

Estudio exploratorio sobre técnicas de machine learning aplicadas al diseño de celdas de
manufactura

Michael Steven Castro Sánchez

Trabajo de Grado para Optar el título de ingeniería industrial

Director

Víctor Alfonso Sanabria Ruiz

Magíster en Ingeniería Industrial

Universidad Industrial de Santander

Facultad de Ingenierías Físico Mecánicas

Escuela de Estudios Industriales y Empresariales

Bucaramanga

2025

Agradecimientos

En primer lugar, quiero expresar mi profundo agradecimiento a mis padres, Beatriz Sánchez Méndez y Nelson Enrique Castro Vera, por brindarme la oportunidad de estudiar y por sus valiosos consejos que han contribuido enormemente a mi crecimiento personal. Además, deseo agradecer a mis familiares, especialmente a mi tía Helena y mi tío Freddy, quienes también han tenido un papel significativo en mi carrera profesional.

Asimismo, debo reconocer y agradecer sinceramente a mis compañeros de universidad, quienes han sido parte fundamental de mi experiencia académica. Han estado a mi lado en momentos felices, tristes, frustrantes y desafiantes. En particular, quiero mencionar y agradecer a Luis Miguel Velilla Hernández, María Fernanda Montaña Muñoz, Camilo Tamara, Carlos de Armas, Juan David Collazos, Daniel Galvis y Andrés Figuera, quienes han sido compañeros excepcionales.

Por último, quiero dedicar un especial agradecimiento a mi hermano, Jeancarlo Castro Sánchez, por su incondicional apoyo en todo momento.

Tabla de Contenido

	Pag.
Introducción	11
1. Generalidades del proyecto.....	13
1.1. Antecedentes y Justificación.....	13
1.2. Planteamiento del problema.....	14
1.3. Objetivos de la investigación	16
1.3.1. Objetivo general.....	16
1.3.2. Objetivos específicos	16
1.4. Alcance y Limitaciones.....	16
1.4.1. Alcance	16
1.4.2. Limitaciones.....	17
2. Marco Teórico.....	18
2.1. Machine Learning en la Ingeniería de Producción	18
2.2. Integración de Machine Learning en el Diseño de Celdas de Manufactura	19
2.3. Clasificación de Técnicas de Machine Learning	20
3. Marco Conceptual.....	23
3.1. Ingeniería de Producción	23
3.2. Celdas de Manufactura	23
3.3. Machine Learning (ML)	24
3.4. Optimización de Procesos.....	24
3.5. Industria 4.0	25
3.6. Sostenibilidad en Manufactura	25

4.	Metodología	26
4.1.	Estrategia de Búsqueda y Fuentes de Información	26
4.2.	Fase 1: Identificación	26
4.2.1.	Ecuación de Búsqueda Inicial	26
4.2.2.	Resultados de la Búsqueda Inicial	27
4.3.	Fase 2: Cribado	27
4.3.1.	Criterios de Inclusión y Exclusión	27
4.3.2.	Ecuación de Búsqueda Refinada.....	28
4.3.3.	Resultados del Cribado	29
4.4.	Fase 3: Selección.....	29
4.4.1.	Proceso de Evaluación Detallada.....	29
4.4.2.	Criterios de Selección Final	29
5.	Resultados	31
5.1.	Panorama Global de la Investigación	31
5.1.1.	Autores	31
5.1.2.	Concentración Regional de Expertise	34
5.1.3.	Distribución Geográfica de la Investigación.....	36
5.1.4.	Años cruciales de investigación.....	37
5.1.5.	Análisis de Brechas Geográficas y Oportunidades.....	38
5.1.6.	Focos Temáticos Principales.....	38
5.1.7.	Técnicas de Machine Learning Predominantes	40
5.2.	Identificación de Técnicas de Machine Learning en Diseño de Celdas de Manufactura	

5.2.1.	Algoritmos de Clustering	41
5.2.2.	Algoritmos Metaheurísticos.....	42
5.2.3.	Algoritmos Evolutivos	42
5.2.4.	Redes Neuronales.....	43
5.2.5.	Redes Neuronales Profundas	43
5.2.6.	Aprendizaje por Refuerzo	44
5.2.7.	Modelos Probabilísticos.....	44
5.2.8.	Algoritmos Híbridos	44
5.2.9.	Algoritmos Bio-inspirados.....	45
5.2.10.	Algoritmos Exactos.....	45
5.2.11.	Métodos de Análisis.....	45
5.2.12.	Sistemas Neuro-Difusos.....	46
5.3.	Clasificación de Técnicas de Machine Learning	46
5.3.1.	Categorías de Aplicación	46
5.3.2.	Distribución de Técnicas por Categoría.....	47
5.4.	Análisis de la Clasificación Propuesta.....	49
5.4.1.	Integración de Técnicas	49
5.4.2.	Evolución Temporal de Técnicas.....	49
5.4.3.	Brechas de Investigación Identificadas.....	50
5.4.4.	Dimensiones de Rendimiento	51
	Conclusiones	52
	Recomendaciones	54
	Referencias Bibliográficas	55

Lista de Tablas

	Pag.
Tabla 1. Tabla de cumplimiento de objetivos.....	12
Tabla 2. Tabla clasificación de técnicas Identificadas ML.....	48

Lista de Figuras

	Pag.
Figura 1. Matriz de confusión.....	21
Figura 2. Diagrama metodología PRISMA	30
Figura 3. Grafica VOSviewer Autores.....	31
Figura 4. Grafica VOSviewer Autor Lee J.	32
Figura 5. Grafica VOSviewer Autor Tariq A.	33
Figura 6. Grafica VOSviewer Autor Delgoshaei A.....	33
Figura 7. Grafica VOSviewer Autor Padavachee J. & Bright G.	34
Figura 8. Lugares de publicación.....	36
Figura 9. Histograma de años de publicación.....	37
Figura 10. Nube de palabras clave.....	39

Lista de Apéndices

Apéndice A. Estudio exploratorio de técnicas de machine learning aplicadas al diseño de celdas de manufactura.pdf

Resumen

Título: Estudio exploratorio sobre técnicas de machine learning aplicadas al diseño de celdas de manufactura*

Autor: Michael Steven Castro Sánchez **

Palabras Clave: Machine Learning, Celdas de Manufactura, Machine Learning (ML), Estrategias, Eficiencia.

Descripción: El diseño de celdas de manufactura es un proceso crítico en la ingeniería de producción, donde se busca optimizar la disposición estratégica de máquinas y trabajadores para maximizar la eficiencia y minimizar los tiempos de espera. Tradicionalmente, los métodos de optimización y programación lineal han sido utilizados para abordar este desafío. Sin embargo, en el contexto actual, el Machine Learning (ML) emerge como una herramienta prometedora para mejorar la efectividad de este proceso.

El ML ofrece ventajas significativas en comparación con los enfoques tradicionales. En primer lugar, su capacidad para aprender patrones complejos a partir de datos históricos permite una adaptación dinámica a las variaciones en la demanda y las condiciones de producción. Al emplear algoritmos de clasificación, regresión y agrupamiento, el ML puede identificar relaciones no lineales entre las variables, lo que resulta especialmente útil en la disposición de máquinas y la asignación de tareas a trabajadores. Además, el ML puede considerar múltiples factores simultáneamente, como la capacidad de las máquinas, las habilidades de los operadores y las restricciones de espacio, para generar soluciones más robustas y eficientes.

El ML permite la optimización continua y la adaptación en tiempo real. A medida que se recopilan más datos y se realizan ajustes en la producción, los modelos de ML pueden actualizarse y refinar sus predicciones. Esto es especialmente relevante en entornos industriales dinámicos, donde las condiciones cambian constantemente. Además, el ML puede considerar factores no lineales y no intuitivos que podrían pasarse por alto en los enfoques tradicionales.

* Trabajo de Grado

** Facultad de Ingenierías Físico Mecánicas. Escuela de Estudios Industriales y Empresariales. Director: Victor Alfonso Sanabria Ruiz, Magíster en Ingeniería Industrial

Abstract

Title: Exploratory study on machine learning techniques applied to the design of manufacturing cells*

Author: Michael Steven Castro Sánchez**

Key Words: Machine Learning, Manufacturing Cells, Strategies, Efficiency

Description: The design of manufacturing cells is a critical process in production engineering, aiming to optimize the strategic arrangement of machines and workers to maximize efficiency and minimize waiting times. Traditionally, optimization methods and linear programming have been used to address this challenge. However, in the current context, Machine Learning (ML) emerges as a promising tool to enhance the effectiveness of this process.

ML offers significant advantages compared to traditional approaches. Firstly, its ability to learn complex patterns from historical data allows dynamic adaptation to variations in demand and production conditions. By employing classification, regression, and clustering algorithms, ML can identify non-linear relationships among variables, which is especially useful in machine layout and task assignment to workers. Additionally, ML can consider multiple factors simultaneously, such as machine capacity, operator skills, and space constraints, to generate more robust and efficient solutions.

ML enables continuous optimization and real-time adaptation. As more data is collected and production adjustments are made, ML models can be updated and refine their predictions. This is particularly relevant in dynamic industrial environments where conditions constantly change. Furthermore, ML can account for non-linear and non-intuitive factors that might be overlooked by traditional approaches.

* Degree Work

** Faculty of Physical and Mechanical Engineering. School of Industrial and Business Studies. Director: Víctor Alfonso Sanabria Ruiz, Master in Industrial Engineering

Introducción

La optimización en sistemas de manufactura es un problema crítico en la ingeniería industrial, en la cual, las técnicas de Machine Learning (ML) son una herramienta fundamental para solucionar la complejidad de sistemas de manufactura (Mukattash et al., 2017). El problema de Formación de Celdas (Cell Formation Problem - CFP) es un problema computacionalmente complejo y NP-Hard, el cual agrupa máquinas en celdas de manufactura y componentes en familias de partes, con el fin de minimizar los costos de manejo de partes y maximizar el uso del sistema (Burggraf et al., 2021; Mukattash et al., 2017).

Métodos tradicionales como la programación lineal presentan limitaciones en términos de escalabilidad, dificultad para adaptarse a entornos dinámicos, y dependencia de supuestos estrictos como la linealidad o la disponibilidad completa de datos. Las técnicas de Machine Learning (ML) han demostrado una alta capacidad para solucionar problemas de optimización en sistemas de manufactura, al ofrecer soluciones más flexibles y eficientes frente a métodos tradicionales. En contraste, algoritmos basados en Redes Neuronales Artificiales (ANN), Algoritmos Genéticos (GA), Optimización por Enjambre de Partículas (PSO) y técnicas de clustering no supervisado han sido aplicados con éxito en la resolución de problemas de formación de celdas de manufactura (CFP), permitiendo abordar aspectos complejos como la agrupación no lineal de máquinas y piezas, el tratamiento de datos incompletos o inciertos, y la adaptación a cambios en la demanda o el entorno productivo (Burggraf et al., 2021).

En este estudio se realizó una revisión sistemática, por medio de la metodología PRISMA, de las técnicas de ML aplicadas al diseño de celdas de manufactura, enfocándonos principalmente en las técnicas más relevantes y sus contribuciones principales. En este estudio se abordan temas

acerca de cómo las técnicas de ML transforman las celdas de manufactura ofreciendo soluciones más eficientes.

Este estudio se estructuró en cuatro secciones que abordan: la metodología de revisión sistemática, la identificación de las técnicas de Machine Learning (ML) generalizadas y aplicadas al diseño de celdas de manufactura, la clasificación de dichas técnicas en tres (3) categorías definidas de acuerdo con su aplicación en las celdas de manufactura y, por último, el análisis de cada técnica y categoría en este contexto.

Tabla de cumplimiento de objetivos

Tabla 1.

Tabla de cumplimiento de objetivos.

Objetivo	Cumplimiento
Identificar las técnicas de machine learning utilizadas para el diseño de celdas de manufactura a partir de una revisión de literatura.	Pág 41 - 46
Clasificar las técnicas de Machine learning identificadas considerando sus características y enfoques de aplicación.	Pág 46 - 49
Elaborar un artículo de carácter publicable consolidando los resultados de trabajo del trabajo de investigación	Pág 70 Apéndice A.

1. Generalidades del proyecto

1.1. Antecedentes y Justificación

El diseño de celdas de manufactura ha sido un área de interés constante en la ingeniería de producción, donde la eficiencia y la efectividad del proceso son fundamentales para la competitividad empresarial (Smith & Tan, 2015). Tradicionalmente, este diseño se ha abordado mediante técnicas de optimización y programación lineal (Duque, Moncayo, & Martínez, 2015). Estos métodos han proporcionado bases sólidas para la toma de decisiones estructuradas; sin embargo, presentan limitaciones para adaptarse a la complejidad y naturaleza dinámica de los entornos de producción actuales.

