_{otros}(s, t)$, que no sólo depende del sensor y del lapso de tiempo de la propia experimentación, sino también de la contribución neta $R(s, t)$ (en unidades monetarias por unidad de tiempo) de la máquina parada a la producción de la planta. Por ejemplo, si una cadena de fabricación de una cadena de producción paralela se detuviera por completo y quedara inoperativa durante la prueba, $R(s, t)$ representaría la diferencia agregada entre los ingresos netos de todos los productos que ha-

bría procesado la máquina durante $T_{col}^{min}(s)$ y el coste de la materia prima no adquirida/consumida durante la prueba¹

Una vez que se ha recopilado suficiente información del proceso, se continúa el proceso realizando diferentes pasos de minería de datos destinados a construir un modelo matemático. Como se ha argumentado anteriormente, esta fase de construcción del modelo tiene como objetivo lograr un beneficio productivo que pueda traducirse en términos económicos. Por ejemplo, un modelo predictivo destinado a detectar productos defectuosos en una máquina de fabricación podría evaluarse en función de su puntuación predictiva (por ejemplo, la proporción de verdaderos positivos o *recall*). En este caso, la recuperación del modelo predictivo desarrollado podría combinarse con el índice de rechazos de la máquina analizada y el coste de las muestras rechazadas para obtener un beneficio económico $B(s, t)$ [unidades monetarias] asociado al modelo, ergo a la adquisición del sensor s , y medido en un determinado horizonte temporal t una vez finalizado el ensayo. El desarrollo del propio modelo más el preprocesamiento previo de los datos capturados añadiría un intervalo de tiempo adicional $T_{modelo}(s)$ a la fase de experimentación.

Antes de profundizar en otras derivaciones, es de vital importancia para el ámbito de este estudio señalar que el beneficio económico estimado $B(s, t)$ no puede cuantificarse de antemano, ya que el valor predictivo de la información recogida por el sensor s es incierto hasta que se captura y se alimenta al modelo para su desarrollo. Esta incertidumbre debería tener profundas implicaciones prácticas a la hora de decidir qué sensor adquirir, así como el esquema de compraventa. En este punto planteamos matemáticamente dos opciones de compra diferentes:

- A. Esquema tradicional de compraventa, por el que el proveedor del sensor recibe una cantidad monetaria $C_{sens}(s)$ por el sensor seleccionado, más pagos adicionales $C_{cal}(s)$, $C_{inst}(s)$ y $C_{mnt}(s)$ en caso de que también ofrezca servicios de mantenimiento, instalación y calibración.
- B. Esquema de alquiler de sensores, en el que se negocia y acuerda entre fabricante y proveedor un coste $C_{alq}(s, t) \ll C_{sens}(s)$ dependiente del tiempo, que se factura y paga durante el tiempo total del ensayo, a saber $T_{xp}(s) \doteq T_{col}^{min}(s) + T_{modelo}(s)$.

Intuitivamente, un esquema de alquiler incurriría en un coste de penalización $C_{alq}(s, T_{xp}(s))$, que se añade al coste final del ensayo si el valor predictivo de los datos captados por el sensor es lo suficientemente bueno como para marcar la diferencia con respecto al equilibrio entre los costes globales y el beneficio $B(s, t)$ del modelo desarrollado. Basándonos en la notación anterior, el coste global del ensayo con el sensor s cuando se adopta un esquema tradicional de compraventa (A en la lista anterior) puede expresarse como:

$$C_A(s) = C_{sens}(s) + C_{cal}(s) + C_{inst}(s) + C_{mnt}(s) \left[\frac{T_{xp}(s)}{T_{mnt}(s)} \right] \quad (4.1)$$

$$+ C_{almc}(s, T_{xp}(s)) + C_{otros}(s, T_{xp}(s)) + R(s, T_{xp}(s)), \quad (4.2)$$

donde (4.1) hace referencia a todos los costes derivados del despliegue del equipo sensor, y (4.2) recoge todos los gastos y pérdidas de producción (si los hubiera) durante la recogida de datos y la construcción y evaluación del modelo. En caso de que el modelo de compraventa se implante en régimen de alquiler (correspondientemente, B en la lista) durante el plazo $T_{xp}(s)$ del ensayo, el coste global viene dado por

$$C_B(s, B_{th}(t)) = C_{alq}(s, T_{xp}(s)) + C_{almc}(s, T_{xp}(s)) + C_{otros}(s, T_{xp}(s)) + R(s, T_{xp}(s)) + \mathbb{I}(B(s, t) \geq B_{th}(t)) [C_{sens}(s) + C_{cal}(s) + C_{inst}(s) + C_{mnt}(s)], \quad (4.3)$$

¹Este cálculo supone implícitamente que la máquina detectada no es productiva en absoluto durante la prueba. En caso contrario, debería adoptarse un modelo de costes mixtos para reflejar en $R(s, t)$ la interacción entre el ahorro de material y las pérdidas de productividad.

donde $\mathbb{I}(\cdot)$ es una función binaria auxiliar que toma valor 1 si su argumento es verdadero y 0 en caso contrario. Puede observarse que $C_A(s) \leq C_B(s)$ siempre que la decisión final sea adquirir el sensor y explotar su información dentro de la línea de producción, decisión que se toma si el beneficio obtenido $B(s, t)$ de las fases de recogida de datos y modelado utilizando el sensor s supera un umbral mínimo esperado $B_{th}(t)$ [unidades monetarias por unidad de tiempo] acordado por el equipo antes de iniciar la prueba. Recopilamos las fórmulas anteriores como $C(s, m, B_{th}(t)) \in \{C_A(s), C_B(s)\}$, que denota el coste del ensayo con el sensor s en función de su modo de adquisición $m \in \{A, B\}$.

Como se ha argumentado antes, la impredecibilidad del valor de $B(s, t)$ para cualquier t antes de adquirir el sensor s impone que no puede adoptarse como métrica para seleccionar un sensor de \mathcal{S} antes de su adquisición. Por lo tanto, un análisis previo de las opciones disponibles para la detección es crucial, aunque no siempre es posible, especialmente en procesos de fabricación vanguardistas como el que se aborda más adelante en este manuscrito. La falta de buenas prácticas de detección previamente descritas supone un riesgo inevitable a la hora de seleccionar el sensor que se va a probar.

4.3. ASPPID, una nueva metodología propuesta

Basándose en el razonamiento anterior, se debería tener como objetivo maximizar el retorno de la inversión cuando se realiza una serie de ensayos - cada uno probando un sensor $s \in \mathcal{S}$ - sin ningún conocimiento a priori ni estimación del valor de los datos capturados por cada una de las elecciones. Se supone que dichos ensayos ocurren secuencialmente en el tiempo, de forma que $s_k \in \mathcal{S}$ denota el sensor seleccionado en el ensayo k . En cada ensayo k el equipo debe tomar dos decisiones con respecto a 1) el modelo de adquisición m_k del sensor s_k seleccionado (A o B, si está disponible previo acuerdo con el proveedor); y 2) un valor objetivo $B_{th}(t)$ del beneficio económico estimado del modelo desarrollado basado en los datos recuperados por los sensores adquiridos a lo largo de la serie de ensayos. Debe quedar claro que si el sensor s_k se selecciona en el ensayo k , se compra ($m_k = A$) y se despliega en la máquina/proceso en cuestión, puede ocurrir que los datos capturados y la fase de modelado no alcancen el valor mínimo antes mencionado, es decir, $B(s_k, t) < B_{th}(t) \forall t$. Sin embargo, puesto que se adquirió el sensor s_k , los sensores seleccionados en ensayos posteriores pueden beneficiarse de la información captada por s_k , proporcionando potencialmente -aunque con incertidumbre- un mejor rendimiento del modelo que si se utilizara el sensor s_{k+1} de forma aislada. Por el contrario, el beneficio obtenido por el modelo construido a partir de s_k podría sufrir una colinealidad entre las variables recogidas en diferentes ensayos, lo que llevaría a una falta de relevancia predictiva de la información proporcionada por el nuevo sensor. Esto revela implícitamente que la elección de los sensores es sensible al orden.

Introduciendo un ligero abuso en la notación, los beneficios acumulados tras K ensayos sucesivos pueden calcularse como $\mathbf{s}_K = [s_1, s_2, \dots, s_K]$ y $\mathbf{m}_K = [m_1, m_2, \dots, m_K]$ (con $m_k \in \{A, B\}$) denotan los sensores seleccionados en los ensayos $\{1, \dots, K\}$ y su modo de compra, respectivamente. Una redefinición similar de los costes globales de los ensayos puede hacerse como

$$C(\mathbf{s}_K, \mathbf{m}_K, B_{th}(t)) = \sum_{k=1}^K C(s_k, m_k, B_{th}(t)), \quad (4.4)$$

que debe mantenerse por debajo de un límite superior C_{max} que representa el presupuesto asignado por la planta de fabricación para realizar ensayos. Una metodología de compra y ensayo debe perseguir el número óptimo K^* y la secuencia \mathbf{s}_K^* de sensores seleccionados y su política de compra \mathbf{m}_K^* para que el beneficio buscado del modelo desarrollado $B_{th}(t)$ se consiga con un coste global

mínimo. Matemáticamente,

$$[K^*, \mathbf{s}_K^*, \mathbf{m}_K^*] = \arg \min_{K, \mathbf{s}_K, \mathbf{m}_K} C(\mathbf{s}_K, \mathbf{m}_K, B_{th}(t)), \quad (4.5)$$

$$\text{subject to } C(\mathbf{s}_k, \mathbf{m}_k, B_{th}(t)) \leq C_{max}, \forall k \in \{1, \dots, K\}, \quad (4.6)$$

$$B(\mathbf{s}_K, \mathbf{m}_K, t) \geq B_{th}(t), \quad (4.7)$$

$$m_k \in \{A, B\} \cap \mathcal{M}_{sup}(s), \quad (4.8)$$

$$s_k \neq s_{k'} \text{ if } k \neq k' \forall k, k' \in \{1, \dots, K\}, \quad (4.9)$$

donde (4.6) denota que el coste global está restringido, (4.8) indica que la elección del modo de compra también debe tener en cuenta la política de venta $\mathcal{M}_{sup}(s) \in \{A, \{A, B\}, B\}$ del proveedor del sensor; y (4.7) impone que el beneficio objetivo debe alcanzarse después de las K pruebas. El proceso para implementar un caso hipotético que comprende $K = 3$ ensayos se ejemplifica en la Figura 4.1, donde es importante notar los impactos de las decisiones tomadas después de cada ensayo en el coste y el beneficio acumulado a lo largo del proceso.

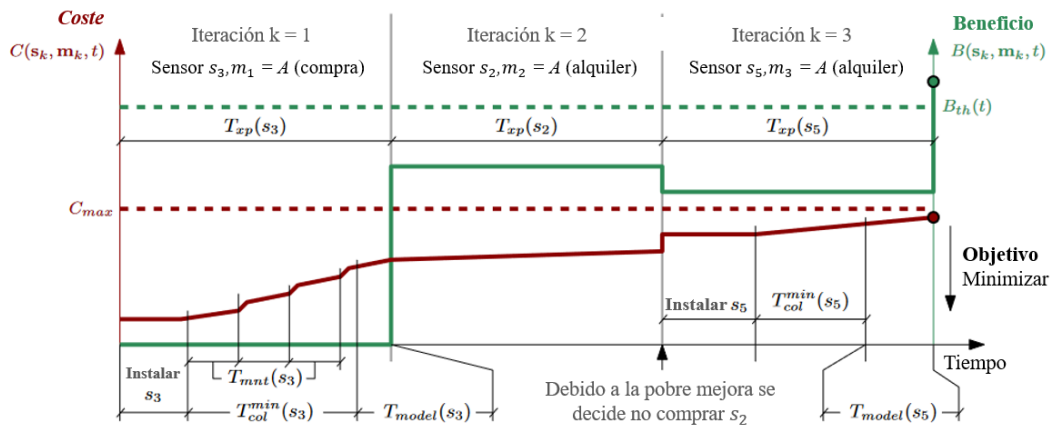


Figura 4.1: Ejemplo de $K = 3$ ensayos de sensores dirigidos por una metodología que propone $\mathbf{s}_K = [s_3, s_2, s_5]$ y $\mathbf{m}_K = [A, B, A]$ para una determinada tarea de modelado predictivo (por ejemplo, detección de defectos). Se ha utilizado un doble eje vertical para reflejar los beneficios y los costes. Debido a la incertidumbre del equipo sobre la utilidad de s_2 para la tarea en cuestión, se decidió alquilarlo durante la duración del ensayo, ahorrando costes tras confirmarse su falta de relevancia predictiva.

Debe quedar claro que las decisiones sobre m_k a lo largo de los ensayos deben tomarse no sólo en función de las opciones de compra permitidas por el proveedor, sino también del conocimiento previo (si lo hay) sobre el potencial del sensor para aportar valor a la consecución del objetivo $B_{th}(t)$. Si esta estimación a priori fuera lo suficientemente fiable, el modo de compra A supondría menos costes que B , pero en la práctica esto conlleva un riesgo de liquidación muy difícil.

Como se ha mencionado anteriormente, hasta el momento no existe ninguna metodología que combine por un lado las metodologías de resolución de problemas existentes en las organizaciones industriales con la captura y procesamiento masivo de las más modernas técnicas de big data, por lo que se presenta como solución una nueva metodología que combina ambas: ASPPID - Analizar, Sensorizar, Preprocesar, Predecir, Implementar, y Desplegar, que se puede desglosar en varios aspectos novedosos que se resumen a continuación:

1. Un enunciado matemático formal del problema de rentabilidad abordado, que pone de manifiesto



la interacción entre coste y beneficio en los procesos industriales intensivos en datos, y motiva la naturaleza iterativa de la metodología propuesta.

2. Un flujo de trabajo de decisión centrado en los datos, que postula al científico de datos como miembro del equipo central de decisión en todas las decisiones tomadas en torno a procesos industriales sensibles a los datos, y una descripción exhaustiva de los pasos implicados en cada etapa del flujo de trabajo.
3. Una validación empírica de la metodología propuesta cuando se adopta para reducir el número de defectos en una planta real de inyección de aluminio del País Vasco (Norte de España). La falta de referencias previas en la literatura sobre esta nueva tecnología de inyección hace que el escenario sea especialmente adecuado para ASPPID, dada la alta incertidumbre en torno a qué sensor(es) utilizar para reducir el ratio de rechazo y la complejidad de aprender del conjunto de datos altamente desequilibrado registrado por el sensor(es). Se darán pruebas de la valiosa contribución del científico de datos a la metodología ASPPID.

Para hacer frente al problema planteado en el apartado anterior, se propone una metodología que haga gravitar todo el proceso de decisión sobre el coste y el rendimiento basado en datos del equipo sensor considerado. La metodología se detalla a continuación.

4.3.1. Descripción general

ASPPID es una metodología iterativa basada en el análisis de datos que persigue la mejora coste-eficiencia de un determinado proceso productivo dentro de las plantas de fabricación involucrando a un científico de datos desde el inicio de la metodología, es decir, desde el momento en que se toman las decisiones económicas sobre el modelo de adquisición de equipos sensores hasta el momento en que el modelo desarrollado se despliega en la línea de producción. Tradicionalmente, los científicos de datos forman parte del equipo de mejora cuando los sensores ya están instalados en las máquinas, encargándose de explotar la información recogida por ellos. De este modo, se limitan a explotar la información que registran los sensores instalados. En la práctica, esta estrategia conduce a errores muy frecuentes: los sensores ya instalados pueden no estar registrando variables y parámetros relevantes para la misión objetivo del modelo, lo que en última instancia pone en peligro el descubrimiento de modelos suficientemente explicativos para alcanzar el objetivo de beneficio $B_{th}(t)$ impuesto. Como ya se ha anticipado, la razón de este desajuste entre la información y las prestaciones del sensor es que, en ciencia de datos, el valor predictivo de los datos no sólo tiene que ver con su cardinalidad, sino también con su relevancia: es frecuente que los responsables de la adquisición de equipamiento industrial basen su decisión en la potencia de los sensores y en el precio, pecando por exceso de información, incorporando sensores redundantes o que registran variables sin influencia en el modelo predictivo, lo que conlleva costes adicionales.

En ASPPID el científico de datos desempeña un papel central dentro de la organización, participando no sólo en el desarrollo de modelos avanzados para el análisis de datos, sino también en la elección y validación de los sensores adquiridos, tras un análisis en profundidad de las prácticas anteriores recogidas en la literatura y teniendo en cuenta el coste de los sensores $C(s, m, B_{th}(s))$.

4.3.2. Fases de ASPPID

Concretamente, ASPPID puede dividirse en 6 etapas fundamentales: 5 que comprenden un ciclo iterativo destinado a cumplir el objetivo u objetivos del proyecto; y un último paso que se realiza una sola vez, una vez alcanzado el objetivo y validado el modelo desarrollado. Estos pasos se representan en la Figura 4.2 y se describen en las siguientes subsecciones:



Figura 4.2: Diagrama esquemático que ilustra el flujo de trabajo iterativo de la metodología ASPPID.

4.3.2.1. Analizar

Impulsada por la industria 4.0 y la democratización de la sensórica, es habitual encontrar en las organizaciones maquinaria con una gran cantidad de sensores capaces de registrar ingentes cantidades de datos captados de las diferentes etapas del proceso productivo. En la práctica, esta información casi nunca se explota y, si se utiliza alguna vez, gran parte de la información capturada es altamente redundante o no aporta ningún valor añadido a la eficiencia productiva de la planta. Esto supone un verdadero problema para las organizaciones: disponen de grandes colecciones de datos, pero no saben cómo explotarlos ni han analizado el sobrecoste como resultado de las decisiones de compra.

ASPPID afronta este problema definiendo una metodología especialmente adecuada para la supervisión de máquinas y procesos industriales con sensores. Un análisis en profundidad del problema o tarea que la organización pretende resolver debe ser el primer paso antes de proceder a la sensorización. Si este análisis no se realiza correctamente o se orienta hacia objetivos erróneos, toda la metodología podría dar lugar a costes considerablemente más elevados, de ahí que este paso sea crucial en nuestra metodología propuesta. En este sentido, todo el conjunto de decisiones a tomar tiene que estar impulsado por una preocupación, por algo a mejorar cuantitativamente. Este objetivo debe ser establecido por el consejo de dirección de la planta/empresa, pero tiene que ser alcanzable, medible y verificable. Una vez fijado el objetivo, hay que organizar un equipo de mejora que lleve a cabo todas las pruebas necesarias para alcanzarlo. Para ello, se deben realizar las siguientes acciones:

4.3.2.1.1. El contrato ASPPID dicta que los ensayos no pueden iniciarse a menos que el equipo de mejora esté de acuerdo con los términos y objetivos impuestos por la dirección. Este acuerdo se formaliza en un *contrato*, que refleja y certifica la confianza y el apoyo de la dirección de la planta o empresa a la que se destina el proyecto de mejora, sintiéndolo como propio. Este contrato obliga a ambas partes a cumplir con las responsabilidades planteadas en sus cláusulas: por un lado, la dirección lo utilizará como herramienta para trazar y verificar los resultados obtenidos por el equipo de mejora dentro del plan de tiempos; por otro, el equipo de mejora será asignado a un proyecto interno habiendo acordado en sus términos, lo que supone una garantía de implicación, compromiso e identificación con sus objetivos, mucho más allá de las implicaciones habituales de un proyecto (por ejemplo, mano de obra, apoyo de la empresa a la inversión). La evolución de todos los equipos de mejora de la planta respecto a sus contratos firmados será analizada al final del año de trabajo

para detectar causas comunes de desviación, desvelar problemas de gestión en la organización y necesidades potenciales de los equipos de mejora predominantes. El contrato debe tener *al menos* los siguientes elementos:

- Título: debe ser descriptivo, conciso y fácil de entender tanto para el cliente (en ASPPID este papel lo asume el consejo de administración) como para el equipo de mejora.
- Descripción del problema para el que se contrata al equipo de mejora. Esta parte debe ser cumplimentada por el cliente y revisada por el equipo de mejora.
- Objetivo del proyecto $B_{th}(t)$, que debe describirse detalladamente y cuantificarse en términos monetarios como beneficio objetivo esperado del modelo a desarrollar dentro del proyecto. Es de suma importancia especificar las unidades en las que se mide el beneficio, ya sea como una tasa a lo largo del tiempo (como en el enunciado del problema en la Sección 4.2) o como una medida alternativa, por ejemplo, beneficio por producto (como unidades monetarias por unidad producida). En todos los casos, este objetivo se utilizará para decidir el éxito/fracaso del proyecto y su cierre. Es importante señalar que este objetivo puede revisarse a lo largo del flujo de trabajo iterativo de ASPPID, aunque cualquier cambio debe ser revisado y acordado por ambas partes.
- Costes máximos del proyecto C_{max} , que establece un límite superior de los costes económicos asociados a la implantación de ASPPID incluyendo mano de obra, compra de sensores, equipos auxiliares y servicios externos. Dado que los costes pueden ser revisados entre ensayos y por transparencia y trazabilidad es aconsejable desglosar el coste máximo de los ensayos en los conceptos antes mencionados.
- Equipo: la definición del equipo de mejora no sólo debe determinar sus miembros, sino también sus horas de dedicación. El liderazgo del equipo será compartido por el director del proyecto y el científico de datos líder. En constante comunicación entre sí, el gestor del proyecto se encargará de gestionar la parte de infraestructura, comprar equipos y contactar con los proveedores de sensores, mientras que el científico de datos líder será responsable del análisis de datos. El resto del equipo de mejora debe estar compuesto por personal conocedor del proceso desde un punto de vista teórico/técnico, así como por personal de ingeniería de mantenimiento y/o arquitectos de datos. El papel de éstos es crucial para determinar qué partes del proceso sospechan que, según su experiencia, originan de forma más prometedora el problema que hay que resolver. Los arquitectos de datos y/o los ingenieros de mantenimiento se asegurarán de que los sensores están instalados y registran los datos correctamente.
- Plan de calendario: que incluya la duración estimada de los ensayos previstos $T_{xp}(s) \forall s \in \mathcal{S}$, los hitos intermedios y las horas de trabajo reservadas para cada miembro del equipo de mejora (véase en la Figura 4.3 un ejemplo de calendario de las fases de ASPPID para el ítem mostrado en la Figura 4.1). Crear planes de plazos realistas ayuda a evaluar el progreso del proyecto y mantiene motivado al equipo. Es importante que el cliente conozca el estado real del proyecto, por lo que se realizarán presentaciones periódicas (en un periodo acordado) y una vez finalizada cada prueba k . Cuando se detecte, cualquier desviación puntual de la planificación original debe documentarse y registrarse minuciosamente, y las contramedidas y acciones correctivas deben proponerse al cliente a su debido tiempo, es decir, en la presentación que se celebre más próxima a la detección de la desviación. El cliente y el jefe de proyecto evaluarán la causa de la desviación, resolviéndola (si es posible).

