



**UNIVERSIDAD DE
CONCEPCIÓN
FACULTAD DE
INGENIERÍA
DEPARTAMENTO DE
INGENIERÍA QUÍMICA**

**Implementación de técnicas avanzadas de
análisis con infrarrojo cercano en conjunto con
Deep clustering para el estudio de la corrosión**

POR

Benjamín Alberto Mora Araneda

Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de
Concepción para optar al título profesional de Ingeniero Civil Químico.

Profesor Guía

Dr. Luis Felipe Montoya Redón

Profesor de Comisión

José Matías Garrido Acuña

Noviembre 2025

Concepción, Chile

© 2025 Benjamín Alberto Mora Araneda

Resumen

La corrosión marina representa uno de los desafíos más críticos para la infraestructura costera e *offshore*, con costos globales superiores a 2.5 billones de dólares anuales (3.4 % del PIB mundial). En Chile, este fenómeno genera pérdidas estimadas de 11.229 millones de dólares anuales, afectando sectores como la acuicultura y la industria naval. La Corrosión Influenciada por Microorganismos (MIC) representa entre el 20 % y el 40 % de la corrosión submarina.

Los métodos de inspección tradicionales presentan limitaciones fundamentales: son reactivos, subjetivos y resultan incapaces de detectar corrosión en etapas incipientes bajo recubrimientos protectores. Los enfoques de aprendizaje profundo supervisado, aunque efectivos, enfrentan un obstáculo crítico: la escasez de grandes conjuntos de datos públicos etiquetados, cuya generación es costosa y propensa a sesgos humanos.

Este trabajo desarrolla una metodología de visión artificial basada en Deep Clustering no supervisado para la segmentación automática de estados de corrosión mediante análisis de imágenes hiperespectrales en el infrarrojo cercano (NIR, 895-1718 nm). El sistema integra un pipeline de cuatro etapas: (1) adquisición con cámara hiperespectral Pika IR+-1060 (344 bandas espectrales), (2) reducción dimensional con PCA (344 a 3 componentes, 99 % varianza), (3) extracción de características con ResNet-50 pre-entrenada usando SimCLR (embeddings 2048D), y (4) clustering mediante UMAP y HDBSCAN optimizados por GridSearchCV.

El sistema identificó automáticamente 12 clústeres en 103 probetas expuestas durante 156 días, correspondientes a diferentes modos de fallo (oxidación, metal desnudo, ampollamiento, agrietamiento, recubrimiento intacto). Solo el 5.23 % de muestras fueron clasificadas como ruido. La validación cuantitativa confirmó la calidad de la segmentación: Silhouette Score = 0.569, Davies-Bouldin Index = 1.19, Calinski-Harabasz Score = 16,059.53. La consistencia entre conjuntos de entrenamiento y testeo demostró capacidad de generalización.

Una ventaja fundamental del pipeline reside en su escalabilidad. Al implementar un enfoque no supervisado, el sistema no requiere etiquetado manual de datos, eliminando un cuello de botella crítico. El modelo puede ser mejorado mediante el aumento de la base de datos con nuevas mediciones hiperespectrales NIR, sin necesidad de costosas campañas de anotación por expertos. Este trabajo demuestra la viabilidad de utilizar imágenes hiperespectrales y Deep Clustering para clasificación automática de estados de corrosión, estableciendo una base para

sistemas de inspección que revolucionen el mantenimiento predictivo de estructuras metálicas.

Palabras clave: Corrosión marina, Deep Clustering, imagen hiperspectral, infrarrojo cercano, ResNet-50, SimCLR, UMAP, HDBSCAN, inspección no destructiva, aprendizaje no supervisado.

Abstract

Marine corrosion represents one of the most critical challenges for coastal and offshore infrastructure, with global costs exceeding 2.5 trillion USD annually (3.4 % of global GDP). In Chile, this phenomenon generates estimated losses of 11.229 billion dollars per year, affecting strategic sectors such as aquaculture and the naval industry. Microbiologically Influenced Corrosion (MIC) accounts for 20-40 % of subsea corrosion.