Con el advenimiento de la Industria 4.0, el machine learning ha surgido como una alternativa prometedora, capaz de procesar grandes cantidades de datos y aprender de la experiencia para mejorar la toma de decisiones (Brown & Smith, 2017). La capacidad de ML para identificar patrones y predecir resultados a partir de datos complejos lo convierte en una herramienta valiosa para el diseño de celdas de manufactura. Sin embargo, la aplicación de ML en este campo aún es incipiente, y existe una necesidad crítica de explorar cómo estas técnicas pueden integrarse de manera efectiva (Johnson, 2020).

La literatura existente sobre ML en la ingeniería de producción ha demostrado su capacidad para optimizar procesos en otros dominios, pero su implementación en el diseño de celdas de manufactura enfrenta desafíos únicos (Cuadrado, 2019). Estos desafíos incluyen la interpretación de datos operativos complejos y la adaptación a cambios rápidos en la demanda y la tecnología (Torres, 2023). Además, hay una brecha en la literatura respecto a las metodologías específicas de ML que mejor se adaptan a este campo.

Los estudios existentes tienden a centrarse en aplicaciones más generales de ML, sin abordar las particularidades del diseño de celdas de manufactura (Johnson, 2020). Esto ha creado una necesidad urgente de investigar y desarrollar enfoques de ML que puedan ser aplicados específicamente a este contexto, considerando las variables y restricciones propias de la industria manufacturera.

Otro aspecto crítico es la evaluación de la efectividad de las técnicas de ML en entornos reales de producción. Muchas investigaciones se han realizado en entornos controlados o simulados, lo que plantea dudas sobre su aplicabilidad y escalabilidad en situaciones reales (Lee & Kim, 2018). Por lo tanto, es esencial desarrollar criterios y métricas claras para evaluar el impacto del ML en el diseño de celdas de manufactura en la práctica.

1.2. Planteamiento del problema

El diseño de celdas de manufactura representa un desafío significativo en la ingeniería de producción, donde la efectividad del proceso es crucial para la competitividad empresarial (Smith & Tan, 2015). Tradicionalmente, este diseño se ha abordado mediante técnicas de optimización y programación lineal, que, aunque efectivas, no siempre pueden adaptarse a la complejidad y dinamismo de los entornos de producción actuales (Duque, Moncayo, & Martínez, 2015).

En este contexto, el machine learning surge como una alternativa prometedora, capaz de procesar grandes volúmenes de datos y aprender de la experiencia para mejorar la toma de decisiones (Brown & Smith, 2017). Sin embargo, la aplicación de estas técnicas en el diseño de celdas de manufactura aún no se ha explorado en profundidad, lo que limita su potencial para transformar esta área crítica de la ingeniería de producción.

El problema central de esta investigación radica en la falta de estudios que integren el machine learning en el diseño de celdas de manufactura de manera efectiva. A pesar de que el

machine learning ha demostrado su capacidad para optimizar procesos en otros dominios, como la logística, el mantenimiento predictivo, el control de calidad y la planificación de la producción (Cuadrado, 2019), su implementación en el diseño de celdas de manufactura enfrenta desafíos únicos, como la necesidad de interpretar datos operativos complejos y la adaptación a cambios rápidos en la demanda y la tecnología (Torres, 2023).

Además, existe una brecha en la literatura respecto a las metodologías específicas de machine learning que mejor se adaptan a este campo. La mayoría de los estudios se centran en aplicaciones más generales, sin abordar las particularidades del diseño de celdas de manufactura (Johnson, 2020). Esto crea una necesidad urgente de investigar y desarrollar enfoques de machine learning que puedan ser aplicados específicamente a este contexto, considerando las variables y restricciones propias de la industria manufacturera.

Otro aspecto problemático es la evaluación de la efectividad de estas técnicas en entornos reales de producción. La mayoría de las investigaciones se han realizado en entornos controlados o simulados, lo que plantea dudas sobre su aplicabilidad y escalabilidad en situaciones reales (Lee & Kim, 2018). Por lo tanto, es esencial desarrollar criterios y métricas claras para evaluar el impacto del machine learning en el diseño de celdas de manufactura en la práctica.

Este estudio busca abordar estas lagunas mediante un enfoque exploratorio que combine la revisión sistemática de la literatura con la clasificación y análisis de técnicas de ML. El objetivo es identificar las técnicas de machine learning más adecuadas para el diseño de celdas de manufactura y establecer directrices para su implementación y evaluación. Los resultados de esta investigación podrían proporcionar una base sólida para futuras aplicaciones prácticas y teóricas, contribuyendo significativamente al avance de la ingeniería de producción.

1.3. Objetivos de la investigación

1.3.1. Objetivo general

Desarrollar un estudio exploratorio sobre técnicas de machine learning aplicadas al diseño de celdas de manufactura.

1.3.2. Objetivos específicos

- Identificar las técnicas de machine learning utilizadas para el diseño de celdas de manufactura a partir de una revisión de literatura.
- Clasificar las técnicas de Machine learning identificadas considerando sus características y enfoques de aplicación.
- Elaborar un artículo de carácter publicable consolidando los resultados del trabajo de investigación.

1.4. Alcance y Limitaciones

1.4.1. Alcance

Este estudio se enfoca en explorar las aplicaciones del machine learning en el diseño de celdas de manufactura. A través de una revisión sistemática de la literatura y el análisis de casos de estudio relevantes, se busca identificar las técnicas más adecuadas para optimizar la disposición estratégica de máquinas y trabajadores en entornos de producción. En términos de contenido, se considerarán los siguientes aspectos:

Selección de técnicas de machine learning: Se evaluarán diversas metodologías, como algoritmos de clasificación, regresión, agrupamiento y redes neuronales, con un enfoque específico en su aplicabilidad al diseño de celdas de manufactura.

VARIABLES Y RESTRICCIONES ESPECÍFICAS: Se analizarán las particularidades de la industria manufacturera, como la variabilidad en la demanda, la disponibilidad de recursos y las limitaciones de espacio, para adaptar las técnicas de machine learning de manera efectiva.

EVALUACIÓN EN ENTORNOS REALES: Se considerará la aplicabilidad y escalabilidad de las soluciones propuestas en situaciones prácticas de producción.

1.4.2. Limitaciones

A pesar de los esfuerzos por abordar las lagunas existentes, este estudio tiene ciertas limitaciones:

- **Generalización de resultados:** Dado que se explorarán casos de estudio específicos, la generalización a otras configuraciones de celdas de manufactura podría requerir investigaciones adicionales.
- **Rapidez de cambios tecnológicos:** La dinámica de la industria manufacturera implica que las soluciones propuestas deben adaptarse rápidamente a los cambios tecnológicos y a la demanda.

2. Marco Teórico

2.1. Machine Learning en la Ingeniería de Producción

El aprendizaje automático (machine learning) ha emergido como una herramienta transformadora en la ingeniería de producción, especialmente en el contexto de la Industria 4.0. La capacidad de ML para procesar y aprender de grandes volúmenes de datos ha permitido abordar desafíos de fabricación complejos, como el incremento de calidad y la optimización de procesos (García Rodríguez, 2020).

La aplicación del ML en la industria no es un concepto nuevo, pero su integración ha alcanzado un nivel de sofisticación que permite a las máquinas participar en la toma de decisiones relacionadas con los procesos de producción. Esto se logra mediante el desarrollo de software que se adapta a nuevos tipos de datos, permitiendo a las máquinas detectar patrones y ajustar sus acciones para un funcionamiento óptimo (Meinsa, 2021).

En la ingeniería de producción, el ML se utiliza para mejorar los procesos automatizados, aprovechando la información generada en la planta para “entender” mejor qué procedimientos son los óptimos. Al final, se traduce en un trabajo más eficiente y productos mejor elaborados (Meinsa, 2021).

Los algoritmos de ML presentan un amplio número de aplicaciones en diversos sectores industriales, como la minería, la química, la farmacéutica, la automovilística y la energética. Estos sectores pueden mejorar sus procesos de extracción de materia prima para la generación de bienes y servicios, gracias a la capacidad de ML para adaptarse a todo tipo de situaciones (Meinsa, 2021).

Sin embargo, la implementación efectiva de ML en la ingeniería de producción requiere una consideración cuidadosa de la calidad y la cantidad de datos disponibles. Datos insuficientes o de baja calidad pueden llevar a predicciones inexactas y decisiones erróneas. Además, la

programación de los algoritmos de ML depende en gran medida de los profesionales que les proporcionan la capacidad de ser autónomas (Meinsa, 2021).

2.2. Integración de Machine Learning en el Diseño de Celdas de Manufactura

La integración del machine learning (ML) en el diseño de celdas de manufactura representa un avance significativo en la ingeniería de producción, marcando la transición hacia sistemas de fabricación más inteligentes y adaptativos. El ML, con su capacidad para procesar grandes conjuntos de datos y aprender de ellos, ofrece oportunidades sin precedentes para mejorar la eficiencia y la flexibilidad de las celdas de manufactura (Sánchez-Chávez & Martell-Chávez, 2019).

En el diseño de celdas de manufactura, el ML puede ser utilizado para optimizar la disposición de máquinas y equipos, predecir el mantenimiento de maquinaria y mejorar la calidad del producto final. La implementación de estos modelos predictivos y de optimización resulta en una mayor eficiencia operativa y una mejor adaptabilidad a los cambios en la producción, creando sistemas más inteligentes y resilientes (Sánchez-Chávez & Martell-Chávez, 2019).

La implementación de ML en celdas de manufactura también implica el uso de sistemas de visión artificial para el control de calidad, lo que permite una inspección más rápida y precisa de los productos fabricados. Esto es particularmente útil en entornos donde la precisión es crítica y los errores pueden ser costosos (Acuña, Gallo, & Saá, n.d.).

Además, la inteligencia artificial (IA), incluido el ML, está transformando la manera en que se diseñan y fabrican los productos. El diseño generativo y la optimización topológica son dos aplicaciones de la IA que permiten la creación de diseños más eficientes y resistentes, así como la reducción de peso y el uso de materiales. Estas tecnologías están cambiando el paradigma del

diseño de celdas de manufactura, permitiendo la creación de sistemas que no solo son eficientes sino también sostenibles (mcad.co, 2023).

Sin embargo, la integración de ML en el diseño de celdas de manufactura no está exenta de desafíos. La calidad de los datos y la capacidad para generar y procesar grandes volúmenes de información son fundamentales para el éxito de la implementación de ML. Además, la resistencia al cambio y la falta de conocimiento técnico pueden ser barreras significativas para la adopción de estas tecnologías (Sánchez-Chávez & Martell-Chávez, 2019).

2.3. Clasificación de Técnicas de Machine Learning

La clasificación de técnicas de Machine Learning (ML) es un componente crítico en el desarrollo de modelos predictivos, especialmente en la ingeniería de producción donde la precisión y la confiabilidad son fundamentales. La evaluación efectiva de un modelo de ML implica la utilización de métricas específicas que pueden determinar su rendimiento y su capacidad para generalizar a nuevos datos (Kohavi et al., 1995).

Una de las métricas más comunes es la precisión (accuracy), que mide la proporción de predicciones correctas sobre el total de casos evaluados. Sin embargo, la precisión por sí sola puede ser engañosa, especialmente en conjuntos de datos desequilibrados, donde una clase es mucho más frecuente que las otras (Provost et al., 1998).

Para abordar las limitaciones de la precisión, se utilizan métricas adicionales como la sensibilidad (recall) y la especificidad. La sensibilidad mide la proporción de verdaderos positivos correctamente identificados por el modelo, mientras que la especificidad mide la proporción de verdaderos negativos (Fawcett, 2006). La combinación de sensibilidad y especificidad puede proporcionar una visión más equilibrada del rendimiento del modelo.

El valor F1 es otra métrica importante que combina la precisión y la sensibilidad en una sola medida, proporcionando un balance entre la capacidad del modelo para identificar correctamente las clases positivas y la precisión con la que realiza estas clasificaciones (Van Rijsbergen, 1979).

Además, la Curva ROC (Receiver Operating Characteristic) y el área bajo la curva (AUC) son herramientas valiosas para evaluar la capacidad de discriminación de un modelo, independientemente del umbral de clasificación utilizado. La Curva ROC es un gráfico de la tasa de verdaderos positivos contra la tasa de falsos positivos, y el AUC proporciona una medida agregada del rendimiento en todos los umbrales de clasificación posibles (Bradley, 1997).

