Research Club Scientia Vol. 4, No 4
Frecuencia: Octubre–Diciembre 2026
ISSN: 3103 - 1315
DOI: https://doi.org/10.65415/mxwrgr77

Aprendizaje automático para la optimización de parámetros y el control adaptativo de la porosidad en la fabricación aditiva de metales por fusión láser en lecho de polvo: una revisión bibliográfica

Machine learning for parameter optimization and adaptive control of porosity in laser powder bed fusion of metals: a literature review

Apprendimento automatico per l'ottimizzazione dei parametri e il controllo adattivo della porosità nella fusione laser a letto di polvere dei metalli: una revisione bibliografica

Nexer Isaac Jara Vargas[I]
njarav3@unemi.edu.ec
ORCID: https://orcid.org/0009-0001-6725-0341
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Miguel Jhair Plaza Vera[I]
njarav3@unemi.edu.ec
ORCID: https://orcid.org/0009-0004-2168-2909
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Byron Jeampetter Arroba Plaza[I]
barrobap@unemi.edu.ec
ORCID: https://orcid.org/0009-0006-4403-8344
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

José Eduardo López Pazmiño[I]
jlopezp18@unemi.edu.ec
ORCID: https://orcid.org/0009-0008-8681-7172
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Jorge Tomas Holguín Anzules[I]
jholguina7@unemi.edu.ec
ORCID: https://orcid.org/0000-0003-4454-4184
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Correspondencia: njarav3@unemi.edu.ec

Artículo de Investigación

***Aceptado:** 26, Noviembre, 2026 ***Publicado:** 27, Noviembre, 2026

I. Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Resumen

La fusión láser en lecho de polvo (LPBF) hace posible producir piezas metálicas de forma compleja, aunque la porosidad, que surge cuando la energía aportada es escasa (falta de fusión) o excesiva (keyhole), limita su uso industrial. Esta revisión bibliográfica narrativa examina qué evidencia existe sobre el aporte de la inteligencia artificial a la reducción de ese defecto mediante la optimización de parámetros, el monitoreo y las estrategias de control. Se analizaron 23 estudios publicados entre 2016 y 2026, hallados con buscadores académicos y plataformas editoriales, y se ordenaron en cinco categorías. Los modelos supervisados (XGBoost, procesos gaussianos, redes neuronales) permiten ubicar, con pocos ensayos, condiciones de proceso con densidad relativa superior al 98 %; las redes convolucionales y los fotodiodos detectan anomalías durante la impresión; y las estrategias de control, que incluyen aprendizaje por refuerzo y gemelos digitales, ajustan potencia y velocidad del láser, aunque su evidencia es sobre todo numérica. Persisten vacíos: escasa demostración experimental de control adaptativo real en LPBF, dependencia del material y falta de datos abiertos. La evidencia sugiere que estas herramientas pueden contribuir a reducir la porosidad, pero la demostración en máquinas reales es todavía limitada y exige validación. Las conclusiones se circunscriben a los 23 estudios revisados.

Palabras clave: fabricación aditiva; fusión láser en lecho de polvo; aprendizaje automático; porosidad; control adaptativo.

Abstract

Laser powder bed fusion (LPBF) allows complex metal components to be built, yet porosity, which appears when the energy delivered is too low (lack of fusion) or too high (keyhole), restricts its industrial use. This narrative literature review examines what evidence exists on the contribution of artificial intelligence to reducing that defect through parameter optimization, monitoring and control strategies. Twenty-three studies published from 2016 to 2026, found with academic search engines and publisher platforms, were analyzed and sorted into five categories. Supervised models (XGBoost, Gaussian processes, neural networks) locate, with few trials, process conditions with relative density above 98 %; convolutional networks and photodiodes detect anomalies during printing; and control strategies, including reinforcement learning and digital twins, adjust laser power and speed, although their evidence is mostly numerical. Gaps remain: little experimental demonstration of real adaptive control in LPBF, material dependence and a lack of open data. The evidence suggests that these tools can help reduce porosity, but demonstration on real machines is still limited and requires validation. Conclusions are restricted to the 23 studies reviewed.

Keywords: additive manufacturing; laser powder bed fusion; machine learning; porosity; adaptive control.

Riassunto

La fusione laser a letto di polvere (LPBF) permette di realizzare componenti metallici complessi, ma la porosità, dovuta a energia scarsa (mancanza di fusione) o eccessiva (keyhole), ne limita l'uso industriale. Questa revisione narrativa della letteratura esamina quali evidenze esistano sul contributo dell'intelligenza artificiale alla riduzione di tale difetto tramite ottimizzazione dei parametri, monitoraggio e strategie di controllo. Sono stati analizzati 23 studi pubblicati tra il 2016 e il 2026, raggruppati in cinque categorie. I modelli supervisionati individuano, con pochi esperimenti, condizioni di processo con densità relativa superiore al 98 %; le reti convoluzionali e i fotodiodi rilevano anomalie durante la stampa; le strategie di controllo, tra cui apprendimento per rinforzo e gemelli digitali, regolano potenza e velocità del laser, ma le prove sono per lo più numeriche. Restano lacune: scarsa dimostrazione sperimentale di un controllo adattivo reale in LPBF, dipendenza dal materiale e mancanza di dati aperti. Le evidenze suggeriscono che questi strumenti possano contribuire a ridurre la porosità, ma la dimostrazione su macchine reali è ancora limitata e richiede validazione. Le conclusioni si limitano ai 23 studi esaminati.

Parole chiave: fabbricazione additiva; fusione laser a letto di polvere; apprendimento automatico; porosità; controllo adattivo.