Una vez finalizado el contrato, deberá ser firmado por las partes: el cliente (directores de planta/empresa) y todos los miembros del equipo. Debe enviarse una copia del contrato firmado a todos los responsables de los miembros del equipo, para que tengan constancia de las horas que sus colaboradores dedicarán al proyecto ASPPID. Una vez firmado el proyecto, debe celebrarse una primera




Figura 4.3: Duración indicativa de cada fase de ASPPID en el ejemplo de la Figura 4.1.

reunión del equipo, en la que los responsables del equipo expliquen detalladamente al resto del equipo por qué se ha formado y el papel que todos los miembros desempeñarán en el equipo. Los objetivos, el calendario y la dedicación deben quedar claros para todos los asistentes.

4.3.2.1.2. Brainstorming Una vez dado este paso, el equipo puede empezar a abordar el proyecto. El primer paso es hacer una sesión de *brainstorming*, o tormenta de ideas, para determinar qué causas pueden estar afectando al problema. Un ejercicio de *brainstorming* es una técnica de creatividad en grupo, en la que todos los participantes deben aportar libremente ideas sobre las causas que afectan a un determinado problema. Para que esta dinámica sea eficaz, es muy importante que todos los participantes se sientan libres de expresar las ideas que creen que pueden influir. Por ello, los jefes de equipo deben comunicar las normas de participación al resto del equipo. Ninguna opinión puede ser subestimada ni ninguna persona coartada. Hay que olvidar los rangos de la organización. Si la presencia de un responsable puede entorpecer el correcto desarrollo de la dinámica, este ejercicio debe realizarse en momentos diferentes, aislando a las partes originarias de posible conflicto.

Para llevar a cabo eficazmente esta sesión de *brainstorming*, ASPPID adopta el denominado diagrama de Ishikawa [159] –también conocido como diagrama espina de pez por su forma–, que consta de un eje en el que reside el problema a abordar. A partir de este eje surgen las espinas, que agrupan los principales aspectos relacionados con el problema: equipos, proceso, personas, materiales, medio ambiente y gestión, tal y como se representa en la Figura 4.4. El objetivo del procedimiento Ishikawa es que el equipo considere todas las posibles causas que pueden afectar al problema en cuestión, no sólo aquellas en las que cada miembro individual probablemente se centra sesgado por su papel en la planta. Cuando se aportan todas las ideas, se seleccionan las que se cree que tienen mayor influencia en el problema. Con ellas se establecerán hipótesis. Otras variables consideradas irrelevantes/menos relevantes se descartan inicialmente, pero pueden volver a tenerse en cuenta en próximos ensayos: debido a la incertidumbre de la selección de sensores y variables, lo que parecía ser la causa raíz y una variable relevante para la tarea/problema en cuestión no suele cumplir las expectativas. Por lo tanto, hay que volver a generar nuevas hipótesis retomando la metodología de Ishikawa junto con todas las alternativas descartadas anteriormente.

En este punto destacamos que la participación del científico de datos desde el inicio del proceso (incluyendo el establecimiento y acuerdo de los objetivos del proyecto) no tiene precedentes, y arroja certeza sobre la posibilidad de alcanzar los beneficios esperados por el resto del equipo sobre el modelo a desarrollar. Para ello, el científico de datos puede contribuir a la sesión de *brainstorming* con bibliografía sobre el problema basado en datos que debe resolverse, estimaciones preliminares basadas en buenas prácticas comunicadas de configuraciones similares, y una explicación de las implicaciones prácticas de las puntuaciones con las que se evalúa el rendimiento del modelo que debe desarrollarse. Como resultado, la sesión de *brainstorming* debería producir un calendario de K en-

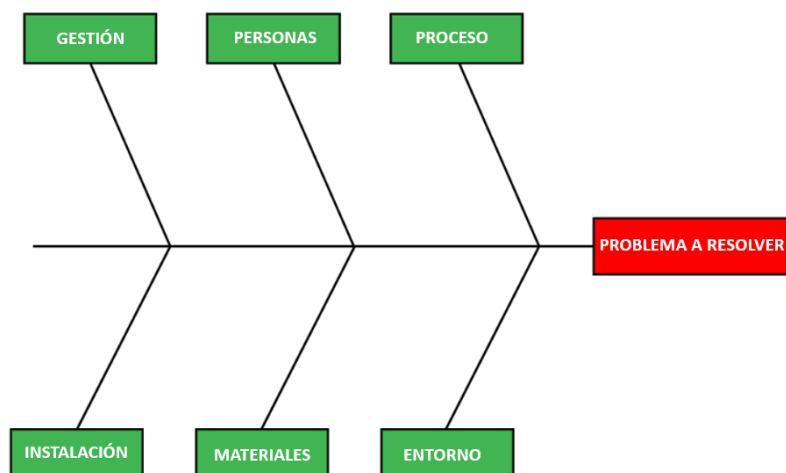


Figura 4.4: Diagrama de Ishikawa utilizado en la fase de análisis de ASPPID.

sayos donde probar diferentes variables monitorizadas, y una indicación cualitativa pero informada del nivel de confianza con respecto a su utilidad para el problema abordado.

4.3.2.2. Sensorizar

Una vez completado el ejercicio de *brainstorming*, es hora de probar el conjunto de variables hipotetizadas en cada ensayo. Para ello, el director del proyecto y el científico de datos principal deben inspeccionar si las variables ya se están registrando en la planta y, en caso afirmativo, si el sensor que captura dicha información es fiable, está correctamente calibrado, se encuentra en condiciones óptimas de funcionamiento [160, 161] y captura datos suficientes para las necesidades de la fase de modelado posterior. Para verificar esto último, el proveedor del sensor debe realizar pruebas y un plan de calibración para evitar errores de funcionamiento, repetibilidad y problemas de sesgo.

Si la información no se está registrando, el equipo debe valorar la adquisición de equipos de detección destinados a captar las variables necesarias. En este punto, ASPPID subraya la importancia de realizar esta adquisición de forma rentable, ya que comprar sensores basándose únicamente en sus especificaciones puede ser contraproducente debido a la imprevisibilidad de la contribución de sus datos capturados al problema en cuestión. Cuando el científico de datos principal declara que la utilidad de s_k en el ensayo k es extremadamente incierta (debido a la falta de historial previo con el sensor o el problema analizado), la derivación de costes de la Sección 4.2 sugiere que se debe preferir el alquiler del equipo de detección a una compra tradicional, si es posible (es decir, es decir, si el proveedor de sensores permite este modelo en la adquisición de s_k , es decir, si $B \in \mathcal{M}_{supp}(s_k)$).

Los sensores pueden suponer una parte importante del coste del proyecto, por lo que adquirirlos sólo después de validar si se estima que son realmente eficaces es fundamental para reducir el coste global $C(\mathbf{s}_K, \mathbf{m}_K, B_{th}(t))$ del proyecto. Siempre que exista riesgo de que las variables a sensorizar no sean capaz de generar modelos de suficiente calidad, el alquiler de sensores es más rentable que su adquisición desde el principio del ensayo. Esta es la razón por la que ASPPID impone que, antes de comprar un sensor, debe demostrarse fehacientemente que cabe esperar que sus datos capturados aporten una ganancia cuantitativa hacia la consecución del objetivo del proyecto. Esta estimación a priori debe realizarla el científico de datos principal (y su equipo, si lo hay) basándose en un estudio bibliográfico previo, entrevistas con el personal de la planta y el estudio de informes con casos

similares.

Una vez sensorizado el proceso/máquina, es el momento de recoger y analizar la información del proceso. Para ello, el equipo debe establecer el periodo de tiempo mínimo $T_{col}^{min}(s_k)$ para que el sensor s_k recoja datos representativos de toda la variabilidad y casuística de los parámetros monitorizados del ensayo en curso. Esta estimación puede realizarse explorando varios aspectos del escenario analizado, como los elementos que provocan la variabilidad de la variable de respuesta que debe predecir el modelo, el patrón de variabilidad (por ejemplo, la estacionalidad) de las magnitudes de las que se obtienen los datos y otras características estadísticas de los datos por igual.

4.3.2.3. Preprocesar

Una vez capturados y almacenados los datos, en ASPPID se procede a preprocesarlos para construir un modelo que permita alcanzar el objetivo del proyecto. Se trata de un paso esencial en el proceso de análisis de datos, ya que la extracción de información valiosa de los datos no sólo depende de los propios modelos, sino también de un proceso completo de preprocesamiento de datos que incluye los siguientes pasos [162]:

- La depuración consiste en la eliminación de las observaciones de datos que difieren significativamente del resto de observaciones, propensas a desajustar el modelo posterior.
- Escalado de datos, mediante el cual se escala cada variable registrada antes de utilizar modelos sensibles al rango de valores que toman sus variables de entrada (por ejemplo, redes neuronales). En [163] se puede encontrar un estudio de las técnicas de escalado.
- Imputación, mediante la cual se eliminan o rellenan muestras de datos con valores perdidos en función de su grado de incompletitud [164, 165].
- Identificación del ruido, mediante la cual se eliminan todas las instancias que dan lugar a una pérdida de precisión del modelo predictivo y no se utilizan para la construcción del modelo [166].
- Transformación de datos, que combina, proyecta y/o resume los datos registrados para que las muestras cumplan los supuestos a priori del modelo predictivo consiguiente (por ejemplo, linealidad, normalidad).

Aunque la relevancia del preprocesamiento de datos ha sido ampliamente reconocida por la comunidad investigadora, ASPPID refleja explícitamente la necesidad de acometer este paso dentro de su ciclo debido a su elevada participación en los costes de modelización $T_{modelo}(s_k)$. Al acordar el calendario y los costes del proyecto, el equipo de gestión debe ser consciente de las necesidades específicas de preprocesamiento de datos de la cartera de sensores considerada y ser advertido de los posibles sobrecostes debidos a este paso. Para minimizar el posible impacto presupuestario del preprocesamiento de datos, el equipo debe preparar un informe informado de estimación de la calidad de los datos, si es posible antes de la negociación y el acuerdo del contrato.

4.3.2.4. Predecir

Tras el preprocesamiento de los datos, el siguiente paso consiste en generar modelos que permitan alcanzar el objetivo de beneficio $B_{th}(t)$ establecido en el acuerdo contractual y, en última instancia, mejorar el rendimiento de la máquina/proceso monitorizado dentro de la planta de fabricación. Para ello, el conjunto de datos recuperados y ya preprocesados se utiliza como punto de partida de una fase de análisis de datos. De acuerdo con la mayoría de los casos de uso práctico previstos para ASPPID, esta fase tendrá como objetivo el desarrollo de un modelo predictivo capaz

de explicar el patrón entre un conjunto de parámetros monitorizados y una variable objetivo, esta última impactando en $B_{th}(t)$ directa o indirectamente (por ejemplo, potencia consumida o producción defectuosa).

En definitiva, primero debe realizarse un análisis exploratorio de los datos [167], que comprende técnicas como la estadística descriptiva, la reducción de la dimensionalidad y la agrupación, entre otras. Una vez realizado el análisis exploratorio, la parte del equipo de mejora encargada del análisis y modelización de datos estará en mejores condiciones para construir el modelo o modelos de datos previstos; en este sentido, la naturaleza de la variable o variables a predecir y el problema planteado requerirán procedimientos diferentes para construir el modelo. Intuitivamente, en entornos industriales los escenarios productivos que adoptan ASPPID para mejorar su rendimiento se basan en sensores, cuya información recogida se utiliza para entrenar y construir un modelo predictivo de clasificación o regresión, dependiendo del tipo de variables objetivo a predecir. En entornos industriales, esta familia de escenarios suele requerir la adopción de técnicas de desbalanceo de clases, selección/construcción de características y validación de modelos, ya que es probable que los datos recogidos carezcan de suficientes ejemplos positivos para modelar adecuadamente el patrón entre los parámetros monitorizados y la(s) variable(s) objetivo. Esta es la razón por la que los métodos de filtro, envoltura o selección de características incrustadas resultan esenciales en la fase de predicción de ASPPID, junto con las técnicas de sobremuestreo, submuestreo o sensibles a los costes para el equilibrio de clases.

Metodológicamente hablando, durante esta fase el equipo de mejora debe tener en cuenta la interpretabilidad del modelo para facilitar su despliegue en caso de que funcione satisfactoriamente con respecto al beneficio objetivo impuesto $B_{th}(t)$. Para ello, ASPPID fomenta la consideración de técnicas de minería de reglas con el fin de inferir conjuntos de reglas interpretables a partir de los modelos desarrollados que puedan ser implantados directamente por el personal de la planta tras su aprobación por el equipo directivo.

4.3.2.5. Implementar

La fase de implementación tiene por objeto verificar que los modelos generados en la fase anterior son válidos en la producción y, por lo tanto, pueden desplegarse si cumplen el objetivo de rendimiento impuesto y, finalmente, aprobarse. Dependiendo del escenario y del problema en cuestión, la implementación puede implicar 1) que el modelo desarrollado se pruebe con nuevos datos no vistos para evaluar sus capacidades de generalización estimadas (como en el caso, por ejemplo, de un modelo predictivo que pronostica el consumo de energía de una determinada máquina); 2) y/o que los parámetros que configuran la máquina/proceso monitorizado se varíen a los optimizados en base a los conocimientos proporcionados por la fase de modelado de datos. En ambos casos, esta fase debe demostrar que los modelos generados en la fase anterior funcionan según lo esperado durante la producción real, de modo que se pueda conceder al consejo de administración una garantía empírica de la mejora que aporta el modelo desarrollado.

Para ello, debe determinarse un periodo de aplicación. Debe ser lo suficientemente largo como para permitir comprobar el impacto de todos los componentes del proceso con una influencia potencial en la variable objetivo (por ejemplo, cambios de herramientas, moldes, etc.), pero lo suficientemente corto como para que se mantenga la tensión del equipo y se reduzcan los costes. Es necesario registrar las fechas de inicio y fin de esta fase para poder calcular el beneficio $B(s_k, \mathbf{m}_k, t)$ de los ahorros obtenidos durante este periodo de tiempo. Una vez finalizado este periodo, las conclusiones de la fase de implementación deben documentarse en su totalidad, junto con una estimación del impacto económico del modelo probado, su comparación con el objetivo establecido $B_{th}(t)$ y, si se considera necesario, recomendaciones fundamentadas del equipo de mejora (especialmente, del/de los científico(s) de datos) sobre una actualización de los objetivos y metas del proyecto ASPPID. Esta información se recopilará en un documento que se entregará al cliente, al que se convocará

a una reunión de revisión para cerrar el bucle k -ésimo del proyecto ASPPID.

4.3.2.6. Desplegar

En dicha reunión se tomará una decisión sobre el cumplimiento del objetivo del proyecto a la luz de la información reportada y de las conclusiones de la iteración ASPPID en curso, y de la evolución de los costes incurridos dentro del proyecto. En caso de que el objetivo $B_{th}(t)$ haya sido alcanzado por el modelo desarrollado, se elabora un estudio de costes del sobre coste necesario para desplegar definitivamente el modelo dentro de la línea de producción, incluyendo la compra de sensores si se han alquilado durante las pruebas anteriores. Si los costes globales estimados para el despliegue están por debajo de C_{max} , el proyecto se declara exitoso. En caso contrario, tanto el equipo como la dirección deben acordar una relajación de la restricción de costes o una inversión del ciclo ASPPID a un ensayo anterior, lo que se decide en función de la idoneidad de cada alternativa para la planta. Por ejemplo, si la diferencia entre $B(s_k, \mathbf{m}_k, t)$ y $B_{th}(t)$ es elevada, el consejo de administración podría decidir destinar fondos adicionales al despliegue del modelo; por el contrario, los gastos superiores a C_{max} deberían apalancarse evaluando el pequeño beneficio sobre $B_{th}(t)$ con la inversión necesaria para desplegar el modelo.

Es aconsejable disponer de una plataforma documental centralizada, que permita conservar documentos que recopilen los conocimientos adquiridos durante el proyecto, ya que muchos de los conocimientos basados en datos obtenidos pueden extrapolarse a otros escenarios que traten productos con características iguales o similares. En estos documentos se deben detallar lo mejor posible las condiciones y aspectos clave que hacen que las conclusiones obtenidas sean generalizables a otros casos de uso. El responsable de registrar esta información es el gestor del proyecto. Una vez grabada la información en la plataforma, se debe organizar una reunión de cierre del proyecto para cotejar que la documentación elaborada está completa. También es importante que el resto de la organización visualice su éxito, por lo que una buena práctica es instalar paneles visibles en el interior de la planta con una descripción lo más sinóptica posible de los pasos dados a lo largo del ciclo ASPPID.

4.4. Experimentación

En esta sección se plantea un caso de uso que tiene como objetivo la predicción de piezas defectuosas en una línea de inyección de aluminio. Desde una perspectiva de análisis de datos, esta tarea predictiva puede modelarse como un problema de clasificación binaria altamente desequilibrado en el que el modelo a desarrollar clasifica los productos como ACEPTADOS (es decir, conformes con los requisitos de calidad) o RECHAZADOS. Aunque la literatura es rica en el tratamiento de este caso particular de problema por medio de modelos predictivos, la inyección de aluminio a baja presión es una tecnología de fabricación totalmente nueva para la que no se conocen referencias previas. Esta particularidad motivó aún más la participación del científico de datos líder de la empresa en todo el flujo de trabajo de decisión, proponiendo cambios profundos en el *modus operandi* que prevalecía en la empresa antes de iniciar este caso de uso. Esos cambios dieron lugar a la definición de un procedimiento iterativo temprano para reubicar el análisis de datos en el núcleo del proyecto, que maduró hacia la metodología ASPPID aquí propuesta.

Se acordó que el objetivo del proyecto ASPPID era el diseño y despliegue de un proceso lo suficientemente robusto como para fabricar piezas con un índice de calidad suficientemente alto para esta primera fase experimental. Este proyecto ha consistido en obtener un análisis predictivo sobre la calidad de las piezas, y reducir los costes del sensor. Este tipo de proceso suele tener un alto índice de desbalanceo. En este caso de estudio, el IR (índice de desbalanceo) es de 7,68.

Para ello, se han probado técnicas de sobremuestreo y submuestreo: Sobremuestreo de clases minoritarias, Técnica de Sobremuestreo Sintético de Minorías (SMOTE, [168]), SMOTE con elimina-

ción de enlaces Tomek [169], la variante borderline de SMOTE [170], Adaptive Synthetic Sampling (ADASYN, [171]), Edited Nearest Neighbours (ENN, [172]) y One-Sided Selection (OSS, [173]).

Como todas las piezas fabricadas pasan un control de calidad interno, las métricas utilizadas fueron la puntuación F1 y, principalmente, *recall*. La precisión se omite debido a que todas las piezas pasan un control de calidad, por lo que el objetivo del modelo es ser capaz de crear buenos modelos para la clase mayoritaria (piezas ACEPTADAS) y la minoritaria (piezas RECHAZADAS). Se incluye también el cálculo de la métrica AUC, con el fin de demostrar que para casos en los que la variable respuesta está desbalanceada no es una buena métrica, ya que está altamente influenciada por la clase mayoritaria.

Siguiendo las directrices de ASPPID para el análisis de datos en la subsección (4.3.2.4) se utilizó un clasificador Random Forest (RF, [174]) con 500 árboles como modelo predictivo interno para elegir entre las técnicas de desequilibrio de clases y descubrir las características que tenían más influencia en la respuesta. Una vez seleccionadas las variables más influyentes, se utilizó un modelo de árbol de decisión C4.5 como modelo predictivo interpretable debido a su sencillez y legibilidad directa en términos de conjuntos de reglas desplegadas. Tanto las técnicas de sobremuestreo y submuestreo + Random Forest como el árbol C4.5 se ejecutaron en una validación cruzada de 5 veces y 5 veces para evitar sesgos en el modelado.

Respecto a la sensorización y sus costes asociados, se utiliza el enfoque matemático detallado en la sección 4.2, y la descripción de como el proceso fue sensorizado y los datos analizados se describen en la siguiente subsección, desplegando la metodología ASPPID. En este caso bastaron $K = 2$ iteraciones de ASPPID para alcanzar el objetivo impuesto:

4.4.0.1. Primera iteración ($k = 1$)

(1.a) Analizar: Una vez definido cuantitativamente el objetivo (traducido de unidades monetarias a una Tasa de No Calidad, *NQR - Not Quality Rate-*, máxima igual a 8 % que debería alcanzar el proyecto para cumplir el objetivo) y tras dotar de presupuesto al proyecto, se organizó un equipo multidisciplinar de mejora, con un director de proyecto y un científico de datos líder como coordinadores del mismo. El resto del equipo se seleccionó en función de los conocimientos técnicos del proceso a supervisar, y se estableció un calendario para desarrollar el proyecto. Una vez creado y firmado el contrato, se inició una primera reunión del equipo con el objetivo de desarrollar un ejercicio Ishikawa para pensar qué parámetros pueden influir en la ración de chatarra de esta nueva tecnología de inyección. Para ello, se utilizó una pizarra y el científico de datos, que dirigía la sesión, explicó las reglas y coordinó el *brainstorming* mediante un diagrama de Ishikawa. Como resultado, el equipo acordó una selección y priorización de factores hipotéticos. Para esta primera iteración, se seleccionaron los siguientes factores:

- Número de horno que procesa cada pieza inyectada.
- Duración del ciclo, es decir, tiempo durante el cual la pieza se procesa en el horno.
- Número de cavidad de la pieza dentro del molde.
- Número de molde dentro del stock de moldes de la planta.
- X_t^1 [confidencial], serie temporal que representa una magnitud registrada durante el procesado en el horno.