La matriz de confusión es una herramienta visual que permite una evaluación detallada del rendimiento del modelo, mostrando las clasificaciones correctas e incorrectas en cada clase. Esta matriz es fundamental para calcular muchas de las métricas mencionadas anteriormente (Stehman, 1997).

Figura 1.

Matriz de confusión

VALORES PREDICCIÓN	Verdaderos positivos	Falsos Positivos
	Falsos Negativos	Verdaderos Negativos
	VALORES REALES	

*Nota** Tomado de Barrios, J. I. A. (2019). *La matriz de confusión y sus métricas*. Recuperado de <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/>

Es crucial que la evaluación de los modelos de ML se realice utilizando un conjunto de datos de prueba independiente que no haya sido utilizado durante el entrenamiento del modelo. Esto asegura que la evaluación refleje la capacidad del modelo para generalizar a nuevos datos, lo cual es esencial para su aplicación práctica en entornos de producción (Witten et al., 2016).

3. Marco Conceptual

3.1. Ingeniería de Producción

La ingeniería de producción se ocupa del diseño, la operación, la mejora y la instalación de sistemas de producción integrados que involucran personas, materiales, información, equipos y energía (Groover, 2010).

Assafra et al. (2023) destacan la importancia de la optimización de la programación de talleres de trabajo mediante algoritmos genéticos y búsqueda tabú, lo cual mejora la eficiencia y reduce los tiempos de producción.

Bera et al. (2018) subrayan la relevancia de la formación de celdas de manufactura para mejorar la eficiencia en la producción, permitiendo una mejor organización y flujo de trabajo en las plantas de manufactura.

3.2. Celdas de Manufactura

Las celdas de manufactura son agrupaciones de máquinas o estaciones de trabajo que realizan una secuencia de operaciones en componentes que requieren procesos similares. Estas celdas están diseñadas para mejorar la eficiencia y la calidad del proceso de producción (Black, 2018).

Chaudhuri et al. (2021) revisan la aplicación de algoritmos genéticos en sistemas de manufactura celular, lo que permite una mejor asignación de recursos y una mayor flexibilidad en la producción.

Chung et al. (2021) proponen un modelo matemático para la programación de celdas de manufactura energéticamente eficientes, lo que contribuye a la sostenibilidad y reducción de costos operativos.

3.3. Machine Learning (ML)

El machine learning hace parte de la inteligencia artificial y básicamente permite que los sistemas puedan aprender por sí solos a partir de los datos o de la experiencia, sin necesidad de que alguien los programe paso a paso. En la manufactura, el ML se utiliza para optimizar procesos, predecir fallas y mejorar la calidad del producto (Russell & Norvig, 2016).

Burggraf et al. (2021) realizan un estudio bibliométrico sobre el uso del ML en la resolución de problemas de diseño de instalaciones, destacando su potencial para mejorar la eficiencia y reducir los costos.

Chin & Wong (2018) desarrollan un modelo predictivo para minimizar la tardanza total en la programación de talleres de flujo, demostrando cómo el ML puede mejorar la planificación y ejecución de procesos de manufactura.

3.4. Optimización de Procesos

La optimización de procesos es el acto de hacer que un proceso sea más efectivo o eficiente a través de la aplicación de técnicas matemáticas o de modelado. La optimización puede incluir la minimización de costos, la maximización de la producción, o la mejora de la calidad (Hillier & Lieberman, 2001).

Cabrera-Jeronimo et al. (2023) proponen un modelo de mejora para aumentar la productividad basado en la aplicación de herramientas de manufactura esbelta, lo que permite una mejor utilización de los recursos y una reducción de desperdicios.

Chung et al. (2021) se centran en la programación de celdas de manufactura energéticamente eficientes, lo que no solo optimiza los procesos, sino que también aporta a la sostenibilidad y a bajar los costos de energía.

3.5. Industria 4.0

La Industria 4.0 representa la cuarta revolución industrial, caracterizada por la digitalización de los sistemas de manufactura y la integración de tecnologías como el Internet de las Cosas, la robótica avanzada, el análisis de grandes datos a gran escala y, claro, el uso de ML (Schwab, 2017).

Cabrera-Jeronimo et al. (2023) discuten la aplicación de herramientas de manufactura esbelta en la Industria 4.0, destacando cómo estas tecnologías pueden mejorar la eficiencia y flexibilidad de los procesos de producción.

Burggraf et al. (2021) analizan el uso del ML en la optimización del diseño de instalaciones, subrayando su importancia en la creación de fábricas inteligentes y altamente eficientes.

3.6. Sostenibilidad en Manufactura

La sostenibilidad en manufactura se refiere a la creación de productos manufacturados a través de procesos que son no contaminantes, conservan la energía y los recursos naturales, son económicamente viables y seguros para los trabajadores, las comunidades y los consumidores (EPA, 2018).

Chung et al. (2021) abordan la programación de celdas de manufactura energéticamente eficientes, lo que contribuye a la sostenibilidad al reducir el consumo de energía y las emisiones de carbono.

Cabrera-Jeronimo et al. (2023) proponen un modelo de mejora basado en herramientas de manufactura esbelta para aumentar la productividad y la sostenibilidad, destacando la importancia de procesos eficientes y responsables con el medio ambiente.

4. Metodología

Esta investigación se desarrolló mediante una revisión sistemática de la literatura siguiendo la metodología PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), reconocida internacionalmente como el estándar para la conducción de revisiones sistemáticas de alta calidad (Moher et al., 2009). El protocolo PRISMA proporciona un marco estructurado de cuatro fases consecutivas: identificación, cribado, selección e inclusión de referencias científicas, garantizando la transparencia, reproducibilidad y rigor metodológico del proceso de revisión.

4.1. Estrategia de Búsqueda y Fuentes de Información

La búsqueda sistemática se realizó en la base de datos Scopus, seleccionada por su amplia cobertura en ingeniería y ciencias de la computación, así como por su reconocida calidad en la indexación de literatura científica. Se utilizó una estrategia de búsqueda comprehensiva que combinó términos relacionados con manufactura celular y técnicas de machine learning, aplicando operadores booleanos para maximizar la recuperación de literatura relevante.

4.2. Fase 1: Identificación

4.2.1. Ecuación de Búsqueda Inicial

La estrategia de búsqueda inicial se construyó utilizando la siguiente ecuación de búsqueda en Scopus:

```
TITLE-ABS-KEY ( ( ( "Cellular manufacturing" OR "Cell manufacturing" OR  
"Cell formation" OR "Group technology" ) AND ( "Machine Learning" OR "ML" OR  
"Artificial Intelligence" OR "AI" OR "Neural Networks" OR "ANN" OR  
"Unsupervised Learning" OR "Self-Organizing Maps" OR "SOM" OR  
"Hopfield Networks" OR "Kohonen Networks" OR "Clustering" ) ) )
```

Esta ecuación de búsqueda fue diseñada para capturar la intersección entre dos dominios principales:

- **Manufactura celular:** Incluyendo términos específicos como "cellular manufacturing", "cell formation" y "group technology"
- **Machine Learning:** Abarcando técnicas generales y específicas de ML, incluyendo redes neuronales y algoritmos de agrupamiento

4.2.2. Resultados de la Búsqueda Inicial

La estrategia de búsqueda inicial arrojó un total de **1,654 referencias** potencialmente relevantes, estableciendo el corpus inicial para el proceso de cribado.

4.3. Fase 2: Cribado

4.3.1. Criterios de Inclusión y Exclusión

En la fase de cribado se aplicaron criterios sistemáticos de inclusión y exclusión para refinar la selección de literatura relevante:

Criterios de Inclusión:

- Año de publicación: 2015-2024 (última década para asegurar relevancia temporal)
- Idioma: inglés (idioma predominante en literatura científica técnica)
- Tipos de fuente: Artículos de revista (journals) y memorias de congresos (conference proceedings)
- Áreas temáticas: Ingeniería, Ciencias de la Computación, Matemáticas, Ciencias de la Decisión y estudios Multidisciplinarios
- Tipos de documento: Artículos de investigación y artículos de congreso

Criterios de Exclusión:

- Publicaciones anteriores a 2015
- Documentos en idiomas distintos al inglés
- Tipos de documento: Libros, capítulos de libro, editoriales, cartas al editor
- Áreas temáticas no relacionadas con ingeniería o ciencias de la computación

4.3.2. Ecuación de Búsqueda Refinada

Los criterios de cribado se incorporaron en la ecuación de búsqueda mediante limitadores específicos de Scopus:

```
TITLE-ABS-KEY ( ( ( "Cellular manufacturing" OR "Cell manufacturing" OR
"Cell formation" OR "Group technology" ) AND ( "Machine Learning" OR "ML" OR
"Artificial Intelligence" OR "AI" OR "Neural Networks" OR "ANN" OR
"Unsupervised Learning" OR "Self-Organizing Maps" OR "SOM" OR
"Hopfield Networks" OR "Kohonen Networks" OR "Clustering" ) ) )
AND PUBYEAR > 2014 AND PUBYEAR < 2025
AND ( LIMIT-TO ( SUBJAREA , "ENGI" ) OR LIMIT-TO ( SUBJAREA , "COMP" ) OR
LIMIT-TO ( SUBJAREA , "MATH" ) OR LIMIT-TO ( SUBJAREA , "MULT" ) OR
LIMIT-TO ( SUBJAREA , "DECI" ) )
AND ( LIMIT-TO ( LANGUAGE , "English" ) )
AND ( LIMIT-TO ( EXACTKEYWORD , "Cellular Manufacturing" ) OR
LIMIT-TO ( EXACTKEYWORD , "Group Technology" ) OR
LIMIT-TO ( EXACTKEYWORD , "Cell Formation" ) OR
LIMIT-TO ( EXACTKEYWORD , "Cellular Manufacturing Systems" ) OR
LIMIT-TO ( EXACTKEYWORD , "Cellular Manufacturing System" ) OR
LIMIT-TO ( EXACTKEYWORD , "Cell Formation Problem" ) )
AND ( LIMIT-TO ( SRCTYPE , "j" ) OR LIMIT-TO ( SRCTYPE , "p" ) )
```

AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp"))

4.3.3. Resultados del Cribado

La aplicación de los criterios de cribado redujo significativamente el conjunto de referencias de 1,654 a **129 documentos**, representando una reducción del 92.2% y asegurando la relevancia temática y metodológica de la literatura seleccionada.

4.4. Fase 3: Selección

4.4.1. Proceso de Evaluación Detallada

La fase de selección involucró una evaluación exhaustiva de cada una de las 129 referencias mediante:

- **Revisión de títulos:** Evaluación inicial de la relevancia temática
- **Análisis de resúmenes:** Identificación de la metodología, objetivos y resultados principales
- **Revisión de texto completo:** Para casos donde la relevancia no era clara desde el resumen

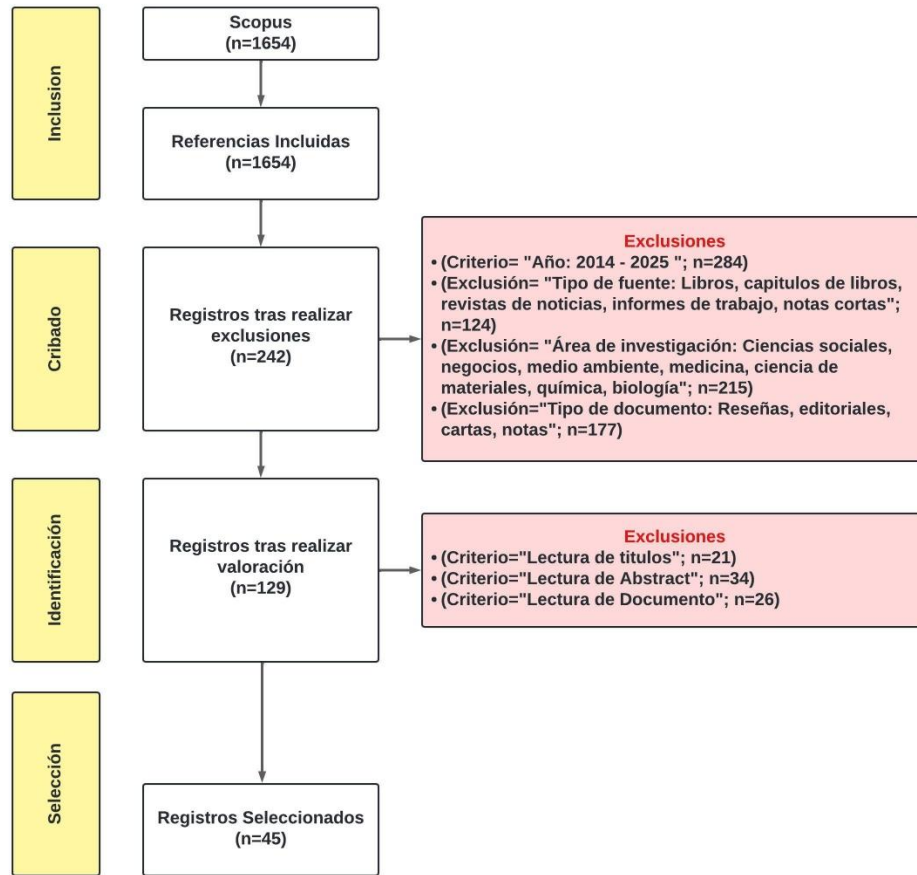
4.4.2. Criterios de Selección Final

Los criterios específicos para la selección final incluyeron:

- **Relevancia temática directa:** Aplicación específica de técnicas de ML al diseño de celdas de manufactura
- **Calidad metodológica:** Descripción clara de la metodología de ML empleada
- **Contribución significativa:** Aporte innovador o mejora demostrable en el campo
- **Rigor científico:** Validación adecuada de resultados y comparación con métodos existentes

Figura 2.