1. Introducción

La fabricación aditiva (FA) de metales dejó de ser solo una herramienta para prototipos y hoy se usa para obtener piezas finales en áreas como la aeroespacial, la biomédica y la energética. La técnica más difundida es la fusión láser en lecho de polvo (LPBF), en la que un láser derrite de forma selectiva capas finas de polvo y, repitiendo el ciclo, levanta la pieza capa sobre capa, con gran libertad de diseño y buenas propiedades mecánicas (Wang et al., 2023). Ese ciclo rápido de fusión y solidificación, no obstante, hace que el proceso reaccione con fuerza a cambios pequeños en las condiciones de trabajo.

La calidad de una pieza LPBF está ligada a muchas variables: la potencia y la velocidad del láser, el grosor de la capa, la separación entre pasadas, la estrategia de escaneo, las características del polvo y la atmósfera de la cámara. Si la energía es insuficiente se forman poros irregulares por falta de fusión; si es demasiada, el baño fundido se desestabiliza y encierra cavidades redondeadas por efecto keyhole (Adak et al., 2026; Wang et al., 2023). Simulaciones a nivel de partícula indican que la evaporación, la presión de retroceso y el flujo de Marangoni producen poros, salpicaduras y franjas sin polvo en puntos concretos de la traza (Khairallah et al., 2016). Como un poro puede iniciar una grieta y reducir la vida a fatiga, controlarlos es indispensable para certificar piezas críticas.

Tradicionalmente, los parámetros se han elegido con diseños de experimentos, mapas de proceso y largas series de ensayos que gastan material, tiempo y horas de máquina, y que hay que repetir con cada aleación y cada equipo (Liu et al., 2023). El aprendizaje automático (ML) propone otra vía: modelos como los procesos gaussianos (GP, y su variante de regresión, GPR) o las redes neuronales convolucionales (CNN) aprenden de los datos las relaciones no lineales entre parámetros y calidad, interpretan las señales de los sensores durante la impresión y sugieren ajustes sin intervención manual (Meng et al., 2020; Mahmoud et al., 2021). A la vez, el aprendizaje por refuerzo (RL) y el control basado en modelos buscan que el láser cambie su potencia o su velocidad según lo que sucede en el baño fundido (Ogoke y Farimani, 2021; Ren y Wang, 2022).

Si bien hay revisiones extensas sobre ML en LPBF, casi todas abordan en términos generales la predicción de propiedades, el diseño de piezas o el monitoreo. Se echa de menos un análisis guiado por una sola pregunta práctica: qué evidencia existe de que la cadena completa de predicción, monitoreo y control adaptativo reduce la porosidad. Esta revisión ofrece ese enfoque, reúne estudios de modelado, sensores y control, y compara cómo se validó cada uno. El texto sigue este orden: objetivos, metodología, resultados por categoría, discusión de hallazgos y vacíos, y conclusiones.

Objetivos

Objetivo general. Analizar, por medio de una revisión bibliográfica, qué evidencia existe sobre la contribución de la optimización de parámetros y del control adaptativo apoyados en inteligencia artificial a la reducción de la porosidad en piezas metálicas fabricadas por fusión láser en lecho de polvo (LPBF).

Objetivos específicos. (a) Reconocer los algoritmos de ML y RL usados para optimizar parámetros y controlar el proceso. (b) Agrupar los estudios según su papel en la cadena de optimización, monitoreo y control. (c) Contrastar materiales, métodos, resultados numéricos y limitaciones. (d) Indicar los vacíos de conocimiento y las oportunidades de investigación. La pregunta científica que guía el trabajo es: ¿cómo reduce el control adaptativo guiado por IA la formación de defectos por porosidad en piezas metálicas impresas en 3D?

Preguntas de investigación. PI1: ¿qué algoritmos de ML y RL se emplean para optimizar parámetros, monitorear y controlar el proceso en LPBF? PI2: ¿qué evidencia hay de reducción de la porosidad y con qué tipo de validación (experimental, de sensores o numérica)? PI3: ¿qué vacíos persisten? La pregunta general, acotada a LPBF y sin dar por demostrada la reducción, es: ¿qué evidencia hay de que el control adaptativo y la optimización de parámetros guiados por IA reducen la formación de porosidad en piezas metálicas fabricadas por LPBF? Estas preguntas se responden en la Tabla 5.

2. Metodología

Se realizó una revisión bibliográfica narrativa y estructurada, con criterios definidos de búsqueda y selección, que no se presenta como revisión sistemática PRISMA. La búsqueda se cerró el 19 de noviembre de 2026. Se emplearon buscadores académicos y web, sin acceso directo a bases de datos de suscripción, que remitieron a tres tipos de fuentes: plataformas editoriales (ScienceDirect, SpringerLink, MDPI, Nature Portfolio, Emerald, Atlantis Press y Wiley), repositorios abiertos (arXiv, OSTI y PubMed Central) y portales agregadores de metadatos (IDEAS/RePEc, OUCI y Peeref), usados para verificar autores, revista, volumen y DOI. No se consultaron directamente Scopus ni Web of Science. Se buscó en inglés, porque la mayor parte de la producción sobre el tema se publica en ese idioma.