(1.b) Sensorizar: una vez identificados, los factores anteriores deben ser sensorizados a partir del proceso monitorizado. Para ello y dada la alta incertidumbre con esta tecnología de inyección, se adoptó uno de los principios de la metodología ASPPID, gastar el mínimo dinero en sensores, evitando adquirir equipos que incrementaran el coste del proyecto sin ninguna garantía de fiabilidad de su contribución al objetivo del proyecto, tal y como se describe en la Sección

4.2. En esta primera iteración el equipo aprovechó un equipo de detección que había sido instalado previamente en otro proceso dentro del plan y que estaba fuera de uso en el momento en que se realizó la prueba. En caso de que este equipo fuera finalmente relevante para el proyecto, se adquirirían nuevas unidades de detección y se instalarían en el proceso supervisado. Se decidió un periodo $T_{col}^{min}(s_1)$ igual a 2 meses para equilibrar la compensación entre las pérdidas debidas a la no productividad del proceso supervisado y la recopilación de datos suficientes para captar la variabilidad subyacente del proceso. Se realizó un desglose detallado de los costes para evaluar conjuntamente todas las decisiones que afectaban al presupuesto del proyecto (uso de sensores provisionales, pérdidas durante el periodo de *sensorización*, etc.).

- (1.c) Preprocesado: una vez recogidos (a razón de 1 muestra por segundo en el caso de X_t^1), los datos se preprocesaron mediante codificación one-hot para las variables categóricas (números de horno, cavidad y molde), mientras que el tiempo de ciclo se convirtió a su puntuación Z. En cuanto a la variable dependiente del tiempo X_t^1 , una serie de entrevistas con conclusiones empíricas del personal permitieron extraer características de importancia potencial para la detección de defectos de las series temporales registradas para cada pieza, como se muestra en la Figura 4.5. Una vez extraídos, los valores de las características se normalizaron a su puntuación Z. La etapa de preprocesamiento produjo un total de 19 predictores binarios y de valor real. En este primer ciclo no fue necesario imputar los datos perdidos, mientras

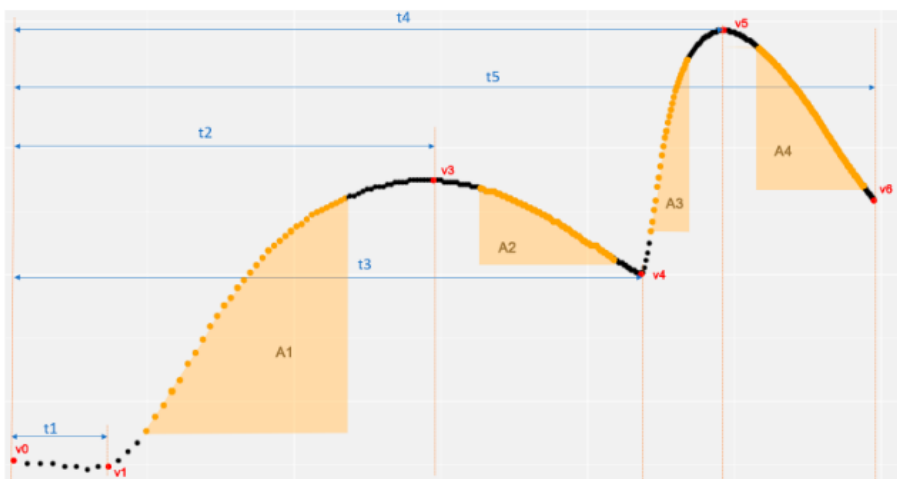


Figura 4.5: Características extraídas de la serie temporal X_t^1 capturada por el sensor seleccionado en el ensayo $k = 1$: puntos extremos $\{v_0, \dots, v_6\}$, áreas $\{A_1, \dots, A_4\}$ y retardos $\{t_1, \dots, t_5\}$, resultando en 16 características.

que sólo se detectaron valores atípicos en X_t^1 debido a errores de lectura sufridos por el sensor instalado. Se realizó una corrección estadística sobre las muestras atípicas identificadas, sustituyendo por la media de la mediana de los 3 valores anteriores y posteriores aquellos puntos cuya diferencia con respecto al valor del punto anterior y posterior es superior a un determinado porcentaje. (ver Figura 4.6).

- (1.d) Predecir: Los resultados en términos de precisión, recall, puntuación F1 y área bajo la curva (AUC, [175]) obtenidos por cada esquema en una validación cruzada de 5×5 para submuestreo y sobremuestreo + RF se muestran en la Tabla 4.1. Dados los malos resultados obtenidos




Figura 4.6: Cálculo de las medianas tras detectar un valor atípico ● y sustitución de la muestra atípica utilizando el valor medio de las medianas calculadas.

Tabla 4.1: Puntuaciones medias de los modelos de la primera iteración de la metodología ASPPID.

Modelo	Recall	Precisión	F1	AUC
OVERSAMPLING + RF	0.2325	0.6427	0.3404	0.8745
SMOTE + RF	0.2988	0.4527	0.3480	0.8214
BORDERLINESMOTE + RF	0.2325	0.4510	0.3051	0.8633
SMOTE-TOMEKLINKS + RF	0.313	0.4346	0.3504	0.8105
ADASYN + RF	0.2331	0.5020	0.3160	0.8666
ENN + RF	0.3199	0.4201	0.3463	0.8032
OSS + RF	0.2164	0.6584	0.3249	0.8837

en esta prueba comparativa, el equipo realizó una última comprobación para determinar si el número de ejemplos del conjunto de datos era suficiente para predecir la variable objetivo. Este estudio se realizó observando la evolución del rendimiento de los modelos a medida que se reduce progresivamente el tamaño del conjunto de datos. Únicamente mostrados para ADASYN + RF (Figura 4.7) por brevedad, los resultados obtenidos para todos los métodos llevan a la misma conclusión: la cantidad de datos recuperados en este primer ensayo era suficiente, ya que los datos adicionales producidos por más muestras (por ejemplo, ampliando $T_{col}^{min}(s_1)$) no mejorarían significativamente el rendimiento del modelo.

Podemos confirmar que AUC no es una buena medida cuando la clase de desequilibrio está presente. Se puede observar que a pesar de que el modelo no clasifica bien la clase positiva, se dan valores altos de AUC. Esto se debe al peso que tiene la clase mayoritaria en la generación del modelo.

- (1.e) Implementar: los resultados insatisfactorios obtenidos con este primer sensor no fueron convincentes para invertir en una fase de *implementación* para validarlos en producción.

Basándose en los datos extraídos de este primer estudio, el equipo de mejora propuso una nueva iteración de la metodología ASPPID a la dirección de la planta, en la que probar un nuevo conjunto de sensores dentro del proceso de producción monitorizado. La primera conclusión extraída y consensuada por ambas partes fue que los sensores utilizados en esta primera prueba no eran suficientes para alcanzar el valor objetivo establecido $B_{th}(t)$, sin embargo, la utilización de sensores ya instalados en otra máquina en lugar de adquirirlos había reducido drásticamente -más de un 90 %- los costes previstos para esta primera iteración. Este hecho reforzó la consideración de la eficiencia de costes como un aspecto clave en iteraciones posteriores de ASPPID, y dirigió a partir de entonces las negociaciones con los proveedores de sensores.

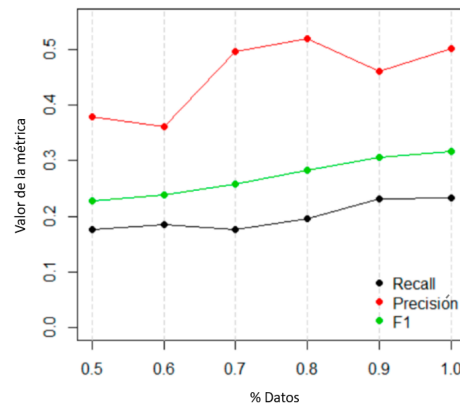


Figura 4.7: Puntuación media de los modelos en función de la cantidad de datos para el enfoque ADASYN + RF.

4.4.0.2. Segunda iteración ($k = 2$)

Esta segunda iteración, y en general, todas las iteraciones dentro de una implementación ASPPID, parten siempre del ejercicio Ishikawa realizado en iteraciones anteriores:

- (2.a) Analizar: el equipo de mejora se reunió de nuevo y generó nuevas hipótesis con las variables inicialmente descartadas. En consecuencia se decidió y acordó sensorizar nuevas magnitudes y elementos a lo largo de la línea de producción, soportando la incertidumbre de su relevancia predictiva con la incorporación de nuevos miembros (previa aprobación del equipo directivo) con conocimientos en Física y Termodinámica. Dado que los sensores de la primera iteración ASPPID no supusieron ningún coste para el proyecto, se volvieron a utilizar en esta segunda prueba. Los nuevos sensores necesarios para capturar el nuevo conjunto de parámetros decidido se alquilaron en lugar de comprarse tras negociar con el proveedor, que finalmente admitió un cambio en su modelo de relación con la empresa (es decir, el proveedor aceptó incluir el modo B en su cartera de ventas $\mathcal{M}_{sup}(s_2)$). Llegados a este punto, es importante prescribir que, en general, las variables y los sensores que las capturan utilizados en los primeros ensayos no deben descartarse del ciclo ASPPID a menos que el equipo de detección asociado sea lo suficientemente caro como para causar un problema presupuestario a lo largo del proyecto, aunque al descartarlos el equipo corra el riesgo de perder valiosas interacciones predictivas entre variables.
- (2.b) Sensorizar: una vez instalados y plenamente operativos los sensores alquilados, se controlaron 3 nuevas series temporales: X_t^2 , X_t^3 y X_t^4 (enmascaradas por motivos de confidencialidad), recogidas durante un período de $T_{col}^{min}(s_2) = 2$ meses a 1 muestra por segundo.
- (2.c) Preprocesar: repitiendo el procedimiento de extracción de rasgos realizado en X_t^1 con las series temporales adicionales de 3 monitorizadas por los nuevos sensores, se produjo un conjunto de datos compuesto por 13522 partes, cada una caracterizada por 35 rasgos, con una tasa de muestras de no calidad del 13,44 %. La normalización y la depuración se llevaron a cabo utilizando las mismas técnicas que en X_t^1 en X_t^2 , X_t^3 y X_t^4 .
- (2.d) Predecir: se realizó un análisis de datos idéntico al de la primera iteración con este nuevo conjunto de datos: se utilizaron técnicas para tratar el desequilibrio de clases y un clasificador RF interno con una validación cruzada de 5×5 veces al construir el modelo, lo que dio lugar a las puntuaciones que figuran en la tabla 4.2.

De todos los modelos generados, se seleccionó la combinación con los valores medios más altos de F1 y recall (SMOTE + RF), ya que todas las piezas se someten a un control de calidad tras ser procesadas, por lo que la precisión es menos relevante en la elección del modelo. El estudio de la importancia predictiva para cada variable (evidenciada por el modelo RF) sugirió la discriminación de dos grupos de características que comprendían más del 50 % de la importancia predictiva sobre los que construir dos clasificadores de árbol de decisión diferentes: uno sólo con el primer grupo de importancia de la variable (Grupo 1), y el segundo con el primer y el segundo grupo (Grupo 1+2). La razón de proceder de este modo estriba en la eventual implantación y despliegue del modelo: operar y afinar menos variables dentro de la línea de producción resulta más rentable y fácil de adoptar por el personal de la planta.

Tabla 4.2: Puntuaciones medias de los modelos de la segunda iteración de la metodología ASPPID.

Modelo	Recall	Precisión	F1	AUC
OVERSAMPLING + RF	0.4604	0.7604	0.5733	0.7585
SMOTE + RF	0.5989	0.5728	0.5854	0.6658
BORDERLINESMOTE + RF	0.5160	0.6757	0.5850	0.7227
SMOTE-TOMEKLINKS + RF	0.6070	0.5595	0.5821	0.6593
ADASYN + RF	0.5324	0.6604	0.5893	0.7125
ENN + RF	0.6243	0.5345	0.5756	0.6455
OSS + RF	0.4971	0.7155	0.5864	0.7361

A diferencia de Random Forest, los árboles de clasificación pueden ser sensibles a la colinealidad [174], por lo que el primer paso consiste en verificar la multilinealidad de las variables implicadas en el Grupo 1, a saber, V09, V10, V15 y V16. A este respecto, una matriz de correlaciones por pares reveló una elevada dependencia lineal entre las variables seleccionadas. A partir de esta información, se construyeron modelos de árbol sobre diferentes subconjuntos de datos basados únicamente en la variable v16, cuyo umbral de decisión demostró ser bastante estable con respecto a diferentes muestras de entrenamiento (comparando entre árboles entrenados sobre diferentes subconjuntos de los datos disponibles). Si se utilizaran ambos grupos de características, se incluirían en el conjunto de datos las variables v14, v1, v8, v4 y v3 que componen el Grupo 1+2. Un análisis de correlación similar al realizado anteriormente puso de manifiesto que sólo existía colinealidad entre las variables del primer grupo. Por lo tanto, todas las características del segundo grupo se introdujeron en el modelo de árbol de decisión, junto con la característica v16 del primer grupo.

Las figuras 4.8.a y 4.9.b muestran el árbol de clasificación más frecuente resultante de crear el modelo explicativo sobre 5 pliegues del conjunto de datos equilibrado con las variables de los grupos 1 y 1+2, respectivamente. Cada nodo muestra la clase predicha predominante (ACEPTADA/RECHAZADA), el porcentaje de observaciones y la ocurrencia de la predicha predominante dentro de dichas observaciones en cada nodo. Puede observarse que v16 es capaz, por sí solo, de separar las dos clases. En cuanto al árbol construido utilizando el grupo 1+2, el número de variables que hay que controlar es mayor, lo que da lugar a un conjunto de reglas demasiado complejo para ser aplicado en producción. Una vez más, se observa que la variable v16 separa perfectamente ambas clases.

Los resultados correspondientes a la aplicación de los árboles anteriores se muestran en la Tabla 4.3. A pesar de que el *NQR* es inferior en el árbol entrenado sobre los grupos 1 y 2, el conjunto de reglas extraído del árbol crecido por el modelo se consideró definitivamente demasiado complejo para ser implementado en la línea de producción. Aunque ambos mode-

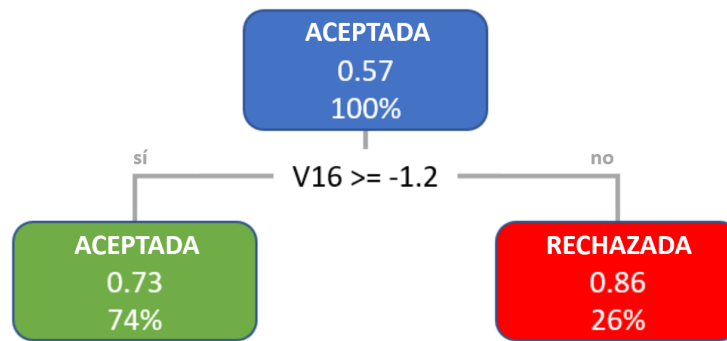


Figura 4.8: Árboles de decisión más frecuentes inferidos a partir de la información recogida con diferentes subconjuntos de características grupo 1.

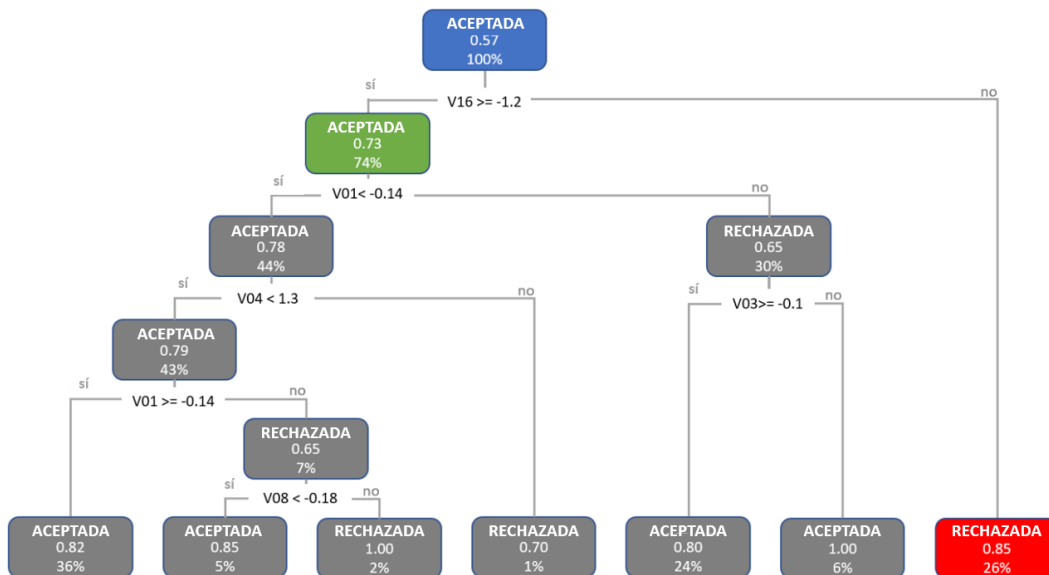


Figura 4.9: Árboles de decisión más frecuentes inferidos a partir de la información recogida con diferentes subconjuntos de características grupo 1+2.

los mejoraron sus puntuaciones NQR con respecto a la referencia en la prueba $k = 1$ (lo que respalda su potencial para producir una tasa de no calidad máxima igual al 8 % en la fase de implementación), el equipo de mejora comunicó al director de ingeniería la compensación de Pareto entre la posibilidad de implementar de las reglas extraídas del modelo y su ganancia de rendimiento en términos de recuerdo. Impulsado por su simplicidad, el responsable optó por el modelo más sencillo basado en la variable $v16$.

- (2.e) Implementar: en esta fase se implementó la regla extraída del modelo de árbol de decisión explicativo seleccionado tras la fase *predict* y se ejecutó en producción durante $T_{imp}(s_2) = 3$ meses. Concretamente, el personal de la planta se aseguró de que la maquinaria cumpliera las condiciones dictadas por el modelo de árbol seleccionado para producir menos piezas defectuosas (puesto que se seleccionó el modelo más sencillo, se redujo a $V16 < -1, 2$).

Esta nueva directiva de producción produjo 23966 piezas, con 1672 RECHAZADAS y 22294 ACEPTADAS, es decir, una tasa de no calidad del 6,98 %, alcanzando el objetivo del proyecto ASPPID en $K = 2$ iteraciones.

Tabla 4.3: NQR (intervalo de confianza medio) de las reglas extraídas de los grupos de características.

Variables	Datos originales	SMOTE + Decision Tree	
		Rama mínima defectos	Rama máximos defectos
Grupo 1+2 (<i>predicción</i>)	$13,34 \pm 0,47 \%$	$7,05 \pm 0,49 \%$	$59,67 \pm 2,04 \%$
Grupo 1 (<i>predicción</i>)	$13,34 \pm 0,47 \%$	$7,37 \pm 0,52 \%$	$57,76 \pm 2,21 \%$
Grupo 1 (<i>implementación</i>)	—	6.98 %	—

Una vez verificado por el equipo de mejora y presentado al equipo directivo, se compró el segundo sensor alquilado, aumentando sólo un 8,62 % el coste global de la prueba con respecto al caso en el que el sensor s_2 se compró desde el principio. Sin embargo, como se muestra en la Figura 4.10, el coste global del equipo de detección gastado durante el proyecto ASPPID, incluyendo la primera y la segunda iteración, se redujo hasta el 43,11 % con respecto a un esquema tradicional de compraventa. Este ahorro de costes fue reconocido por el equipo directivo a una elección acertada e informada de los equipos de detección, y a una estrecha correspondencia entre las métricas de rendimiento del modelo predictivo desarrollado y los requisitos del caso de uso, que aunaba la facilidad de despliegue y el cumplimiento del objetivo de rendimiento impuesto.

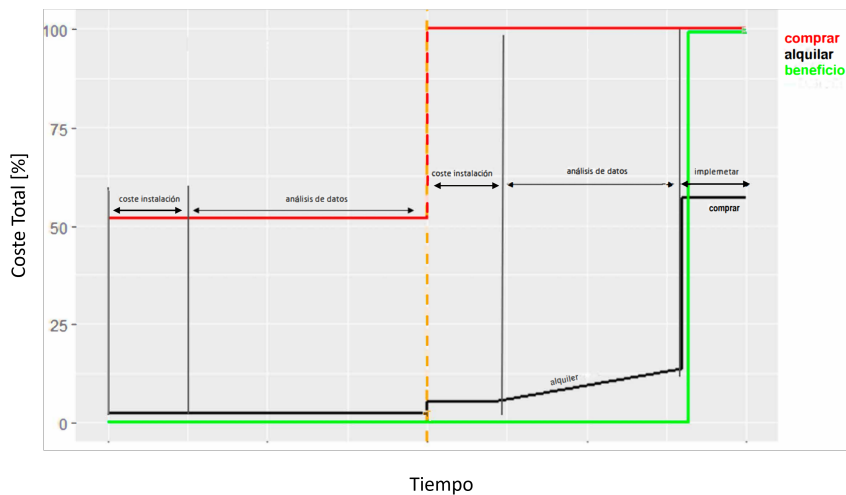


Figura 4.10: Comparación gráfica entre los costes derivados de las estrategias de alquiler (—) y compra (—) en la adquisición de sensores dentro de la metodología ASPPID. El gráfico también incluye la progresión del beneficio (—) a lo largo del ciclo ASPPID.

4.4.0.3. Desplegar

Verificados los resultados de la fase de *implementación*, el director del proyecto actualizó la información del AMFE en la base de conocimientos de la empresa [176].

4.5. Resultados y conclusiones

Se ha presentado ASPPID, una novedosa metodología iterativa para la selección eficiente de equipos de detección en procesos industriales y maquinaria, capitalizando esencialmente un papel predominante del científico de datos a lo largo de todo el flujo de trabajo de decisión, no sólo dentro de las etapas en las que se explotan los datos capturados. La metodología propuesta comprende etapas en las que todas las decisiones se toman para minimizar los costes y cumplir el objetivo de beneficio del proyecto global.

Para ello, ASPPID propone organizar un equipo en el que el científico de datos principal salve la distancia tradicional entre la compra de sensores y su utilidad esperada con respecto a los objetivos del proyecto. Además, si el proveedor lo permite, ASPPID recomienda explorar nuevas formas de aprovisionamiento e instalación temporal de sensores, de forma que los costes extra de alquiler se vean compensados por un menor riesgo asumido por el equipo, especialmente cuando el proyecto se realiza con datos generados en escenarios de aplicación con escasas o nulas buenas prácticas reportadas por la comunidad. La adopción de esta metodología es especialmente adecuada cuando no se dispone de información a priori sobre el potencial de los datos capturados por el sensor para sesgar el proyecto en cuestión; en este caso se considera crucial una profunda implicación del científico de datos en la selección de los equipos de sensorizado que se probarán a lo largo de los ensayos para no sobredimensionar los requisitos de sensorizado de la planta.