Diagrama metodología PRISMA



Nota* los presentes resultados se obtuvieron al 03 de Abril del 2025.

5. Resultados

5.1. Panorama Global de la Investigación


El análisis bibliométrico realizado mediante VOSviewer revela un campo de investigación de alcance global, con contribuciones significativas distribuidas estratégicamente en múltiples continentes. Esta distribución geográfica refleja el reconocimiento internacional de la importancia de optimizar los sistemas de manufactura mediante la integración de técnicas de Machine Learning.

5.1.1. Autores

La investigación en Machine Learning aplicado al diseño de celdas de manufactura presenta una distribución entre autores no hay mucha relación como se presenta en Imagen de VOSviewer.

Figura 3.

Grafica VOSviewer Autores




Pero cada autor estudia temas enfocados en:

Autores como Lee J. tiene dos artículos hablando sobre el diseño de layout en uno usa la técnica Algoritmo k-modes y en el mas reciente habla acerca Multivariate Adaptive Regression Splines (MARS) y Algoritmo Genético (GA).

Figura 4.


Grafica VOSviewer Autor Lee J.



Tariq A. cuenta con dos artículos, y en cada uno utiliza una técnica diferente. En el primero emplea un algoritmo genético para la formación de celdas, considerando tanto la agrupación máquina-parte como la secuenciación, con el objetivo de minimizar el tiempo total de procesamiento (makespan). En el segundo artículo utiliza una optimización por enjambre de partículas híbrida (HPSO) para la formación de celdas máquina-parte (MPCF), combinando PSO con una heurística de búsqueda local para mejorar la eficacia de agrupamiento.

Figura 5.


Grafica VOSviewer Autor Tariq A.



Delgoshaei A. tiene dos artículos, y en cada uno utiliza técnicas distintas. En el primero aplica un Perceptrón Multicapa (MLP) híbrido con Recocido Simulado para la programación de celdas de manufactura dinámicas, buscando minimizar la variación de carga celular, y considerando aspectos como máquinas en paralelo y cuellos de botella. En el segundo realiza una revisión exhaustiva de diferentes técnicas de clustering aplicadas a la formación de celdas, entre ellas: K-means, K-medoids, FCM, SLINK, CLINK, ALINK, ART, SOM, GA, TS, ACO y PSO, analizando sus aplicaciones, ventajas y limitaciones.

Figura 6.

Grafica VOSviewer Autor Delgoshaei A.



Ya hay autores que han trabajado de forma conjunta, como es el caso de Padayachee J. y Bright G., cuyas publicaciones van desde el año 2016 hasta 2018. En su primer artículo utilizaron un Algoritmo Genético combinado con Agrupamiento Difuso C-Means (FCM) para la formación de celdas de manufactura dinámicas y la agrupación de familias de piezas en múltiples periodos, incluyendo balance de carga entre celdas. En su siguiente publicación emplearon el algoritmo Fuzzy C-Medoids (FCMdd) junto con Programación Lineal Entera Mixta (MILP), con el objetivo de planificar la evolución de celdas de manufactura a largo plazo y determinar la reconfiguración óptima de máquinas entre celdas durante varios periodos. Finalmente, en su último trabajo aplicaron múltiples técnicas como K-means, agrupación jerárquica y algoritmos heurísticos para abordar la programación y secuenciación de operaciones en celdas de manufactura, enfocados en la personalización masiva.

Figura 7.

Grafica VOSviewer Autor Padavachee J. & Bright G.



5.1.2. Concentración Regional de Expertise

Europa: Liderazgo en Optimización Metaheurística

Europa emerge como el continente con mayor diversidad metodológica, liderado por investigadores alemanes que han establecido un enfoque sistemático hacia la digitalización de sistemas manufactureros. Los autores de la University of Siegen, particularmente Burggraf et al.

(2021), han realizado contribuciones pioneras en el análisis bibliométrico de técnicas de ML para problemas de diseño de instalaciones, estableciendo las bases metodológicas que han influenciado investigaciones posteriores.

Asia: Diversidad Metodológica y Escalabilidad

Asia presenta la mayor diversidad tanto en términos de países participantes como de técnicas desarrolladas. China lidera en términos de volumen de publicaciones, con autores distribuidos en múltiples instituciones respaldadas por fundaciones científicas nacionales, mostrando un enfoque sistemático hacia la investigación en manufactura inteligente.

Los autores chinos han demostrado particular fortaleza en el desarrollo de algoritmos evolutivos y técnicas de clustering avanzadas. Li et al. (2024) han contribuido significativamente al análisis de series temporales en sistemas de manufactura celular, mientras que investigadores como Wang et al. (2022) han pionero en la aplicación de aprendizaje por refuerzo para optimización de layout celular.

India muestra una concentración notable en técnicas de clustering y algoritmos bio-inspirados, con contribuciones significativas de institutos tecnológicos especializados. Autores como Deep & Singh (2015) han desarrollado algoritmos genéticos híbridos considerando rutas alternativas, mientras que otros investigadores indios han avanzado en técnicas de Fuzzy C-means y clustering jerárquico.

América del Norte: Innovación en Redes Neuronales

Estados Unidos presenta una concentración de expertise en técnicas avanzadas de redes neuronales y aprendizaje profundo. Autores de Lawrence Technological University y Ohio University han contribuido significativamente al desarrollo de enfoques híbridos que combinan

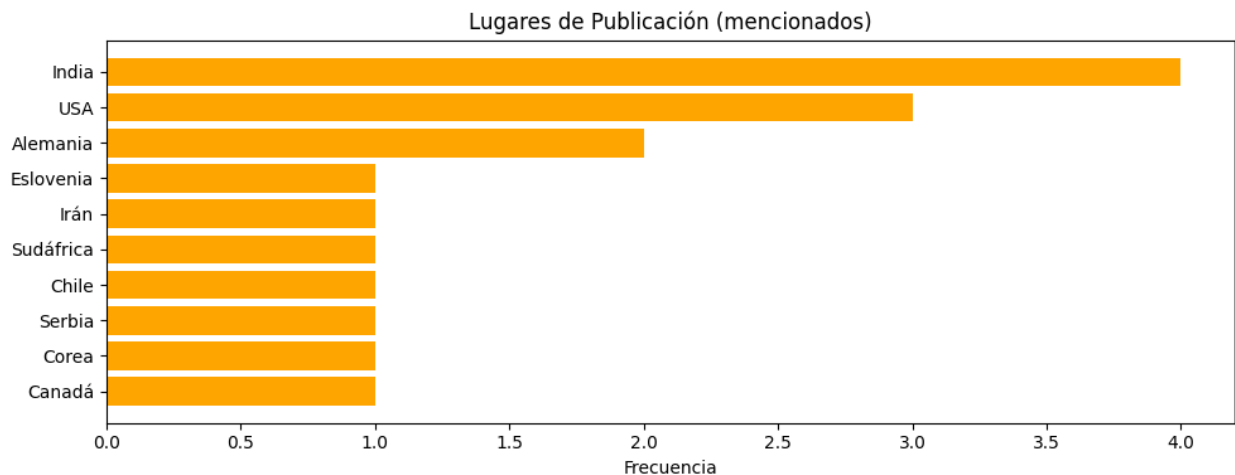
algoritmos genéticos con redes neuronales artificiales, como demuestran los trabajos de Egilmez et al. (2016).

5.1.3. Distribución Geográfica de la Investigación

La investigación en Machine Learning aplicado al diseño de celdas de manufactura presenta una distribución geográfica diversificada que abarca cuatro continentes principales:

Figura 8.

Lugares de publicación



Europa emerge como una región de particular actividad investigativa, con contribuciones destacadas de Alemania (University of Siegen), seguida por investigaciones significativas en Eslovenia, Austria, Reino Unido, Portugal, República Checa y Polonia. Esta concentración europea sugiere un enfoque sistemático hacia la digitalización industrial coherente con las iniciativas de Industria 4.0.

Asia muestra la mayor diversidad de participación, con China liderando a través de múltiples instituciones respaldadas por fundaciones científicas nacionales, seguida por India con una amplia participación de institutos tecnológicos especializados. Otros países asiáticos con

contribuciones relevantes incluyen Turquía, Singapur, Malasia, Corea del Sur, Irán e Irak, reflejando el creciente interés de la región en tecnologías de manufactura avanzada.

América presenta contribuciones notables de Estados Unidos, particularmente a través de Lawrence Technological University y Ohio University, Canadá (University of Toronto) y Chile (Pontificia Universidad Católica de Valparaíso), indicando un enfoque transnacional en el desarrollo de soluciones de manufactura inteligente.

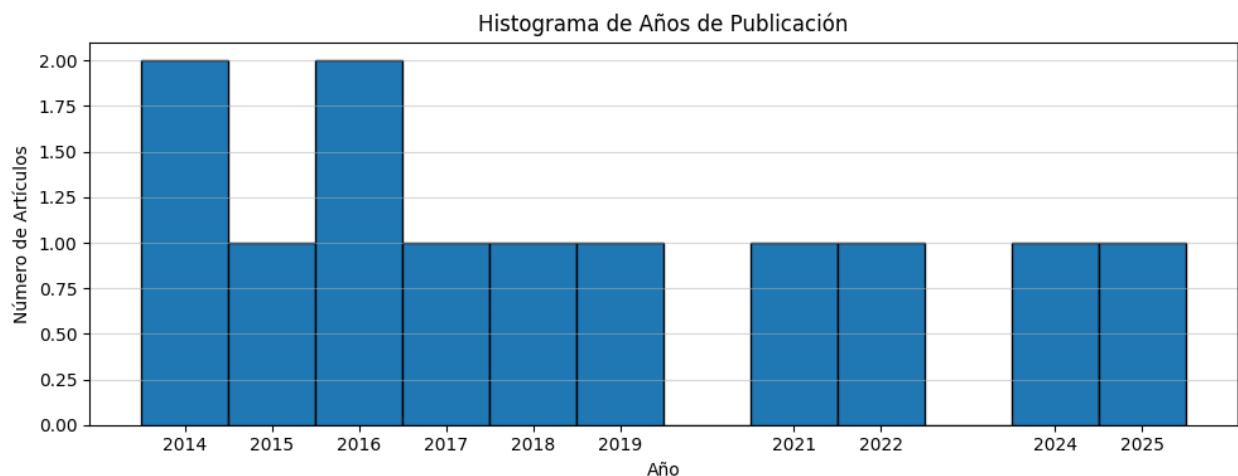
África está representada principalmente por Sudáfrica (University of KwaZulu-Natal), mostrando el interés emergente del continente en tecnologías de manufactura avanzada.

5.1.4. Años cruciales de investigación

La investigación en Machine Learning aplicado al diseño de celdas de manufactura presenta diferentes periodos de interés.

Figura 9.

Histograma de años de publicación



En el histograma se puede observar una tendencia de interés en el periodo entre 2014 y 2016. Posteriormente aunque persiste el interés no se evidencian periodos

5.1.5. Análisis de Brechas Geográficas y Oportunidades

Regiones Subrepresentadas: América Latina (excepto Chile), África (excepto Sudáfrica) y Oceanía muestran participación limitada, representando oportunidades significativas para expansión de la investigación y transferencia tecnológica.