La ecuación conceptual de búsqueda unió tres bloques con AND: ("laser powder bed fusion" OR "LPBF" OR "selective laser melting" OR "additive manufacturing") AND ("machine learning" OR "neural network" OR "reinforcement learning" OR "Gaussian process" OR "digital twin") AND ("porosity" OR "process parameter optimization" OR "closed-loop control" OR "in-situ monitoring" OR "melt pool"). En la práctica se usaron versiones más cortas de esa ecuación y búsquedas por título y autor, adaptadas a la interfaz de cada fuente, además de la revisión de las referencias de las revisiones halladas. No se conservó un registro de cada consulta ni de los resultados por fuente. El periodo cubierto fue 2016–2026.

Tabla 1. Criterios de inclusión y exclusión

Tipo	Criterio
Inclusión	Artículo original, revisión o acta arbitrada; metales procesados por fusión láser en lecho de polvo o proceso aditivo metálico comparable; uso de ML, RL o control basado en datos o modelos; relación explícita con parámetros, porosidad, baño fundido o detección de defectos; metadatos verificables (autores, revista, año).
Exclusión	Estudios sin relación con metales; documentos sin método o resultado identificable; trabajos sin metadatos verificables; textos sin revisión por pares cuando existía una versión publicada (en ese caso se cita la versión de la revista).
Casos especiales	Se incluyó a Khairallah et al. (2016), estudio mecanicista sin ML, como base física para interpretar el origen de los poros (C5). Los estudios de deposición por energía dirigida (DED) se aceptaron solo como evidencia indirecta sobre algoritmos de control y sus resultados no se extrapolan a LPBF. No se incluyeron preprints: arXiv y OSTI se usaron para localizar versiones, y se cita la versión publicada en revista.

El cribado lo realizó el equipo de autores a partir del título y el resumen, sin doble revisión independiente. Los duplicados entre fuentes se eliminaron manualmente comparando título, autores y DOI. No se llevó un conteo por etapas, por lo que no se presenta diagrama de flujo. La mayoría de los estudios se evaluó mediante el resumen y los metadatos disponibles en línea, y solo algunos se leyeron en texto completo; esta es una limitación del trabajo. Quedaron 23 estudios. De cada uno se registraron año, material, algoritmo, tipo de validación (experimental, numérica o mixta) y resultado cuantitativo, y mediante análisis de contenido se asignó a una única categoría según su aporte principal. No se aplicó una evaluación formal de la calidad metodológica. Las cifras que aparecen provienen de los resúmenes y textos accesibles de cada estudio, y la redacción es propia.

3. Resultados

Características de los estudios incluidos

La muestra final reunió 23 estudios publicados entre 2016 y 2026. La mayor producción se ubica en 2020 (cinco estudios) y 2023 (cuatro), y continúa en 2024, 2025 y 2026 (Figura 1). Predominan grupos de Estados Unidos (Carnegie Mellon, Penn State, Lawrence Livermore, Oak Ridge, UC Irvine, Vanderbilt), seguidos por Corea del Sur, Reino Unido e Irlanda. Los materiales más comunes son los aceros inoxidables 316L y 17-4 PH, luego Inconel 718, Ti-6Al-4V, AlSi10Mg y cobre. Las Figuras 1 y 2 describen el corpus seleccionado (n = 23) y no la producción mundial sobre el tema. La Tabla 2 resume cada estudio y diferencia material, proceso y entorno de simulación; "No precisado" indica que el resumen consultado no menciona la aleación.

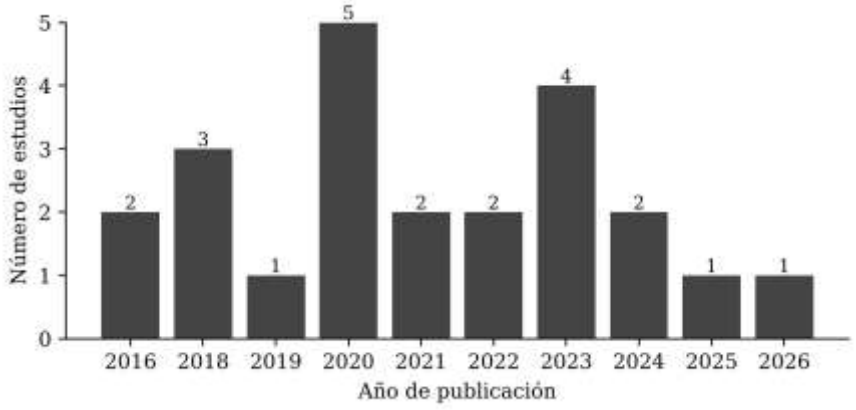


Figura 1. Distribución temporal de los estudios incluidos (n = 23). Fuente: elaboración propia.

Tabla 2. Características de los estudios incluidos

Autor/año	Enfoque	Material	Proceso / entorno	Aporte principal	Validación
Khairallah et al. (2016)	Simulación a escala de partícula	316L	LPBF (simulación)	Mecanismos de formación de poros, salpicaduras y zonas desnudas	Numérica
Tapia et al. (2016)	Procesos gaussianos espaciales	17-4 PH	LPBF	Predicción de porosidad según potencia y velocidad	Experimental
Scime y Beuth (2018a)	Visión por computadora no supervisada	No precisado	LPBF (imágenes del lecho)	Detección de anomalías en la dispersión del polvo	Experimental
Scime y Beuth (2018b)	CNN multiescala	No precisado	LPBF (imágenes del lecho)	Clasificación autónoma de anomalías del lecho	Experimental
Yuan et al. (2018)	ML en dos pasos con imágenes	No precisado	LPBF (trazas)	Evaluación rápida de la calidad de trazas	Experimental
Scime y Beuth (2019)	Agrupamiento no supervisado y clasificador	Inconel 718	LPBF	Firmas de baño fundido ligadas a keyhole y balling	Experimental
Druzgalski et al. (2020)	Control anticipativo (feed forward), sin realimentación	No precisado	LPBF	Optimización local de parámetros en geometrías complejas	Experimental
Kwon et al. (2020)	Red neuronal profunda	No precisado	Fusión selectiva por láser	Clasificación de imágenes de baño fundido en seis niveles de potencia	Experimental
Meng y Zhang (2020)	Proceso gaussiano	316L, 17-4 PH	LPBF	Mapas de proceso y criterio de entalpía normalizada	Experimental
Meng et al. (2020)	Revisión	Varios	Fabricación aditiva	Aplicaciones de ML en fabricación aditiva	Revisión

