



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

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

Michael Steven Castro Sánchez ¹

¹Grupo de investigación OPALO, Universidad Industrial de Santander, Colombia. Orcid: xx. correo electrónico: michael2194075@correo.uis.edu.co

Recibido: dd mes aaaa. Aceptado: dd mes aaaa. Versión final: dd mes aaaa

Resumen

Este estudio exploratorio identificó y clasificó las principales técnicas de Machine Learning (ML) aplicadas al diseño de celdas de manufactura mediante una revisión sistemática siguiendo la metodología PRISMA. Se identificaron doce técnicas generalizadas, entre ellas algoritmos de clustering, metaheurísticos, evolutivos, redes neuronales, aprendizaje por refuerzo y sistemas neuro-difusos. El análisis de cuarenta y cinco (45) aplicaciones reveló que la "Formación y Agrupamiento de Celdas" predomina con un cuarenta y cuatro por ciento (44%) de las aplicaciones, mientras que el "Modelado y Planificación de Sistemas" y la "Optimización de Procesos" representaron el treinta y uno por ciento (31%) y veinticuatro por ciento (24%) respectivamente. Se observó una tendencia creciente hacia la hibridación de técnicas y la evolución desde enfoques determinísticos hacia métodos más adaptativos, con mayor presencia reciente de aprendizaje profundo, redes generativas y aprendizaje por refuerzo. El estudio identificó brechas en la investigación, como la subrepresentación de sistemas neuro-difusos, la fragmentación de soluciones y la limitada validación industrial de técnicas avanzadas, señalando la necesidad de enfoques más integradores que aborden simultáneamente los aspectos estructurales, funcionales y operativos de los sistemas de manufactura celular.

Palabras clave: Machine Learning; Manufactura Celular; Formación de Celdas; Tecnología de Grupo; Inteligencia Artificial.

Abstract

This exploratory study identified and classified the main Machine Learning (ML) techniques applied to manufacturing cell design through a systematic review following the PRISMA methodology. Twelve generalized techniques were identified, including clustering algorithms, metaheuristics, evolutionary algorithms, neural networks, reinforcement learning, and neuro-fuzzy systems. The analysis of forty-five (45) applications revealed that "Cell Formation and Grouping" predominates with forty-four percent (44%) of applications, while "System Modeling and Planning" and "Process Optimization" represented thirty-one percent (31%) and twenty-four percent (24%) respectively. A growing

trend was observed towards the hybridization of techniques and evolution from deterministic approaches to more adaptive methods, with a recent increased presence of deep learning, generative networks, and reinforcement learning. The study identified research gaps, such as the underrepresentation of neuro-fuzzy systems, the fragmentation of solutions, and the limited industrial validation of advanced techniques, indicating the need for more integrative approaches that simultaneously address the structural, functional, and operational aspects of cellular manufacturing systems..

Keywords: Machine Learning; Cellular Manufacturing; Cell Formation; Group Technology; Artificial Intelligence.

1. 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 [1]. 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 [1], [2].

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 [1]. 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 [2].

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.

2. Metodología

La investigación se desarrolló mediante una revisión sistemática de la literatura siguiendo la metodología 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.

2.1. Revisión de literatura gris

La exploración inicial de literatura gris se realizó a través de Google Académico y el buscador general de la Biblioteca de la Universidad, con el objetivo de obtener una comprensión preliminar del tema y orientar la investigación. Esto permite identificar palabras clave potenciales, cómo:

- Cellular manufacturing, Cell manufacturing, Cell formation, Cell formation, Group technology, Group technology, Group technology.
- Machine Learning, ML, Artificial Intelligence, AI.
- Neural Networks, ANN, Unsupervised Learning, Self-Organizing Maps, SOM, Hopfield Networks, Kohonen Networks, Clustering.

2.2. Selección de base de datos

La base de datos elegida para llevar a cabo la búsqueda y recopilación de información en este estudio es Scopus. Scopus es una amplia base de datos bibliográfica de alcance multidisciplinario que abarca una gran variedad de revistas científicas, libros, actas de conferencias y otras fuentes pertinentes.

Scopus simplifica la búsqueda de documentos relacionados con el tema de investigación en diversas áreas del conocimiento. Además, proporciona herramientas para organizar y filtrar la información por año, tipo de documento, materia y otros criterios, lo que permite refinar los resultados y seleccionar aquellos que son relevantes para este estudio.

2.3. Formulación ecuación de búsqueda

La búsqueda las palabras clave descubiertas durante la revisión preliminar de literatura gris, se llevaron a cabo múltiples iteraciones en la base de datos Scopus.