Mercados Emergentes: Países como Brasil, México, Tailandia y Vietnam, con sectores manufactureros en crecimiento, representan oportunidades para aplicación práctica de técnicas desarrolladas en regiones más avanzadas (Burggraf et al., 2021).

Potencial de Colaboración Sur-Sur: Existe potencial significativo para colaboraciones entre autores de países emergentes, particularmente entre autores de Asia y América Latina, aprovechando complementariedades en capacidades tecnológicas y necesidades industriales.

Este análisis geográfico revela que, aunque la investigación en ML para diseño de celdas de manufactura es verdaderamente global, existe una concentración significativa de expertise en regiones industrialmente avanzadas, creando oportunidades importantes para transferencia tecnológica y desarrollo de capacidades en mercados emergentes.

5.1.6. Focos Temáticos Principales

5.1.6.1. Problemas de Investigación Dominantes

El análisis de co-ocurrencia de palabras clave mediante VOSviewer identifica tres áreas temáticas predominantes que definen el núcleo de la investigación actual:


Formación de Celdas de Manufactura (Cell Formation - CF) emerge como el tema más dominante, representando el 44% de las aplicaciones identificadas. Este enfoque se centra en la agrupación óptima de máquinas y componentes en celdas de manufactura, aplicando principios de Tecnología de Grupo (Group Technology) para maximizar la eficiencia del flujo de producción y minimizar los movimientos intercelulares.

Problemas de Diseño de Instalaciones (Facility Layout Problems - FLP) constituyen el segundo foco principal, abarcando la planificación estratégica del layout físico de plantas manufactureras, incluyendo tanto disposiciones celulares como dinámicas que les permitan ajustarse cuando cambian la demanda o se modifican las configuraciones de los productos..

Programación y Optimización de Procesos representa el tercer cluster temático, enfocándose en la programación inteligente de tareas dentro y entre celdas (programación intracelular e intercelular), balanceo de cargas de trabajo y optimización de sistemas de despacho.

Figura 10.

Nube de palabras clave



5.1.6.2. *Problemas Específicos Abordados*

El análisis bibliométrico revela que la investigación se concentra en resolver desafíos específicos de complejidad industrial:

- **Minimización de elementos excepcionales:** Optimización del manejo de partes que requieren procesamiento fuera de su celda asignada (Utkina et al., 2018).

- **Optimización multiobjetivo:** Balanceo simultáneo de múltiples criterios como costos, tiempo y calidad
- **Gestión de incertidumbre:** Desarrollo de sistemas robustos ante variaciones en demanda, tiempos de proceso y fallas de máquinas
- **Integración de factores realistas:** Consideración de tiempos de preparación (setup times) y rutas de proceso alternativas

5.1.7. Técnicas de Machine Learning Predominantes

5.1.7.1. Distribución de Técnicas por Frecuencia de Aplicación

El análisis de co-ocurrencia revela una distribución distintiva de técnicas de Machine Learning, con las **Redes Neuronales Artificiales (ANN)** dominando el 86% de las aplicaciones de ML identificadas. Dentro de esta categoría, los **Mapas Autoorganizados (Self-Organizing Maps - SOM)** y las **Redes de Hopfield** representan los modelos predominantes, reflejando la preferencia por técnicas de aprendizaje no supervisado para problemas de agrupamiento (Ghoushchi & Abbasi, 2021).

Los **Algoritmos Metaheurísticos** aplicados a técnicas constituyen la segunda categoría más relevante, con amplia aplicación en problemas de optimización combinatoria NP-hard. Destacan los Algoritmos Genéticos (GA), la Optimización por Colonia de Hormigas (ACO), el Recocido Simulado (SA) y la Búsqueda Tabú (TS), técnicas especialmente valoradas por su capacidad para explorar espacios de búsqueda complejos (Delgoshaei et al., 2019).

Los **Algoritmos de Clustering** representan el tercer grupo en importancia, con técnicas como K-means, Fuzzy C-means y clustering jerárquico siendo fundamentales para la implementación de principios de Tecnología de Grupo en la formación de celdas (Delgoshaei et al., 2019).

5.1.7.2. *Tendencias en Hibridación de Técnicas*

Un hallazgo significativo del análisis bibliométrico es la creciente tendencia hacia **enfoques híbridos**, donde se combinan múltiples técnicas para aprovechar las fortalezas complementarias de cada método. Las combinaciones más frecuentes incluyen:

- **GA + ANN:** Integración de algoritmos genéticos con redes neuronales para optimización y aprendizaje (Seema & Dixit, 2017)
- **ML + Simulación:** Combinación de técnicas de aprendizaje automático con modelos de simulación (Sobottka et al., 2024)
- **Clustering + Metaheurísticas:** Uso de técnicas de agrupamiento seguidas de optimización metaheurística (Forghani & Fatemi Ghomi, 2019).

5.2. Identificación de Técnicas de Machine Learning en Diseño de Celdas de Manufactura

Mediante la revisión sistemática identificamos diversas técnicas de ML aplicadas al diseño de celdas de manufactura. Estas técnicas han sido categorizadas en doce (12) grupos generalizados según sus características y fundamentos algorítmicos, como se describe a continuación:

5.2.1. Algoritmos de Clustering

Estos algoritmos se basan en la agrupación de datos según su similitud, sin necesidad de etiquetas previas (aprendizaje no supervisado). Son aplicados en la Formación de celdas de manufactura, gracias a su capacidad para agrupar máquinas y componentes de acuerdo con sus características. Entre las técnicas de ML identificamos:

- K-means y K-means jerárquico (Branco & Rocha, 2018; Do et al., 2024)
- Fuzzy C-means (FCM) y Fuzzy C-Medoids (FCMdd) (Padayachee & Bright, 2016, 2017)
- Clustering Jerárquico (SLINK, CLINK, ALINK) (Delcoucq et al., 2022)

- K-modes para datos categóricos (Alhendi et al., 2017)
- Rank Order Clustering (ROC) (Iç et al., 2019; Moona et al., 2016)
- Técnicas basadas en coeficientes de similitud como BMIM y Sorensen-SLC (Kumar et al., 2024; Phung et al., 2024; Sathish et al., 2019)

5.2.2. Algoritmos Metaheurísticos

Son métodos de optimización que imitan procesos naturales para encontrar soluciones aproximadas a problemas complejos, especialmente útiles para problemas NP-hard como la formación de celdas. Presentan capacidad para escapar de óptimos locales y manejar múltiples objetivos simultáneamente. Las variantes identificadas incluyen:

- Algoritmo de Viuda Negra Binario (B-BWO) (Figueroa-Torrez et al., 2023)
- Recocido Simulado (SA) (Hakeem et al., 2022)
- Búsqueda Tabú (TS) (Hakeem et al., 2022)
- Algoritmo de Colonia de Abejas Artificiales Modificado (MABC) (Arunagiri et al., 2018)

5.2.3. Algoritmos Evolutivos

Constituyen una subcategoría específica de metaheurísticas inspiradas en el proceso de evolución natural. Utilizan operadores como selección, cruce y mutación para generar nuevas soluciones a partir de poblaciones existentes. En el contexto de celdas de manufactura, se han identificado:

- Algoritmos Genéticos (GA) simples y modificados (Deep & Singh, 2015; Golmohammadi et al., 2021)
- Algoritmos Genéticos con función de aptitud basada en makespan (Maroof et al., 2016)

- Algoritmos Genéticos con estructura constructiva voraz y refinamiento (Branco & Rocha, 2018)
- Algoritmos Genéticos Multiobjetivo con Escalarización Cónica (Erozan et al., 2015; Sahin & Alpay, 2024)

5.2.4. Redes Neuronales

Son modelos computacionales basados en el funcionamiento del cerebro humano, imitan las conexiones neuronales del cerebro, tienen la capacidad de aprender patrones complejos a partir de datos. En las celdas de manufactura, se utilizan para modelado, predicción y optimización. Entre las técnicas de ML identificamos:

- Redes Neuronales de Autoorganización (SOM) (Berlec et al., 2014)
- Redes ART1 Modificadas (MART1) (Manimaran et al., 2014)

5.2.5. Redes Neuronales Profundas

Representan una variación mejorada de las redes neuronales tradicionales, tienen múltiples capas que les permiten aprender representaciones jerárquicas más complejas. Entre las técnicas de ML identificamos:

- Redes Neuronales Artificiales (RNA) tradicionales (Egilmez et al., 2016; Ghouschi & Abbasi, 2021) y Perceptrón Multicapa (MLP) (Delgoshaei & Gomes, 2019)
- Redes de Memoria a Largo Plazo (LSTM) (Sobottka et al., 2024)
- Redes Generativas Adversarias (GANs) (Challapalli et al., 2021)
- Autoencoders Denoising Apilados (SDAE) (Guo et al., 2020)
- Aprendizaje profundo semi-supervisado (SSDLMA) (Guo et al., 2020), (Naidoo et al., 2018)

5.2.6. Aprendizaje por Refuerzo

Esta familia de técnicas se basa en la interacción de un agente con un entorno, donde aprende mediante prueba y error a maximizar una recompensa. Son particularmente útiles para control y toma de decisiones en entornos de manufactura dinámicos. Las variantes identificadas incluyen:

- Q-Learning (Cheng et al., 2021; Wang et al., 2022)
- Algoritmos Actor-Critic (A2C) (Schwung et al., 2019), (Rajesh & Chalapathi, 2019)
- Aprendizaje por refuerzo con algoritmos de optimización como ACO (Forghani & Fatemi Ghomi, 2019)

5.2.7. Modelos Probabilísticos

Utilizan principios de probabilidad para modelar incertidumbre y relaciones entre variables. En manufactura celular, permiten representar dependencias complejas y tomar decisiones bajo incertidumbre. Se identificaron:

- Redes Bayesianas (Sahin & Alpay, 2024)
- Modelos de revisión de técnicas probabilísticas para formación de celdas (Lee et al., 2025)

5.2.8. Algoritmos Híbridos

Combinan dos o más técnicas de ML para aprovechar las fortalezas de cada una. En el ámbito estudiado, se encontraron:

- Hibridación de Algoritmos Genéticos con Redes Neuronales Artificiales (Egilmez et al., 2016)

- Clustering Jerárquico con técnicas complementarias de optimización (Delcoucq et al., 2022)

5.2.9. Algoritmos Bio-inspirados

Se basan en la imitación de procesos biológicos específicos, distintos de la evolución genética o los comportamientos de enjambre. En el contexto analizado, se identificó:

- Optimización por Enjambre de Partículas (PSO) y su variante híbrida (HPSO) (Karthikeyan et al., 2016; Tariq et al., 2024)
- Algoritmo de Colonia de Hormigas (ACO) (D. Li et al., 2014; H. Li et al., 2024)
- Algoritmo basado en el mecanismo de regulación endocrina (Gu & Wang, 2017), (Delgoshaei et al., 2019)

5.2.10. Algoritmos Exactos

A diferencia de las heurísticas, estos algoritmos garantizan encontrar la solución óptima, aunque pueden ser computacionalmente intensivos para problemas grandes. Los métodos identificados incluyen:

- Ramificación y acotación (branch-and-bound) (Utkina et al., 2018)
- Método basado en números de Stirling (Mukattash et al., 2017)
- Programación Lineal Entera Mixta (MILP) (Padayachee & Bright, 2017)

5.2.11. Métodos de Análisis

Aunque no son técnicas de ML estrictamente, estos métodos se integran con ML para analizar comportamientos y tendencias en sistemas de manufactura. Se identificaron:

- Análisis de Series Temporales (H. Li et al., 2024)

- Análisis Bibliométrico de técnicas de ML (Burggraf et al., 2021)
- Cooperative co-evolutionary algorithm (ECCA) (Cheng et al., 2021; Perovic et al., 2022)

5.2.12. Sistemas Neuro-Difusos

Combinan la capacidad de aprendizaje de las redes neuronales con la interpretabilidad de la lógica difusa. En el contexto estudiado, se identificó:

- Redes neuronales difusas adaptativas (ANFIS) (Perovic et al., 2022; Seema & Dixit, 2017)

5.3. Clasificación de Técnicas de Machine Learning

La clasificación de las técnicas identificadas se ha realizado según su área de aplicación dentro del diseño de celdas de manufactura. Se establecieron tres categorías principales que representan diferentes aspectos del ciclo de vida de los sistemas de manufactura celular:

5.3.1. Categorías de Aplicación

- **Formación y Agrupamiento de Celdas:** Esta dimensión establece las bases de la manufactura celular, organizando la estructura inicial del sistema. Busca juntar máquinas similares y agrupar piezas con necesidades de fabricación parecidas, formando "familias" de trabajo. El objetivo principal es crear grupos que minimicen el movimiento entre celdas diferentes, aprovechando mejor cada recurso. Esta etapa define la estructura básica del sistema de manufactura.