Traditional inspection methods present fundamental limitations: they are reactive, subjective, and unable to detect incipient corrosion under protective coatings. Supervised deep learning approaches, although effective, face a critical obstacle: the scarcity of large labeled public datasets, whose generation is costly and prone to human biases.

This work develops a computer vision methodology based on unsupervised Deep Clustering for automatic segmentation of corrosion states through near-infrared (NIR, 895-1718 nm) hyperspectral image analysis. The system integrates a four-stage pipeline: (1) acquisition with Pika IR+-1060 hyperspectral camera (344 spectral bands), (2) dimensional reduction with PCA (344 to 3 components, 99 % variance), (3) feature extraction with ResNet-50 pre-trained using SimCLR (2048D embeddings), and (4) clustering using UMAP and HDBSCAN optimized by GridSearchCV.

The system automatically identified 12 clusters in 103 specimens exposed for 156 days, corresponding to different failure modes (oxidation, bare metal, blistering, cracking, intact coating). Only 5.23 % of samples were classified as noise. Quantitative validation confirmed segmentation quality: Silhouette Score = 0.569, Davies-Bouldin Index = 1.19, Calinski-Harabasz Score = 16,059.53. Consistency between training and testing sets demonstrated generalization capability. A fundamental advantage of the pipeline lies in its scalability. By implementing an unsupervised approach, the system does not require manual data labeling, eliminating a critical bottleneck. The model can be improved by expanding the database with new NIR hyperspectral measurements, without costly expert annotation campaigns. This work demonstrates the viability of using hyperspectral imaging and Deep Clustering for automatic classification of corrosion states, establishing a foundation for inspection systems that revolutionize predictive maintenance of metallic structures.

Keywords: Marine corrosion, Deep Clustering, hyperspectral imaging, near-infrared, ResNet-50, SimCLR, UMAP, HDBSCAN, non-destructive inspection, unsupervised learning.

Índice

1. Introducción	1
1.1. Contexto y Relevancia del Problema	1
1.2. Limitaciones de los Métodos de Inspección Tradicionales y Corrosión Microbiológica	1
1.3. Estrategias Contemporáneas de Mitigación	2
1.4. Tecnologías Emergentes: Visión Artificial e Imagen Hiperspectral	3
1.5. Aprendizaje Profundo y Detección Automática	4
1.6. Desafíos del Aprendizaje Supervisado y Alternativas No Supervisadas	5
1.7. Propuesta Metodológica	6
2. Objetivos	7
2.1. Objetivo General	7
2.2. Objetivos Específicos	7
3. Metodología	8
3.1. Descripción de Materiales	9
3.1.1. Sistema de Adquisición Hiperspectral	9
3.1.2. Descripción de las Probetas	10
3.2. Preprocesamiento y Reducción Dimensional	11
3.2.1. Justificación de la Reducción Dimensional	11
3.2.2. Pipeline de Reducción Espectral	11
3.2.3. Proyección de Imágenes	13
3.3. Data Augmentation	13
3.4. Extracción de Características con Aprendizaje Auto-Supervisado	15
3.4.1. Limitaciones del Aprendizaje Supervisado y Justificación del Transfer Learning	15
3.4.2. Muestreo y Preprocesamiento de Parches	16
3.4.3. Vectorización mediante ResNet-50 Pre-entrenada	16
3.5. Análisis de Clustering y Segmentación No Supervisada	18
3.5.1. Pipeline de Clustering: UMAP + HDBSCAN	18