Tabla 1. Ecuación de búsqueda

Bases de Datos	Ecuación de búsqueda	Resultados
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")))	1.654

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.

Resultados de la búsqueda inicial arrojó un total de 1,654 referencias potencialmente relevantes, estableciendo el corpus inicial para el proceso de cribado.

2.4. Cribado

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

Tabla 2. Fase de selección

Criterios	Descripción
De Inclusión	<ul style="list-style-type: none"> • 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
	<ul style="list-style-type: none"> • 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

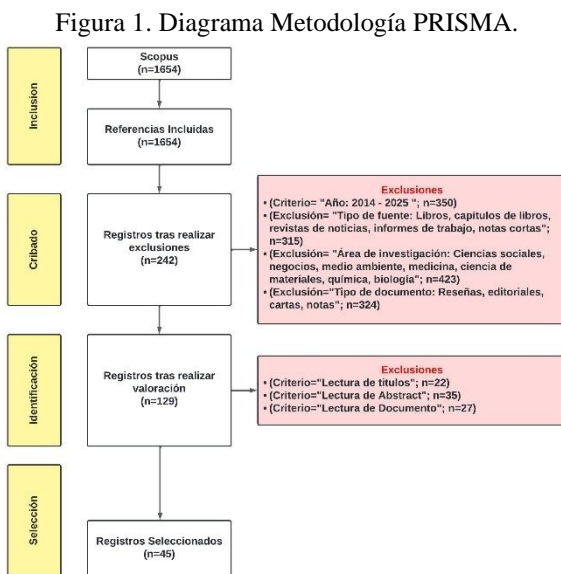
Usando la ecuación de búsqueda inicial, donde se obtuvieron 1.654 artículos en la base de datos Scopus. Posteriormente, se aplicaron criterios de inclusión y exclusión, reduciendo el número de artículos a 129, representando una reducción del 92.2% y asegurando la relevancia temática y metodológica de la literatura seleccionada.

2.5. Selección

El proceso de selección consistió en una revisión exhaustiva de las 129 referencias obtenidas inicialmente. Esta evaluación se llevó a cabo en tres niveles: primero, se realizó una revisión de títulos para hacer una evaluación preliminar sobre la relevancia temática de

cada documento; luego, se procedió al análisis de resúmenes con el fin de identificar si los artículos abordaban metodologías, objetivos y resultados relacionados con el enfoque del estudio; y finalmente, en los casos en que la información del resumen no era suficiente para determinar la pertinencia, se revisó el texto completo. Para la selección final de los artículos incluidos en el análisis, se aplicaron criterios específicos como la relevancia temática directa, es decir, que aplicaran técnicas de machine learning específicamente al diseño de celdas de manufactura; la calidad metodológica, valorando que se describiera con claridad la técnica de ML empleada; la contribución significativa, entendida como una propuesta innovadora o una mejora clara respecto a trabajos anteriores; y finalmente, el rigor científico, evidenciado en la validación de resultados y su comparación con métodos existentes.

A continuación, en la figura 1 se ilustra el proceso que se realizó:



Fuente: Elaboración propia.

Al final se seleccionaron 45 documentos relevantes.

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

3.1. 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 [3], [4]
- Fuzzy C-means (FCM) y Fuzzy C-Medoids (FCMdd) [5], [6]
- Clustering Jerárquico (SLINK, CLINK, ALINK) [7]
- K-modes para datos categóricos [8]
- Rank Order Clustering (ROC) [9], [10]
- Técnicas basadas en coeficientes de similitud como BMIM y Sorensen-SLC [11], [12], [13]

3.2. 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) [14]
- Recocido Simulado (SA) [15]
- Búsqueda Tabú (TS) [15]
- Algoritmo de Colonia de Abejas Artificiales Modificado (MABC) [16]

3.3. 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 [17], [18]
- Algoritmos Genéticos con función de aptitud basada en makespan [19]
- Algoritmos Genéticos con estructura constructiva voraz y refinamiento [4]
- Algoritmos Genéticos Multiobjetivo con Escalarización Cónica [20], [21]

3.4. 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) [22]
- Redes ART1 Modificadas (MART1) [23]

3.5. 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 [24], [25] y Perceptrón Multicapa (MLP) [26]
- Redes de Memoria a Largo Plazo (LSTM) [27]
- Redes Generativas Adversarias (GANs) [28]
- Autoencoders Denoising Apilados (SDAE) [29]
- Aprendizaje profundo semi-supervisado (SSDLMA) [29], [30]