Autor/año	Enfoque	Material	Proceso / entorno	Aporte principal	Validación
Silbernagel et al. (2020)	Autocodificador convolucional y agrupamiento	Cobre puro	LPBF	Búsqueda automática de parámetros por imágenes	Experimental
Mahmoud et al. (2021)	Revisión	Varios	LPBF	ML en monitoreo y control de proceso	Revisión
Ogoke y Farimani (2021)	Aprendizaje por refuerzo profundo	No aplica	Simulación térmica de LPBF	Política de velocidad del láser contra sobrecalentamiento	Numérica
Lapointe et al. (2022)	Redes neuronales (modelos directo e inverso)	No precisado	LPBF	Parámetros láser a partir de señal de fotodiodo y geometría	Experimental
Ren y Wang (2022)	GPR y control óptimo	No aplica	Simulación (Netfabb) de LPBF	Regulación del tamaño del baño fundido	Numérica
Dharmadhikari et al. (2023)	Q-learning	316L	DED (no LPBF)	Combinación óptima de potencia y velocidad	Numérica y experimental
Liu et al. (2023)	Revisión	Varios	LPBF	ML para optimización de proceso y desempeño	Revisión
Nath y Mahadevan (2023)	Control predictivo bayesiano con modelo sustituto	No precisado	LPBF (simulación y datos térmicos)	Control probabilístico de porosidad capa a capa	Numérica con datos térmicos
Wang et al. (2023)	XGBoost con transformación sigmoide	316L, Ti-6Al-4V, AlSi10Mg	Fusión en lecho de polvo	Predicción de densidad relativa > 98 %	Experimental
Inam et al. (2024)	Revisión	Varios	LPBF	ML para optimización de parámetros	Revisión

Autor/año	Enfoque	Material	Proceso / entorno	Aporte principal	Validación
Malik et al. (2024)	Red recurrente y RL (gemelo digital)	No precisado	LPBF (simulación)	Predicción y mitigación de falta de fusión	Numérica
Amiri et al. (2025)	GP jerárquico y ensayos de alto rendimiento	17-4 PH	LPBF	Relación proceso-propiedades mecánicas	Experimental
Adak et al. (2026)	Regresión logística, árboles, ensamblados y redes	Inconel 718	LPBF	Ventanas de proceso y morfología del baño fundido	Experimental

Categorías temáticas

El análisis de contenido dio lugar a cinco categorías (Figura 2 y Tabla 3). Cada estudio se asignó a una sola categoría según su aporte principal. Tres de ellas, modelos de ventana de proceso (C1), monitoreo in situ (C2) y estrategias de control y aprendizaje por refuerzo (C3), contienen seis estudios cada una. C3 reúne tres subtipos: control anticipativo sin realimentación (Druzgalski et al., 2020), control en lazo cerrado o predictivo evaluado de forma numérica (Ogoke y Farimani, 2021; Ren y Wang, 2022; Nath y Mahadevan, 2023; Malik et al., 2024) y RL con evidencia experimental en deposición por energía dirigida (DED) (Dharmadhikari et al., 2023). Las revisiones previas (C4) son cuatro, y la física del defecto (C5) aporta un estudio de base mecanicista que explica el porqué físico de los demás.

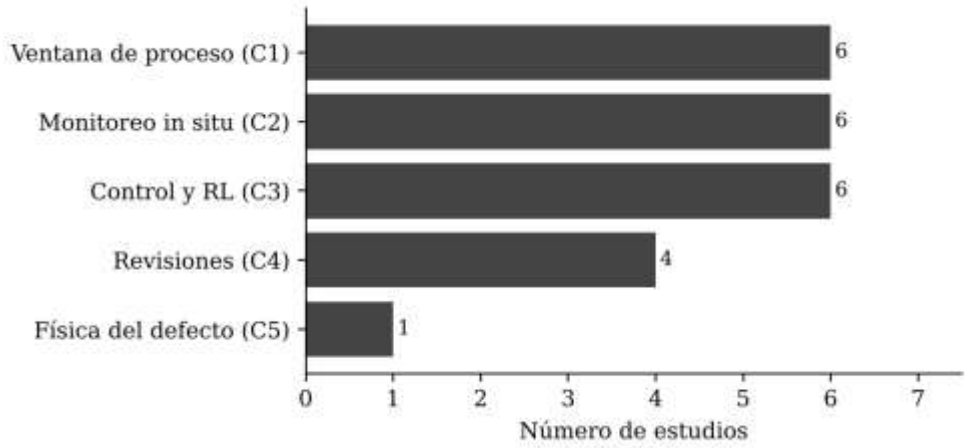


Figura 2. Estudios por categoría temática (n = 23). Fuente: elaboración propia.

