

La inteligencia artificial sobre la ingeniería de superficies

Artificial Intelligence in Surface Engineering

Alejandra Luna Gómez ¹

Ashley Abril García Garfias ²

Juan Román Álvarez Meneses ³

Ernesto David García Bustos ⁴

Marco Antonio Doñu Ruiz ⁵

Noé López Perrusquia ⁶

Universidad Politécnica del Valle de México, Doctorado en Ciencia de Materiales, Tultitlán, MÉXICO

¹ ORCID: 0009-0006-1156-5519 / alma.luna@cuautitlán.unam.mx

Universidad Nacional Autónoma de México, Facultad de Estudios Superiores Cuautitlán, Cuautitlán, MÉXICO

² ORCID: 0009-0006-9717-1958 / aabril.27.gg@gmail.com

³ ORCID: 0009-0008-1297-7317 / roman070818@gmail.com

Universidad Politécnica del Valle de México, Grupo Ciencia e ingeniería de Materiales, Tultitlán, MÉXICO

⁵ ORCID: 0000-0002-3411-7990 / marco.donu@upvm.edu.mx

⁶ ORCID: 0000-0001-9209-8612 / nlopezp@upvm.edu.mx

Universidad Politécnica del Valle de México, SECIHTI, Tultitlán, MÉXICO

⁴ ORCID: 0000-0001-7502-4486 / gc@unman.gb

<https://científica.site>

Recibido 13/08/2026, aceptado 28/09/2026, publicado 10/10/2026.



Resumen

La evaluación de recubrimientos superficiales es fundamental para garantizar la durabilidad y el rendimiento de componentes metálicos en aplicaciones industriales. Esta revisión examina el papel transformador de la inteligencia artificial, en particular de las Redes Neuronales Convolucionales (CNN) y los Transformers de Visión (ViT), en la automatización de la caracterización de recubrimientos. La integración de estas arquitecturas de aprendizaje profundo con el procesamiento digital de imágenes permite un análisis objetivo, rápido y reproducible, que supera la subjetividad y las limitaciones de tiempo de la evaluación manual tradicional. La convergencia de la visión por computadora, el aprendizaje automático y modelos predictivos de ingeniería de superficies abre la posibilidad de analizar simultáneamente defectos microestructurales, clasificar la calidad de adhesión y optimizar parámetros de proceso. Esto revoluciona el control de calidad en la industria de recubrimientos y facilita el desarrollo de materiales más fiables y de alto rendimiento.

Palabras clave: redes neuronales convolucionales, caracterización de recubrimientos, inteligencia artificial en ciencia de materiales.

Abstract

The evaluation of surface coatings is essential to ensure the durability and performance of metallic components in industrial applications. This review examines the transformative role of artificial intelligence, particularly Convolutional Neural Networks (CNN) and Vision Transformers (ViT), in automating coating characterization. The integration of these deep learning architectures with digital image processing enables objective, fast, and reproducible analysis, overcoming the subjectivity and time limitations of traditional manual evaluation. The convergence of computer vision, machine learning, and predictive surface engineering models opens up the possibility of simultaneously analyzing microstructural defects, classifying adhesion quality, and optimizing process parameters. This revolutionizes quality control in the coatings industry and facilitates the development of more reliable, high-performance materials.

Index terms: convolutional neural networks, coating characterization, artificial intelligence in materials science.

I. INTRODUCCIÓN

En la búsqueda constante por mejorar la durabilidad y el rendimiento de los materiales en entornos industriales exigentes, los recubrimientos superficiales desempeñan un papel fundamental. Su eficacia operativa depende críticamente de dos factores: la integridad estructural de la capa aplicada y la calidad de su adhesión al sustrato base. Durante décadas, la evaluación de estos parámetros ha dependido de métodos manuales, los cuales, aunque basados en la pericia técnica, son intrínsecamente subjetivos, lentos y propensos al error humano derivado de la fatiga del operador (véase Fig. 1).