3.6. 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 [31], [32]
- Algoritmos Actor-Critic (A2C) [33], [34]
- Aprendizaje por refuerzo con algoritmos de optimización como ACO [35]

3.7. 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 [21]
- Modelos de revisión de técnicas probabilísticas para formación de celdas [36]

3.8. Algoritmos Híbridos

En caso de 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 [24]
- Clustering Jerárquico con técnicas complementarias de optimización [7]

3.9. 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) [37], [38]
- Algoritmo de Colonia de Hormigas (ACO) [39], [40]
- Algoritmo basado en el mecanismo de regulación endocrina [41], [42]

3.10. 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) [43]
- Método basado en números de Stirling [1]
- Programación Lineal Entera Mixta (MILP) [6]

3.11. 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 [40]
- Análisis Bibliométrico de técnicas de ML [2]
- Cooperative co-evolutionary algorithm (ECCA) [32], [44]

3.12. 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) [44], [45]

4. 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:

4.1. 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.

4.2. 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 Figura 2.), 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 Figura 2.), 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 Figura 2.), 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 3. Clasificación de técnicas Identificadas.

Técnica ML (Generalizada)	Formación y Agrupamiento de Celdas	Modelado y Planificación de Sistemas	Optimización de Procesos de Manufactura	Suma total
Algoritmos Bio-inspirados	1	1	1	3
Algoritmos de 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	0	0	3	3
Métodos de Análisis Modelos Probabilísticos	0	1	1	2
Redes Neuronales	1	1	0	2
Redes Neuronales Profundas	1	2	1	4
Sistemas Neuro-Difusos	1	2	0	3
Sistemas Neuro-Difusos	0	0	1	1
Suma total	20	14	11	45

4.3. 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).




Figura 2. Diagrama circular recuento de categorías de aplicaciones identificadas.

4.4. 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 simultáneas 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.

4.5. 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.

4.6. 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.

4.7. 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.

5. 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.

6. Referencias

- [1] A. M. Mukattash, K. K. Tahboub, and M. B. Adil, "Interactive design of cellular manufacturing systems, optimality and flexibility," *International Journal on Interactive Design and Manufacturing*, 2017, doi: 10.1007/s12008-017-0417-9.
- [2] P. Burggraf, J. Wagner, and B. Heinbach, "Bibliometric Study on the Use of Machine Learning as Resolution Technique for Facility Layout Problems," *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3054563.
- [3] Y. Do *et al.*, "HVLV-Motor-KC: Production Efficiency of HVLV Motor Classification using K-means Clustering," *WSEAS Transactions on Systems and Control*, vol. 21, no. 44, 2024, doi: 10.37394/23209.2024.21.44.
- [4] R. M. Branco and C. R. Rocha, "Group technology: Genetic algorithm based on greedy constructive structure and refinement by k-means method applied to manufacturing cell formation problems," in *IOS Press*, 2018, p. 817. doi: 10.3233/978-1-61499-898-3-817.
- [5] J. Padayachee and G. Bright, "A multi-period group technology method for dynamic cellular manufacturing systems," *South African Journal of Industrial Engineering*, vol. 27, no. 4, 2016, doi: 10.7166/27-4-1524.
- [6] J. Padayachee and G. Bright, "A method for optimising the evolution of cellular manufacturing systems," in *2017 International Conference on Machine Vision and Information Technology (MVIT)*, 2017. doi: 10.1109/M2VIP.2017.8211502.
- [7] L. Delcoudq, T. Dupiereux-Fettweis, F. Lecron, and P. Fortemps, "Resource and Activity Clustering Based on a Hierarchical Cell Formation Algorithm," *Applied Intelligence*, 2022, doi: 10.1007/s10489-022-03457-9.
- [8] M. Alhendi, M. Aladeemyand, and J. Lee, "K-modes clustering algorithm for cell formation of cellular manufacturing systems," 2017.
- [9] G. Moona, A. Kumar, and H. Kumar, "Restructuring of a plant production layout by using different array-based clustering techniques," *International Journal of Advanced Operations Management*, 2016, doi: 10.1504/IJAOM.2016.081301.
- [10] Y. T. Iç, B. V. Ağca, and M. Yurdakul, "Partitioning of a manufacturing system into machine cells—a practical application," *Production Engineering*, 2019, doi: 10.1007/s12530-019-09301-9.
- [11] G. Kumar, K. K. Goyal, N. K. Batra, and H. Mehdi, "Execution of revised BMIM similarity coefficient for part family formation in reconfigurable manufacturing system," *J Adhes*, 2024, doi: 10.1080/01694243.2024.2411304.
- [12] L. X. Phung, T. K. Nguyen, and S. H. Truong, "The Enhancement of the Overall Group Technology Efficacy using Clustering Algorithm for Cell Formation," *Acta Polytechnica Hungarica*, vol. 21, no. 2, 2024, doi: 10.12700/APH.21.2.2024.2.4.
- [13] S. Sathish, A. R. Lakshmanan, P. Karuppuswamy, and C. Bhagyanathan, "An effective Sorensen-single linkage clustering hybrid algorithm for cell formation problems in cellular manufacturing industry," *Concurr Comput*, 2019, doi: 10.1002/cpe.5211.
- [14] P. Figueroa-Torrez, O. Durán, B. Crawford, and F. Cisternas-Caneo, "A Binary Black Widow Optimization Algorithm for Addressing the Cell Formation Problem Involving Alternative Routes and Machine Reliability," *Mathematics*, vol. 11, no. 16, p. 3475, 2023, doi: 10.3390/math11163475.
- [15] D. D. Hakeem, S. S. A. Al-Zubaidi, and L. A. H. Al-Kindi, "Multi-Objective Cellular Manufacturing Metaheuristics: Review Paper," in *2022 International Conference on Network Applications and Services (ICNAS)*, 2022. doi: 10.1109/ICNAS55512.2022.9944685.