3.5.2. Optimización del Hiperparámetro <code>min_cluster_size</code>	21
3.6. Métricas de Evaluación de Clusters	21
3.6.1. Silhouette Score (Coeficiente de Silueta)	21
3.6.2. Davies-Bouldin Score (Índice de Davies-Bouldin)	22
3.6.3. Calinski-Harabasz Score (Índice de Calinski-Harabasz)	22
4. Resultados	24
4.1. Reducción Dimensional y Espacio Latente	24
4.2. Segmentación y Validación de Clústeres	25
4.2.1. Optimización de Hiperparámetros mediante Grid Search	25
4.2.2. Métricas de Calidad del Clustering	27
4.3. Caracterización de Estados de Corrosión	27
4.3.1. Estados de Referencia y Defectos Incipientes	28
4.3.2. Fallas Físicas del Recubrimiento (Ampollamiento y Agrietamiento)	28
4.3.3. Oxidación y Exposición de Sustrato	29
4.3.4. Fallas Críticas y Múltiples	29
4.3.5. Detección de Ruido	30
4.4. Comparación con el Estado del Arte en Deep Clustering	30
4.4.1. Análisis Comparativo	31
4.4.2. Posicionamiento del Trabajo	32
5. Conclusiones	34
5.1. Cumplimiento de Objetivos	34
5.2. Conclusiones Generales e Impacto	35
5.3. Limitaciones y Trabajo Futuro	36
Anexos	38
Anexo Figuras: Imágenes Ampliadas	38
Anexo A: Estrategias de Prevención de la Corrosión	43
Anexo B: Inhibidores Ecológicos	44
Anexo C: Modelos de Deep Learning	45
Anexo D: Deep Clustering	47

Anexo E: Detección Espectral	48
Anexo F: Restauración de Imágenes	50
Anexo G: Impacto Económico	51
Anexo H: Firmas Espectrales	52

Índice de figuras

1.	Diagrama esquemático del pipeline metodológico completo mostrando las etapas de procesamiento y las dimensionalidades en cada paso.	9
2.	Transformación de imágenes hiperespectrales (344 bandas) a representaciones pseudo-RGB (3 canales) mediante PCA.	13
3.	Ejemplos de parches originales y sus transformaciones geométricas y espectrales aplicadas para data augmentation.	15
4.	Esquema conceptual del método SimCLR usado para pre-entrenar ResNet-50 mediante aprendizaje contrastivo.	18
5.	Representación esquemática de la proyección UMAP de 2048 a 32 dimensiones preservando estructura topológica.	19
6.	Esquema del clustering basado en densidad con HDBSCAN mostrando detección automática de clusters y ruido.	20
7.	Varianza explicada por los componentes principales. La retención de ¿99% de información con solo 3 componentes justifica la reducción dimensional para el procesamiento con CNNs. (Ver versión ampliada en Anexo 17)	24
8.	Visualización de la proyección PCA aplicada a una imagen hiperespectral de probeta corroída. De izquierda a derecha: imagen RGB original y las tres componentes principales extraídas. Cada componente captura diferentes características espectrales: estructura global (Comp. 1), transiciones químicas (Comp. 2) y heterogeneidades locales (Comp. 3). (Ver versión ampliada en Anexo 18)	25
9.	Proyección UMAP 2D de los embeddings de 2048 dimensiones. Los colores representan los clústeres asignados por HDBSCAN, evidenciando la capacidad del modelo para separar semánticamente los estados de corrosión. (Ver versión ampliada en Anexo 19)	26
10.	Análisis de sensibilidad de hiperparámetros UMAP mediante GridSearchCV. El mapa muestra el Silhouette Score en función de <code>n_neighbors</code> y <code>n_components</code> . La configuración óptima (<code>n_neighbors=25</code> , <code>n_components=32</code> , <code>Silhouette=0.569</code>) se marca en rojo. (Ver versión ampliada en Anexo 20)	26