Actualmente, la inteligencia artificial (IA) está transformando radicalmente este paradigma, ofreciendo niveles de precisión, rapidez y objetividad sin precedentes en la caracterización de materiales. La convergencia de la visión por computadora y los modelos de aprendizaje profundo permite automatizar la detección de fallos y la cuantificación de propiedades mecánicas, optimizando así los protocolos de control de calidad.




Fig. 1. Comparación de análisis de microgrietas mediante un enfoque tradicional y un enfoque automatizado.

II. EL DESAFÍO DE LAS MICROGRIETAS Y SU LOCALIZACIÓN Y MEDICIÓN CON REDES NEURONALES CONVOLUCIONALES

Las microgrietas radiales representan uno de los desafíos más complejos en la ingeniería de superficies. Estas imperfecciones, de escala microscópica, actúan como puntos críticos de concentración de esfuerzos que pueden comprometer gravemente la función protectora del recubrimiento, propagándose hacia el exterior de manera análoga a los radios de una rueda. Su identificación temprana es vital para prevenir fallos catastróficos en componentes de alta responsabilidad [2]. Tradicionalmente, la medición de estas fisuras ha sido un proceso manual, cuya precisión depende enteramente de la experiencia del operador y de la resolución de las micrografías obtenidas. Ante la necesidad de una evaluación más robusta, el uso de Redes Neuronales Convolucionales (CNN) ha emergido como la solución técnica superior como se muestra en la Figura 2. Las CNN han demostrado capacidades excepcionales en tareas de visión artificial, particularmente en la segmentación precisa de imágenes, permitiendo aislar patrones específicos como las

microgrietas del ruido de fondo característico de las micrografías [3]. Investigaciones recientes han aplicado con éxito arquitecturas avanzadas, como Mask R-CNN y TransUNet, para detectar microgrietas a nivel de píxel, cuantificando con precisión su longitud y área [4]. Un avance notable en este campo es el desarrollo del modelo PGI-CrackNet, capaz de detectar microgrietas de aproximadamente 15 μm en aleaciones de titanio, superando significativamente la capacidad de detección de los métodos de inspección convencionales y permitiendo el seguimiento automático de las etapas de formación de grietas [5]. Asimismo, el uso de CNN de múltiples ramas permite actualmente medir simultáneamente la longitud, profundidad y orientación de estas fisuras, proporcionando datos críticos para evaluar el daño real que pueden inducir bajo condiciones de carga operativa [6]. Con el propósito de contrastar las capacidades y el rendimiento de estas arquitecturas de aprendizaje profundo frente a los enfoques tradicionales, la Tabla 1 resume los principales modelos analizados en la literatura reciente.

TABLA 1
COMPARATIVA DE ARQUITECTURAS DE APRENDIZAJE PROFUNDO Y VISIÓN ARTIFICIAL APLICADAS
A LA CARACTERIZACIÓN DE RECUBRIMIENTOS SUPERFICIALES

Modelo / Arquitectura	Aplicación en Ingeniería de Superficies	Ventaja Principal	Referencia
Mask R-CNN / TransUNet	Detección y segmentación de microgrietas a nivel de píxel	Cuantificación precisa de la longitud y área de fisuras complejas en micrografías.	Joshi <i>et al.</i> , 2025 [4]
PGI-CrackNet	Capacidad de identificar microfisuras de hasta 15 μm , superando métodos visuales tradicionales.	Capacidad de identificar microfisuras de hasta 15 μm , superando métodos visuales tradicionales.	Zhao <i>et al.</i> , 2025 [5]
Vision Transformers (ViT)	Clasificación global de tipo de daño y severidad	Modelado superior de relaciones espaciales globales mediante mecanismos de autoatención.	Maurício <i>et al.</i> , 2023 [13]
MobileViT-S	Clasificación de grados de corrosión en aceros recubiertos	Alta versatilidad y rendimiento robusto bajo diversas condiciones de iluminación industrial.	Zhao <i>et al.</i> , 2025 [5]




Fig. 2. Medición automática de microgrietas con redes neuronales artificiales.