Para validar la metodología propuesta se utilizó un caso de uso llevado a cabo en una industria manufacturera real. La aplicación de ASPPID dio lugar a una reducción de los costes de los sensores superior al 43 % con respecto al caso en el que todos los sensores se adquirieron desde el principio, al tiempo que se cumplía un ratio de rechazo (NQR) inferior al valor objetivo impuesto al inicio de ASPPID.

Capítulo 5

Optimización de la planificación de la producción

Este capítulo se centra en describir la optimización de la planificación de la producción haciendo uso de la inteligencia artificial como soporte de la mejora. El capítulo queda organizado de la siguiente manera: la sección 5.1 introduce el tipo de problema que se pretende resolver y por qué es crítico para las organizaciones. A continuación, la sección 5.2 detalla el caso de uso que se va a resolver. La sección 5.3 describe la metodología aplicada para alcanzar los objetivos, y que se aplicará en la sección 5.4. La sección 5.5 expone los resultados y conclusiones generales para este problema.

5.1. Introducción

Tal y como se describió en la introducción y en la sección 2.1.2, la planificación de la producción es uno de los principales problemas de las organizaciones industriales, donde se ha demostrado que los algoritmos evolutivos ayudan a tomar esas decisiones formulando de diferentes maneras la eficiencia buscada para el plan de producción, que en esencia se reduce a fabricar el mayor número de unidades posible con el mínimo desperdicio [177, 178].

Con dos objetivos fijados, la reducción del *makespan* y la minimización de costes derivados principalmente del consumo energético, es intuitivo deducir que ambos objetivos pueden ser contrapuestos, especialmente cuando se trata de activos que demandan energía cuya tasa de producción está estrechamente correlacionada con la cantidad de energía necesaria para producir (por ejemplo, hornos de arco eléctrico). Este problema puede generalizarse como una variante multiobjetivo de *JSP* que comprende dos objetivos: i) *makespan* y ii) *costes de producción*, que se supone que dependen de diferentes conceptos relacionados y no relacionados con la energía. El coste económico dependerá principalmente, según el tipo de industria, de la cantidad de consumo energético de las máquinas, que puede ser diferente en función de su estado (en *espera / activa / parada*).

Por otra parte, los costes de producción también se rigen en gran medida por el coste de la mano de obra, que puede variar en función del turno. También pueden tenerse en cuenta otros factores de coste cuando se considera el coste como objetivo de producción, pero en determinadas plantas industriales la energía se convierte en el concepto que domina los gastos de producción [39].

A la hora de optimizar cualquier formulación *JSP*, la metodología más comúnmente adoptada consiste en seleccionar una serie de algoritmos metaheurísticos que conformen una muestra representativa del estado del arte, y realizar un estudio experimental para determinar qué algoritmo de entre ellos ofrece la mejor solución. Sin embargo, el fin último de la investigación en esta dirección

debe ser la obtención de un optimizador capaz de resolver eficazmente instancias de problemas de interés, orientado a mejorar los resultados de otros métodos ya existentes. Entre las prácticas habituales seguidas con este fin se incluyen el ajuste manual de los parámetros de un algoritmo dado, o la adición de nuevos componentes (por ejemplo, un operador de variación o un método de búsqueda local) al proceso de búsqueda, que pueden explotar el conocimiento específico del problema. Como resultado, a menudo se produce un algoritmo denominado *nuevo*, pero en la mayoría de los casos la plantilla algorítmica del algoritmo de búsqueda metaheurística sigue siendo esencialmente la misma.

En este sentido, damos un paso más y exploramos el potencial de las herramientas de diseño automatizado de algoritmos para el *JSP* multiobjetivo. Dado un conjunto de componentes algorítmicos que pueden combinarse entre sí, y un conjunto de problemas utilizados como conjunto de entrenamiento, las herramientas automatizadas de diseño de algoritmos pueden descubrir de forma autónoma un algoritmo evolutivo que esté adaptado para tratar eficientemente instancias no vistas del mismo problema. Mientras que la aplicabilidad del diseño algorítmico automatizado (también conocido como *configuración automática de algoritmos*) ha sido pulsada para muchos escenarios de aplicación diferentes hasta la fecha [179, 180], hasta donde sabemos no ha habido ningún estudio previo que evalúe hasta qué punto las *JSP* multiobjetivo pueden beneficiarse de estas herramientas, ni ha habido ningún debate informado previo sobre las ventajas prácticas derivadas de su adopción. Para cubrir este nicho, este trabajo se apoya en el *framework jMetal* como motor de optimización multiobjetivo, que recientemente ha liberado funcionalidades para el diseño automatizado de algoritmos evolutivos multiobjetivo [181, 182] basadas en el conocido paquete *irace* para la configuración y diseño automatizado de algoritmos [183]. Definimos varias instancias de entrenamiento y prueba de una formulación multiobjetivo del *JSP* en la que, además de los factores considerados en [39], se incluyen como nuevos conceptos de coste los costes de personal por turnos y los diferentes costes de electricidad por horas.

5.2. Problema a resolver

Una de las conclusiones del análisis de las taxonomías realizado en el estado del arte es que los problemas se centraban principalmente en dos objetivos, desde el punto de vista energético, el consumo de energía es prioritario, y desde el punto de vista operativo, el *makespan* es clave. Por lo tanto, proponemos resolver un problema bi-objetivo que trata de encontrar la solución óptima para estos dos objetivos, pero teniendo además en cuenta los tiempos y consumos de las máquinas, los tiempos y consumos de arranque y parada de las máquinas y su velocidad, el coste eléctrico horario y el coste de personal.

Otro de los puntos críticos detectados en el estado del arte es que muchos de los estudios se han centrado principalmente en el desarrollo de nuevos algoritmos que suponen una mejora respecto a los algoritmos tradicionales. En este estudio vamos a basarnos en explotar el potencial de los algoritmos ya existentes mediante la óptima configuración de los hiperparámetros. Para ello será necesario generar un auto-configurador de parámetros que permita encontrar los hiperparámetros de los algoritmos de optimización multiobjetivo capaces de encontrar las mejores soluciones.

5.3. AutoMOEA - Metodología propuesta

Para conseguir resolver el problema planteado en el apartado anterior vamos a necesitar diseñar un algoritmo de configuración de hiperparámetros automático que sea capaz de abordar los problemas de *JSP* con la energía como uno de sus objetivos. Por tanto, debe responder a las siguientes cuestiones:

- ¿Qué componentes y parámetros algorítmicos se utilizan? (subsección 5.3.2)

- ¿Qué casos problemáticos deben utilizarse para la formación? (subsección 5.3.3)
- ¿Cómo medir la calidad de una configuración concreta, dado que los frentes de Pareto de las instancias *JSP* no se conocen de antemano? (subsección 5.3.4)
- ¿Qué recursos informáticos se necesitan y cuánto tiempo se tarda en buscar la configuración de AutoMOEA por irace? (subsección 5.3.5 y 5.3.6)

Pero antes de responder a estas cuestiones, y de modo introductorio, es necesario detallar como son las instancias de problemas a resolver que se van a tener en cuenta. Dichas instancias son de carácter público [184], y sólo tienen en cuenta el tiempo de ejecución de los trabajos y el número de máquinas disponibles para realizar los mismos, por lo que no incorporan información relativa a la energía. Dichas instancias son de la forma:

```

5 3
0 19 9 33 ...
9 11 10 22 ...
...
```

Donde la primera fila indica el número de trabajos y el número de máquinas (5 y 3 en el ejemplo) y las siguientes contienen pares que incluyen la máquina y el tiempo necesario para ejecutar esa parte del trabajo. En este caso, por ejemplo, el primer trabajo ejecuta la máquina 0 durante 19 unidades de tiempo

5.3.1. Enriquecimiento de instancias JSP

Para poder integrar la energía como uno de los objetivos, es necesario enriquecer la información de estas instancias, con información adicional sobre la energía, teniendo en cuenta las paradas, los tiempos muertos, velocidades de las máquinas, coste de los relevos y el coste horario de la energía. Por lo tanto se han incluido nuevos campos asociados a la energía:

- Consumo de energía por unidad de tiempo:
 - *machineWorkingEnergy*: Consumo total de energía por unidad de tiempo mientras una máquina está en funcionamiento.
 - *machineIdleEnergy*: Unidad de tiempo de consumo total de energía mientras una máquina está en estado inactivo.
 - *machineWorkingToStopEnergy*: Consumo total de energía por unidad de tiempo mientras una máquina deja de funcionar.
 - *machineWorkingToIdleEnergy*: Consumo total de energía por tiempo unido mientras una máquina pasa del estado de trabajo al de reposo.
- Variables de velocidad de la máquina:
 - *numberOfVelocities*: Conjunto de las velocidades que puede tener una máquina.
- Penalización de la energía de la velocidad:
 - *velocityPenalty*: Penalización del consumo de energía por diferentes velocidades.
- Variables temporales unitarias:

- *machineTimeToIdle*: Unidades de tiempo que necesita una máquina para pasar del estado de reposo al de arranque o del arranque al reposo.
- *machineTimeToStop*: Unidades de tiempo que necesita una máquina para pasar del estado de trabajo al de parada o viceversa.
- Variables relativas al coste de personal
 - *personalCost*: Coste medio de cada relevo, siendo constante durante todo un relevo.
- Coste horario de la energía
 - *electricCostPerHour* : Coste promedio horario para cada hora del día.

Con estas nuevas variables podemos definir cuánta energía y tiempo va a consumir una máquina para un determinado trabajo que se ejecuta en x número de unidades de tiempo. Cabe destacar que el usuario puede configurar diferentes velocidades de máquina y tiempos de espera de máquina, permitiendo tomar decisiones como dejar una máquina en estado de reposo hasta la siguiente operación o apagarla y volverla a arrancar, establecer el coste de los relevos y el coste energético del KWh para cada hora a lo largo del día.

5.3.2. Diseño

5.3.2.1. Codificación de la solución

Una decisión crucial a la hora de abordar el problema definido anteriormente con algoritmos metaheurísticos es la estrategia de codificación de la solución, es decir, la metodología para representar numéricamente cualquier solución al problema.

Para empezar, se utilizará una codificación de lista de enteros, representando cada solución como una lista de enteros con longitud $J \times M$, donde J es el número de trabajos y M es el número de máquinas, tal y como se presentó en [185]. Para incluir la posibilidad de no trabajar en una o más horas durante el día, se agrega una nueva lista, de longitud igual a la lista anterior multiplicada por un factor Z , divisible por 24, de modo que cada entrada de la lista es ahora una hora en un bloque de 24 entradas consecutivas. El algoritmo busca las horas del día para trabajar con este coste horario, ya que genera una matriz Z veces replicada (múltiplo de 24), cuya codificación binaria indica las horas laborables/no laborables. Como resultado, esto afecta directamente al *makespan* (más tiempo hasta la finalización si el trabajo abarca horas cuyo gen codificado se establece en 0) y al coste (debido a las horas punta y no punta del coste eléctrico, y los costes de los diferentes turnos). Con ello, podemos satisfacer la condición de que la planta opere en horas de energía más barata o, en cambio, decida producir en periodos de menor coste de personal. Como cada valor de esta cadena está comprendido entre 1 y J , e imponiendo que cada valor sólo puede repetirse J veces, la lista se recorre secuencialmente, de forma que cada vez que aparece un determinado valor sobre la lista se da un paso adelante en el trabajo, hasta que éste finaliza.

Para introducir el concepto de energía, se generan listas de igual longitud para velocidad de máquina, máquina parada, turno y coste horario, de forma que la suma de los costes asociados del producto escalar de estos vectores nos dará el coste de producción. La Figura 5.1 ilustra esta estrategia de codificación, mostrando las diferentes listas incluidas en el genotipo de la solución. Para empezar, *trabajo a ejecutar* denota el número del trabajo a ejecutar, codificado como un entero entre 0 y $J - 1$. El *velocidad de ejecución* indica la velocidad a la que se ejecuta el trabajo, que es un multiplicador ($\times 1$, $\times 2$ o $\times 3$) de la velocidad de procesamiento base de la máquina. Los elementos de la lista denominados *¿parada o en espera al finalizar?* son iguales a 1 ó 0, dependiendo de si la máquina pasa al estado *inactiva* tras finalizar su trabajo o, por el contrario, está parada. La lista *coste de mano de obra* indica el turno durante el cual se procesa el trabajo: turno de mañana, tarde o

	Hora 1	Hora 2	Hora 3	Hora 4		Hora 23	Hora 24
Trabajo a ejecutar	1	1	3	0		5	2
Velocidad de máquina	1	1	2	2		1	3
¿Parada o en espera al acabar?	1	2	1	1		1	1
Turno horario	1	1	1	1		3	3
Coste eléctrico por hora	15	12	12	15		12	11

Figura 5.1: Ejemplo de la estrategia de codificación de soluciones adoptada.

noche, cada uno con un coste medio de mano de obra por hora. Por último, el *coste de electricidad por hora* indica el coste medio horario de electricidad incurrido en la producción según las horas en las que se procesan los trabajos y el estado y velocidad de procesamiento de las máquinas.

5.3.2.2. Operadores de variación

La estrategia de codificación anterior es adecuada para los operadores de cruce y mutación definidos en [39], que se utilizarán en nuestros experimentos. En concreto, se definen dos operadores, *JSPCrossover* para el cruce y *JSPMutation* para la mutación.

El operador de cruce procede como sigue: tras seleccionar dos soluciones padre de la población, se elige uniformemente al azar una dimensión de la solución codificada entre horario, velocidad o inactividad. A continuación, se vuelven a seleccionar dos posiciones aleatorias dentro de la lista correspondiente a la dimensión seleccionada y se intercambian entre los dos padres, dando lugar a dos hijos. La probabilidad de cruce se fija en el 90 % para los algoritmos sin autoconfigurador. En el operador de mutación, se realiza una selección aleatoria entre (horario, velocidad y reposo). A continuación, se realiza un intercambio aleatorio entre dos posiciones elegidas al azar. La probabilidad de mutación se ha fijado en 100 % (es decir, siempre se aplica la mutación).

El *JSP* se implementa en *jMetal*, incluyendo los mencionados operadores de variación específicos etiquetados como *JSPMutation* y *JSPCrossover*, de forma que cualquiera de los algoritmos evolutivos multiobjetivo disponibles en *jMetal* pueda utilizarlos para resolver el problema. El uso combinado de *jMetal* e *irace* para el ajuste automático de parámetros se basa en la propuesta presentada en [186], donde se presentó un estudio sobre la configuración automática de NSGA-II [64]. Aquí utilizamos una plantilla algorítmica similar que, al instanciarse con un conjunto determinado de componentes, da lugar a un algoritmo evolutivo concreto.

El espacio de diseño actual se detalla en la Tabla 5.1. Partiendo de un tamaño de población fijo de 50 soluciones, el tamaño de la población descendiente puede tomar un valor en el rango de 1 (es decir, en estado estacionario) a 400, y se puede incorporar un archivo externo; en tal caso, el tamaño de la población puede variar dentro del rango entero [10, 200] y el resultado de la búsqueda serán las soluciones contenidas en el archivo en lugar de la población. El archivo tiene un tamaño máximo de 50 individuos, y se utiliza el estimador de densidad de distancia de hacinamiento [64] para podarlo cuando se llena.

El modelo algorítmico supone que se utiliza un método de clasificación y un estimador de densidad para discriminar las soluciones tanto en el paso de selección como en el de sustitución. Estos componentes pueden ser el ranking de no dominancia y la distancia de *crowding* de NSGA-II y el ranking de *strength* y el estimador de densidad k-próximo (KNN) de SPEA2 [187]. Si se selecciona KNN, el valor de K oscila entre 1 y 3. La selección puede ser aleatoria o por torneo. La selección puede ser aleatoria o por torneo con un tamaño de torneo entre 2 y 10. Por último, la probabilidad de aplicar el operador *JSPCrossover* oscila entre 0.0 y 1.0 (siempre se aplica el *JSPMutation*).

Tabla 5.1: Espacio de parámetros de AutoMOEA para resolver *JSP*. El tamaño de la población es 50.

Parámetro	Dominio de búsqueda
offspringPopulationSize	[1, 400]
algorithmResult	{externalArchive, population}
populationSizeWithArchive	[10, 200] (subject to algorithmResult == externalArchive)
ranking	{dominanceRanking, strengthRanking}
densityEstimator	{crowdingDistance, kNN}
kValueForKNN	[1,3] (subject to densityEstimator == kNN)
selection	{tournament, random}
selectionTournamentSize	[2, 10] (subject to selection == tournament)
crossover	JSPCrossover
crossoverProbability	[0.0, 1.0]
mutation	JSPMutation

5.3.3. Conjunto de instancias de entrenamiento

Elegir un conjunto de entrenamiento adecuado es una decisión clave porque afecta, por un lado, a la capacidad del algoritmo diseñado para generalizar y resolver eficazmente otros problemas. Por otro lado, también repercute en el tiempo de computación requerido por irace para encontrar la mejor combinación de componentes. Hemos de tener en cuenta que, por defecto, irace genera 100.000 configuraciones.

Dado que éste es nuestro primer estudio sobre las capacidades del diseño algorítmico automático para abordar la *JSP* con metaheurísticas, hemos elegido las tres instancias *JSP* más pequeñas, *LA04*, *LA10*, y *FT06*. De este modo, priorizamos encontrar los hiperparámetros de forma rápida del diseño algorítmico final, con la esperanza de que generalice bien aunque sólo se evalúe en instancias sencillas del problema. En este sentido, la condición de parada del AutoMOEA se reduce a computar un máximo de 25.000 evaluaciones de funciones, mientras que en la sección de experimentación este número se incrementará a 200.000. La eficacia de estas decisiones se evaluará en la sección experimental.

5.3.4. Medición de la calidad de las configuraciones

La herramienta irace requiere una medida que, dadas dos configuraciones algorítmicas diferentes, determine cuál es la mejor. Dado que el objeto de comparación son las aproximaciones del frente de Pareto, debería aplicarse un indicador de calidad. Sin embargo, la mayoría de ellos (por ejemplo, distancia generacional invertida, ϵ , etc.) se calculan utilizando un frente de Pareto de referencia. Tampoco conocemos los frentes de Pareto de los problemas de referencia *JSP*. Por lo tanto, hemos seleccionado el indicador de hipervolumen, ya que sólo requiere un punto de referencia. Para definir dichos puntos de referencia, hemos examinado, para cada caso de problema, todos los frentes producidos tras una serie de pruebas piloto realizadas fuera de línea. Después de registrar los puntos extremos abarcados por todos estos frentes para cada objetivo, hemos añadido un desplazamiento conservador para garantizar que los frentes encontrados por AutoMOEA probablemente los dominen.

5.3.5. Recursos informáticos y código fuente

El uso de irace para encontrar configuraciones es una tarea computacional intensiva. En nuestro estudio, hemos utilizado un entorno de virtualización ubicado en el Centro de Investigación Ada Byron de la Universidad de Málaga (España). En concreto, hemos utilizado una máquina virtual

con procesador Intel(R) Xeon(R) Platinum 8358 CPU @ 2.60GHz (64 cores) y 64GB de RAM. El sistema operativo es Ubuntu 21.04 y las versiones de Java y *irace* son, respectivamente, JDK 14 y 3.4.1. La versión de *jMetal* es 6.0-SNAPSHOT. Utilizando estos recursos, el tiempo de ejecución de *irace* ha sido de unas 6 horas. De acuerdo con las directrices y buenas prácticas prescritas en [39], todo el código fuente y los resultados reportados en este manuscrito están disponibles bajo petición escrita a los autores.

5.3.6. Configuración de AutoMOEA encontrada por *irace*

La mejor configuración para AutoMOEA encontrada por *irace* se detalla en la Tabla 5.2, donde se incluye en la columna de la izquierda la configuración de NSGA-II como referencia. Curiosamente, se observa que AutoMOEA no utiliza un archivo externo, a diferencia del algoritmo AutoNSGA-II reportado en [186], que sí hacía uso de él. Además, el tamaño de la población de descendientes se reduce de 50 a 36, el estimador de densidad es *strength ranking*, las probabilidades de cruce son similares a la de NSGA-II, y el tamaño del torneo es de 5 en lugar de 2. Los experimentos en lo que sigue revelarán si estas diferencias en el espacio de diseño se traducen en ganancias significativas de rendimiento cuando se evalúan en casos de problemas no vistos.

Tabla 5.2: Parametrización de NSGA-II y AutoMOEA para *JSP*. El tamaño de la población es de 50 soluciones.

Parámetros	NSGA-II	AutoMOEA
algorithmResult	population	population
offspringPopulationSize	50	36
ranking	dominanceRanking	strengthRanking
densityEstimator	crowdingDistance	crowdingDistance
crossover	JSSPCrossover	JSSPCrossover
crossoverProbability	0.90	0.955
selection	tournament	tournament
selectionTournamentSize	2	5

5.4. Experimentación

Una vez planteado el diseño, se lleva a cabo la experimentación sobre las siguientes instancias *JSP*:

- *la04* [188], 5 máquinas y 10 trabajos.
- *la10* [188], 5 máquinas y 15 trabajos.
- *ft06* [189], 6 máquinas y 6 trabajos.
- *orb01* [188], 10 máquinas and 10 trabajos.
- *abz5* [190], 10 máquinas y 10 trabajos.
- *swv20* [191], 10 máquinas y 50 trabajos.
- *ta12* [192], 15 máquinas y 20 trabajos.
- *dmu11* [193], 15 máquinas y 30 trabajos.
- *yn03* [194], 20 máquinas y 20 trabajos.

- *dmu40* [193], 20 máquinas y 50 trabajos.
- *ta77* [184], 20 máquinas y 100 trabajos.

El criterio para seleccionar las instancias de este problema es cubrir al menos un conjunto de datos de cada una de las publicaciones que han aparecido en la literatura analizada, pero tratando de elegir una variedad suficiente de instancias, en cuanto al número de máquinas y al número de trabajos, con una complejidad gradual del problema, de menor a mayor.

Una vez que irace ha encontrado una solución potencialmente buena sobre las instancias *JSP* de entrenamiento consideradas, el siguiente paso es evaluar si el AutoMOEA auto diseñado es capaz de mejorar los resultados obtenidos por otros algoritmos sobre las instancias *JSP* consideradas. Concretamente, hemos seleccionado los que son representativos de las tres categorías de algoritmos evolutivos multiobjetivo: Basados en Pareto (NSGA-II [64] y SPEA2 [187]), basados en descomposición (MOEA/D [65] y GWASFGA [195]), y basados en indicadores (SMS-EMOA [66]). Todos los algoritmos - incluido AutoMOEA - están configurados con un tamaño de población de 50 individuos, mientras que la condición de parada se fija en un máximo de 200.000 evaluaciones de funciones. Todos ellos utilizan los mismos operadores de variación JSPCrossover, con una probabilidad de 0,9 (excepto AutoMOEA, que utiliza 0,955), y JSPMutation. MOEA/D aplica la agregación de Tschebyscheff, la probabilidad de selección de vecindario es 0,90, el tamaño del vecindario es 20 y el número máximo de soluciones reemplazadas es 2. GWASFGA requiere un parámetro ϵ , que se establece en 0,01.