11.	Distribución de muestras por clúster. La similitud entre (a) y (b) confirma la estabilidad y escalabilidad del modelo ante nuevos datos. (Ver versiones ampliadas en Anexo 21)	28
12.	Estados de referencia. (a) Recubrimiento intacto. (b) y (c) Alteraciones superficiales menores sin fallo estructural. (Ver versiones ampliadas en Anexo 22) . . .	28
13.	Defectos físicos. (a) y (b) Ampollamiento (Blistering). (c) Agrietamiento (Cracking) con exposición de sustrato. (Ver versiones ampliadas en Anexo 22)	29
14.	Pérdida de integridad. (a) Sustrato expuesto brillante. (b) Oxidación activa. (c) Agrietamiento con oxidación incipiente. (Ver versiones ampliadas en Anexo 22) .	29
15.	Modos de fallo críticos. (a) Corrosión por picado. (b) y (c) Degradación avanzada con múltiples mecanismos simultáneos. (Ver versiones ampliadas en Anexo 22) .	29
16.	Clúster -1: Ruido y artefactos filtrados automáticamente. (Ver versión ampliada en Anexo 22)	30
17.	Versión ampliada: Varianza explicada por los componentes principales	38
18.	Versión ampliada: Proyección PCA aplicada a imagen hiperespectral de probeta corroída	39
19.	Versión ampliada: Proyección UMAP 2D de los embeddings	40
20.	Versión ampliada: Análisis de sensibilidad de hiperparámetros UMAP mediante GridSearchCV	41
21.	Versiones ampliadas: Distribución de muestras por clúster en entrenamiento y testeo	41
22.	Versiones ampliadas: Caracterización visual de todos los clústeres identificados .	42

Índice de cuadros

1.	Comparación del desempeño de clustering con métodos del estado del arte . . .	31
2.	Metodologías de prevención de la corrosión para acero en ambientes marinos . .	44
3.	Investigaciones sobre metodologías ecológicas de inhibición de corrosión	45
4.	Comparativa de rendimiento de modelos de detección y clasificación de corrosión	46
5.	Rendimiento de métodos de Deep Clustering en benchmarks estándar	48
6.	Rendimiento de sistemas hiperspectrales y NIR en detección de corrosión . . .	49
7.	Nuevas arquitecturas para restauración de video e imagen submarina	50
8.	Impacto económico de la corrosión a nivel global y nacional	52
9.	Características espectrales de productos de corrosión en ambiente marino	53

1 Introducción

1.1 Contexto y Relevancia del Problema

La corrosión marina constituye uno de los desafíos más críticos para la infraestructura costera y *offshore* a nivel mundial. Según cifras referenciadas en el estudio de (Yu et al., 2025b), el costo global de la corrosión excede los 2.5 billones de dólares estadounidenses anuales, equivalente aproximadamente al 3.4 % del Producto Interno Bruto mundial. Este fenómeno no solo compromete la integridad estructural de los activos industriales, sino que conlleva gastos operativos sustanciales asociados al mantenimiento preventivo y la sustitución prematura de materiales degradados.

En el contexto nacional, el impacto económico es proporcionalmente significativo dada la extensa costa chilena. Según los datos del (Banco Mundial, 2024), el PIB de Chile para 2024 asciende a 330.267 millones de dólares; aplicando la estimación global del 3.4 % como referencia conservadora, el costo anual estimado de la corrosión en el país alcanza aproximadamente 11.229 millones de dólares. Esta cifra cobra mayor relevancia al considerar factores ambientales locales, como la presencia de la corriente de Humboldt, que intensifica las condiciones corrosivas y favorece el *biofouling* en estructuras sumergidas.

La industria nacional evidencia estos efectos en sus reportes financieros. De acuerdo con (Camanchaca S.A., 2023), en el sector acuícola se reporta en el ítem de “otros resultados” del segmento de salmones un valor negativo de 4.538 miles de dólares estadounidenses (MUS\$) para el año 2023, directamente relacionado con el mantenimiento de jaulas y procesos operativos afectados por la corrosión submarina. En el sector naval, según (Astilleros y Maestranzas de la Armada, 2023), los gastos asociados a la reparación de estructuras sumergidas alcanzan un monto cercano a los 63.428 miles de dólares estadounidenses (MUS\$), consolidándose como una de las cifras más representativas del impacto directo de este fenómeno en la industria nacional.