III. TRANSFORMERS DE VISIÓN (ViT) PARA EL CONTEXTO GLOBAL

Mientras que las CNN son excelentes para capturar detalles locales, los Vision Transformers (ViT) aportan una visión más global. En lugar de analizar la imagen por partes, los ViT procesan la imagen completa mediante un mecanismo de autoatención que captura las relaciones contextuales entre diferentes regiones [7]. Esto es especialmente útil para clasificar el tipo de daño y la severidad del recubrimiento en su conjunto. Por ejemplo, un ViT puede distinguir si un patrón de agrietamiento corresponde a un fallo por fatiga, un problema de adhesión o un error en el proceso de aplicación, considerando toda la microestructura [8]. Su capacidad para modelar características globales los hace particularmente efectivos, incluso cuando se dispone de conjuntos de datos de entrenamiento limitados [9].

La capacidad de los ViT para evaluar la integridad global de los recubrimientos es especialmente crítica cuando se trata de diagnosticar problemas de adhesión. Sin embargo, la visión por computadora no puede resolver por sí sola los desafíos de fondo inherentes a la interfaz metal-recubrimiento. Aquí es donde emergen las soluciones tribológicas y termoquímicas como el boriding, que actúan en complemento sinérgico con los sistemas de detección inteligente. En otras palabras, mientras que la IA proporciona la capacidad diagnóstica para identificar y clasificar estados de adhesión deficiente, el boriding ofrece la solución estructural para prevenirlos desde su origen.

En el ámbito de la inspección marina, diversos estudios han demostrado que los ViT logran una mayor precisión en la clasificación del estado de recubrimientos en comparación con arquitecturas como ResNet, precisamente por su capacidad para modelar relaciones espaciales globales [10]. De manera similar, se han aplicado modelos como MobileViT-S para la clasificación de grados de corrosión en aceros recubiertos bajo diversas condiciones de iluminación, demostrando la versatilidad de estos modelos en entornos industriales complejos [11].

IV. EL PROCESO DE BORIDIGN Y LA ADHESIÓN

El boriding (o boruración) se posiciona como una de las técnicas más robustas en la ingeniería de superficies. Se trata de un proceso termoquímico avanzado basado en la difusión de átomos de boro en la red cristalina del material base, generando capas de boruros metálicos (típicamente FeB y Fe₂B en aceros) caracterizadas por una dureza extrema y un bajo coeficiente de fricción. Este tratamiento no solo prolonga la vida útil de componentes mecánicos sometidos a condiciones de desgaste abrasivo y corrosión severa, sino que redefine la integridad de la interfaz metal-recubrimiento [12].




Fig. 3. Ensayo Rockwell C para evaluar la adhesión del recubrimiento al sustrato.

Un aspecto crítico que ha captado la atención en años recientes es la capacidad del boriding para actuar como una capa de "anclaje" o sustrato intermedio. Al crear una zona de transición con un gradiente de propiedades mecánicas controlado, el tratamiento de boruración minimiza el contraste de dureza entre el núcleo dúctil y la superficie rígida, reduciendo drásticamente el riesgo de fallos por delaminación. Esto permite que recubrimientos de capa delgada (PVD o CVD) se adhieran con una firmeza superior, creando un sistema multicapa de alto desempeño [13].

Dada la naturaleza crítica de la interfaz entre el recubrimiento y el sustrato, la comunidad técnica ha estandarizado métodos rigurosos para cuantificar su adherencia. La evaluación de esta unión no es meramente estética, sino una garantía de seguridad estructural. Entre los protocolos más reconocidos a nivel internacional destacan las normativas desarrolladas por organismos técnicos (como las directrices VDI 3198, DIN 4856 e ISO 26443), que establecen pruebas de indentación bajo carga controlada, como el ensayo Rockwell C.