- [16] A. Arunagiri, U. Marimuthu, P. Gopalakrishnan, A. Slota, J. Zajac, and M. P. Paulraj, "Sustainability formation of machine cells in group technology systems using modified artificial bee colony algorithm," *Sustainability*, vol. 10, no. 1, p. 42, 2018, doi: 10.3390/su10010042.
- [17] K. Deep and P. K. Singh, "Machine cell formation: Using genetic algorithm-based heuristic considering alternative route," *International Journal of Operational Research*, vol. 24, no. 3, 2015, doi: 10.1504/IJOR.2015.070863.
- [18] A.-M. Golmohammadi, H. Rasay, Z. A. Amiri, M. Solgi, and N. Balajeh, "Soft Computing Methodology to Optimize the Integrated Dynamic Models of Cellular Manufacturing Systems in a Robust Environment," *Complexity*, vol. 2021, p. 3040391, 2021, doi: 10.1155/2021/3040391.
- [19] A. Maroof, A. Tariq, and S. Maqsood, "Makespan as a design tool for CMS design," in *2015 International Conference on Emerging Technologies (ICET)*, 2016. doi: 10.1109/ICET.2015.7389194.
- [20] I. Erozan, O. Torkul, and O. Ustun, "Proposal for a decision support software for the design of cellular manufacturing systems with multiple routes," *The International Journal of Advanced Manufacturing Technology*, vol. 76, no. 9–12, 2015, doi: 10.1007/s00170-014-6397-z.
- [21] Y. B. Sahin and S. Alpay, "Integrated cell formation and part scheduling: A new mathematical model along with two meta-heuristics and a case study for truck industry," *Scientia Iranica*, 2024, doi: 10.24200/sci.2023.59026.6023.
- [22] T. Berlec, P. Potočnik, E. Govekar, and M. Starbek, "A method of production fine layout planning based on self-organising neural network clustering," *Int J Prod Res*, vol. 52, no. 14, 2014, doi: 10.1080/00207543.2014.910619.
- [23] A. Manimaran, G. Nagaraj, P. Venkumar, and R. Ganesamoorthy, "Manufacturing cell formation considering various production factors using modified ART1 networks," 2014.
- [24] G. Egilmez, C. Celikkilek, M. Altun, and G. A. Süer, "Cell loading and shipment optimisation in a cellular manufacturing system: An integrated genetic algorithms and neural network approach," *International Journal of Intelligent Systems Engineering*, 2016, doi: 10.1504/IJISE.2016.079822.
- [25] S. J. Ghoushchi and A. Abbasi, "An optimisation approach for simulation operator allocation and job dispatching rule in a cellular manufacturing system," *International Journal of Services and Operations Management*, 2021, doi: 10.1504/IJSOM.2021.117644.
- [26] A. Delgoshaei and C. Gomes, "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*, vol. 13, no. 2, 2019, doi: 10.1299/jamdsm.2019jamdsm0021.
- [27] T. Sobottka *et al.*, "Optimizing operations of flexible assembly systems: demonstration of a digital twin concept with optimized planning and control, sensors and visualization," *J Intell Manuf*, 2024, doi: 10.1007/s10845-024-02537-6.
- [28] A. Challapalli, J. Konlan, D. Patel, and G. Li, "Discovery of Cellular Unit Cells With High Natural Frequency and Energy Absorption Capabilities by an Inverse Machine Learning Framework," *Front Mech Eng*, vol. 7, 2021, doi: 10.3389/fmech.2021.779098.
- [29] Y. Guo, W. F. Lu, and J. Y. H. Fuh, "Semi-supervised deep learning based framework for assessing manufacturability of cellular structures in direct metal laser sintering process," *J Intell Manuf*, 2020, doi: 10.1007/s10845-020-01575-0.
- [30] E. Naidoo, J. Padayachee, and G. Bright, "Scheduling Technique for Customised Parts with Modular Fixtures in On-Demand Fixture Manufacturing Cells," in *2018 IEEE 15th International Conference on Control and Automation (ICCA)*, 2018. doi: 10.1109/ICCA.2018.8444201.
- [31] J. Wang, Y. Sun, and W. Zhang, "Reinforcement learning approach for cellular manufacturing layout optimization," *J Manuf Syst*, 2022, doi: 10.1016/j.jmsy.2022.01.008.
- [32] L. Cheng, Q. Tang, L. Zhang, and K. Meng, "Mathematical model and enhanced cooperative co-evolutionary algorithm for scheduling energy-efficient manufacturing cell," *J Clean Prod*, 2021, doi: 10.1016/j.jclepro.2021.129248.
- [33] A. Schwung, D. Schwung, and M. S. A. Hameed, "Cooperative robot control in flexible manufacturing cells: Centralized vs. distributed approaches," in *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*, 2019. doi: 10.1109/INDIN41052.2019.8972060.
- [34] K. V. D. Rajesh and P. V. Chalapathi, "Performance analysis of enhanced cell formation techniques in a manufacturing industry: A case study," 2019.
- [35] K. Forghani and S. M. T. F. Ghomi, "A queuing theory-based approach to designing cellular