1.2 Limitaciones de los Métodos de Inspección Tradicionales y Corrosión Microbiológica

Los métodos de inspección convencionales, como los ensayos no destructivos por ultrasonido o la inspección visual directa, presentan deficiencias significativas que limitan su efectividad.

Estas técnicas son inherentemente reactivas, subjetivas, requieren contacto físico con las estructuras y resultan incapaces de detectar corrosión en etapas incipientes, especialmente aquella que se desarrolla debajo de recubrimientos protectores. Según (Imran et al., 2023), los métodos tradicionales de procesamiento de imágenes para detección de corrosión requieren recursos humanos sustanciales, elevada carga de trabajo y recursos financieros considerables, limitando su implementación a escala industrial.

Un aspecto crítico frecuentemente subestimado es la Corrosión Influenciada por Microorganismos (MIC, por sus siglas en inglés). De acuerdo con el estudio de (Dalmora et al., 2025), entre el 20 % y el 40 % de la corrosión submarina es impulsada por acción microbiológica, específicamente por bacterias reductoras de sulfatos (SRB), cuya actividad metabólica genera condiciones electroquímicas locales que aceleran dramáticamente la degradación del material. En este contexto, (Kobisy et al., 2025) destacan que la investigación actual se centra en el desarrollo de polímeros de recubrimiento basados en productos naturales como el quitosano, que sean económicamente viables y minimicen el impacto ambiental, considerando que aproximadamente el 20 % de la corrosión en plantas petroleras *offshore* se atribuye a la corrosión submarina.

1.3 Estrategias Contemporáneas de Mitigación

La mitigación de la corrosión marina ha evolucionado significativamente, transitando desde enfoques tradicionales basados en recubrimientos epóxicos y biocidas tóxicos hacia estrategias sostenibles y tecnológicamente avanzadas. Según la revisión sistemática de (Dalmora et al., 2025), las estrategias contemporáneas se clasifican en el desarrollo de recubrimientos inteligentes, el uso de inhibidores ecológicos y la optimización de técnicas electroquímicas (para más información sobre las metodologías específicas, sus mecanismos de acción, ventajas y limitaciones, consulte Tabla 2 en Anexos).

En el ámbito de superficies superhidrofóbicas, (Li et al., 2025) desarrollaron un recubrimiento compuesto sobre aleación de aluminio 7075 mediante ablación láser y oxidación electrolítica por plasma, logrando un ángulo de contacto de 155.6° y reducción de la densidad de corriente de corrosión en cuatro órdenes de magnitud. Paralelamente, (Mouez et al., 2025) sintetizaron recubrimientos de nanotubos de carbono sobre acero *maraging* utilizando biomasa de cáscara de naranja, reduciendo la densidad de corriente de corrosión tres veces y aumentando la resistencia a la corrosión cinco veces respecto al acero desnudo, con un incremento de impedancia de tres

órdenes de magnitud.

En polímeros funcionalizados, (Yu et al., 2025a) investigaron recubrimientos de quitosano con 2-mercaptobenzotiazol (MBT), demostrando que el enlace químico entre el inhibidor y la matriz de quitosano ofrece protección superior con impedancia de baja frecuencia ($|Z|_{0.01Hz}$) superior a $10^5 \Omega\text{cm}^2$. Adicionalmente, (Kumar et al., 2025) destacan en su revisión sistemática que los extractos de plantas, aminoácidos y biopolímeros están reemplazando compuestos sintéticos tóxicos con eficiencias competitivas. En protección electroquímica, (Lv et al., 2020) analizaron el efecto de la polarización catódica en acero X65 expuesto a SRB, evidenciando que las corrientes catódicas elevadas no solo protegen termodinámicamente el metal, sino que crean un ambiente local alcalino que inhibe la adhesión bacteriana inicial.