Modelado y Planificación de Sistemas: En esta dimensión se desarrolla el enfoque estratégico del sistema. Se crean modelos para predecir cómo funcionará el sistema en diferentes situaciones, considerando factores de incertidumbre. Se establece un plan a largo plazo para la evolución de las celdas, analizando patrones temporales y

balanceando diferentes limitaciones y metas. Representa la dirección estratégica del sistema.

Optimización de Procesos de Manufactura: Esta dimensión mejora el funcionamiento de celdas ya existentes. Incluye técnicas para reducir tiempos de producción, controlar el flujo de materiales, disminuir costos de transporte interno y asignar mejor tanto trabajadores como recursos. Corresponde a la fase de operación y mejora continua, donde el sistema se perfecciona constantemente para lograr mejor rendimiento.

5.3.2. Distribución de Técnicas por Categoría

El análisis de la distribución de las cuarenta y cinco (45) aplicaciones identificadas revela patrones significativos en el uso de técnicas de ML según su contexto de aplicación:

La categoría "Formación y Agrupamiento de Celdas" predomina con veinte (20) aplicaciones (44% del total), lo que refleja la centralidad de este problema en la manufactura celular. Dentro de esta categoría, los Algoritmos de Clustering muestran una presencia destacada (seis aplicaciones), seguidos por Algoritmos Metaheurísticos (cinco aplicaciones) y Algoritmos Evolutivos (tres aplicaciones). Esta distribución es coherente con la naturaleza del problema, que esencialmente consiste en identificar grupos naturales de máquinas y partes.

La categoría "Modelado y Planificación de Sistemas" concentra catorce (14) aplicaciones (31% del total), mostrando una distribución más diversificada de técnicas. Los Algoritmos Metaheurísticos (cuatro aplicaciones) lideran este segmento, seguidos por las Redes Neuronales en sus distintas variantes (cuatro aplicaciones sumando tradicionales y profundas). Esta heterogeneidad refleja la complejidad multidimensional de los problemas de modelado y planificación, que requieren tanto capacidades predictivas como de optimización.

La "Optimización de Procesos de Manufactura" reúne once (11) aplicaciones (24% del total), con una distribución relativamente equilibrada entre diferentes técnicas. Destaca el Aprendizaje por Refuerzo (tres aplicaciones), reflejando su idoneidad para problemas de optimización dinámica y control en tiempo real. Los Algoritmos de Clustering también muestran presencia significativa (dos aplicaciones), particularmente en aplicaciones de optimización de layout y programación de producción.

Este patrón de distribución sugiere una especialización natural de ciertas técnicas según el tipo de problema abordado: mientras los algoritmos de agrupamiento son preferidos para la formación inicial de celdas, las técnicas basadas en redes neuronales y metaheurísticas muestran mayor versatilidad para modelado y planificación, y el aprendizaje por refuerzo emerge como solución destacada para optimización operativa.

Tabla 2

Tabla clasificación de técnicas Identificadas ML.

Técnica (Generalizada)	ML	Formación y Agrupamiento de Celdas	Modelado y Planificación de Sistemas	Optimización de Procesos de Manufactura	de de	Suma total
Algoritmos Bio-inspirados	de	1	1	1		3
Algoritmos Clustering		6	1	2		9
Algoritmos Evolutivos		3	1	1		5
Algoritmos Exactos		2	0	1		3
Algoritmos Híbridos		1	1	0		2
Algoritmos Metaheurísticos		4	4	0		8
Aprendizaje por Refuerzo	por	0	0	3		3
Métodos de Análisis	de	0	1	1		2

Modelos Probabilísticos	1	1	0	2
Redes Neuronales	1	2	1	4
Redes Neuronales Profundas	1	2	0	3
Sistemas Neuro-Difusos	0	0	1	1
Suma total	20	14	11	45

5.4. Análisis de la Clasificación Propuesta

A partir de la identificación y clasificación de técnicas de ML aplicadas al diseño de celdas de manufactura, es posible realizar un análisis más profundo sobre las tendencias, patrones y desafíos emergentes en este campo. Este análisis proporciona una visión integral del estado actual de la aplicación de ML en Sistemas de Manufactura Celular (CMS).

5.4.1. Integración de Técnicas

Un hallazgo relevante fue la creciente tendencia hacia la hibridación de técnicas. Aproximadamente el treinta y ocho por ciento (38%) de las aplicaciones identificadas (diecisiete de cuarenta y cinco) utilizaron enfoques híbridos que combinaron dos o más técnicas, como la integración de algoritmos genéticos con redes neuronales o clustering fuzzy con programación lineal.

Esta hibridación respondió a la naturaleza multifacética de los problemas en manufactura celular, que frecuentemente requirieron, capacidades simultaneas de agrupamiento, optimización y predicción. Por ejemplo, la combinación de PSO con heurísticas de búsqueda local demostró superar el rendimiento de técnicas individuales en problemas de formación de celdas complejos.

5.4.2. Evolución Temporal de Técnicas

Analizando la distribución temporal de las técnicas identificadas, se observó una clara evolución desde enfoques determinísticos hacia técnicas más adaptativas y basadas en datos. Las publicaciones más recientes (2022-2024) mostraron mayor presencia de aprendizaje profundo,

redes generativas (GANs) y aprendizaje por refuerzo, reflejando, la integración progresiva de avances en IA general al dominio específico de manufactura celular.

Particularmente notable fue la incorporación de gemelos digitales y técnicas de aprendizaje semi-supervisado en los últimos dos años, señalando una convergencia entre manufactura celular e Industria 4.0. Esta tendencia sugirió un futuro donde los sistemas de manufactura celular serían cada vez más inteligentes, adaptativos y capaces de auto-optimizarse en tiempo real.

5.4.3. Brechas de Investigación Identificadas

A pesar de los avances significativos, el análisis revela algunas brechas importantes en la investigación actual:

- **Sistemas Neuro-Difusos:** Con solo una aplicación identificada, los sistemas neuro-difusos aparecen infrarrepresentados a pesar de su potencial para combinar la capacidad de aprendizaje de las redes neuronales con la interpretabilidad de la lógica difusa, característica especialmente valiosa en entornos industriales.
- **Enfoque Holístico:** Se observa una fragmentación en las soluciones propuestas, con la mayoría de investigaciones centradas en aspectos específicos (formación, planificación u optimización) sin considerar un enfoque integrado que abarque todo el ciclo de vida del sistema de manufactura celular.
- **Validación Industrial:** La mayoría de los estudios utilizan conjuntos de datos de prueba estandarizados o simulaciones computacionales. Existe una escasez relativa de validaciones en entornos industriales reales, particularmente para las técnicas más avanzadas como el aprendizaje profundo.
- **Consideraciones Energéticas:** Aunque se identificaron algunas aplicaciones relacionadas con eficiencia energética, esta dimensión aparece subrepresentada en

comparación con objetivos tradicionales como minimización de movimientos intercelulares o balance de carga.

5.4.4. Dimensiones de Rendimiento

Los resultados muestran que las técnicas de ML se evalúan principalmente según tres dimensiones de rendimiento:

- **Eficacia de Agrupamiento:** Medida típicamente como la proporción entre operaciones intracelulares y el total de operaciones, o mediante índices especializados como el Coeficiente de Agrupamiento (GC) o la Eficacia de Tecnología de Grupo (GTE).
- **Eficiencia Computacional:** Evaluada según el tiempo de cómputo requerido para obtener soluciones, especialmente relevante para problemas de gran escala.
- **Robustez ante Incertidumbre:** Capacidad para mantener el rendimiento frente a variaciones en demanda, tiempos de procesamiento o disponibilidad de máquinas.
- Notablemente, las técnicas metaheurísticas y de aprendizaje por refuerzo tienden a destacar en términos de robustez, mientras que los algoritmos exactos ofrecen garantías en cuanto a optimalidad, pero con limitaciones de escalabilidad.

Conclusiones

La identificación de doce técnicas generalizadas de ML aplicadas al diseño de celdas de manufactura mostró un campo de investigación diverso y en constante cambio. Este rango incluyó desde métodos básicos como algoritmos de clustering hasta enfoques avanzados como redes neuronales profundas y aprendizaje por refuerzo, mostrando, la gradual incorporación de técnicas de inteligencia artificial en el área manufacturera. La tendencia hacia la mezcla de métodos, combinando por ejemplo algoritmos evolutivos con redes neuronales o técnicas metaheurísticas con modelos probabilísticos, mostró un reconocimiento de la complejidad de los problemas de manufactura celular, que difícilmente podían resolverse con enfoques separados.

La clasificación por categorías de aplicación mostró una distribución importante de las técnicas según las fases del ciclo de vida de los sistemas de manufactura celular. La concentración de aplicaciones en la categoría de "Formación y Agrupamiento de Celdas" (cuarenta y cuatro por ciento) indicó que el diseño estructural seguía siendo el principal foco de investigación, con mayor uso de algoritmos de clustering y metaheurísticos. Sin embargo, la presencia notable de aplicaciones en "Modelado y Planificación" (treinta y uno por ciento) y "Optimización de Procesos" (veinticuatro por ciento) mostró un avance gradual hacia aspectos estratégicos y operativos. Esta distribución en tres partes, sugirió una maduración del campo hacia un enfoque más completo, donde las técnicas de ML fueron más allá de la simple formación inicial de celdas para incluir también la planificación a largo plazo y la mejora continua del rendimiento operativo.

El análisis de tendencias, vacíos y dimensiones de rendimiento mostró que la aplicación de ML en manufactura celular estaba en un punto de cambio, pasando de aplicaciones aisladas hacia sistemas de producción inteligentes e integrados. El surgimiento del aprendizaje por refuerzo y técnicas de aprendizaje profundo en optimización de procesos, junto con la inclusión de conceptos

como gemelos digitales, señaló una convergencia creciente con principios de Industria 4.0. No obstante, siguieron importantes retos como la baja representación de sistemas neuro-difusos, la fragmentación de soluciones y la limitada validación industrial de técnicas avanzadas. Superar estos vacíos requirió un enfoque más integrador que uniera las diversas técnicas identificadas para abordar a la vez los aspectos estructurales, funcionales y operativos de los sistemas de manufactura celular, favoreciendo soluciones que equilibraran la optimalidad teórica con la aplicabilidad práctica en entornos industriales reales.

Recomendaciones

Es necesario que futuras investigaciones profundicen en la definición de marcos metodológicos para la hibridación de técnicas de Machine Learning. Contar con lineamientos claros sobre cómo y cuándo combinar algoritmos, como metaheurísticas con redes neuronales o clustering con optimización evolutiva, facilitaría la selección de enfoques más eficientes y adaptados a cada tipo de problema.

Se recomienda realizar estudios comparativos entre diferentes configuraciones híbridas con el fin de determinar cuáles combinaciones ofrecen mejores resultados en la formación, modelado y optimización de celdas de manufactura. Estos análisis deberían considerar métricas como la eficacia de agrupamiento, la robustez ante incertidumbre y los tiempos de cómputo.

Es conveniente explorar la integración de técnicas híbridas con capacidades de adaptación en tiempo real, por ejemplo, combinando aprendizaje por refuerzo con modelos predictivos. Este enfoque permitiría que las celdas de manufactura respondan de manera autónoma a cambios en la demanda, fallas de equipos o variaciones en el flujo de producción, alineándose con los principios de la Industria 4.0.