Tabla 3. Categorías temáticas derivadas del análisis

Categoría	Descripción	Estudios	Autores representativos
C1. Modelos de ventana de proceso	Predicen densidad, porosidad o propiedades a partir de los parámetros	n = 6	Tapia et al. (2016); Meng y Zhang (2020); Silbernagel et al. (2020); Wang et al. (2023); Amiri et al. (2025); Adak et al. (2026)
C2. Monitoreo in situ	Detectan anomalías o defectos con cámaras y fotodiodos	n = 6	Scime y Beuth (2018a, 2018b, 2019); Yuan et al. (2018); Kwon et al. (2020); Lapointe et al. (2022)
C3. Estrategias de control y RL	Ajustan potencia y velocidad: control anticipativo sin realimentación, control en lazo cerrado simulado y RL	n = 6	Druzgalski et al. (2020); Ogoke y Farimani (2021); Ren y Wang (2022); Dharmadhikari et al. (2023, DED); Nath y Mahadevan (2023); Malik et al. (2024)
C4. Revisiones	Sintetizan aplicaciones y retos del ML en aditiva	n = 4	Meng et al. (2020); Mahmoud et al. (2021); Liu et al. (2023); Inam et al. (2024)
C5. Física del defecto	Explican el origen de poros y salpicaduras	n = 1	Khairallah et al. (2016)

Síntesis de hallazgos por categoría

Modelos de ventana de proceso (C1). Los trabajos coinciden en que la potencia del láser y la velocidad de escaneo son las variables que más influyen en el baño fundido y en los defectos (Adak et al., 2026). Tapia et al. (2016) usaron procesos gaussianos espaciales para anticipar la porosidad en acero 17-4 PH, y Meng y Zhang (2020) construyeron mapas de proceso para 316L y 17-4 PH donde el umbral de entalpía normalizada que separa la conducción del keyhole fue diferente en cada acero (30 y 25). Silbernagel et al. (2020) probaron en cobre puro un esquema que agrupa imágenes ópticas con un autocodificador convolucional y califica cada grupo por su calidad, como paso hacia la elección automática de parámetros. Wang et al. (2023) plantearon un modelo XGBoost no atado a un material que predice condiciones con densidad relativa mayor al 98 %, comprobado con varios polvos, y Amiri et al. (2025) unieron ensayos de alto rendimiento con procesos gaussianos jerárquicos para necesitar menos caracterizaciones costosas. Adak et al. (2026) mostraron en Inconel 718 que ponderar las clases ayuda a detectar ventanas adecuadas sin depender de una única partición de datos.

Monitoreo in situ (C2). Scime y Beuth (2018a) demostraron que una cámara sobre el lecho, junto con un algoritmo de visión, detecta y clasifica anomalías en la dispersión del polvo, y su versión con red convolucional multiescala ganó flexibilidad y exactitud (Scime y Beuth, 2018b). En 2019 relacionaron la forma del baño fundido en Inconel 718 con la posterior aparición de keyhole y balling, lo que dio un clasificador de firmas de defecto válido incluso en voladizos. Kwon et al. (2020) clasificaron imágenes del baño en seis niveles de potencia con un error menor al 1,1 % sobre 13 200 imágenes de prueba, aunque lo que clasifican es la potencia, no la porosidad. Yuan et al. (2018) valoraron la calidad de trazas láser en dos pasos, y Lapointe et al. (2022) entrenaron un modelo directo y uno inverso que obtienen los parámetros láser a partir de la geometría y de una señal de fotodiodo deseada, con mejor exactitud dimensional en piezas complejas.

Estrategias de control y aprendizaje por refuerzo (C3). Druzgalski et al. (2020) propusieron una optimización anticipativa (feed forward) que asigna parámetros distintos a cada vector de escaneo según la geometría local; al no usar realimentación, no se clasifica aquí como demostración de lazo cerrado. Ogoke y Farimani (2021) lograron con RL profundo una política que ajusta la velocidad del láser para mantener un baño uniforme y evitar el sobrecalentamiento, pero solo la probaron en simulaciones térmicas. Ren y Wang (2022) controlaron el tamaño del baño con GPR y control óptimo de la potencia, también verificado de forma numérica. Nath y Mahadevan (2023) combinaron simulación física, cámara infrarroja y un modelo sustituto bayesiano para estimar la porosidad capa por capa y corregir potencia y velocidad cuando la porosidad prevista pasa un límite. Dharmadhikari et al. (2023) encontraron con Q-learning una combinación de 888,9 W y 566,7 mm/min para un baño de 1 mm de profundidad en acero 316L, con diferencia menor a 50 µm frente al experimento; es evidencia de DED y sus parámetros no deben extrapolarse a LPBF. Malik et al. (2024) incorporaron una red recurrente y RL a un gemelo digital que predice y mitiga la falta de fusión.

Revisiones y física del defecto (C4 y C5). Las revisiones coinciden en que los mayores obstáculos son la no linealidad del proceso, la poca disponibilidad de datos de calidad y la dificultad de pasar del laboratorio a la planta (Inam et al., 2024; Liu et al., 2023; Mahmoud et al., 2021; Meng et al., 2020). El estudio mecanicista de Khairallah et al. (2016) distingue mecanismos de formación de poros en los bordes de la traza, en el fondo del baño y en los extremos de la pista, y aclara por qué una variable como la energía volumétrica no alcanza por sí sola para predecir el defecto.