- manufacturing systems,” *Scientia Iranica*, 2019, doi: 10.24200/sci.2018.5020.1047.
- [36] J. Lee, P. C. Chua, B. Liu, S. K. Moon, and M. Lopez, “A hybrid data-driven optimization and decision-making approach for a digital twin environment: Towards customizing production platforms,” *Int J Prod Econ*, 2025, doi: 10.1016/j.ijpe.2024.109447.
- [37] S. Karthikeyan, M. Saravanan, and S. G. Kumar, “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*, 2016, doi: 10.1504/IJENM.2016.080459.
- [38] A. Tariq, W. Javaid, W. Shahzad, M. Yasir, and S. Iqbal, “A Hybrid PSO Based Algorithm for Solving the Machine-Part Cell Formation Problem,” *J Sci Ind Res (India)*, vol. 83, no. 7, 2024, doi: 10.56042/jsir.v83i7.3871.
- [39] D. Li, X. Meng, M. Li, and Y. Tian, “An ACO-based intercell scheduling approach for job shop cells with multiple single processing machines and one batch processing machine,” *J Intell Manuf*, 2014, doi: 10.1007/s10845-013-0859-2.
- [40] H. Li, Z. Cai, S. Zhang, J. Zhao, and S. Si, “Time series importance measure-based reliability optimization for cellular manufacturing systems,” *Reliab Eng Syst Saf*, 2024, doi: 10.1016/j.ress.2024.109929.
- [41] W. Gu and Y. Wang, “An artificial intelligence application for cellular manufacturing system inspired by the endocrine mechanism,” in *2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, 2017, doi: 10.1109/ITNEC.2017.8285049.
- [42] A. Delgoshaei, A. Delgoshaei, and A. Ali, “Evolution of clustering techniques in designing cellular manufacturing systems: A state-of-art review,” *International Journal of Industrial Engineering Computations*, vol. 10, no. 2, 2019, doi: 10.5267/j.ijiec.2018.8.002.
- [43] I. E. Utkina, M. V Batsyn, and E. K. Batsyna, “A branch-and-bound algorithm for the cell formation problem,” *Int J Prod Res*, 2018, doi: 10.1080/00207543.2018.1444811.
- [44] S. Perovic, V. Todic, J. Pervaz, I. Cosic, and S. Radisic, “Hybrid Product Cost Calculation Model as a Decision Support Tool,” *Tehnički vjesnik*, 2022, doi: 10.17559/TV-20211231154627.
- [45] Seema and A. R. Dixit, “Application of Soft Computing Techniques for Cell Formation Problems: A Review,” in *2017 International Conference on Advances in Mechanical, Industrial, Automation and Management Systems (AMIAMS)*, 2017, doi: 10.1109/AMIAMS.2017.8069219.