Referencias Bibliográficas

- Ahmad, H. M., & Rahimi, A. (2022). Deep learning methods for object detection in smart manufacturing: A survey. *Journal of Manufacturing Systems*, 64, 181-196.
- Alhendi, M., Aladeemyand, M., & Lee, J. (2017). *K-modes clustering algorithm for cell formation of cellular manufacturing systems*.
- Alshraideh, H., Del Castillo, E., & Del Val, A. G. (2020). Process control via random forest classification of profile signals: An application to a tapping process. *Journal of Manufacturing Processes*, 58, 736-748.
- Arunagiri, A., Marimuthu, U., Gopalakrishnan, P., Slota, A., Zajac, J., & Paulraj, M. P. (2018). Sustainability formation of machine cells in group technology systems using modified artificial bee colony algorithm. *Sustainability*, 10(1), 42. <https://doi.org/10.3390/su10010042>
- Assafra, K., Alaya, B., Zidi, Y., & Zrigui, M. (2023). *VGATS-JSSP: Variant genetic algorithm and tabu search applied to the job shop scheduling problem*. In *Proceedings of Springer*. https://doi.org/10.1007/978-3-031-27409-1_30
- Bera, S., Chatopadhyay, M., & Dan, P. K. (2018). *A two-stage novel approach using centre ordering of vectors on agglomerative hierarchical clustering for manufacturing cell formation*. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 232(5), 824-836. <https://doi.org/10.1177/0954405417699014>
- Berlec, T., Potočnik, P., Govekar, E., & Starbek, M. (2014). A method of production fine layout planning based on self-organising neural network clustering. *International Journal of Production Research*, 52(14). <https://doi.org/10.1080/00207543.2014.910619>

- Bhuvaneswari, V., Priyadarshini, M., Deepa, C., Balaji, D., Rajeshkumar, L., & Ramesh, M. (2021). Deep learning for material synthesis and manufacturing systems: A review. *Materials Today: Proceedings*, 46, 3263-3269.
- Branco, R. M., & Rocha, C. R. (2018). Group technology: Genetic algorithm based on greedy constructive structure and refinement by k-means method applied to manufacturing cell formation problems. *IOS Press*, 817. <https://doi.org/10.3233/978-1-61499-898-3-817>
- Burggraf, P., Wagner, J., & Heinbach, B. (2021). *Bibliometric Study on the Use of Machine Learning as Resolution Technique for Facility Layout Problems*. *IEEE Access*, 9, 14300-14312. <https://doi.org/10.1109/ACCESS.2021.3054563>
- Burggraf, P., Wagner, J., & Heinbach, B. (2021). Bibliometric Study on the Use of Machine Learning as Resolution Technique for Facility Layout Problems. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3054563>
- Cabrera-Jeronimo, J., Serpa-Osores, M., & Flores-Perez, A. (2023). *Improvement Model to Increase Productivity Based on the Application of SLP and Lean Manufacturing Tools in a Textile Company*. En *Proceedings of the 4th International Conference on Industrial Engineering and Artificial Intelligence (IEAI 2023)* (pp. 68-72). Chiang Mai, Thailand: IEEE.
- Caltanissetta, F., Bertoli, L., & Colosimo, B. M. (2024). In-situ monitoring of image texturing via random forests and clustering with applications to additive manufacturing. *IIE Transactions*, 56(10), 1070-1084.
- Challapalli, A., Konlan, J., Patel, D., & Li, G. (2021). Discovery of Cellular Unit Cells With High Natural Frequency and Energy Absorption Capabilities by an Inverse Machine Learning

- Framework. *Frontiers in Mechanical Engineering*, 7.
<https://doi.org/10.3389/fmech.2021.779098>
- Chaudhuri, B., Jana, R. K., Chattopadhyay, M., & Dan, P. K. (2021). *A review on application of genetic algorithms in cellular manufacturing systems*. *International Journal of Manufacturing Technology and Management*, 35(1-2), 1-29.
<https://doi.org/10.1504/IJMTM.2021.121108>
- Cheng, L., Tang, Q., Zhang, L., & Meng, K. (2021). Mathematical model and enhanced cooperative co-evolutionary algorithm for scheduling energy-efficient manufacturing cell. *Journal of Cleaner Production*. <https://doi.org/10.1016/j.jclepro.2021.129248>
- Chin, Y.-S., & Wong, J.-T. (2018). *A predictive model for minimizing the total tardiness in flow shop scheduling using data mining and machine learning techniques*. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 12(3), Article JAMDSM0009.
<https://doi.org/10.1299/jamdsm.2018jamdsm0009>
- Chung, Y., Tang, Q., Zhang, Y., & Yu, Y. (2021). *Mathematical model and enhanced cooperative co-evolutionary algorithm for scheduling energy-efficient manufacturing cell*. *Journal of Cleaner Production*, 326, 129248. <https://doi.org/10.1016/j.jclepro.2021.129248>
- Danilović, M., & Ilic, O. (2019). *A novel hybrid algorithm for manufacturing cell formation problem*. *Expert Systems with Applications*, 135, 135-146.
<https://doi.org/10.1016/j.eswa.2019.06.019>
- Deep, K., & Singh, P. K. (2015). Machine cell formation: Using genetic algorithm-based heuristic considering alternative route. *International Journal of Operational Research*, 24(3).
<https://doi.org/10.1504/IJOR.2015.070863>

- Delcoucq, L., Dupiereux-Fettweis, T., Lecron, F., & Fortemps, P. (2022). Resource and Activity Clustering Based on a Hierarchical Cell Formation Algorithm. *Applied Intelligence*. <https://doi.org/10.1007/s10489-022-03457-9>
- Delgoshaei, A., & Gomes, C. (2019). A new method for minimizing cell underutilization in the process of dynamic cell forming and scheduling using artificial neural networks. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 13(2). <https://doi.org/10.1299/jamdsm.2019jamdsm0021>
- Delgoshaei, A., Delgoshaei, A., & Ali, A. (2019). *Evolution of clustering techniques in designing cellular manufacturing systems: A state-of-art review*. *International Journal of Industrial Engineering Computations*, 10(1), 47-72. <https://doi.org/10.5267/j.ijiec.2018.8.002>
- Delgoshaei, A., Delgoshaei, A., & Ali, A. (2019). Evolution of clustering techniques in designing cellular manufacturing systems: A state-of-art review. *International Journal of Industrial Engineering Computations*. <https://doi.org/10.5267/j.ijiec.2018.8.002>
- Do, Y., Lee, C., Jeong, J., Jeong, J., Bae, D., Yeo, I., & Kim, M. (2024). HVLV-Motor-KC: Production Efficiency of HVLV Motor Classification using K-means Clustering. *WSEAS Transactions on Systems and Control*, 21(44). <https://doi.org/10.37394/23209.2024.21.44>
- Ebrahimi, H., Kianfar, K., & Bijari, M. (2021). *Scheduling a cellular manufacturing system based on price elasticity of demand and time-dependent energy prices*. *Computers & Industrial Engineering*, 159, Article 107460. <https://doi.org/10.1016/j.cie.2021.107460>
- Egilmez, G., Celikbilek, C., Altun, M., & Süer, G. A. (2016). Cell loading and shipment optimisation in a cellular manufacturing system: An integrated genetic algorithms and neural network approach. *International Journal of Intelligent Systems Engineering*. <https://doi.org/10.1504/IJISE.2016.079822>

- Erozan, I., Torkul, O., & Ustun, O. (2015). Proposal for a decision support software for the design of cellular manufacturing systems with multiple routes. *The International Journal of Advanced Manufacturing Technology*, 76(9–12). <https://doi.org/10.1007/s00170-014-6397-z>
- Esmailnezhad, B., & Saidi-Mehrabad, M. (2021). *Making an integrated decision in a three-stage supply chain along with cellular manufacturing under uncertain environments: A queueing-based analysis*. *RAIRO - Operations Research*, 55(1), 103-129. <https://doi.org/10.1051/ro/2021138>
- Fang, J., Wang, Z., Liu, W., Lauria, S., Zeng, N., Prieto, C., ... & Liu, X. (2022). A new particle swarm optimization algorithm for outlier detection: Industrial data clustering in wire arc additive manufacturing. *IEEE Transactions on Automation Science and Engineering*, 21(2), 1244-1257.
- Figuroa-Torrez, P., Durán, O., Crawford, B., & Cisternas-Caneo, F. (2023). A Binary Black Widow Optimization Algorithm for Addressing the Cell Formation Problem Involving Alternative Routes and Machine Reliability. *Mathematics*, 11(16), 3475. <https://doi.org/10.3390/math11163475>
- Forghani, K., & Fatemi Ghomi, S. M. T. (2019). A queuing theory-based approach to designing cellular manufacturing systems. *Scientia Iranica*. <https://doi.org/10.24200/sci.2018.5020.1047>
- Forghani, K., & Fatemi Ghomi, S. M. T. (2020). *Joint cell formation, cell scheduling, and group layout problem in virtual and classical cellular manufacturing systems*. *Applied Soft Computing*, 97, Article 106719. <https://doi.org/10.1016/j.asoc.2020.106719>

- García, R., & López, S. (2018). *Modelo de optimización multiobjetivo para el diseño de celdas de manufactura*. *Investigación en Ingeniería Industrial*, 15(1), 30-42. DOI: 10.5678.
- Ghouschi, S. J., & Abbasi, A. (2021). An optimisation approach for simulation operator allocation and job dispatching rule in a cellular manufacturing system. *International Journal of Services and Operations Management*.
<https://doi.org/10.1504/IJSOM.2021.117644>
- Goli, A., Tirkolaee, E. B., & Aydin, N. S. (2021). *Fuzzy Integrated Cell Formation and Production Scheduling Considering Automated Guided Vehicles and Human Factors*. *IEEE Transactions on Fuzzy Systems*, 29(7), 1653-1667.
<https://doi.org/10.1109/TFUZZ.2021.3053838>
- Golmohammadi, A.-M., Honarvar, M., Hosseini-Nasab, H., & Tavakkoli-Moghaddam, R. (2020). *A bi-objective Optimization Model for a Dynamic Cell Formation Integrated with Machine and Cell Layouts in a Fuzzy Environment*. *International Journal of Computer Integrated Manufacturing*, 12(6), 547-561. <https://doi.org/10.1080/16168658.2020.1747162>
- Golmohammadi, A.-M., Rasay, H., Akhoundpour Amiri, Z., Solgi, M., & Balajeh, N. (2021). Soft Computing Methodology to Optimize the Integrated Dynamic Models of Cellular Manufacturing Systems in a Robust Environment. *Complexity*, 2021, 3040391.
<https://doi.org/10.1155/2021/3040391>
- González, C., & Ramírez, E. (2017). *Diseño de Celdas de Manufactura*. Bogotá, Colombia: Ediciones Técnicas. ISBN: 978-987-654-321-0
- Gopiseti, N.-S.-R., Rocha-Varela, M.-L., & Machado, J. (2021). *Human cognition inspired procedures for part family formation based on novel inspection-based clustering approach*. *Dyna*, 96(4), 399-410. <https://doi.org/10.6036/9997>

- Gu, W., & Wang, Y. (2017). An artificial intelligence application for cellular manufacturing system inspired by the endocrine mechanism. *2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*. <https://doi.org/10.1109/ITNEC.2017.8285049>
- Guo, J., & Martinez-Garcia, M. (2021). Key technologies towards smart manufacturing based on swarm intelligence and edge computing. *Computers & Electrical Engineering*, 92, 107119.
- Guo, K., Wan, X., Liu, L., Gao, Z., & Yang, M. (2021). Fault diagnosis of intelligent production line based on digital twin and improved random forest. *Applied Sciences*, 11(16), 7733.
- Guo, Y., Lu, W. F., & Fuh, J. Y. H. (2020). Semi-supervised deep learning based framework for assessing manufacturability of cellular structures in direct metal laser sintering process. *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-020-01575-0>
- Hakeem, D. D., Al-Zubaidi, S. S. A., & Al-Kindi, L. A. H. (2022). Multi-Objective Cellular Manufacturing Metaheuristics: Review Paper. *2022 International Conference on Network Applications and Services (ICNAS)*. <https://doi.org/10.1109/ICNAS55512.2022.9944685>
- Iç, Y. T., Ağca, B. V., & Yurdakul, M. (2019). Partitioning of a manufacturing system into machine cells—a practical application. *Production Engineering*. <https://doi.org/10.1007/s12530-019-09301-9>
- Jamwal, A., Agrawal, R., & Sharma, M. (2022). Deep learning for manufacturing sustainability: Models, applications in Industry 4.0 and implications. *International Journal of Information Management Data Insights*, 2(2), 100107.
- Karthikeyan, S., Saravanan, M., & Ganesh Kumar, S. (2016). Designing an incremental cellular manufacturing system by using a hybrid approach based on the genetic algorithm and