Tabla 4. Matriz comparativa de estudios representativos

Estudio	Material y método	Resultado	Tipo de resultado	Limitación observada
Wang et al. (2023)	316L, Ti-6Al-4V y AlSi10Mg; XGBoost	Condiciones con densidad relativa > 98 % (no es una reducción respecto de un control)	Cuantitativo experimental	Umbral binario; requiere propiedades del polvo
Meng y Zhang (2020)	316L y 17-4 PH; proceso gaussiano	Entalpía normalizada crítica de 30 (316L) y 25 (17-4 PH)	Cuantitativo experimental	Umbral dependiente del material
Kwon et al. (2020)	Fusión selectiva; red profunda	Error < 1,1 % en 13 200 imágenes (clasificación de potencia, no de porosidad)	Cuantitativo (clasificación)	No mide porosidad directamente
Scime y Beuth (2019)	Inconel 718; agrupamiento y clasificador	Firmas de baño asociadas a keyhole y balling	Cualitativo	Una aleación y cámara de vista fija
Silbernagel et al. (2020)	Cobre; autocodificador y agrupamiento	Resultados coherentes con hallazgos clásicos	Cualitativo	Puntuación de calidad poco cuantitativa
Druzgalski et al. (2020)	LPBF; control anticipativo por vectores	Mejora de piezas de geometría compleja	Cualitativo	Sin realimentación: no demuestra lazo cerrado
Dharmadhikari et al. (2023)	316L (DED); Q-learning	888,9 W y 566,7 mm/min; diferencia < 50 µm	Cuantitativo numérico y experimental (DED)	Proceso distinto de LPBF; no extrapolable
Ogoke y Farimani (2021)	Simulación térmica; RL profundo	Política de velocidad de láser estable	Cualitativo (numérico)	Sin validación experimental
Ren y Wang (2022)	Simulación; GPR y control óptimo	Regula el tamaño del baño en varias pistas	Cualitativo (numérico)	Verificación numérica

Estudio	Material y método	Resultado	Tipo de resultado	Limitación observada
Nath y Mahadevan (2023)	LPBF; control bayesiano con modelo sustituto	Corrige potencia y velocidad al superar el límite de porosidad	Cualitativo (numérico)	Depende de la calibración del modelo sustituto
Malik et al. (2024)	LPBF; red recurrente y RL	Predice y mitiga falta de fusión	Cualitativo (numérico)	Resultados numéricos
Amiri et al. (2025)	17-4 PH; GP jerárquico	Menos ensayos de caracterización	Cualitativo	Un solo material
Adak et al. (2026)	Inconel 718; modelos supervisados	Ventanas con aprendizaje ponderado por clases	Cualitativo	Datos de una aleación y una máquina

Tipos de resultado y de validación. Conviene distinguir tres planos: (i) validación experimental de parámetros (C1), donde se mide densidad relativa o porosidad en piezas, como en Tapia et al. (2016) y Wang et al. (2023); (ii) validación de sensores y clasificadores (C2), donde se mide la exactitud de la detección y no la reducción de defectos; y (iii) demostración de control adaptativo real, que en este corpus casi no aparece en LPBF: los controladores se evaluaron en simulación, el control anticipativo de Druzgalski et al. (2020) no usa realimentación y el único RL experimental corresponde a DED. Además, una densidad relativa superior al 98 % no equivale a una reducción porcentual de porosidad respecto de un control, y el error de clasificación de Kwon et al. (2020) tampoco mide porosidad.

Tabla 5. Síntesis de hallazgos por pregunta de investigación

Pregunta	Hallazgo principal	Evidencia	Interpretación
PI1: ¿Qué algoritmos se emplean?	Procesos gaussianos, XGBoost, redes neuronales y CNN, y aprendizaje por refuerzo	23 estudios	El campo combina predicción, monitoreo y control
PI2: ¿Qué evidencia hay de reducción de porosidad y con qué validación?	Evidencia experimental de ventanas de proceso (densidad relativa > 98 %) y de detección de anomalías; el control adaptativo se evaluó sobre todo en simulación	Wang et al. (2023); Kwon et al. (2020); Ogoke y Farimani (2021); Nath y Mahadevan (2023)	La reducción está mejor respaldada fuera de línea; falta demostración experimental directa de control adaptativo en LPBF

Pregunta	Hallazgo principal	Evidencia	Interpretación
PI3: ¿Qué vacíos persisten?	Validación experimental en lazo cerrado, dependencia del material y datos abiertos	C3 y C4	Se requiere más evidencia industrial

4. Discusión

Los resultados permiten contestar el objetivo con matices: la evidencia sugiere que la optimización de parámetros y las estrategias de control apoyadas en IA pueden contribuir a reducir la porosidad en LPBF, aunque la firmeza de esa evidencia cambia según la categoría y el tipo de validación. Esto importa porque muestra que reducir defectos no depende de una técnica aislada, sino de una cadena que parte de predecir ventanas seguras, sigue con vigilar el proceso y termina, potencialmente, corrigiéndolo durante la impresión.

Los modelos de ventana de proceso (C1) aportan la evidencia experimental más firme. Que un modelo entrenado con pocos ensayos identifique condiciones con densidad superior al 98 % (Wang et al., 2023) sugiere que el espacio de parámetros tiene una estructura aprendible, lo que cambia el ensayo y error por una exploración dirigida. Esto va en la línea de los procesos gaussianos de Tapia et al. (2016) y Amiri et al. (2025), que además miden la incertidumbre. Aun así, el distinto umbral de entalpía en 316L y 17-4 PH (Meng y Zhang, 2020) explica por qué los modelos suelen fallar al cambiar de material y apoya el intento de incluir propiedades del polvo.