La calidad de las aproximaciones al frente de Pareto logradas por cada algoritmo en la comparación se evalúa en términos de indicadores de calidad multiobjetivo. En concreto, se han utilizado dos indicadores: ϵ -aditivo (EP) [196] e hipervolumen normalizado (NHV). EP es una medida de la desviación absoluta necesaria para trasladar cada solución en una aproximación del frente de Pareto de forma que domine débilmente el frente utilizado como referencia. Por otro lado, NHV se calcula como 1,0 menos la relación entre el hipervolumen del frente que se va a evaluar y el hipervolumen del frente de referencia. La métrica del hipervolumen [197] calcula el volumen (en el espacio de objetivos) cubierto por los miembros de un conjunto dado de soluciones no dominadas con respecto a un punto de referencia. Para cuantificar los resultados de cada algoritmo, realizamos 25 ejecuciones independientes por cada par de problema-algoritmo, informando de la mediana y el rango intercuartílico (IQR) para cada indicador de calidad.

Los resultados de esta comparación se recogen en las tablas 5.3.a (EP) y 5.3.b (NHV), donde los mejores y segundos mejores resultados se destacan en fondo gris oscuro y claro, respectivamente. Además, para comprobar la significancia estadística de las diferencias de rendimiento, hemos aplicado las pruebas de comparaciones múltiples post-hoc de Friedman y Holm y las pruebas de suma de rangos de Wilcoxon [198], ambas a un nivel de significación del 5%. Los frentes de referencia para calcular los indicadores de calidad se han obtenido agregando, para cada problema, las soluciones devueltas por todas las ejecuciones de todos los algoritmos, de forma que el frente de referencia esté compuesto por todas las soluciones no dominadas del conjunto agregado. Dichos frentes de referencia se muestran en las figuras 5.2.a a 5.2.h, junto con una comparación entre los frentes correspondientes a la mediana del valor NHV obtenido por NSGA-II y AutoMOEA (gráficos 5.2.i a 5.2.p).

Al inspeccionar estos resultados, observamos en primer lugar que, según EP (que mide la convergencia de las aproximaciones del frente de Pareto), AutoMOEA obtiene los mejores resultados en 8 de las 11 instancias *JSP* consideradas. Si nos centramos en las tres primeras instancias del problema, que se utilizaron para el proceso de auto-diseño (entrenamiento), SPEA2 resulta ser el algoritmo que arroja los mejores (más bajos) valores indicadores. Se puede seguir un razonamiento similar si consideramos los resultados de NHV: AutoMOEA vuelve a obtener los mejores resultados de media, alcanzando el mejor y el segundo mejor (menor) valor del indicador en 7 y 3 de todas las instancias del problema consideradas. Sin embargo, de forma similar al indicador EP, AutoMOEA

Tabla 5.3: Mediana y rango intercuartílico de los indicadores de calidad (a) PE y (b) VNH obtenidos por los algoritmos comparados.

	NSGA-II	SPEA2	MOEA/D	SMS-EMOA	GWASFGA	AutoMOEA
LA04	1,14e - 01 _{2,3e-02}	9,40e - 02 _{2,0e-02}	8,39e - 01 _{6,7e-01}	1,14e - 01 _{4,6e-02}	2,75e - 01 _{1,6e-01}	9,75e - 02 _{2,0e-02}
LA10	9,93e - 02 _{3,8e-02}	1,10e - 01 _{3,8e-02}	6,91e - 01 _{1,4e-01}	1,11e - 01 _{3,7e-02}	3,34e - 01 _{6,3e-02}	1,17e - 01 _{2,6e-02}
FT06	2,22e - 01 _{5,6e-17}	2,22e - 01 _{0,0e+00}	1,67e + 00 _{1,0e+00}	2,22e - 01 _{1,1e-01}	1,00e + 00 _{1,7e-01}	2,22e - 01 _{5,6e-02}
ORB01	2,73e - 01 _{1,3e-01}	2,61e - 01 _{5,5e-02}	1,09e + 00 _{2,2e-01}	2,93e - 01 _{1,4e-01}	6,84e - 01 _{2,0e-01}	2,44e - 01 _{1,0e-01}
ABZ5	1,89e - 01 _{1,1e-01}	1,63e - 01 _{9,8e-02}	8,32e - 01 _{1,9e-01}	2,02e - 01 _{5,8e-02}	4,19e - 01 _{1,2e-01}	1,56e - 01 _{8,3e-02}
SWV20	2,35e - 01 _{3,2e-02}	2,86e - 01 _{7,9e-02}	8,84e - 01 _{1,4e-01}	2,92e - 01 _{8,5e-02}	2,91e - 01 _{9,9e-02}	1,61e - 01 _{9,6e-02}
TA12	2,62e - 01 _{1,0e-01}	2,98e - 01 _{8,8e-02}	8,74e - 01 _{2,6e-01}	3,54e - 01 _{1,8e-01}	3,29e - 01 _{1,9e-01}	1,91e - 01 _{9,5e-02}
DMU11	3,72e - 01 _{1,6e-01}	3,92e - 01 _{1,1e-01}	1,22e + 00 _{3,9e-01}	3,69e - 01 _{1,0e-01}	3,99e - 01 _{2,0e-01}	2,48e - 01 _{1,5e-01}
YN03	2,80e - 01 _{1,9e-01}	3,35e - 01 _{1,3e-01}	1,08e + 00 _{3,2e-01}	3,88e - 01 _{1,7e-01}	4,00e - 01 _{1,7e-01}	2,28e - 01 _{1,3e-01}
DMU40	5,88e - 01 _{3,0e-01}	7,14e - 01 _{3,2e-01}	2,74e + 00 _{6,1e-01}	6,23e - 01 _{2,1e-01}	9,33e - 01 _{3,0e-01}	3,12e - 01 _{1,9e-01}
TA77	1,35e + 00 _{3,3e-01}	2,06e + 00 _{3,3e-01}	3,08e + 00 _{5,6e-01}	1,31e + 00 _{3,1e-01}	2,37e + 00 _{3,7e-01}	5,32e - 01 _{5,1e-01}

(a) EP

	NSGA-II	SPEA2	MOEA/D	SMS-EMOA	GWASFGA	AutoMOEA
LA04	6,13e - 02 _{7,2e-02}	1,18e - 02 _{6,5e-02}	8,01e - 01 _{4,8e-01}	7,55e - 02 _{6,8e-02}	1,61e - 01 _{4,2e-02}	4,23e - 02 _{7,3e-02}
LA10	6,67e - 02 _{3,4e-02}	8,64e - 02 _{4,2e-02}	6,49e - 01 _{1,6e-01}	8,12e - 02 _{4,4e-02}	2,45e - 01 _{6,8e-02}	9,65e - 02 _{3,8e-02}
FT06	1,05e - 01 _{2,4e-01}	5,53e - 02 _{6,7e-02}	1,00e + 00 _{0,0e+00}	1,40e - 01 _{3,1e-01}	1,00e + 00 _{2,3e-01}	9,76e - 02 _{2,0e-01}
ORB01	3,38e - 01 _{1,7e-01}	2,95e - 01 _{6,9e-02}	1,00e + 00 _{8,2e-02}	3,16e - 01 _{2,2e-01}	6,25e - 01 _{2,3e-01}	3,10e - 01 _{1,9e-01}
ABZ5	1,65e - 01 _{1,3e-01}	1,30e - 01 _{8,6e-02}	8,12e - 01 _{2,1e-01}	1,70e - 01 _{8,5e-02}	3,50e - 01 _{1,3e-01}	1,27e - 01 _{8,4e-02}
SWV20	2,26e - 01 _{8,4e-02}	2,64e - 01 _{8,4e-02}	8,79e - 01 _{1,5e-01}	2,67e - 01 _{8,9e-02}	2,60e - 01 _{1,0e-01}	1,44e - 01 _{1,2e-01}
TA12	2,51e - 01 _{1,1e-01}	2,83e - 01 _{8,2e-02}	8,69e - 01 _{2,0e-01}	3,49e - 01 _{1,8e-01}	3,00e - 01 _{2,0e-01}	1,68e - 01 _{1,0e-01}
DMU11	3,20e - 01 _{1,9e-01}	3,36e - 01 _{1,3e-01}	1,00e + 00 _{1,2e-02}	3,23e - 01 _{1,1e-01}	3,37e - 01 _{2,2e-01}	3,04e - 01 _{1,9e-01}
YN03	2,80e - 01 _{1,7e-01}	3,57e - 01 _{1,6e-01}	1,00e + 00 _{5,2e-02}	3,45e - 01 _{1,8e-01}	3,40e - 01 _{1,9e-01}	2,27e - 01 _{1,5e-01}
DMU40	6,14e - 01 _{3,1e-01}	7,33e - 01 _{3,6e-01}	1,00e + 00 _{0,0e+00}	6,45e - 01 _{2,5e-01}	9,41e - 01 _{2,1e-01}	2,86e - 01 _{2,1e-01}
TA77	1,00e + 00 _{0,0e+00}	1,00e + 00 _{0,0e+00}	1,00e + 00 _{0,0e+00}	1,00e + 00 _{0,0e+00}	1,00e + 00 _{0,0e+00}	5,41e - 01 _{5,8e-01}

(b) NHV

Tabla 5.4: LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .EP.

	SPEA2	MOEAD	SMS-EMOA	GWASFGA	AutoMOEA
NSGAI	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
SPEA2	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
MOEAD	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	▽▽▽▽▽▽▽▽▽▽▽▽	▽▽▽▽▽▽▽▽▽▽▽▽	▽▽▽▽▽▽▽▽▽▽▽▽
SMS-EMOA	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
GWASFGA	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	▽▽▽▽▽▽▽▽▽▽▽▽

obtiene los segundos mejores resultados al resolver las instancias LA04 y FT06, mientras que SPEA2 es el algoritmo que presenta las mejores cifras en las 5 instancias más pequeñas. NSGA-II obtiene los mejores resultados en la instancia LA10 y los segundos mejores en las 6 instancias de mayor dimensionalidad.

Los resultados de aplicar el test de suma de rangos de Wilcoxon se muestran en las tablas 5.4, 5.5 y 5.6 indican que las diferencias de AutoMOEA con respecto a todos los algoritmos son significativas en la mayoría de los casos, mientras que en las cinco instancias menores, las diferencias frente a NSGA-II y SPEA2 no son significativas salvo un problema. Finalmente, la aplicación del test de Friedman (Tabla 5.7) confirma que AutoMOEA ocupa el primer lugar entre todos los algoritmos comparados para ambos indicadores.

Tabla 5.5: LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .IGD+.

	SPEA2	MOEAD	SMS-EMOA	GWASFGA	AutoMOEA
NSGAI	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
SPEA2	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
MOEAD	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	▽▽▽▽▽▽▽▽▽▽▽▽	▽▽▽▽▽▽▽▽▽▽▽▽	▽▽▽▽▽▽▽▽▽▽▽▽
SMS-EMOA	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▽▽▽▽▽▽▽▽
GWASFGA	-----▲▲▲-----▲▲	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	-----▲▲▲-----	▲▲▲▲▲▲▲▲▲▲▲▲▲▲	▽▽▽▽▽▽▽▽▽▽▽▽



Tabla 5.6: LA04 LA10 FT06 ORB01 ABZ5 SWV20 TA12 DMU11 YN03 DMU40 TA77 .NHV.

	SPEA2	MOEAD	SMS-EMOA	GWASFGA	AutoMOEA
NSGAI	▽ - ▽ - - - ▲ ▲ - - - ▲ -	▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ -	▲ - ▲ - - - ▲ ▲ - - - -	▲ ▲ ▲ ▲ ▲ - - - - ▲ -	- ▲ - - - ▽ ▽ ▽ ▽ ▽ ▽ ▽
SPEA2		▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ ▲ -	▲ - ▲ - - - - - - - ▽ -	▲ ▲ ▲ ▲ ▲ - - - - ▲ -	- - ▲ - - ▽ ▽ ▽ ▽ ▽ ▽ ▽
MOEAD			▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ -	▽ ▽ ▲ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽	▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽
SMS-EMOA				▲ ▲ ▲ ▲ ▲ - - - - ▲ -	▽ - ▽ - ▽ ▽ ▽ ▽ ▽ ▽ ▽
GWASFGA					▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽ ▽

A modo de ejemplo, mostramos también en la Figura 5.3 las soluciones extremas para la instancia ta12 respecto a la energía y el makespan. La imagen superior muestra la configuración de mejor consumo energético, y tal y como era esperable, esta configuración tiene un mayor makespan, mientras que la imagen inferior tiene un *makespan* menor, pero un mayor coste energético. El resultado que se muestra en la figura es el esperable, ya que si tenemos en cuenta las variables que afectan a un mayor consumo energético tenemos que tener en cuenta el coste de la electricidad por horas, el coste horario, la velocidad de la máquina,... que son opuestas al objetivo de reducir el tiempo de fabricación. Por lo tanto, en la imagen superior podemos ver trabajos que llevan más tiempo (barras horizontales más largas) y mayor número de huecos entre barras. En la imagen inferior tenemos un *makespan* mucho más reducido a base de concentrar más la producción, con menos huecos y trabajos más cortos (a mayor velocidad). Numéricamente la de mejor (mínimo) consumo energético, arriba en la figura, tiene un consumo de 603908 unidades de energía y un *makespan* de 2378 unidades de tiempo, mientras que la solución de mejor *makespan* tiene 610910 unidades de energía y un *makespan* de 1796 unidades de tiempo.

5.5. Resultados

A la luz de los resultados presentados en la sección anterior, nos detenemos ahora en diferentes cuestiones de investigación relacionadas con el ámbito general de este trabajo: el potencial de la configuración algorítmica automática para resolver *JSP* multiobjetivo con conciencia energética. Para ello, la discusión se guía por las respuestas dadas a cada una de las preguntas, reforzadas por los resultados experimentales reportados:

- **RQ1: ¿Existen diferencias en el rendimiento de los optimizadores metaheurísticos multiobjetivo clásicos cuando se aplican al *JSP* sensible al consumo energético?**

Cuando se deja de lado AutoMOEA en la comparación entre algoritmos, las tablas 5.3.a y 5.3.b revelan que NSGA-II supera al resto de algoritmos clásicos para la mayoría de las instancias sintéticas *JSP* consideradas. Además, en aquellas pocas instancias en las que otros algoritmos obtienen mejores resultados, NSGA-II es la segunda mejor opción, o está competitivamente cerca de los que dominan el *benchmark*. Este resultado es notable y se alinea con los obtenidos en otros trabajos relacionados con otros dominios de aplicación, en los que este algoritmo obtuvo resultados muy competitivos incluso si sus parámetros no se ajustaron con precisión para el problema de optimización en cuestión y se dejaron iguales a los valores típicos.

- **RQ2: ¿un optimizador configurado automáticamente aporta alguna mejora con respecto a los optimizadores multiobjetivo clásicos**

La respuesta es claramente positiva: AutoMOEA, que está diseñado para la mejor calidad media de las aproximaciones del frente de Pareto de las instancias *JSP* de entrenamiento, se generaliza muy bien a instancias *JSP* no vistas, consiguiendo diferencias de rendimiento que son estadísticamente relevantes. Curiosamente, su rendimiento superior no se mantiene en las instancias *JSP* de entrenamiento LA04, LA10 y FT06: esto es consecuencia del hecho de que el proceso de búsqueda



Figura 5.2: (a)-(h): Composición del frente de referencia de cada instancia *JSP* de prueba; (i)-(p): frentes correspondientes a la mediana del valor NHV de NSGA-II y AutoMOEA.

Tabla 5.7: Clasificaciones medias de Friedman con valores p ajustados de Holm (0,05) de los algoritmos comparados para los indicadores EP y NHV sobre los problemas de prueba.

Algoritmo	EP				NHV			
	Ranking	p -value	Holm	Hipótesis	Ranking	p -value	Holm	Hipótesis
AutoMOEA	1,545	1,0	0,0	-	1,727	1,0	0,0	-
NSGA-II	2,273	$5,994e - 29$	0,05	Rechazada	2,364	$1,513e - 22$	0,05	Rechazada
SPEA2	2,909	$2,523e - 97$	0,025	Rechazada	3,091	$2,523e - 97$	0,025	Rechazada
SMS-EMOA	3,545	$4,736e - 207$	0,017	Rechazada	3,364	$2,784e - 139$	0,017	Rechazada
GWASFGA	4,727	1,0	0,013	Rechazada	4,545	1,0	0,013	Rechazada
MOEA/D	6,0	1,0	0,01	Rechazada	5,909	1,0	0,01	Rechazada

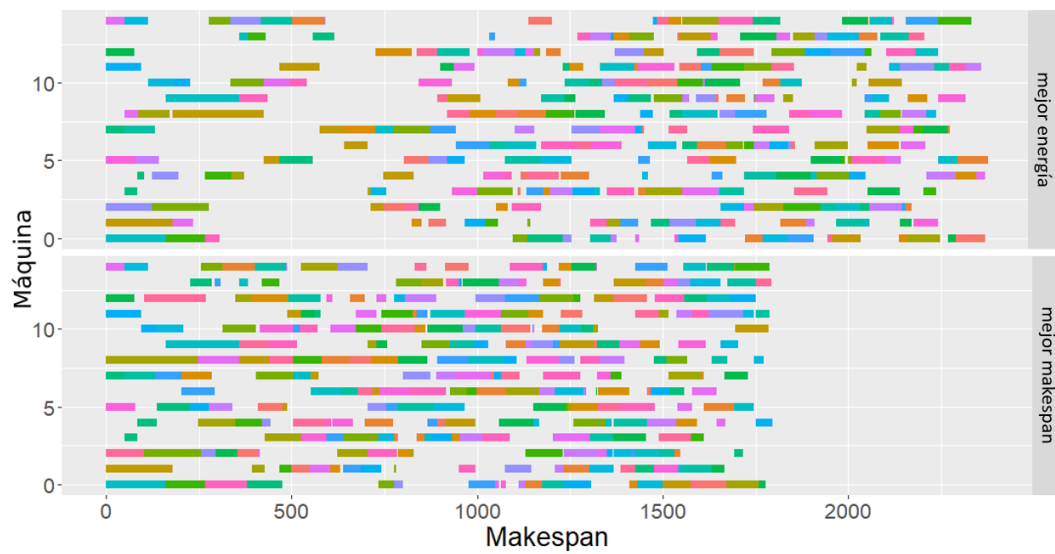


Figura 5.3: Ejemplo para las dos soluciones extremas de la instancia ta12 (mejor solución energética y mejor solución energética).

emprendido por irace se rige por el rendimiento medio calculado en estas instancias. Esta búsqueda basada en la media implica que AutoMOEA no tiene necesariamente el mejor rendimiento en estas instancias de entrenamiento pero, como ocurre con el equilibrio entre infra-ajuste y sobre ajuste en el aprendizaje automático, AutoMOEA alcanza un punto más dulce entre el rendimiento de entrenamiento y el de prueba que los optimizadores multiobjetivo clásicos. Desde un punto de vista práctico, esta observación es de la máxima relevancia, ya que sugiere que AutoMOEA podría no necesitar forzar una nueva ejecución de autoconfiguración al abordar un nuevo escenario *JSP*. Esto choca con la aplicación de cualquiera de las metaheurísticas multiobjetivo clásicas, cuya configuración de parámetros debe ajustarse para cada nuevo escenario *JSP* con el fin de mejorar la calidad de sus aproximaciones al frente de Pareto.

- **RQ3: En escenarios reales, ¿tiene sentido recurrir a herramientas de configuración algorítmica automática para mejorar el equilibrio coste-productividad de las líneas de producción?**

La respuesta a esta tercera pregunta de investigación no es binaria, ya que depende en gran medida del modelo de costes de la línea de producción estudiada. Profundizamos en esta cuestión con un ejemplo práctico: supongamos que nos enfrentamos a tres escenarios para cada instancia de *JSP*, en

función del reparto entre costes de producción fijos y variables. Los costes fijos incluyen el coste del edificio, el mantenimiento/amortización del inmovilizado, la amortización del uso de las máquinas, los costes indirectos de personal, la compra de materias primas, los costes de comercialización, etc. Estos costes son extrapolables a la producción horaria, por lo que suponen una parte fija del coste de producción por hora. Por otro lado, los costes de producción variables incluyen el coste de la energía, el personal de producción y las tarifas eléctricas. Dado que NSGA-II es el mejor algoritmo clásico de la comparativa y que autoMOEA ha demostrado superar al resto de sus homólogos en la mayoría de los casos, el ejemplo sólo considera estos algoritmos. Para cada uno de estos escenarios inspeccionaremos los programas de producción con menor consumo energético entre el conjunto global de soluciones dominadas encontradas por estos algoritmos para las diferentes instancias *JSP*. Junto con sus valores de *makespan* asociados, procederemos a analizar las implicaciones en términos de coste económico total de la producción para los tres escenarios previstos anteriormente. Para ello, los tres escenarios supondrán una parte fija del coste igual a 10, 100 y 1,000 €/hora, respectivamente. El coste fijo global C_{fijo} necesario para completar el compromiso de producción viene dado por el producto entre el tiempo de fabricación (en horas) y la cuota de coste fijo por hora asumida para cada escenario. Del mismo modo, el coste variable C_{var} asociado al compromiso de producción vendrá determinado por el coste de la energía y el turno de trabajo durante el cual se procesan los trabajos.