Estas pruebas permiten clasificar la calidad de la adhesión mediante una escala visual de fallos (que va desde patrones HF1, indicativos de una unión excelente, hasta HF6, donde se presenta un desprendimiento catastrófico). La implementación de estas normas es vital en la industria moderna, ya que el cumplimiento del estándar certifica que el componente será capaz de resistir deformaciones plásticas y ciclos de fatiga sin perder su capa protectora. Sin embargo, este proceso de clasificación, al ser tradicionalmente visual y cualitativo, ha sido catalogado como el "cuello de botella" en los laboratorios de control de calidad, siendo el terreno perfecto para la intervención de sistemas inteligentes que eliminen la ambigüedad inherente al ojo humano.

V. SINERGIA REDES NEURONALES Y PROCESAMIENTOS DE IMÁGENES EN CARACTERIZACIÓN

La caracterización precisa de materiales es un pilar fundamental en la ingeniería moderna, especialmente en el ámbito de los recubrimientos y tratamientos superficiales. Tradicionalmente, el análisis de microestructuras ha dependido de la pericia de metalurgistas y científicos, quienes interpretan visualmente micrografías para determinar propiedades y diagnosticar fallos [2]. Sin embargo, la creciente complejidad de los materiales y la necesidad de procesos más rápidos y objetivos han impulsado la búsqueda de soluciones automatizadas.




Fig. 4. Sinergia de datos experimentales obtenidos de microfisuras y su clasificación mediante redes neuronales artificiales.

La integración de redes neuronales artificiales y técnicas avanzadas de procesamiento digital de imágenes emerge como una poderosa sinergia para abordar este desafío, tal como se ejemplifica en la Figura 4. La base de esta integración reside en la capacidad de las redes para aprender patrones complejos a partir de datos experimentales [10]. Por ejemplo, se ha demostrado que las redes neuronales pueden predecir con alta precisión propiedades mecánicas clave, como la dureza y el espesor en capas superficiales tratadas, superando a los métodos analíticos tradicionales [10].

El verdadero potencial de estas herramientas se desbloquea cuando se combinan con la visión por computadora para el análisis microestructural [3]. Mediante el uso de redes neuronales convolucionales (CNN) y modelos avanzados, es posible segmentar automáticamente fases, cuantificar porosidad y detectar defectos de forma objetiva y reproducible en micrografías de aceros tratados [11]. Esta combinación no solo acelera el análisis, sino que estandariza el control de calidad, permitiendo modelar incluso la cinética de crecimiento de capas mediante enfoques híbridos neuro-difusos [12].

VI. HACIA LA CARACTERIZACIÓN AUTOMATIZADA EN INGENIERÍA DE SUPERFICIES MEDIANTE REDES NEURONALES

La ingeniería de superficies está atravesando una transformación definitiva impulsada por la inteligencia artificial. Como hemos analizado, la transición desde los métodos de evaluación manuales hacia sistemas automatizados basados en Redes Neuronales Convolucionales (CNN) y Vision Transformers (ViT) no es solo una mejora incremental, sino un cambio de paradigma. La capacidad de estas herramientas para realizar mediciones precisas de microgrietas, clasificar estados de corrosión y evaluar la calidad de la adhesión conforme a estándares internacionales como la norma VDI [9], elimina la subjetividad humana y optimiza los tiempos de respuesta en entornos industriales [11].




Fig. 5. Hacia sistemas automatización de cuantificación y predicción de microfisuras.

Los avances en el área demuestran que la sinergia entre el procesamiento digital de imágenes y modelos de aprendizaje profundo permite obtener métricas cuantitativas que antes eran imposibles de estandarizar [3], [11]. Asimismo, la capacidad predictiva de los modelos neurodifusos para modelar la cinética de crecimiento de capas boruradas sugiere que estamos ante el umbral de una ingeniería de superficies proactiva, capaz de sugerir parámetros de proceso óptimos