En el monitoreo in situ (C2) los estudios coinciden en que la señal óptica del baño y del lecho trae información suficiente para anticipar defectos (Scime y Beuth, 2018b, 2019; Kwon et al., 2020). Una razón posible es que la forma y la intensidad del baño reflejan el balance de energía que genera falta de fusión o keyhole, algo coherente con los mecanismos descritos por Khairallah et al. (2016). Con todo, como Kwon et al. (2020) clasifican niveles de potencia y no poros reales, conviene leer su exactitud con cautela: un baño bien clasificado no asegura una pieza sin defectos.

Las estrategias de control (C3) tienen el mayor potencial y también la mayor distancia entre promesa y prueba. Las políticas de aprendizaje por refuerzo y los controladores con procesos gaussianos se validaron sobre todo en simulación (Ogoke y Farimani, 2021; Ren y Wang, 2022; Malik et al., 2024), y el único resultado experimental con RL corresponde a un proceso distinto del LPBF (Dharmadhikari et al., 2023). Una explicación razonable es lo difícil que resulta instalar un controlador en tiempo real en máquinas comerciales cerradas, sumado al costo de entrenar agentes. La optimización anticipativa de Druzgalski et al. (2020) mejoró piezas reales, pero sin realimentación durante la construcción, por lo que no equivale a un lazo cerrado; y la propuesta probabilística de Nath y Mahadevan (2023) acerca el control de la porosidad a la práctica al usar datos térmicos, aunque con verificación numérica.

Frente a las revisiones previas, los hallazgos coinciden en que la falta de datos y la no linealidad son los obstáculos principales (Inam et al., 2024; Liu et al., 2023; Mahmoud et al., 2021; Meng et al., 2020). La diferencia de este trabajo es que centra la lectura en la porosidad y compara el tipo de validación de cada estudio, lo que deja ver que el avance numérico supera claramente al experimental. En la práctica, los resultados sugieren usar modelos de ventana fuera de línea para la calificación inicial, monitoreo in situ para detectar desviaciones y, solo cuando exista validación suficiente, control adaptativo en piezas de alto valor. Para la ingeniería industrial esto podría traducirse en menos material gastado, menos tiempo de calificación y menos piezas rechazadas, pero ningún estudio revisado aporta una comparación directa de costos o desperdicio, por lo que se trata de un beneficio potencial y no demostrado.

La revisión tiene limitaciones. La búsqueda se hizo con buscadores académicos y fuentes en línea y en inglés, sin consulta directa de Scopus ni Web of Science, por lo que la selección pudo incurrir en sesgo; no se aplicó PRISMA, no se evaluó formalmente la calidad de los estudios y la mayoría se valoró por su resumen. Los 23 estudios son pocos frente a toda la literatura y sus resultados numéricos no son directamente comparables por la variedad de materiales, equipos y métricas. Las conclusiones se limitan a este corpus. Aun así, la evidencia revisada sugiere que la IA puede ser una vía útil para reducir la porosidad en LPBF, siempre que se acompañe de validación experimental.

Vacíos de conocimiento y perspectivas futuras

Se detectaron cuatro vacíos. Primero, los controladores adaptativos se validaron sobre todo de forma numérica, por lo que hacen falta ensayos en máquinas reales con medición posterior de la porosidad. Segundo, los modelos suelen entrenarse con un solo material o equipo, lo que limita su transferencia; el aprendizaje por transferencia y los modelos que incorporan propiedades del polvo son caminos prometedores. Tercero, faltan conjuntos de datos abiertos y métricas comunes para comparar algoritmos en igualdad de condiciones. Cuarto, el costo computacional del RL y la latencia de los sensores dificultan actuar en tiempo real; futuros trabajos podrían probar modelos sustitutos livianos y modelos guiados por la física.

Como líneas futuras se plantean: comparar algoritmos con los mismos datos; integrar monitoreo multisensor con control; evaluar el ahorro económico y ambiental de material; y reportar la propiedad mecánica final de las piezas controladas, no solo su porosidad.

5. Conclusiones

Dentro de los 23 estudios revisados, el aprendizaje automático usado fuera de línea acelera la búsqueda de ventanas de proceso con baja porosidad y reduce los ensayos necesarios en LPBF; el monitoreo in situ aporta señales para detectar anomalías durante la construcción; y las estrategias

de control adaptativo, incluido el aprendizaje por refuerzo, son prometedoras pero cuentan con respaldo experimental limitado en LPBF. Llevarlas a la industria dependerá de modelos menos atados a un material, de bases de datos abiertas y de sensores integrados. Estas líneas pueden orientar proyectos de manufactura aditiva más eficientes y sostenibles, donde la ingeniería industrial tiene un papel potencial en la calificación y el control de calidad.

Agradecimientos

Los autores agradecen la orientación de la asignatura de Ciencia de los Materiales de la Universidad Estatal de Milagro.

Financiación: los autores declaran que no recibieron financiación externa para la realización de este trabajo.

Conflicto de intereses: los autores declaran no tener conflictos de interés.