Intuitivamente, un programa de producción con un mayor *makespan* aumentaría los costes fijos, pero seguramente reduciría los costes variables, ya que las máquinas trabajan a menor velocidad, evitando turnos nocturnos (más caros) o evitando horas del día en las que el coste de la electricidad es elevado. Por el contrario, una menor duración de vida reduciría la parte fija del coste, pero aumentaría la parte variable, al trabajar las máquinas a mayor velocidad y concentrarse la producción en turnos de trabajo más caros, lo que provocaría un aumento global del coste de producción. Este razonamiento intuitivo, que está estrechamente vinculado a la respuesta buscada para la RQ3, se valida en la Tabla 5.8. Las columnas de estas tablas denotan las diferencias económicas entre las soluciones de energía mínima de los frentes de Pareto aproximados por NSGA-II y AutoMOEA. Para empezar, $\Delta C_{fijo} = C_{fijo}(NSGA-II) - C_{fijo}(AutoMOEA)$ representa la diferencia entre los costes fijos de producción de las soluciones encontradas por ambos algoritmos para cada instancia *JSP*, que están intrínsecamente relacionados con su *makespan* asociado: las series de producción más largas implicarán una mayor parte fija del gasto de producción. Por otro lado, $\Delta C_{var} = C_{var}(NSGA-II) - C_{var}(AutoMOEA)$ reflejan la diferencia en términos de costes de producción variables. Por último, $\Delta C_T = \Delta C_{fijo} + \Delta C_{var}$ representa la diferencia de coste total entre las programaciones de ambos algoritmos. Es importante señalar que cuando cualquiera de estos *gaps* es positivo, el programa optimizado por AutoMOEA produce un beneficio económico en comparación con el de NSGA-II. Por el contrario, valores negativos de estas diferencias revelan que el programa de NSGA-II es más conveniente económicamente.

Como puede observarse en esta tabla, la conveniencia económica de adoptar el programa de producción de mínimo consumo energético hallado por AutoMOEA depende del tipo de producto fabricado por la planta y de sus costes de producción asociados. Los plazos de fabricación más largos pueden ser perjudiciales para la viabilidad económica de la planta, ya que los costes fijos son más elevados, por lo que la parte variable de los costes de producción desempeña un papel crucial a este respecto. Esto puede observarse en el ejemplo LA10: si los costes fijos por hora son bajos, la menor parte variable del programa de energía mínima desarrollado por el NSGA-II resulta crítica para el equilibrio económico general del compromiso. Por el contrario, cuando los costes fijos aumentan, la menor duración asociada a la solución de energía mínima de AutoMOEA da lugar a un mayor excedente de costes fijos, lo que hace que esta solución sea más rentable que la de NSGA-II. Esto, junto con las restricciones no funcionales que a menudo se dan en escenarios industriales prácticos (por ejemplo, disponibilidad de personal para los turnos de noche, o restricciones normativas en términos de sostenibilidad), sugiere que no se puede dar una respuesta universal a esta RQ.

Tabla 5.8: Diferencias entre los costes de producción fijos y variables de las soluciones de energía mínima encontradas por NSGA-II y AutoMOEA para cada instancia *JSP*, suponiendo una tasa de coste fijo por hora de 10, 100 y 1.000€/hora.

Instancia	LA04	LA10	FT06	ORB01	ABZ5	SWV20	TA12	DMU11	YN03	DMU40	TA77
10 €/hora											
ΔC_{fijo}	300,00	260,00	0,00	300,00	-420,00	855,00	-210,00	1,940,00	3,500,00	1,285,00	-5,070,00
ΔC_{var}	-860,00	-1,240,00	0,00	49,50	-729,00	5,275,00	1,977,50	3,509,00	5,400,00	29,563,00	363,816,00
ΔC_T	-560,00	-980,00	0,00	349,50	-1,149,00	6,130,00	1,767,50	5,449,00	8,900,00	30,848,00	358,746,00
$i_{Mejor?}$	NSGA-II	NSGA-II	Igual	AutoMOEA	NSGA-II	AutoMOEA	AutoMOEA	AutoMOEA	AutoMOEA	AutoMOEA	AutoMOEA
100 €/hora											
ΔC_{fijo}	1,200,00	5,200,00	0,00	6,000,00	-8,400,00	17,100,00	-4,200,00	38,800,00	14,000,00	25,700,00	-101,400,00
ΔC_{var}	-860,00	-1,240,00	0,00	49,50	-729,00	5,275,00	1,977,50	3,509,00	5,400,00	29,563,00	363,816,00
ΔC_T	340,00	3,960,00	0,00	6,049,50	-9,129,00	22,375,00	-2,222,50	42,309,00	19,400,00	55,263,00	262,416,00
$i_{Mejor?}$	AutoMOEA	AutoMOEA	Igual	AutoMOEA	NSGA-II	AutoMOEA	NSGA-II	AutoMOEA	AutoMOEA	AutoMOEA	AutoMOEA
1,000 €/hora											
ΔC_{fijo}	12,000,00	52,000,00	0,00	60,000,00	-84,000,00	171,000,00	-42,000,00	388,800,00	140,000,00	257,000,00	-1,014,000,00
ΔC_{var}	-860,00	-1,240,00	0,00	49,50	-729,00	5,275,00	1,977,50	3,509,00	5,400,00	29,563,00	363,816,00
ΔC_T	11,140,00	50,760,00	0,00	60,049,50	-84,729,00	176,275,00	-40,022,50	391,509,00	145,500,00	286,563,00	-650,184,00
$i_{Mejor?}$	AutoMOEA	AutoMOEA	Igual	AutoMOEA	NSGA-II	AutoMOEA	NSGA-II	AutoMOEA	AutoMOEA	AutoMOEA	NSGA-II

5.6. Conclusiones

Se ha presentado un estudio sobre la adopción de un enfoque de diseño automático de algoritmos para resolver eficientemente una formulación *JSP* multiobjetivo que incluye consideraciones energéticas como objetivo. Nuestra propuesta se basa en la combinación de dos herramientas de software, a saber, el marco de optimización jMetal y el paquete irace para la configuración automática de algoritmos. El resultado es un optimizador multiobjetivo acuñado como AutoMOEA, que resulta de un proceso de diseño automático sobre un conjunto de entrenamiento compuesto por tres pequeñas instancias del *JSP*, así como un espacio de parámetros compuesto por 9 dimensiones de un algoritmo metaheurístico de optimización multiobjetivo.

La propuesta ha sido validada experimentalmente en una comparativa compuesta por optimizadores multiobjetivo representativos (NSGA-II, SPEA2, MOEA/D, GASWFGA, y SMS-EMOA) y 11 instancias de *JSP* con distinto número de máquinas (de 5 a 20) y trabajos (de 10 a 100). Los resultados de los experimentos en términos de los indicadores de calidad épsilon aditivo e hipervolumen normalizado han revelado que AutoMOEA supera al resto de técnicas según los dos indicadores, obteniendo los mejores resultados globales en todo el conjunto de pruebas comparativas con significación estadística en la mayoría de los casos. Las diferencias de rendimiento no son significativas en los casos de *JSP* en los que AutoMOEA no alcanza los mejores valores del indicador. Nuestra discusión sobre los resultados ha ido más allá de la comparación de rendimiento para profundizar en su relevancia en entornos industriales prácticos, donde hemos expuesto que las diferencias de rendimiento deben examinarse más a fondo en términos de las partes fijas y variables del coste incurrido por las programaciones evolucionadas.

El trabajo futuro profundizará en esta última observación final, ideando nuevas formulaciones del problema *JSP* con conciencia energética que incorporen aspectos no funcionales que puedan afectar a la calidad y viabilidad económica de las programaciones producidas.

Capítulo 6

Conclusiones, contribuciones y líneas futuras

Este capítulo expone las ideas finales de este trabajo. La sección 6.1 expone las conclusiones obtenidas a partir de los experimentos realizados en las dos aportaciones técnicas principales de la tesis. Seguidamente, la sección 6.2 describe todas las publicaciones científicas derivadas de la investigación realizada en la tesis, proporcionando detalle del impacto y contenidos de cada una de ellas. Finalmente, la sección 6.3 cierra la tesis con una breve discusión sobre direcciones y líneas de trabajo que surgen como consecuencia de esta tesis.

6.1. Conclusiones

En la sección 1.2 de la introducción de la tesis, se establecieron una serie de hipótesis a las que esta tesis ha procurado proporcionar una respuesta informada por pruebas experimentales y evidencias de aplicación en entornos industriales. Partiendo de dichas evidencias, expuestas a lo largo de los capítulos de la tesis, es el momento de repasar las hipótesis y proporcionarles dicha respuesta:

- **Hipótesis 1: Los procesos productivos cuya mejora sea abordada desde el prisma de la captura, procesamiento y análisis de datos son susceptibles de mejorar significativamente.**

Hasta hace algunos años era muy habitual en los entornos industriales – y en algunos casos, lo sigue siendo – tomar decisiones basadas en la experiencia y en el conocimiento que expertos en el proceso productivo tenían, basados tanto en las leyes y propiedades físicas que teorizan el comportamiento de los procesos productivos (conductividad térmica de una plancha de acero, por ejemplo), así como el propio conocimiento adquirido de la observación directa entre las variables de proceso y el resultado de dicho proceso. Esta toma de decisiones muchas veces no es óptima debido a dos causas principales: Por un lado, la teoría expuesta en los trabajos de investigación presenta entornos ideales que resultan ser aproximaciones del mundo real, pero con pequeñas variaciones respecto al mismo. Retomando el ejemplo de la conductividad térmica de una plancha de metal en una acería, por ejemplo, la presencia de impurezas o la diferente densidad de la plancha hacen que la conductividad no sea una constante en toda su superficie. Por otra parte, las relaciones de las variables de proceso observadas con respecto a la calidad del producto final del mismo se basan en relaciones directas, pues el ser humano es bueno determinando relaciones directas, pero si existen iteraciones entre varias variables o, lo que es lo mismo, varias variables afectando a la vez al proceso, entonces la capacidad de discernir de manera adecuada se diluye, siendo imposible determinar no

sólo qué variables están afectando, sino además cómo lo están haciendo. Por tanto, encontrar la *receta* óptima que evite generar piezas defectuosas se torna una labor titánica.

Para subsanar este tipo de problemas, existen diferentes metodologías de mejora continua que han ido apareciendo aplicadas a los procesos industriales, introducidas en el apartado 3.1. Entre ellas, *6Sigma* es la que centra de una manera más clara sus esfuerzos en la introducción de técnicas de análisis de datos aplicadas a procesos industriales. Sin embargo, esta metodología no provee al usuario de las herramientas adecuadas para hacer frente a la sensorización. Esto provoca, ante la democratización de la misma, que las plantas industriales se conviertan en generadores de grandes volúmenes de información, pero sin aportar un valor añadido que justifique su captura, estando las nuevas máquinas que se incorporan a los procesos preparadas para registrar ingentes cantidades de información.

Es por ello por lo que se hace necesario introducir una nueva metodología, como la propuesta en la sección 4.3 (*ASPPID*), que tenga en consideración este punto, es decir, el cómo y qué sensorizar de los procesos productivos, basados en demostrar mediante un análisis de datos avanzado, mediante técnicas de *machine learning*, la influencia de los parámetros en los procesos productivos. De esta manera se consigue, teniendo en cuenta el coste de sensorización y las oportunidades asociadas de generar valor, sensorizar los procesos de una manera coherente y ordenada, que garantice tener controlado en todo momento las inversiones en sensorización y, por otro lado, garantice que la información que se va a registrar sea sensible de afectar a la calidad final del proceso productivo, generando valor añadido.

Se demuestra en la sección 4.5 que, aplicando este tipo de metodologías en una planta industrial, registrando información de calidad con una frecuencia fijada, se puede mejorar el proceso industrial reduciendo el número de partes producidas con calidad NOK y proporcionando al usuario final de la planta de producción un sistema de recomendación de parámetros óptimos (locales) que garantizan la fabricación con la menor tasa de defectos, tal y como puede observarse en las Figuras 4.8 y 4.9.

Podemos, por tanto, concluir que la **Hipótesis 1 es cierta**, y que los procesos productivos cuya mejora sea abordada desde el prisma de la captura, procesado y análisis de datos son susceptibles de mejorar significativamente.

- **Hipótesis 2: El uso de técnicas de optimización multiobjetivo pueden dar lugar a mejoras en las planificaciones de producción cuando se tienen en cuenta la reducción del consumo energético asociado al proceso en cuestión.**

Tal y como se mencionó en la introducción, la planificación de la producción es un problema de ordenación de tareas, donde el número de combinaciones es del orden $(n!)^m$, siendo n el número de trabajos y m el número de máquinas. Si a este problema, ya de por sí complejo, le añadimos restricciones (e.g., disponibilidad de máquina o disponibilidad de operarios cualificados), y además fijamos más de un objetivo (minimizar el consumo energético y el *makespan*), el descubrir soluciones óptimas resulta una tarea imposible de alcanzar sin ayuda del uso de algoritmos de optimización. Para reflejar el alcance de la complejidad del problema, sirva de ejemplo la Figura 5.3, en donde pueden verse dos configuraciones diferentes para el mismo problema, basadas en la mejor configuración de la energía y del *makespan*.

La validez de esta segunda hipótesis se ha explorado en el capítulo 5, que aborda la resolución de una colección de problemas de planificación multiobjetivo con dos objetivos contrapuestos, la reducción del *makespan* y la reducción de los costes (principalmente energéticos) mediante el uso de algoritmos de optimización multiobjetivo. Para ello, el capítulo considera el uso de instancias sintéticas de acceso público, debido a que el número de ordenes de fabricación de una empresa es uno de los mayores secretos industriales. Dichas instancias han sido enriquecidas con información relativa a consumos energéticos. Haciendo uso de algoritmos de optimización multiobjetivo ha sido posible encontrar soluciones para dichos objetivos contrapuestos, tal y como puede verse en la Figura 5.2 y en la Tabla 5.8.

Por tanto podemos concluir que la **Hipótesis 2 es cierta**, y que utilizar algoritmos de optimización multiobjetivo ayuda a encontrar soluciones a problemas de planificación donde la reducción de la energía consumida por el proceso de producción es uno de sus objetivos.

- **[Hipótesis 3] La inteligencia artificial supone una herramienta disruptiva, capaz de aportar valor añadido en la generación de conocimiento y toma de decisiones dentro de las organizaciones industriales.**

La inteligencia artificial se considera una tecnología disruptiva porque es capaz de cambiar significativamente la forma en que se realizan las tareas y se toman decisiones en una amplia variedad de campos, e incluso, conseguir automatizar procesos que antes no era posible. La industria no es ajena a ello, y existen múltiples casos de uso donde la inteligencia artificial ya está implementada e incluso con un alto grado de madurez, como la visión artificial para la inspección de piezas.

Para validar esta hipótesis se han desarrollado los capítulos 4 y 5, en los que se demuestra como la inteligencia artificial consigue mejorar campos dentro de la industria. Por un lado, en las secciones introductorias de ambos capítulos (4.1 y 5.1) se citan referencias bibliográficas de casos de uso en la industria respecto a la implementación de esta tecnología. Pero además, en dichos capítulos, en la fase de experimentación (secciones 4.4 y 5.4) se demuestra, mediante la aplicación en casos de uso, el uso de técnicas de aprendizaje automático (*machine learning*) para la mejora de los procesos productivos y la optimización de la planificación de la producción, con sus respectivas conclusiones en las secciones 4.5 y 5.5, donde quedan validadas.

Por tanto, concluimos que la **Hipótesis 3 es cierta**, y avalada por los resultados obtenidos en este trabajo de investigación, podemos afirmar que la inteligencia artificial supone una herramienta disruptiva, capaz de aportar valor añadido en la generación de conocimiento y toma de decisiones dentro de las organizaciones industriales.

6.2. Contribuciones

Los hallazgos de investigación logrados a lo largo de la tesis han sido publicado en varias publicaciones científicas. En concreto, se han publicado tres artículos, dos de ellos en revistas indexadas en el *Journal Citation Reports* (JCR) del *Web of Science*, así como una contribución a un congreso internacional y otro artículo de congreso en preparación. Se ofrece a continuación un listado exhaustivo de los detalles bibliográficos de dichas publicaciones, así como un resumen de sus contenidos:

Artículos publicados en revistas:

- **J. Para, J. Del Ser, A. J. Nebro, U. Zurutuza y F. Herrera. «Analyze, sense, preprocess, predict, implement, and deploy (ASPPID): An incremental methodology based on data analytics for cost-efficiently monitoring the industry 4.0». *Engineering Applications of Artificial Intelligence* 82 (2019), págs. 30-43**
- *Indicios de calidad*: Factor de impacto (2019): 4.021, Q1 en la categoría COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE (34/137).
- *Resumen*: Presenta la metodología Analizar, Sensorizar, Preprocesar, Predecir, Implementar y Desplegar (*ASPPID*), un flujo de trabajo iterativo que abarca desde la adquisición de equipos de detección hasta la evaluación cuantitativa de su contribución a la mejora de la fase de producción en cuestión. El objetivo de esta metodología es ayudar a los equipos de mejora a tomar decisiones con conocimiento de causa sobre qué partes del proceso deben ser detectadas y cómo explotar esta información para lograr una mejora verificable del ciclo de producción. La aplicación de esta metodología se ejemplifica en un caso de uso real centrado en la industria del automóvil, en el que la detección de defectos en un proceso de

recocido puede modelarse como un problema de clasificación con un conjunto de datos muy desequilibrado. Los resultados obtenidos tras varias iteraciones de la metodología ASPPID propuesta muestran que el ratio de rechazo se reduce al detectar la parte correcta del proceso con costes de inversión reducidos, lo que pone de manifiesto el papel crucial de la ciencia de datos en la cadena de negocio de las plantas de fabricación.

- **J. Para, J. Del Ser y A. J. Nebro.** «Energy-Aware Multi-Objective Job Shop Scheduling Optimization with Metaheuristics in Manufacturing Industries: A Critical Survey, Results, and Perspectives». *Applied Sciences* 12.3 (2022), pág. 1491
- *Indicios de calidad:* Factor de impacto (2021): 2.838, Q2 en la categoría ENGINEERING, MULTIDISCIPLINARY (39/92).
- *Resumen:* Proporciona una revisión en profundidad de la literatura existente sobre optimización multiobjetivo de la programación *JSP* con metaheurísticas, en la que uno de los objetivos es la minimización del consumo energético. Revisa sistemáticamente y analiza críticamente las características más relevantes tanto de las formulaciones de los problemas como de los algoritmos para resolverlos eficazmente. El artículo también informa con resultados empíricos de las principales conclusiones de la nuestra crítica bibliográfica con una comparación de rendimiento entre algoritmos evolutivos multiobjetivo representativos aplicados a una diversidad de instancias de prueba sintéticas. El objetivo último de este artículo es llevar a cabo un análisis crítico, detectando las buenas prácticas y las oportunidades de mejora que se derivan de los conocimientos actuales en esta área de investigación.

Contribuciones a congresos internacionales:

- **J. Para, J. Del Ser, A. Aguirre, A.J. Nebro.** «Decision Making in Industry 4.0 Scenarios Supported by Imbalanced Data Classification». In: *Del Ser, J., Osaba, E., Bilbao, M., Sanchez-Medina, J., Vecchio, M., Yang, XS. (eds) Intelligent Distributed Computing XII. IDC 2018. Studies in Computational Intelligence*, vol 798. Springer, Cham, 2018.
- *Resumen:* Muestra la forma de llevar a cabo un proceso de análisis de datos en un entorno industrial. La aportación más importante de este trabajo es centrarse en la importancia de realizar dinámicas de generación de hipótesis con los expertos en el proceso, previas a la captura de datos. Para explicarlo, se ha realizado un caso de estudio real, comenzando con la dinámica de generación de hipótesis, continúa con el preprocesado de datos desequilibrados y la generación de modelos matemáticos con varios algoritmos de clasificación, obteniendo como resultado un parámetro de recomendación que apoya la toma de decisiones, con el objetivo de conseguir una mayor calidad de fabricación.
- **J. Para, J. Del Ser, A. J. Nebro.** Solving a Multi-Objective Job Shop Scheduling Problem With an Automatically Configured Evolutionary Algorithm. *Accepted for publication in the International Conference in Optimization and Learning (OLA2023). Málaga (Spain), May 2023*
- *Resumen:* Nos centramos en resolver una formulación multiobjetivo del problema *JSP* caracterizada por considerar la minimización del consumo de energía. Después de realizar un estudio experimental comparando varias metaheurísticas representativas (NSGA-II, SPEA2, SMS-EMOA, MOEA/D, y GWASFGA), utilizamos la herramienta *irace* para encontrar una combinación de componentes y parámetros que den lugar a un algoritmo específico para resolver las instancias *JSP* consideradas. El enfoque adoptado da como resultado un algoritmo evolutivo capaz de producir soluciones más precisas que las técnicas utilizadas en el estudio comparativo.

Otras contribuciones:

- Módulo de jMetal para la aplicación de algoritmos de optimización metaheurística a problemas JSP multiobjetivo: <https://github.com/jMetal/JSP>

6.3. Líneas futuras de investigación

Las líneas de estudio abordadas durante esta tesis doctoral invitan a plantear varios trabajos de investigación a los que dedicarles esfuerzos en el futuro. Algunos de ellos surgen de la idea de continuar con los problemas abordados, centrándose en intentar mejorar la calidad de los resultados obtenidos. Por otro lado, es posible abrir nuevas líneas de investigación a modo de “ramas” derivadas del trabajo realizado. Debatámoslas a continuación, como prospectiva y cierre de la tesis:

- Desde el punto de vista de la mejora de la producción, una línea de investigación muy interesante, a la vez que útil y práctica, se enfocaría hacia la hibridación de la metodología ASPPID con metodologías existentes de producción para minería de datos (e.g. CRISP-DM) y desarrollo ágil de software (corr. SCRUM o Lean Software, entre otros). En particular, una de las cuestiones abiertas más relevantes desde el punto de vista de producción es la incorporación de múltiples criterios de decisión conflictivos al proceso de toma de decisiones.
- A su vez, es posible vislumbrar nuevas aplicaciones de ASPPID a otros escenarios industriales, como el mantenimiento predictivo de maquinaria remota o la detección de pérdidas no técnicas en Smart Grids, entre otros. En virtud de su generalidad y flexibilidad, ASPPID puede conseguir, además, una mejora de los modelos matemáticos mediante el aporte de otras fuentes de datos, como procesos productivos similares en diferentes plantas productivas, con el fin de obtener modelos globales y establecer herramientas que permitan productivizar los modelos que mejores prestaciones consigan, sean globales o locales.
- En relación con la planificación de la producción, una posible vía estimulada por esta tesis apunta a la evaluación de un mayor número y diversidad de instancias *JSP* sensibles al consumo energético, incluyendo un mayor número de algoritmos y buscando sus valores óptimos de hiperparámetros.
- Además, pretendemos desarrollar una metodología para traducir las diferencias de rendimiento observadas entre metaheurísticas multiobjetivo a indicadores del mundo real. En muchos casos de uso práctico que requieren resolver un problema *JSP*, no hay garantía de que el rendimiento superior observado de un algoritmo dado en términos de indicadores de calidad multiobjetivo se traduzca directamente en ganancias operativas reales de impacto en producción. Profundizar en este aspecto crucial de la aplicación en el mundo real de los algoritmos metaheurísticos [201] puede ser una línea de investigación aplicada de sumo interés para la aplicabilidad de esta familia de algoritmos a casos de uso prácticos.
- Por último, como idea más general, se puede mejorar la herramienta dispuesta en *github*, pudiendo permitir incorporar más restricciones a la generación de soluciones para el problema de la planificación de la producción, como puede ser la disponibilidad de materia prima y previsión de la misma, disponibilidad de operarios basados en una matriz de conocimiento, donde cada elemento de la matriz establece la relación entre capacidades del operario y necesidades de formación del proceso, restricciones de calendario, e incorporando otros objetivos económicos.