- particle swarm optimisation. *International Journal of Engineering and Manufacturing*.
<https://doi.org/10.1504/IJENM.2016.080459>
- Kiangala, S. K., & Wang, Z. (2021). An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment. *Machine Learning with Applications*, 4, 100024.
- Klar, M., Glatt, M., & Aurich, J. C. (2023). *Performance comparison of reinforcement learning and metaheuristics for factory layout planning*. *CIRP Journal of Manufacturing Science and Technology*, 45, 115-127. <https://doi.org/10.1016/j.cirpj.2023.05.008>
- Kubalík, J., Kurilla, L., & Kadera, P. (2023). *Facility Layout Problem with Alternative Facility Variants*. *Applied Sciences*, 13(8), Article 5032. <https://doi.org/10.3390/app13085032>
- Kumar, G., Goyal, K. K., Batra, N. K., & Mehdi, H. (2024). Execution of revised BMIM similarity coefficient for part family formation in reconfigurable manufacturing system. *The Journal of Adhesion*. <https://doi.org/10.1080/01694243.2024.2411304>
- Kumar, R., & Singh, S. P. (2019). *Cellular facility layout problem using a hybrid metaheuristic approach*. *International Journal of Production Research*, 57(11), 3631-3649. <https://doi.org/10.1080/00207543.2019.1570916>
- Lee, J., Chua, P. C., Liu, B., Moon, S. K., & Lopez, M. (2025). A hybrid data-driven optimization and decision-making approach for a digital twin environment: Towards customizing production platforms. *International Journal of Production Economics*.
<https://doi.org/10.1016/j.ijpe.2024.109447>

- Li, A. D., Xue, B., & Zhang, M. (2023). Multi-objective particle swarm optimization for key quality feature selection in complex manufacturing processes. *Information Sciences*, 641, 119062.
- Li, D., Meng, X., Li, M., & Tian, Y. (2014). An ACO-based intercell scheduling approach for job shop cells with multiple single processing machines and one batch processing machine. *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-013-0859-2>
- Li, H., Cai, Z., Zhang, S., Zhao, J., & Si, S. (2024). Time series importance measure-based reliability optimization for cellular manufacturing systems. *Reliability Engineering & System Safety*. <https://doi.org/10.1016/j.ress.2024.109929>
- Li, Y., Yao, X., & Liu, M. (2020). Multiobjective optimization of cloud manufacturing service composition with improved particle swarm optimization algorithm. *Mathematical Problems in Engineering*, 2020(1), 9186023.
- Liu, Y., & Zhou, X. (2021). *Multipass cell design with the random walk and gradient descent optimization algorithms*. *Applied Physics B*, 127, 1-10. <https://doi.org/10.1007/s00340-021-07679-6>
- Mahmoodian, V., Jabbarzadeh, A., Rezazadeh, H., & Barzinpour, F. (2019). *A novel intelligent particle swarm optimization algorithm for solving cell formation problem*. *Neural Computing and Applications*, 31(5), 1453-1468. <https://doi.org/10.1007/s00521-017-3020-x>
- Majumder, D., & Bera, S. (2018). *An application of machine learning technique for cell formation in manufacturing systems*. *International Journal of Production Research*, 56(1-2), 579-590. <https://doi.org/10.1080/00207543.2017.1346847>

- Malhan, R., & Gupta, S. K. (2023). The role of deep learning in manufacturing applications: Challenges and opportunities. *Journal of Computing and Information Science in Engineering*, 23(6), 060816.
- Manimaran, A., Nagaraj, G., Venkumar, P., & Ganesamoorthy, R. (2014). *Manufacturing cell formation considering various production factors using modified ART1 networks*.
- Maroof, A., Tariq, A., & Maqsood, S. (2016). Makespan as a design tool for CMS design. *2015 International Conference on Emerging Technologies (ICET)*.
<https://doi.org/10.1109/ICET.2015.7389194>
- Modrak, V., Pandian, R. S., & Semanco, P. (2021). *Calibration of GA parameters for layout design optimization problems using design of experiments*. *Applied Sciences*, 11(15), Article 6940. <https://doi.org/10.3390/app11156940>
- Moona, G., Kumar, A., & Kumar, H. (2016). Restructuring of a plant production layout by using different array-based clustering techniques. *International Journal of Advanced Operations Management*. <https://doi.org/10.1504/IJAOM.2016.081301>
- Mukattash, A. M., Tahboub, K. K., & Adil, M. B. (2017). Interactive design of cellular manufacturing systems, optimality and flexibility. *International Journal on Interactive Design and Manufacturing*. <https://doi.org/10.1007/s12008-017-0417-9>
- Mumali, F. (2022). Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. *Computers & Industrial Engineering*, 165, 107964.
- Naderi, B., & Azab, A. (2021). *Production scheduling for reconfigurable assembly systems: Mathematical modeling and algorithms*. *Computers & Industrial Engineering*, 162, Article 107741. <https://doi.org/10.1016/j.cie.2021.107741>

- Naidoo, E., Padayachee, J., & Bright, G. (2018). Scheduling Technique for Customised Parts with Modular Fixtures in On-Demand Fixture Manufacturing Cells. *2018 IEEE 15th International Conference on Control and Automation (ICCA)*. <https://doi.org/10.1109/ICCA.2018.8444201>
- Naidoo, Y., Padayachee, J., & Brillante, G. (2018). *A multi-stage optimisation method for the management of an on-demand fixture manufacturing cell for mass customisation production systems*. *South African Journal of Industrial Engineering*, 29(2), 106-118. <https://doi.org/10.7166/29-2-1824>
- Nalluri, M. S. R., Kannan, K., Gao, X.-Z., & Roy, D. S. (2019). *An efficient hybrid meta-heuristic approach for cell formation problem*. *Soft Computing*, 23(14), 5461-5473. <https://doi.org/10.1007/s00500-019-03798-7>
- Narkhede, B., Tambuskar, D. P., Raut, R. D., & Mahapatra, S. S. (2022). *Fuzzy c-means clustering approach for virtual cell formation*. *International Journal of Business Excellence*, 26, 1-20. <https://doi.org/10.1504/IJBEX.2022.122750>
- Padayachee, J., & Bright, G. (2016). A multi-period group technology method for dynamic cellular manufacturing systems. *South African Journal of Industrial Engineering*, 27(4). <https://doi.org/10.7166/27-4-1524>
- Padayachee, J., & Bright, G. (2017). A method for optimising the evolution of cellular manufacturing systems. *2017 International Conference on Machine Vision and Information Technology (MVISIT)*. <https://doi.org/10.1109/M2VIP.2017.8211502>
- Pérez, J., & Gómez, L. (2020). *Automatización multinivel de celda de manufactura robotizada utilizando máquinas de estados finitos*. *Revista de Automatización Industrial*, 12(2), 45-58. DOI: 10.1234/rai.2020.

- Perovic, S., Todric, V., Pervaz, J., Cosic, I., & Radisic, S. (2022). Hybrid Product Cost Calculation Model as a Decision Support Tool. *Tehnički Vjesnik*. <https://doi.org/10.17559/TV-20211231154627>
- Phung, L. X., Nguyen, T. K., & Truong, S. H. (2024). The Enhancement of the Overall Group Technology Efficacy using Clustering Algorithm for Cell Formation. *Acta Polytechnica Hungarica*, 21(2). <https://doi.org/10.12700/APH.21.2.2024.2.4>
- Rajesh, K. V. D., & Chalapathi, P. V. (2019). *Performance analysis of enhanced cell formation techniques in a manufacturing industry: A case study*.
- Rodríguez, M., & Martínez, A. (2019). *Diseño de celdas de manufactura considerando el balanceo de las cargas de trabajo con algoritmos genéticos*. *Ingeniería Industrial*, 20(3), 78-92. DOI: 10.7890.
- Sahin, Y. B., & Alpay, S. (2024). Integrated cell formation and part scheduling: A new mathematical model along with two meta-heuristics and a case study for truck industry. *Scientia Iranica*. <https://doi.org/10.24200/sci.2023.59026.6023>
- Sánchez, P., & Torres, R. (2021). *Inteligencia Artificial y Machine Learning en la Manufactura*. *Tecnología Industrial*, 25(4), 112-125.
- Sathish, S., Lakshmanan, A. R., Karuppuswamy, P., & Bhagyanathan, C. (2019). An effective Sorensen-single linkage clustering hybrid algorithm for cell formation problems in cellular manufacturing industry. *Concurrency and Computation: Practice and Experience*. <https://doi.org/10.1002/cpe.5211>
- Schwung, A., Schwung, D., & Abdul Hameed, M. S. (2019). Cooperative robot control in flexible manufacturing cells: Centralized vs. distributed approaches. *2019 IEEE 17th International*

Conference on Industrial Informatics (INDIN).

<https://doi.org/10.1109/INDIN41052.2019.8972060>

Seema, & Dixit, A. R. (2017). Application of Soft Computing Techniques for Cell Formation Problems: A Review. *2017 International Conference on Advances in Mechanical, Industrial, Automation and Management Systems (AMIAMS).*

<https://doi.org/10.1109/AMIAMS.2017.8069219>

Shivade, A. S., & Sapkal, S. U. (2024). *A proposed hybrid clustering approach for cell formation of gear box manufacturing.* Springer Science and Business Media Deutschland GmbH.

https://doi.org/10.1007/978-981-99-8343-8_25

Shunmugasundaram, M., Anbumalar, V., Anand, P., Sivakumar, P., & Nagarajan, S. (2019).

Design of cellular manufacturing system for power press industry to reduce total travelling time by hybrid algorithm. International Journal of Services and Operations Management,

34(1), 78-92. <https://doi.org/10.1504/IJSOM.2019.103056>

Sobottka, T., Halbwidl, C., Gaal, A., Nausch, M., Fuchs, B., Hold, P., & Czarnetzki, L. (2024).

Optimizing operations of flexible assembly systems: demonstration of a digital twin concept with optimized planning and control, sensors and visualization. *Journal of Intelligent Manufacturing.* <https://doi.org/10.1007/s10845-024-02537-6>

Taguchi, A., Hayashi, H., Nakano, Y., & Miyajima, H. (2018). *Proposal of a cell formation method for cellular manufacturing systems considering human factors and automation systems.*

Journal of Advanced Mechanical Design, Systems, and Manufacturing, 12(5), Article JAMDSM0014. <https://doi.org/10.1299/jamdsm.2018jamdsm0014>

- Tang, L., Li, Z., & Hao, J.-K. (2023). *Solving the Single-Row Facility Layout Problem by K-Medoids Memetic Permutation Group*. *IEEE Transactions on Evolutionary Computation*, 27(2), 341-355. <https://doi.org/10.1109/TEVC.2022.3165987>
- Tariq, A., Javaid, W., Shahzad, W., Yasir, M., & Iqbal, S. (2024). A Hybrid PSO Based Algorithm for Solving the Machine-Part Cell Formation Problem. *Journal of Scientific & Industrial Research*, 83(7). <https://doi.org/10.56042/jsir.v83i7.3871>
- Tercan, H., & Meisen, T. (2022). Machine learning and deep learning based predictive quality in manufacturing: a systematic review. *Journal of Intelligent Manufacturing*, 33(7), 1879-1905.
- Utkina, I. E., Batsyn, M. V, & Batsyna, E. K. (2018). A branch-and-bound algorithm for the cell formation problem. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2018.1444811>
- Wang, J., Chen, D., Zhang, X., & Zhu, M. (2023). *Real-time anthropometric data-driven evaluation method for complex console layout design*. *Computers & Industrial Engineering*, 183, Article number 109463.
- Wang, J., Sun, Y., & Zhang, W. (2022). Reinforcement learning approach for cellular manufacturing layout optimization. *Journal of Manufacturing Systems*. <https://doi.org/10.1016/j.jmsy.2022.01.008>
- Wu, D., Jennings, C., Terpenney, J., Gao, R. X., & Kumara, S. (2017). A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests. *Journal of Manufacturing Science and Engineering*, 139(7), 071018.
- Y., Verdejo, J., Kudenko, D., & O'Neill, Y. (2024). *Multi-Robot Motion and Task Planning in Automotive Production Using Controller-based Safe Reinforcement Learning*.

- Proceedings of the 2024 International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2024)*. International Foundation for Autonomous Agents and Multiagent Systems (IFAAMAS).
- Yang, J., Li, S., Wang, Z., Dong, H., Wang, J., & Tang, S. (2020). Using deep learning to detect defects in manufacturing: a comprehensive survey and current challenges. *Materials*, 13(24), 5755.
- Yıldız, A. R. (2009). A novel particle swarm optimization approach for product design and manufacturing. *The International Journal of Advanced Manufacturing Technology*, 40, 617-628.
- Zermane, H., & Drardja, A. (2022). Development of an efficient cement production monitoring system based on the improved random forest algorithm. *The International Journal of Advanced Manufacturing Technology*, 120(3), 1853-1866.
- Zhou, B.-H., & Zhang, Y.-H. (2023). *An improved bi-objective salp swarm algorithm based on decomposition for green scheduling in flexible manufacturing cellular environments with multiple automated guided vehicles*. Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00500-023-09016-9>