Referencias

Adak, D., Akram, M. B., Roy, S., & Balasubramanian, G. (2026). Neural network enabled process parameter optimization for laser powder bed fusion of Inconel 718. Journal of Manufacturing and Materials Processing, 10(7), 219. https://doi.org/10.3390/jmmp10070219

Amiri, M., Zanjani Foumani, Z., Cao, P., Valdevit, L., & Bostanabad, R. (2025). Unveiling processing–property relationships in laser powder bed fusion: The synergy of machine learning and high-throughput experiments. Materials & Design, 252, 113705. https://doi.org/10.1016/j.matdes.2025.113705

Dharmadhikari, S., Menon, N., & Basak, A. (2023). A reinforcement learning approach for process parameter optimization in additive manufacturing. Additive Manufacturing, 71, 103556. https://doi.org/10.1016/j.addma.2023.103556

Druzgalski, C. L., Ashby, A., Guss, G., King, W. E., Roehling, T. T., & Matthews, M. J. (2020). Process optimization of complex geometries using feed forward control for laser powder bed fusion additive manufacturing. Additive Manufacturing, 34, 101169. https://doi.org/10.1016/j.addma.2020.101169

Inam, D., Ali, I., Shah Syed, A. A., & Ul Ahad, I. (2024). A review of machine learning methods for process parameter optimization in laser powder bed fusion. En Proceedings of the 4th International Conference on Key Enabling Technologies (KEYTECH 2024). Atlantis Press. https://doi.org/10.2991/978-94-6463-602-4_40

Khairallah, S. A., Anderson, A. T., Rubenchik, A., & King, W. E. (2016). Laser powder-bed fusion additive manufacturing: Physics of complex melt flow and formation mechanisms of pores, spatter, and denudation zones. Acta Materialia, 108, 36–45. https://doi.org/10.1016/j.actamat.2016.02.014

Kwon, O., Kim, H. G., Ham, M. J., Kim, W., Kim, G.-H., Cho, J.-H., Kim, N. I., & Kim, K. (2020). A deep neural network for classification of melt-pool images in metal additive manufacturing. Journal of Intelligent Manufacturing, 31(2), 375–386. https://doi.org/10.1007/s10845-018-1451-6

Lapointe, S., Guss, G., Reese, Z., Strantza, M., Matthews, M. J., & Druzgalski, C. L. (2022). Photodiode-based machine learning for optimization of laser powder bed fusion parameters in complex geometries. Additive Manufacturing, 53, 102687. https://doi.org/10.1016/j.addma.2022.102687

Liu, J., Ye, J., Silva Izquierdo, D., Vinel, A., Shamsaei, N., & Shao, S. (2023). A review of machine learning techniques for process and performance optimization in laser beam powder bed fusion additive manufacturing. Journal of Intelligent Manufacturing, 34(8), 3249–3275. https://doi.org/10.1007/s10845-022-02012-0

Mahmoud, D., Magolon, M., Boer, J., Elbestawi, M. A., & Mohammadi, M. G. (2021). Applications of machine learning in process monitoring and controls of L-PBF additive manufacturing: A review. Applied Sciences, 11(24), 11910. https://doi.org/10.3390/app112411910

Malik, A. W., Mahmood, M. A., & Liou, F. (2024). Digital twin–driven optimization of laser powder bed fusion processes: A focus on lack-of-fusion defects. Rapid Prototyping Journal, 30(10), 1977–1988. https://doi.org/10.1108/RPJ-02-2024-0091

Meng, L., & Zhang, J. (2020). Process design of laser powder bed fusion of stainless steel using a Gaussian process-based machine learning model. JOM, 72(1), 420–428. https://doi.org/10.1007/s11837-019-03792-2

Meng, L., McWilliams, B., Jarosinski, W., Park, H.-Y., Jung, Y.-G., Lee, J., & Zhang, J. (2020). Machine learning in additive manufacturing: A review. JOM, 72(6), 2363–2377. https://doi.org/10.1007/s11837-020-04155-y

Nath, P., & Mahadevan, S. (2023). Probabilistic predictive control of porosity in laser powder bed fusion. Journal of Intelligent Manufacturing, 34(3), 1085–1103. https://doi.org/10.1007/s10845-021-01836-6

Ogoke, F., & Farimani, A. B. (2021). Thermal control of laser powder bed fusion using deep reinforcement learning. Additive Manufacturing, 46, 102033. https://doi.org/10.1016/j.addma.2021.102033

Ren, Y., & Wang, Q. (2022). Gaussian-process based modeling and optimal control of melt-pool geometry in laser powder bed fusion. Journal of Intelligent Manufacturing, 33(8), 2239–2256. https://doi.org/10.1007/s10845-021-01781-4

Scime, L., & Beuth, J. (2018a). Anomaly detection and classification in a laser powder bed additive manufacturing process using a trained computer vision algorithm. Additive Manufacturing, 19, 114–126. https://doi.org/10.1016/j.addma.2017.11.009

Scime, L., & Beuth, J. (2018b). A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process. Additive Manufacturing, 24, 273–286. https://doi.org/10.1016/j.addma.2018.09.034

Scime, L., & Beuth, J. (2019). Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process. Additive Manufacturing, 25, 151–165. https://doi.org/10.1016/j.addma.2018.11.010

Silbernagel, C., Aremu, A., & Ashcroft, I. (2020). Using machine learning to aid in the parameter optimisation process for metal-based additive manufacturing. Rapid Prototyping Journal, 26(4), 625–637. https://doi.org/10.1108/RPJ-08-2019-0213

Tapia, G., Elwany, A. H., & Sang, H. (2016). Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models. Additive Manufacturing, 12(Pt B), 282–290. https://doi.org/10.1016/j.addma.2016.05.009

Wang, J., Jeong, S., Kim, E., Kim, H. S., & Lee, B.-J. (2023). Material-agnostic machine learning approach enables high relative density in powder bed fusion products. Nature Communications, 14, 6557. https://doi.org/10.1038/s41467-023-42319-x

Yuan, B., Guss, G. M., Wilson, A. C., Hau-Riege, S. P., DePond, P. J., McMains, S., Matthews, M. J., & Giera, B. (2018). Machine-learning-based monitoring of laser powder bed fusion. Advanced Materials Technologies, 3(12), 1800136. https://doi.org/10.1002/admt.201800136