antes de fabricar la pieza. Es claro que la integración de estos ecosistemas inteligentes promete un futuro donde el diagnóstico de materiales sea instantáneo, trazable y altamente fiable. La estandarización de estos métodos mediante normas técnicas, apoyada por la robustez de las arquitecturas neuronales, consolidará el desarrollo de materiales más resistentes y duraderos, marcando el inicio de una nueva era en la metalurgia predictiva. Esta combinación no solo acelera el análisis, sino que estandariza el control de calidad, permitiendo modelar incluso la cinética de crecimiento de capas mediante enfoques híbridos neuro-difusos. Con el propósito de dimensionar el alcance de la literatura existente, la Tabla 2 clasifica los estudios revisados según su naturaleza metodológica, diferenciando entre trabajos basados en simulación numérica, ensayos físicos destructivos y validaciones experimentales mediante microscopía avanzada.

TABLA 2
 CLASIFICACIÓN METODOLÓGICA DE LOS ESTUDIOS Y ENFOQUES CITADOS EN LA CARACTERIZACIÓN DE SUPERFICIES

Modelo / Arquitectura	Aplicación en Ingeniería de Superficies	Naturaleza Metodológica	Referencia
PGI-CrackNet y SEM	Identificación de microgrietas en aleaciones	Validación in-situ (Microscopía Electrónica de Barrido)	Chang et al., 2025 [1]
Ensayo Rockwell C + CNN	Clasificación de calidad de adhesión (Norma VDI 3198)	Ensayos físicos experimentales y clasificación visual	Lenz et al., 2020 [9]
Modelos Neuro-difusos	Predicción de la cinética de crecimiento de capas	Modelado numérico y simulación matemática	Mebarek & Keddami, 2019 [12]
Vision Transformers (ViT) y CNN	Análisis global de daños y procesamiento de imágenes	Modelos computacionales de aprendizaje profundo	Maurício et al., 2023 [13]

Tradicionalmente, la aplicación de la inteligencia artificial en la ingeniería de superficies se ha visualizado de forma fragmentada: por un lado, herramientas de visión por computadora para la detección de defectos estéticos o microgrietas superficiales; por otro, modelos matemáticos y neurodifusos orientados a predecir variables fisicoquímicas, como la cinética de crecimiento de las capas de boruros metálicos ("FeB" y "Fe₂B") en función de la temperatura y el tiempo de tratamiento.

Sin embargo, la gran interrogante que redefine el estado del arte es si la IA puede tender un puente directo entre la respuesta visual y la evolución microestructural: *¿es posible que, a partir de las características morfológicas y la densidad de microgrietas visibles en la superficie, el sistema logre inferir la cinética de difusión del boro y la resistencia interna del recubrimiento?*

Aunque los modelos actuales operan mayoritariamente en dominios separados, la segmentación visual por un lado y la predicción numérica por el otro, la tendencia apunta al desarrollo de arquitecturas híbridas multimodales. Estas plataformas combinan la extracción de rasgos espaciales mediante redes profundas con el modelado neurodifuso, permitiendo no solo diagnosticar el daño presente, sino simular y anticipar el comportamiento

VII. RETOS Y LIMITACIONES CRÍTICAS EN LA CARACTERIZACIÓN INTELIGENTE DE SUPERFICIES

A pesar del gran potencial demostrado por las arquitecturas de aprendizaje profundo en la ingeniería de superficies, su adopción masiva en entornos industriales de alta exigencia enfrenta importantes desafíos metodológicos y técnicos que deben resolverse:

- Sobreajuste (Overfitting) y dependencia de entorno: Un riesgo latente en los modelos actuales es que aprendan las características específicas de las condiciones de iluminación, ataque químico o la óptica del microscopio del laboratorio donde se generaron los datos de entrenamiento, perdiendo precisión al ser desplegados en equipos industriales externos.
- El dilema del etiquetado de datos y el sesgo del experto: El entrenamiento de redes neuronales supervisadas requiere bases de datos extensas y etiquetadas a nivel de píxel. Dado que este etiquetado inicial sigue recayendo en la inspección visual humana, el modelo hereda inevitablemente la subjetividad y el sesgo cognitivo del experto que clasificó las micrografías originales.
- Interpretabilidad y el problema de la "caja negra": Modelos complejos como las CNN y los Vision Transformers (ViT) operan frecuentemente como cajas negras. En componentes críticos para sectores de alta responsabilidad (como la industria aeroespacial o la automotriz), la falta de explicabilidad sobre por qué un algoritmo determinó un fallo de adhesión o un nivel de severidad dificulta su certificación normativa absoluta.
- Problemas de generalización entre materiales: Un modelo entrenado para identificar microgrietas o capas de difusión en aceros al carbono o aceros aleados (como los sistemas borurados) raramente puede transferir su conocimiento directamente a aleaciones de titanio, aluminio o recubrimientos cerámicos avanzados (PVD/CVD) sin un proceso exhaustivo de reentrenamiento o técnicas de transferencia de aprendizaje (transfer learning).

Es importante destacar que un modelo entrenado para identificar microgrietas o capas de difusión en aceros al carbono o aceros aleados (como los sistemas borurados) raramente puede transferir su conocimiento directamente a aleaciones de titanio, aluminio o recubrimientos cerámicos avanzados (PVD/CVD) sin un proceso exhaustivo de reentrenamiento o técnicas de transferencia de aprendizaje (transfer learning). En consecuencia, el desarrollo de modelos universales capaces de adaptarse dinámicamente a diversas matrices metálicas continúa siendo el gran horizonte de investigación en la metalurgia computacional.

VIII. CONCLUSIONES

La incorporación de la inteligencia artificial en la ingeniería de superficies representa un cambio fundamental para transformar los métodos tradicionales de inspección en procesos automatizados y objetivos. Para consolidar esta evolución hacia una metalurgia predictiva, la investigación futura debe avanzar en una hoja de ruta clara que impulse el desarrollo de modelos híbridos multimodales, combinando la precisión local de las redes neuronales convolucionales con el contexto global de los Vision Transformers para evaluar la adhesión en tiempo real durante tratamientos como el boriding. Asimismo, resulta clave adoptar el aprendizaje federado para permitir la colaboración segura y el intercambio de datos entre diferentes industrias sin vulnerar la confidencialidad comercial. Finalmente, los esfuerzos futuros deberán enfocarse en la fusión termovisual para conectar el análisis de las imágenes superficiales con la predicción de la cinética de difusión interna, logrando así metodologías más robustas y alineadas con las exigencias industriales.

CRediT (Contributor Roles Taxonomy)

Author's contributions: Conceptualization: AALG, NLP; Methodology: AALG, NLP; Investigation: AALG, AAGG, JRAM; Writing-original draft preparation: AALG, AAGG, NLP; Writing-review and editing: AALG, NLP, MADR; Supervision: NLP, MADR; Formal analysis: AALG, NLP; Project administration: AALG; Funding acquisition: AALG.

Funding: The authors are thankful to Universidad Nacional Autónoma de México for the support of the project through the PAPIMI 2026 call.

Data Availability Statement: Data are contained within the article.

Conflict of interest: The authors declare that there is no conflict of interest.