Bibliografía

- [1] J. McCarthy. «Artificial intelligence, logic and formalizing common sense». *Philosophical logic and artificial intelligence*. Springer, 1989, págs. 161-190.
- [2] J. Moor. «The Dartmouth College artificial intelligence conference: The next fifty years». *Ai Magazine* 27.4 (2006), págs. 87-87.
- [3] M. Haenlein y A. Kaplan. «A brief history of artificial intelligence: On the past, present, and future of artificial intelligence». *California management review* 61.4 (2019), págs. 5-14.
- [4] S. Grigorescu, B. Trasnea, T. Cocias y G. Macesanu. «A survey of deep learning techniques for autonomous driving». *Journal of Field Robotics* 37.3 (2020), págs. 362-386.
- [5] S. P. Singh, A. Kumar, H. Darbari, L. Singh, A. Rastogi y S. Jain. «Machine translation using deep learning: An overview». *2017 international conference on computer, communications and electronics (comptelix)*. IEEE. 2017, págs. 162-167.
- [6] Y. Han, Z. Han, J. Wu, Y. Yu, S. Gao, D. Hua y A. Yang. «Artificial intelligence recommendation system of cancer rehabilitation scheme based on IoT technology». *IEEE Access* 8 (2020), págs. 44924-44935.
- [7] S. Alian, J. Li y V. Pandey. «A personalized recommendation system to support diabetes self-management for American Indians». *IEEE Access* 6 (2018), págs. 73041-73051.
- [8] P. Rajpurkar, E. Chen, O. Banerjee y E. J. Topol. «AI in health and medicine». *Nature Medicine* 28.1 (2022), págs. 31-38.
- [9] H. Lasi, P. Fettke, H.-G. Kemper, T. Feld y M. Hoffmann. «Industry 4.0». *Business & information systems engineering* 6.4 (2014), págs. 239-242.
- [10] S. F. Latham y M. R. Braun. «The performance implications of financial slack during economic recession and recovery: observations from the software industry (2001-2003)». *Journal of Managerial Issues* (2008), págs. 30-50.
- [11] W. Browne, L. Yao, I. Postlethwaite, S. Lowes y M. Mar. «Knowledge-elicitation and data-mining: Fusing human and industrial plant information». *Engineering Applications of Artificial Intelligence* 19.3 (2006), págs. 345-359.
- [12] E. Fernandez-Camacho y C. Bordons-Alba. *Model predictive control in the process industry*. Springer, 1995.
- [13] Z. Zhang, X. He y A. Kusiak. «Data-driven minimization of pump operating and maintenance cost». *Engineering Applications of Artificial Intelligence* 40 (2015), págs. 37-46.
- [14] A. Diez-Olivan, J. Del Ser, D. Galar y B. Sierra. «Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0». *Information Fusion* 50 (2019), págs. 92-111.
- [15] R. S. Peres, J. Barata, P. Leitao y G. Garcia. «Multistage quality control using machine learning in the automotive industry». *IEEE Access* 7 (2019), págs. 79908-79916.



- [16] S. Cheriyan, S. Ibrahim, S. Mohanan y S. Treesa. «Intelligent Sales Prediction Using Machine Learning Techniques». *2018 International Conference on Computing, Electronics & Communications Engineering (iCCECE)*. IEEE. 2018, págs. 53-58.
- [17] J. Villalba-Diez, D. Schmidt, R. Gevers, J. Ordieres-Meré, M. Buchwitz y W. Wellbrock. «Deep learning for industrial computer vision quality control in the printing industry 4.0». *Sensors* 19.18 (2019), pág. 3987.
- [18] R. D. MacRosty y C. L. Swartz. «Dynamic optimization of electric arc furnace operation». *AIChE journal* 53.3 (2007), págs. 640-653.
- [19] F. Muyl, L. Dumas y V. Herbert. «Hybrid method for aerodynamic shape optimization in automotive industry». *Computers & Fluids* 33.5-6 (2004), págs. 849-858.
- [20] B. De Muer, C. De Ranter, J. Crols y M. Steyaert. «A simulator-optimizer for the design of very low phase noise cmos lc-oscillators». *ICECS'99. Proceedings of ICECS'99. 6th IEEE International Conference on Electronics, Circuits and Systems (Cat. No. 99EX357)*. Vol. 3. IEEE. 1999, págs. 1557-1560.
- [21] H.-C. Pfohl, B. Yahsi y T. Kurnaz. «Concept and diffusion-factors of industry 4.0 in the supply chain». *Dynamics in logistics*. Springer, 2017, págs. 381-390.
- [22] A. Gunasekaran, T. Papadopoulos, R. Dubey, S. F. Wamba, S. J. Childe, B. Hazen y S. Akter. «Big data and predictive analytics for supply chain and organizational performance». *Journal of Business Research* 70 (2017), págs. 308-317.
- [23] S. Chehbi-Gamoura y R. Derrouiche. «Big valuable data in supply chain: Deep analysis of current trends and coming potential». *Working Conference on Virtual Enterprises*. Springer. 2017, págs. 230-241.
- [24] D. J. Hoiomt, P. B. Luh y K. R. Pattipati. «A practical approach to job-shop scheduling problems». *IEEE transactions on Robotics and Automation* 9.1 (1993), págs. 1-13.
- [25] A. S. Manne. «On the job-shop scheduling problem». *Operations research* 8.2 (1960), págs. 219-223.
- [26] T. Weise. *An Introduction to Optimization Algorithms*. github, 2020.
- [27] M. J. Blesa, C. Blum, P. Festa, A. Roli y M. Sampels. *Hybrid Metaheuristics: 8th International Workshop, HM 2013, Ischia, Italy, May 23-25, 2013. Proceedings*. Vol. 7919. Springer, 2013.
- [28] C. Blum y A. Roli. «Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison». *ACM Computing Surveys* 35.3 (2003), págs. 268-308.
- [29] R. Cheng, M. Gen e Y. Tsujimura. «A tutorial survey of job-shop scheduling problems using genetic algorithms—I. Representation». *Computers & industrial engineering* 30.4 (1996), págs. 983-997.
- [30] J. T. Houghton, G. J. Jenkins y J. J. Ephraums. «Climate change» (1990).
- [31] R. Cavicchioli, W. J. Ripple, K. N. Timmis, F. Azam, L. R. Bakken, M. Baylis, M. J. Behrenfeld, A. Boetius, P. W. Boyd, A. T. Classen et al. «Scientists' warning to humanity: microorganisms and climate change». *Nature Reviews Microbiology* 17.9 (2019), págs. 569-586.
- [32] J. Błażewicz, W. Domschke y E. Pesch. «The job shop scheduling problem: Conventional and new solution techniques». *European journal of operational research* 93.1 (1996), págs. 1-33.
- [33] P. Chretienne, E. G. Coffman Jr, J. K. Lenstra y Z. Liu. «Scheduling theory and its applications». *Journal of the Operational Research Society* 48.7 (1997), págs. 764-765.

- [34] L. Davis et al. «Job shop scheduling with genetic algorithms». *Proceedings of an international conference on genetic algorithms and their applications*. Vol. 140. 1985.
- [35] C. Bierwirth. «A generalized permutation approach to job shop scheduling with genetic algorithms». *Operations-Research-Spektrum* 17.2 (1995), págs. 87-92.
- [36] T. Yamada y R. Nakano. «Genetic algorithms for job-shop scheduling problems». *Proceedings of modern heuristic for decision support* (1997), págs. 67-81.
- [37] N. Shahsavari-Pour y B. Ghasemishabankareh. «A novel hybrid meta-heuristic algorithm for solving multi objective flexible job shop scheduling». *Journal of Manufacturing Systems* 32.4 (2013), págs. 771-780.
- [38] Y. R. Kalshetty, A. C. Adamuthe y S. P. Kumar. «Genetic algorithms with feasible operators for solving job shop scheduling problem». *Journal of Scientific Research* 64.1 (2020).
- [39] J. Para, J. Del Ser y A. J. Nebro. «Energy-Aware Multi-Objective Job Shop Scheduling Optimization with Metaheuristics in Manufacturing Industries: A Critical Survey, Results, and Perspectives». *Applied Sciences* 12.3 (2022).
- [40] J. Ni, Y. Chen, Y. Chen, J. Zhu, D. Ali y W. Cao. «A survey on theories and applications for self-driving cars based on deep learning methods». *Applied Sciences* 10.8 (2020), págs. 2749.
- [41] D. Sobania, M. Briesch y F. Rothlauf. «Choose your programming copilot: a comparison of the program synthesis performance of github copilot and genetic programming». *Proceedings of the Genetic and Evolutionary Computation Conference*. 2022, págs. 1019-1027.
- [42] A. A. Rescigno, E. Vanmassenhove, J. Monti y A. Way. «A Case Study of Natural Gender Phenomena in Translation. A Comparison of Google Translate, Bing Microsoft Translator and DeepL for English to Italian, French and Spanish.» *CLiC-it*. 2020.
- [43] Z.-H. Zhou. *Machine learning*. Springer Nature, 2021.
- [44] I. Muhammad y Z. Yan. «SUPERVISED MACHINE LEARNING APPROACHES: A SURVEY.» *ICTACT Journal on Soft Computing* 5.3 (2015).
- [45] F. Osisanwo, J. Akinsola, O Awodele, J. Hinmikaiye, O Olakanmi y J Akinjobi. «Supervised machine learning algorithms: classification and comparison». *International Journal of Computer Trends and Technology (IJCTT)* 48.3 (2017), págs. 128-138.
- [46] M. Crawford, T. M. Khoshgoftaar, J. D. Prusa, A. N. Richter y H. Al Najada. «Survey of review spam detection using machine learning techniques». *Journal of Big Data* 2.1 (2015), págs. 1-24.
- [47] K. Sharma, A. Kaur y S. Gujral. «Brain tumor detection based on machine learning algorithms». *International Journal of Computer Applications* 103.1 (2014).
- [48] M. Jagielski, A. Oprea, B. Biggio, C. Liu, C. Nita-Rotaru y B. Li. «Manipulating machine learning: Poisoning attacks and countermeasures for regression learning». *2018 IEEE Symposium on Security and Privacy (SP)*. IEEE. 2018, págs. 19-35.
- [49] C. Fan, Z. Cui y X. Zhong. «House prices prediction with machine learning algorithms». *Proceedings of the 2018 10th International Conference on Machine Learning and Computing*. 2018, págs. 6-10.
- [50] C.-Y. Lee, B.-J. Chou y C.-F. Huang. «Data science and reinforcement learning for price forecasting and raw material procurement in petrochemical industry». *Advanced Engineering Informatics* 51 (2022), págs. 101443.
- [51] I. Lana, J. Del Ser, M. Velez y E. I. Vlahogianni. «Road traffic forecasting: Recent advances and new challenges». *IEEE Intelligent Transportation Systems Magazine* 10.2 (2018), págs. 93-109.

- [52] S. Kotsiantis, D. Kanellopoulos, P. Pintelas et al. «Handling imbalanced datasets: A review». *GESTS international transactions on computer science and engineering* 30.1 (2006), págs. 25-36.
- [53] H. B. Barlow. «Unsupervised learning». *Neural computation* 1.3 (1989), págs. 295-311.
- [54] T. S. Madhulatha. «An overview on clustering methods». *arXiv preprint arXiv:1205.1117* (2012).
- [55] P. W. Murray, B. Agard y M. A. Barajas. «Forecasting supply chain demand by clustering customers». *IFAC-PapersOnLine* 48.3 (2015), págs. 1834-1839.
- [56] L. Van Der Maaten, E. Postma, J. Van den Herik et al. «Dimensionality reduction: a comparative». *J Mach Learn Res* 10.66-71 (2009), pág. 13.
- [57] S. Kotsiantis y D. Kanellopoulos. «Association rules mining: A recent overview». *GESTS International Transactions on Computer Science and Engineering* 32.1 (2006), págs. 71-82.
- [58] X. J. Zhu. «Semi-supervised learning literature survey» (2005).
- [59] K. Miettinen. *Nonlinear Multiobjective Optimization*. Boston: Kluwer Academic Publishers, 1999.
- [60] T. Weise, M. Zapf, R. Chiong y A. J. Nebro. «Why Is Optimization Difficult?» *Nature-Inspired Algorithms for Optimisation*. Ed. por R. Chiong. Vol. 193/2009. Studies in Computational Intelligence. Springer, 2009, págs. 1-50.
- [61] D. Molina, J. Poyatos, J. Del Ser, S. García, A. Hussain y F. Herrera. «Comprehensive taxonomies of nature-and bio-inspired optimization: Inspiration versus algorithmic behavior, critical analysis recommendations». *Cognitive Computation* 12.5 (2020), págs. 897-939.
- [62] K. Deb. *Multi-Objective Optimization Using Evolutionary Algorithms*. New York, NY, USA: John Wiley & Sons, Inc., 2001.
- [63] C. Coello Coello, G. Lamont y D. van Veldhuizen. *Multi-Objective Optimization Using Evolutionary Algorithms*. NY, USA: John Wiley & Sons, Inc. 2nd Ed., 2007.
- [64] K. Deb, A. Pratap, S. Agarwal y T. Meyarivan. «A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II». *IEEE Transactions on Evolutionary Computation* 6.2 (2002), págs. 182-197.
- [65] Q. Zhang y H. Li. «MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition». *IEEE T. Evolut. Comput.* 11.6 (2007), págs. 712-731. ISSN: 1089-778X.
- [66] N. Beume, B. Naujoks y M. Emmerich. «SMS-EMOA: Multiobjective selection based on dominated hypervolume». *European Journal of Operational Research* 181.3 (2007), págs. 1653-1669.
- [67] E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca y V. G. Da Fonseca. «Performance assessment of multiobjective optimizers: An analysis and review». *IEEE Transactions on evolutionary computation* 7.2 (2003), págs. 117-132.
- [68] H. Ishibuchi, H. Masuda e Y. Nojima. «A study on performance evaluation ability of a modified inverted generational distance indicator». *Proceedings of the 2015 annual conference on genetic and evolutionary computation*. 2015, págs. 695-702.
- [69] K. Deb. «Multi-objective optimisation using evolutionary algorithms: an introduction». *Multi-objective evolutionary optimisation for product design and manufacturing*. Springer, 2011, págs. 3-34.
- [70] M. Best y D. Neuhauser. «Walter A Shewhart, 1924, and the Hawthorne factory». *BMJ quality & safety* 15.2 (2006), págs. 142-143.

- [71] S. A. Halim Lim, J. Antony, N. Arshed y S. Albliwi. «A systematic review of statistical process control implementation in the food manufacturing industry». *Total Quality Management & Business Excellence* 28.1-2 (2017), págs. 176-189.
- [72] I. Madanhire y C. Mbohwa. «Application of statistical process control (SPC) in manufacturing industry in a developing country». *Procedia Cirp* 40 (2016), págs. 580-583.
- [73] W. E. Deming. «Improvement of quality and productivity through action by management». *National productivity review* 1.1 (1981), págs. 12-22.
- [74] N. Bouranta, E. L. Psomas y A. Pantouvakis. «Identifying the critical determinants of TQM and their impact on company performance: Evidence from the hotel industry of Greece». *The TQM Journal* (2017).
- [75] N. Sinha, A. K. Garg, S. Dhingra y N. Dhall. «Mapping the linkage between organizational culture and TQM: the case of Indian auto component industry». *Benchmarking: An International Journal* (2016).
- [76] R. M. Becker. «Lean manufacturing and the Toyota production system». *Encyclopedia of world biography* (1998).
- [77] M. J. Harry. «Six Sigma: a breakthrough strategy for profitability». *Quality progress* 31.5 (1998), pág. 60.
- [78] A. Shokri, G. Bradley y F. Nabhani. «Reducing the scrap rate in an electronic manufacturing SME through Lean Six Sigma methodology» (2016).
- [79] E. Delgado López. «Propuesta de un plan para la reducción de la merma utilizando la metodología six sigma en una planta de productos plásticos» (2015).
- [80] D Winter, D Crowley, C Ward, S Williams, C McMahon y K Potter. «Using real-time data for increasing the efficiency of the automated fibre placement process». *International Journal of Vehicle Structures & Systems* 9.1 (2017), pág. 11.
- [81] D. Braha. *Data mining for design and manufacturing: methods and applications*. Vol. 3. Springer Science & Business Media, 2013.
- [82] M. S. Rahim, M. Rahman y A. E. Chowdhury. «Mining industrial engineered data of apparel industry: a proposed methodology». *International Journal of Computer Applications* 161.7 (2017), págs. 1-7.
- [83] J. F. Burnham. «Scopus database: a review». *Biomedical digital libraries* 3.1 (2006), págs. 1-8.
- [84] B. Zhang, Q.-k. Pan, L. Gao, X.-y. Li, L.-l. Meng y K.-k. Peng. «A multiobjective evolutionary algorithm based on decomposition for hybrid flowshop green scheduling problem». *Computers & Industrial Engineering* 136 (2019), págs. 325-344.
- [85] Y. Fu, G. Tian, A. M. Fathollahi-Fard, A. Ahmadi y C. Zhang. «Stochastic multi-objective modelling and optimization of an energy-conscious distributed permutation flow shop scheduling problem with the total tardiness constraint». *Journal of cleaner production* 226 (2019), págs. 515-525.
- [86] H. Öztóp, M. F. Tasgetiren, D. T. Eliyi y Q.-K. Pan. «Green permutation flowshop scheduling: a trade-off-between energy consumption and total flow time». *International Conference on Intelligent Computing*. Springer. 2018, págs. 753-759.
- [87] C. Lu, L. Gao, Q. Pan, X. Li y J. Zheng. «A multi-objective cellular grey wolf optimizer for hybrid flowshop scheduling problem considering noise pollution». *Applied Soft Computing* 75 (feb. de 2019), págs. 728-749.

- [88] D. Yang, X. Zhou, Z. Yang, Q. Jiang y W. Feng. «Multi-objective optimization Model for Flexible Job Shop Scheduling Problem Considering Transportation Constraints: A Comparative Study». *2020 IEEE Congress on Evolutionary Computation (CEC)*. IEEE, jul. de 2020.
- [89] H. Wang, B. Sheng, Q. Lu, X. Yin, F. Zhao, X. Lu, R. Luo y G. Fu. «A novel multi-objective optimization algorithm for the integrated scheduling of flexible job shops considering preventive maintenance activities and transportation processes». *Soft Computing* 25.4 (oct. de 2020), págs. 2863-2889.
- [90] M. Tasgetiren, H. Öztop, L. Gao, Q.-K. Pan y X. Li. «A Variable Iterated Local Search Algorithm for Energy-Efficient No-idle Flowshop Scheduling Problem». *Procedia Manufacturing* 39 (2019), págs. 1185-1193.
- [91] X. Zheng, S. Zhou, R. Xu y H. Chen. «Energy-efficient scheduling for multi-objective two-stage flow shop using a hybrid ant colony optimisation algorithm». *International Journal of Production Research* 58.13 (2020), págs. 4103-4120.
- [92] Z. Liu, J. Yan, Q. Cheng, C. Yang, S. Sun y D. Xue. «The mixed production mode considering continuous and intermittent processing for an energy-efficient hybrid flow shop scheduling». *Journal of Cleaner Production* 246 (feb. de 2020), pág. 119071.
- [93] J. fang Chen, L. Wang y Z. ping Peng. «A collaborative optimization algorithm for energy-efficient multi-objective distributed no-idle flow-shop scheduling». *Swarm and Evolutionary Computation* 50 (nov. de 2019), pág. 100557.
- [94] X. Wu, X. Shen y C. Li. «The flexible job-shop scheduling problem considering deterioration effect and energy consumption simultaneously». *Computers & Industrial Engineering* 135 (2019), págs. 1004-1024.
- [95] W. J. Song, C. Y. Zhang, W. W. Lin y X. Y. Shao. «Flexible Job-Shop Scheduling Problem with Maintenance Activities Considering Energy Consumption». *Applied Mechanics and Materials* 521 (feb. de 2014), págs. 707-713.
- [96] Y. Kou, C. Li, L. Li, Y. Tang y X. Li. «Energy-efficient rescheduling for the flexible machining systems with random machine breakdown and urgent job arrival». *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*. IEEE, oct. de 2019.
- [97] S.-L. Jiang y L. Zhang. «Energy-oriented scheduling for hybrid flow shop with limited buffers through efficient multi-objective optimization». *IEEE Access* 7 (2019), págs. 34477-34487.
- [98] H. Mokhtari y A. Hasani. «An energy-efficient multi-objective optimization for flexible job-shop scheduling problem». *Computers & Chemical Engineering* 104 (sep. de 2017), págs. 339-352.
- [99] G. Wang, X. Li, L. Gao y P. Li. «A Multi-Objective Whale Swarm Algorithm for Energy-Efficient Distributed Permutation Flow shop Scheduling Problem with Sequence Dependent Setup Times». *IFAC-PapersOnLine* 52.13 (2019), págs. 235-240.
- [100] G. Gong, R. Chiong, Q. Deng, W. Han, L. Zhang, W. Lin y K. Li. «Energy-efficient flexible flow shop scheduling with worker flexibility». *Expert Systems with Applications* 141 (mar. de 2020), pág. 112902.
- [101] Q. Cheng, C. Liu, H. Chu, Z. Liu, W. Zhang y J. Pan. «A New Multi-Objective Hybrid Flow Shop Scheduling Method to Fully Utilize the Residual Forging Heat». *IEEE Access* 8 (2020), págs. 151180-151194.

- [102] S. Schulz, B. Udo y S. Liji. «Multi-objective hybrid flow shop scheduling with variable discrete production speed levels and time-of-use energy prices». *Zeitschrift für Betriebswirtschaft* 90.9 (2020), págs. 1315-1343.
- [103] K. Geng, C. Ye, Z. hua Dai y L. Liu. «Bi-Objective Re-Entrant Hybrid Flow Shop Scheduling considering Energy Consumption Cost under Time-of-Use Electricity Tariffs». *Complexity* 2020 (feb. de 2020), págs. 1-17.
- [104] H. Li, J. Duan y Q. Zhang. «Multi-objective integrated scheduling optimization of semi-combined marine crankshaft structure production workshop for green manufacturing». *Transactions of the Institute of Measurement and Control* 43.3 (ago. de 2020), págs. 579-596.
- [105] S. Zhou, M. Jin y N. Du. «Energy-efficient scheduling of a single batch processing machine with dynamic job arrival times». *Energy* 209 (oct. de 2020), pág. 118420.
- [106] H. Luo, B. Du, G. Q. Huang, H. Chen y X. Li. «Hybrid flow shop scheduling considering machine electricity consumption cost». *International journal of production economics* 146.2 (2013), págs. 423-439.
- [107] K. Li, X. Zhang, J. Y.-T. Leung y S.-L. Yang. «Parallel machine scheduling problems in green manufacturing industry». *Journal of Manufacturing Systems* 38 (2016), págs. 98-106.
- [108] J.-q. Li, H.-y. Sang, Y.-y. Han, C.-g. Wang y K.-z. Gao. «Efficient multi-objective optimization algorithm for hybrid flow shop scheduling problems with setup energy consumptions». *Journal of Cleaner Production* 181 (2018), págs. 584-598.
- [109] Y. Liu, H. Dong, N. Lohse y S. Petrovic. «A multi-objective genetic algorithm for optimisation of energy consumption and shop floor production performance». *International Journal of Production Economics* 179 (2016), págs. 259-272.
- [110] K Mayandi y P Jeyaraj. «Bending, buckling and free vibration characteristics of FG-CNT-reinforced polymer composite beam under non-uniform thermal load». *Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications* 229.1 (2015), págs. 13-28.
- [111] Z. Jiang, Z. Le et al. «Study on multi-objective flexible job-shop scheduling problem considering energy consumption». *Journal of Industrial Engineering and Management (JIEM)* 7.3 (2014), págs. 589-604.
- [112] J.-q. Li, X.-r. Tao, B.-x. Jia, Y.-y. Han, C. Liu, P. Duan, Z.-x. Zheng y H.-y. Sang. «Efficient multi-objective algorithm for the lot-streaming hybrid flowshop with variable sub-lots». *Swarm and Evolutionary Computation* 52 (2020), pág. 100600.
- [113] L. Yin, X. Li, L. Gao, C. Lu y Z. Zhang. «Energy-efficient job shop scheduling problem with variable spindle speed using a novel multi-objective algorithm». *Advances in Mechanical Engineering* 9.4 (2017), pág. 1687814017695959.
- [114] M. Mazare, M. Taghizadeh y M Rasool Najafi. «Kinematic analysis and design of a 3-DOF translational parallel robot». *International journal of Automation and Computing* 14.4 (2017), págs. 432-441.
- [115] Y. Han, J. Li, H. Sang, Y. Liu, K. Gao y Q. Pan. «Discrete evolutionary multi-objective optimization for energy-efficient blocking flow shop scheduling with setup time». *Applied Soft Computing* 93 (2020), pág. 106343.
- [116] K. Geng, C. Ye, L. Cao y L. Liu. «Multi-objective reentrant hybrid flowshop scheduling with machines turning on and off control strategy using improved multi-verse optimizer algorithm». *Mathematical Problems in Engineering* 2019 (2019).

- [117] Q. Luo, Q. Deng, G. Gong, L. Zhang, W. Han y K. Li. «An efficient memetic algorithm for distributed flexible job shop scheduling problem with transfers». *Expert Systems with Applications* 160 (dic. de 2020), pág. 113721.
- [118] C. Peng, T. Peng, Y. Zhang, R. Tang y L. Hu. «Minimising Non-Processing Energy Consumption and Tardiness Fines in a Mixed-Flow Shop». *Energies* 11.12 (dic. de 2018), pág. 3382.
- [119] B. Zhou y X. Liao. «Decomposition-based 2-echelon multi-objective evolutionary algorithm with energy-efficient local search strategies for shop floor multi-crane scheduling problems». *Neural Computing and Applications* 32.14 (ene. de 2020), págs. 10719-10739.
- [120] M. F. Amiri y J. Behnamian. «Multi-objective green flowshop scheduling problem under uncertainty: Estimation of distribution algorithm». *Journal of Cleaner Production* 251 (abr. de 2020), pág. 119734.
- [121] S. Luo, L. Zhang e Y. Fan. «Energy-efficient scheduling for multi-objective flexible job shops with variable processing speeds by grey wolf optimization». *Journal of Cleaner Production* 234 (oct. de 2019), págs. 1365-1384.
- [122] E. da Jiang y L. Wang. «An improved multi-objective evolutionary algorithm based on decomposition for energy-efficient permutation flow shop scheduling problem with sequence-dependent setup time». *International Journal of Production Research* 57.6 (ago. de 2018), págs. 1756-1771.
- [123] S. Zhou, X. Li, N. Du, Y. Pang y H. Chen. «A multi-objective differential evolution algorithm for parallel batch processing machine scheduling considering electricity consumption cost». *Computers & Operations Research* 96 (ago. de 2018), págs. 55-68.
- [124] Y. Gao, Q. Wang, Y. Feng, H. Zheng, B. Zheng y J. Tan. «An Energy-Saving Optimization Method of Dynamic Scheduling for Disassembly Line». *Energies* 11.5 (mayo de 2018), pág. 1261.
- [125] G. Gong, R. Chiong, Q. Deng y Q. Luo. «A memetic algorithm for multi-objective distributed production scheduling: minimizing the makespan and total energy consumption». *Journal of Intelligent Manufacturing* 31.6 (ene. de 2020), págs. 1443-1466.
- [126] S. Schulz, J. S. Neufeld y U. Buscher. «A multi-objective iterated local search algorithm for comprehensive energy-aware hybrid flow shop scheduling». *Journal of Cleaner Production* 224 (jul. de 2019), págs. 421-434.
- [127] P. Vallejos-Cifuentes, C. Ramirez-Gomez, A. Escudero-Atehortua y E. R. Velasquez. «Energy-Aware Production Scheduling in Flow Shop and Job Shop Environments Using a Multi-Objective Genetic Algorithm». *Engineering Management Journal* 31.2 (ene. de 2019), págs. 82-97.
- [128] C. Lu, L. Gao, X. Li, J. Zheng y W. Gong. «A multi-objective approach to welding shop scheduling for makespan, noise pollution and energy consumption». *Journal of Cleaner Production* 196 (sep. de 2018), págs. 773-787.
- [129] B.-H. Zhou y C.-Y. Shen. «Multi-objective optimization of material delivery for mixed model assembly lines with energy consideration». *Journal of Cleaner Production* 192 (ago. de 2018), págs. 293-305.
- [130] M. Simab, M. S. Javadi y A. E. Nezhad. «Multi-objective programming of pumped-hydrothermal scheduling problem using normal boundary intersection and VIKOR». *Energy* 143 (ene. de 2018), págs. 854-866.
- [131] D. Lei, L. Gao e Y. Zheng. «A novel teaching-learning-based optimization algorithm for energy-efficient scheduling in hybrid flow shop». *IEEE Transactions on Engineering Management* 65.2 (mayo de 2018), págs. 330-340.

- [132] L. Yin, X. Li, L. Gao, C. Lu y Z. Zhang. «A novel mathematical model and multi-objective method for the low-carbon flexible job shop scheduling problem». *Sustainable Computing: Informatics and Systems* 13 (mar. de 2017), págs. 15-30.
- [133] H. Mokhtari y A. Hasani. «An energy-efficient multi-objective optimization for flexible job-shop scheduling problem». *Computers & Chemical Engineering* 104 (sep. de 2017), págs. 339-352.
- [134] Y. Liu, H. Dong, N. Lohse y S. Petrovic. «Reducing environmental impact of production during a Rolling Blackout policy – A multi-objective schedule optimisation approach». *Journal of Cleaner Production* 102 (sep. de 2015), págs. 418-427.
- [135] V Moorthy, P Sangameswararaju, S Ganesan y S Subramanian. «Investigation on the effectiveness of ABC algorithm for hydrothermal energy management considering emission aspects». *International Journal of Energy Sector Management* 9.2 (jun. de 2015), págs. 251-273.
- [136] P. M. Castro, B. Custódio y H. A. Matos. «Optimal scheduling of single stage batch plants with direct heat integration». *Computers & Chemical Engineering* 82 (nov. de 2015), págs. 172-185.
- [137] M. Dai, D. Tang, A. Giret, M. A. Salido y W. Li. «Energy-efficient scheduling for a flexible flow shop using an improved genetic-simulated annealing algorithm». *Robotics and Computer-Integrated Manufacturing* 29.5 (oct. de 2013), págs. 418-429.
- [138] C. Wang, Z. Ji e Y. Wang. «Many-objective flexible job shop scheduling using NSGA-III combined with multi-attribute decision making». *Modern Physics Letters B* 32.34n36 (dic. de 2018), pág. 1840110.
- [139] J. Ding, S. Schulz, L. Shen, U. Buscher y Z. Lü. «Energy aware scheduling in flexible flow shops with hybrid particle swarm optimization». *Computers & Operations Research* 125 (ene. de 2021), pág. 105088.
- [140] A. Hasani y S. M. H. Hosseini. «A bi-objective flexible flow shop scheduling problem with machine-dependent processing stages: Trade-off between production costs and energy consumption». *Applied Mathematics and Computation* 386 (dic. de 2020), pág. 125533.
- [141] D. Yuksel, M. F. Tasgetiren, L. Kandiller y Q.-K. Pan. «Metaheuristics for Energy-Efficient No-Wait Flowshops: A Trade-off Between Makespan and Total Energy Consumption». *2020 IEEE Congress on Evolutionary Computation (CEC)*. IEEE, jul. de 2020.
- [142] X. K. Tian, B. C. Ma, J. W. Zhang, R. Y. Zhao y J Wang. «Research on multi-objective optimization and simulation to HFSSP hybrid flow-shop scheduling problem for energy saving». *IOP Conference Series: Materials Science and Engineering* 504 (abr. de 2019), pág. 012108.
- [143] J. Li, Y. Li, H. Yang, K. Gao, Y. Wang y T. Sun. «Flexible Job Shop Scheduling Problem by Chemical-Reaction Optimization Algorithm». *Advanced Intelligent Computing*. Springer Berlin Heidelberg, 2011, págs. 584-591.
- [144] Y. Zhang, J. Wang e Y. Liu. «Game theory based real-time multi-objective flexible job shop scheduling considering environmental impact». *Journal of Cleaner Production* 167 (nov. de 2017), págs. 665-679.
- [145] L. Zhang, Y. Cao, F. Yang y Q. Zhao. «Machine Learning and Visual Computing». *Applied Computational Intelligence and Soft Computing* 2017 (2017).
- [146] C. Thirumalai, A. Duba y R. Reddy. «Decision making system using machine learning and Pearson for heart attack». *Electronics, Communication and Aerospace Technology (ICECA), 2017 International conference of*. Vol. 2. IEEE. 2017, págs. 206-210.

- [147] J. Kretschmar, K. Gebhardt, C. Theiß y V. Schau. «Range Prediction Models for E-Vehicles in Urban Freight Logistics Based on Machine Learning». *International Conference on Data Mining and Big Data*. Springer. 2016, págs. 175-184.
- [148] F. Shrouf, J. Ordieres y G. Miragliotta. «Smart factories in Industry 4.0: A review of the concept and of energy management approached in production based on the Internet of Things paradigm». *Industrial Engineering and Engineering Management (IEEM), 2014 IEEE International Conference on*. IEEE. 2014, págs. 697-701.
- [149] R. F. Babiceanu y R. Seker. «Big Data and virtualization for manufacturing cyber-physical systems: A survey of the current status and future outlook». *Computers in Industry* 81 (2016), págs. 128-137.
- [150] R. Iqbal, F. Doctor, B. More, S. Mahmud y U. Yousuf. «Big Data analytics and Computational Intelligence for Cyber-Physical Systems: Recent trends and state of the art applications». *Future Generation Computer Systems* (2017).
- [151] W. S. H. M. W. Ahmad y M. F. A. Fauzi. «Evaluation of Feature Extraction and Selection Techniques for the Classification of Wood Defect Images" Hau Lee Tong, "Hu Ng, "Tzen Vun Timothy Yap». *Journal of Engineering and Applied Sciences* 12.3 (2017), págs. 602-608.
- [152] D. M. Wegner, J. A. Abell y M. A. Wincek. *Automated stochastic method for feature discovery and use of the same in a repeatable process*. US Patent App. 14/997,854. Jul. de 2017.
- [153] X. Yao, S. K. Moon y G. Bi. «A hybrid machine learning approach for additive manufacturing design feature recommendation». *Rapid Prototyping Journal* 23.6 (2017), págs. 983-997.
- [154] J. H. Ang, C. Goh, A. A. F. Saldivar e Y. Li. «Energy-efficient through-life smart design, manufacturing and operation of ships in an Industry 4.0 environment». *Energies* 10.5 (2017), pág. 610.
- [155] C.-W. Park, K.-S. Kwon, W.-B. Kim, B.-K. Min, S.-J. Park, I.-H. Sung, Y. S. Yoon, K.-S. Lee, J.-H. Lee y J. Seok. «Energy consumption reduction technology in manufacturing—A selective review of policies, standards, and research». *International Journal of Precision Engineering and Manufacturing* 10.5 (2009), págs. 151-173.
- [156] B. Nikolic, J. Ignjatic, N. Suzic, B. Stevanov y A. Rikalovic. «PREDICTIVE MANUFACTURING SYSTEMS IN INDUSTRY 4.0: TRENDS, BENEFITS AND CHALLENGES.» *Annals of DAAAM & Proceedings* 28 (2017).
- [157] S. Ramírez-Gallego, B. Krawczyk, S. García, M. Woźniak y F. Herrera. «A survey on data preprocessing for data stream mining: current status and future directions». *Neurocomputing* 239 (2017), págs. 39-57.
- [158] D. Wu, C. Jennings, J. Terpenney, R. X. Gao y S. Kumara. «A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests». *Journal of Manufacturing Science and Engineering* 139.7 (2017), pág. 071018.
- [159] L. Enarsson. «Evaluation of suppliers: how to consider the environment». *International Journal of Physical Distribution & Logistics Management* (1998).
- [160] R. K. Burdick, C. M. Borrór y D. C. Montgomery. «A review of methods for measurement systems capability analysis». *Journal of Quality Technology* 35.4 (2003), págs. 342-354.
- [161] E. Dietrich. «Capability of measurement processes based on ISO/FDIS 22514-7 and VDA 5». *Key Engineering Materials*. Vol. 613. Trans Tech Publ. 2014, págs. 354-362.

- [162] M. R. Chmielewski y J. W. Grzymala-Busse. «Global discretization of continuous attributes as preprocessing for machine learning». *International journal of approximate reasoning* 15.4 (1996), págs. 319-331.
- [163] L. Al Shalabi y Z. Shaaban. «Normalization as a preprocessing engine for data mining and the approach of preference matrix». *2006 International conference on dependability of computer systems*. IEEE. 2006, págs. 207-214.
- [164] M. S. Santos, J. P. Soares, P. Henriques Abreu, H. Araújo y J. Santos. «Influence of data distribution in missing data imputation». *Conference on Artificial Intelligence in Medicine in Europe*. Springer. 2017, págs. 285-294.
- [165] R. J. Little y D. B. Rubin. *Statistical analysis with missing data*. Vol. 793. John Wiley & Sons, 2019.
- [166] D. Gamberger, N. Lavrac y S. Dzeroski. «Noise detection and elimination in data preprocessing: experiments in medical domains». *Applied artificial intelligence* 14.2 (2000), págs. 205-223.
- [167] P. F. Velleman y D. C. Hoaglin. *Applications, basics, and computing of exploratory data analysis*. Duxbury Press, 1981.
- [168] N. V. Chawla, K. W. Bowyer, L. O. Hall y W. P. Kegelmeyer. «SMOTE: synthetic minority over-sampling technique». *Journal of artificial intelligence research* 16 (2002), págs. 321-357.
- [169] I. Tomek. «Two modifications of CNN.» (1976).
- [170] H. Han, W.-Y. Wang y B.-H. Mao. «Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning». *International conference on intelligent computing*. Springer. 2005, págs. 878-887.
- [171] H. He, Y. Bai, E. A. Garcia y S. Li. «ADASYN: Adaptive synthetic sampling approach for imbalanced learning». *2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence)*. IEEE. 2008, págs. 1322-1328.
- [172] D. L. Wilson. «Asymptotic properties of nearest neighbor rules using edited data». *IEEE Transactions on Systems, Man, and Cybernetics* 3 (1972), págs. 408-421.
- [173] M. Kubat, S. Matwin et al. «Addressing the curse of imbalanced training sets: one-sided selection». *Icml*. Vol. 97. 1. Nashville, USA. 1997, pág. 179.
- [174] L. Breiman. «Random forests». *Machine learning* 45.1 (2001), págs. 5-32.
- [175] V. López, A. Fernández, S. García, V. Palade y F. Herrera. «An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics». *Information sciences* 250 (2013), págs. 113-141.
- [176] R. e. a. McDermott. *The basics of FMEA*. SteinerBooks, 1996.
- [177] R. Rai, M. K. Tiwari, D. Ivanov y A. Dolgui. «Machine learning in manufacturing and Industry 4.0 applications». *International Journal of Production Research* 59.16 (2021), págs. 4773-4778.
- [178] L. Monostori, A. Márkus, H. Van Brussel y E Westkämpfer. «Machine learning approaches to manufacturing». *CIRP annals* 45.2 (1996), págs. 675-712.
- [179] C. Huang, Y. Li y X. Yao. «A survey of automatic parameter tuning methods for metaheuristics». *IEEE transactions on evolutionary computation* 24.2 (2019), págs. 201-216.
- [180] Y. Eryoldaş y A. Durmuşoğlu. «A Literature Survey on Offline Automatic Algorithm Configuration». *Applied Sciences* 12.13 (2022), pág. 6316.

- [181] J. J. Durillo y A. J. Nebro. «jMetal: A Java framework for multi-objective optimization». *Advances in Engineering Software* 42.10 (2011), págs. 760-771.
- [182] A. J. Nebro, J. J. Durillo y M. Vergne. «Redesigning the jMetal multi-objective optimization framework». *Genetic and Evolutionary Computation Conference* (jul. de 2015), págs. 1093-1100.
- [183] M. López-Ibáñez, J. Dubois-Lacoste, L. P. Cáceres, M. Birattari y T. Stützle. «The irace package: Iterated racing for automatic algorithm configuration». *Operations Research Perspectives* 3 (2016), págs. 43-58. ISSN: 22147160.
- [184] E. Taillard. «Benchmarks for basic scheduling problems». *European Journal of Operational Research* 64.2 (1993), págs. 278-285.
- [185] T. Weisse. *An Introduction to Optimization Algorithms*. 2020.
- [186] A. J. Nebro, M. López-Ibáñez, C. Barba-González y J. García-Nieto. «Automatic configuration of NSGA-II with jMetal and irace». *Genetic and Evolutionary Computation Conference* (jul. de 2019), págs. 1374-1381.
- [187] E. Zitzler, M. Laumanns y L. Thiele. *SPEA2: Improving the Strength Pareto Evolutionary Algorithm*. Inf. téc. 103. Swiss Federal Institute of Technology (ETH), Zurich, Switzerland, 2001.
- [188] D. Applegate y W. Cook. «A computational study of the job-shop scheduling problem». *ORSA Journal on Computing* 3.2 (1991), págs. 149-156.
- [189] E. Balas. «Machine sequencing via disjunctive graphs: an implicit enumeration algorithm». *Operations Research* 17.6 (1969), págs. 941-957.
- [190] J. Adams, E. Balas y D. Zawack. «The Shifting Bottleneck Procedure for Job Shop Scheduling». *Management Science* 34.3 (1988), págs. 391-401.
- [191] R. H. Storer, S. D. Wu y R. Vaccari. «New search spaces for sequencing problems with application to job shop scheduling». *Management Science* 38.10 (1992), págs. 1495-1509.
- [192] E. Balas y A. Vazacopoulos. «Guided local search with shifting bottleneck for job shop scheduling». *Management Science* 44.2 (1998), págs. 262-275.
- [193] E. Demirkol, S. V. Mehta y R. Uzsoy. «Benchmarks for Shop Scheduling Problems». *European Journal of Operational Research* 109.1 (ago. de 1998), págs. 137-141.
- [194] E. Nowicki y C. Smutnicki. «An advanced tabu search algorithm for the job shop problem». *Journal of Scheduling* 8.2 (2005), págs. 145-159.
- [195] R. Saborido, A. B. Ruiz y M. Luque. «Global WASF-GA: An Evolutionary Algorithm in Multiobjective Optimization to Approximate the Whole Pareto Optimal Front». *Evolutionary Computation* 25.2 (jun. de 2017), págs. 309-349. ISSN: 1063-6560.
- [196] E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca y V. G. da Fonseca. «Performance assessment of multiobjective optimizers: an analysis and review». *IEEE Transactions on Evolutionary Computation* 7.2 (2003), págs. 117-132. ISSN: 1089-778X.
- [197] E. Zitzler y L. Thiele. «Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach». *IEEE Transactions on Evolutionary Computation* 3.4 (1999), págs. 257-271.
- [198] D. J. Sheskin. *Handbook of Parametric and Nonparametric Statistical Procedures*. Chapman & Hall/CRC, 2007. ISBN: 1584888148, 9781584888147.

- [199] J. Para, J. Del Ser, A. J. Nebro, U. Zurutuza y F. Herrera. «Analyze, sense, preprocess, predict, implement, and deploy (ASPPID): An incremental methodology based on data analytics for cost-efficiently monitoring the industry 4.0». *Engineering Applications of Artificial Intelligence* 82 (2019), págs. 30-43.
- [200] J. Para, J. Del Ser y A. J. Nebro. «Energy-Aware Multi-Objective Job Shop Scheduling Optimization with Metaheuristics in Manufacturing Industries: A Critical Survey, Results, and Perspectives». *Applied Sciences* 12.3 (2022), pág. 1491.
- [201] E. Osaba, E. Villar-Rodríguez, J. Del Ser, A. J. Nebro, D. Molina, A. LaTorre, P. N. Suganthan, C. A. C. Coello y F. Herrera. «A Tutorial on the Design, Experimentation and Application of Metaheuristic Algorithms to Real-World Optimization Problems». *Swarm and Evolutionary Computation* (2021), pág. 100888.