REFERENCES

- [1] Z. Chang, C. Wang, Q. Wang, X. Cheng, C. Wang, X. Liu, B. Wang, Y. Zhang, R. Wang, "High-precision identification and classification of alloy fatigue microcracks through deep learning and in-situ SEM," *Computational Materials Science*, vol. 252, p. 113795, 2025, doi: <https://doi.org/10.1016/j.commatsci.2025.113795>
- [2] I. Azuri, I. Rosenhek-Goldian, N. Regev-Rudski, G. Fantner, S. R. Cohen, "The role of convolutional neural networks in scanning probe microscopy: A review," *Beilstein Journal of Nanotechnology*, vol. 12, pp. 878-901, 2021, doi: <https://doi.org/10.3762/bjnano.12.66>
- [3] S. H. Mokhlis, A. A. Alhomoud, R. I. Alshaw, S. K. Alhazzani, L. A. Alhazzaa, "A review of detecting and quantification of cracks using convolutional neural networks and image processing techniques," in *Image Processing, Computer Vision, and Pattern Recognition and Information and Knowledge Engineering*, L. Deligiannidis, F. Ghareh Mohammadi, F. Shenavarmasouleh, S. Amirian, and H. R. Arabnia, Eds., Springer, 2025, pp. 1-8, doi: https://doi.org/10.1007/978-3-031-85933-5_18
- [4] I. Joshi, N. Deshmukh, P. Gurjar, R. Sreemathy, "A review on convolutional neural networks and vision transformers," in *ICT Systems and Sustainability. ICT4SD 2024*, vol. 1159, M. Tuba, S. Akashe, and A. Joshi, Eds., Springer, 2025, doi: https://doi.org/10.1007/978-981-97-8526-1_11
- [5] L. Zhao, Y. Wang, F. Bu, P. Wang, L. Tian, C. Liu, "Corrosion damage detection and evaluation of coated steel components under multiple illumination conditions," *Measurement*, vol. 250, p. 117179, 2025, doi: <https://doi.org/10.1016/j.measurement.2025.117179>
- [6] P. A. Dearnley, A. Matthews, and A. Leyland, "Tribological behaviour of thermochemical surface engineered steels," in *Thermochemical Surface Engineering of Steels*, 2^a ed., E. J. Mittemeijer, M. A. J. Somers, Eds., Woodhead Publishing, 2026, pp. 257-283, doi: <https://doi.org/10.1016/B978-0-12-820587-7.00005-X>
- [7] N. López-Perrusquia, M. A. Doñu-Ruiz, F. Vasquez, O. Trujillo-Alfaro, Y. E. Vargas-Oliva, "Study of adhesion in steels surface hardened," *Advanced Materials Research*, vol. 535-537, pp. 513-516, 2012, doi: <https://doi.org/10.4028/www.scientific.net/amr.535-537.513>
- [8] VDI, *Testing of the adhesion of hard coatings; Rockwell C indentation test; Classification of damage patterns* (VDI 3198), Beuth Verlag.
- [9] B. Lenz, H. Hasselbruch, A. Mehner, "Automated evaluation of Rockwell adhesion tests for PVD coatings using convolutional neural networks," *Surface and Coatings Technology*, vol. 385, p. 125365, 2020, doi: <https://doi.org/10.1016/j.surfcoat.2020.125365>
- [10] K. Genel, I. Ozbek, A. Kurt, C. Bindal, "Boronizing response of AISI W1 steel and use of artificial neural network for prediction of borided layer properties," *Surface and Coatings Technology*, vol. 160, no. 1, pp. 38-43, 2002, doi: [https://doi.org/10.1016/S0257-8972\(02\)00400-0](https://doi.org/10.1016/S0257-8972(02)00400-0)
- [11] O. D. Gonzalez Arias, M. A. Donu Ruiz, J. V. Cortes Suarez, C. R. Torres San Miguel, D. Sánchez Huitron, T. de la Mora Ramírez, N. López Perrusquia, "Flaw detection on surface-treated steels using convolutional neural networks (CNN)," *Microscopy and Microanalysis*, vol. 30, no. Suppl. 1, pp. 450-451, 2024, doi: <https://doi.org/10.1093/mam/ozae044.209>
- [12] B. Mebarek, M. Keddami, "A fuzzy neural network approach for modeling the growth kinetics of FeB and Fe2B layers during the boronizing process," *Matériaux & Techniques*, vol. 106, no. 6, p. 603, 2019, doi: <https://doi.org/10.1051/mattech/2019002>
- [13] J. Maurício, I. Domingues, J. Bernardino, "Comparing vision transformers and convolutional neural networks for image classification: A literature review," *Applied Sciences*, vol. 13, no. 9, p. 5521, 2023, doi: <https://doi.org/10.3390/app13095521>