1.4 Tecnologías Emergentes: Visión Artificial e Imagen Hiperespectral

Para superar las limitaciones de los métodos tradicionales, la investigación reciente se ha orientado hacia la automatización mediante Inteligencia Artificial (IA) y técnicas avanzadas de visión artificial. La frontera tecnológica actual combina el análisis mediante redes neuronales profundas con imagen hiperespectral (HSI) en el espectro del infrarrojo cercano (NIR). A diferencia de la imagen visual convencional RGB, la tecnología hiperespectral captura cientos de bandas espectrales estrechas, permitiendo identificar materiales basándose en sus “firmas” espectrales químicas únicas.

De acuerdo con (Enguita et al., 2025), sistemas que fusionan sensores LiDAR con cámaras HSI operando en el rango VNIR (400–1000 nm) han demostrado capacidad para diferenciar condiciones superficiales (corrosión, recubrimientos intactos, metal desnudo) y variaciones en el espesor de recubrimientos protectores, con precisión espacial de localización inferior a 2 cm. Estas capacidades permiten identificar óxidos específicos como hematita ($\alpha\text{-Fe}_2\text{O}_3$), goethita ($\alpha\text{-FeOOH}$) y lepidocrocita ($\gamma\text{-FeOOH}$) mediante sus características de reflectancia distintivas en la región NIR. Complementariamente, (Su et al., 2024) desarrollaron métodos de corrección para espectrómetros Vis-NIR (400–2500 nm) que permiten mediciones precisas de pH en agua de mar, reduciendo el error cuadrático medio de predicción de 0.45 a 0.08 y aumentando el coeficiente de determinación de 0.85 a 0.99.

1.5 Aprendizaje Profundo y Detección Automática

Los modelos de aprendizaje profundo han demostrado capacidades excepcionales para la detección y clasificación automática de defectos superficiales (para información detallada sobre el rendimiento de los principales modelos, consulte Tabla 4 en Anexos).

De acuerdo con el estudio de (Yu et al., 2025b), las arquitecturas ResNet-50 pre-entrenadas han reportado un rendimiento experimental de 100 % de exactitud, precisión y F1-Score en tareas de clasificación binaria controlada sobre conjuntos de 9,000 imágenes de alta resolución (512×512 píxeles) en condiciones específicas del laboratorio. En comparación, (Yu et al., 2025b) reportan que InceptionV3 se posiciona como alternativa robusta con 99 % de rendimiento global, mientras que VGG16/19 mostraron rendimiento inferior (96-97 %) debido a mayor costo computacional. Para detección en tiempo real, (Ali, 2025) reportan que YOLOv5 es superior para inspecciones con ROVs, procesando video a 45 FPS (frente a 15 FPS de Mask R-CNN) con precisión media (mAP@0.5) del 93 %, superando el 87 % de los modelos de segmentación. Adicionalmente, (Dhungana et al., 2025) compararon YOLOv8 y YOLOv11 en entornos de visibilidad crítica en tuberías submarinas, destacando la capacidad de YOLOv11 para mantener detección donde versiones anteriores fallaban por oclusión.

En aplicaciones especializadas, (Son et al., 2024) entrenaron Mask R-CNN con 35,753 imágenes para detectar área de corrosión y predecir profundidad mediante algoritmos de regresión, permitiendo estimar pérdida de material sin contacto físico. Por su parte, (Zhang et al., 2024) desarrollaron un robot de adsorción con red UNet optimizada para segmentación automática de daños, combinada con controlador de rechazo de perturbaciones activas que asegura estabilidad frente a corrientes marinas.

Para mejorar la calidad de datos submarinos, (Cai et al., 2025) presentaron DUVR-Net, una red de restauración de video que utiliza información temporal entre fotogramas para corregir distorsión de color y desenfoque de movimiento. Complementariamente, (Guo et al., 2025) proponen un marco de restauración híbrido guiado por balance de color que sugiere recuperar detalles finos perdidos por turbidez. El trabajo de (Espinoza Llanos, 2023) y (Jamaludin and Imran, 2024) consolidan estas aplicaciones demostrando la viabilidad de IA para corrosión en estructuras marinas.

1.6 Desafíos del Aprendizaje Supervisado y Alternativas No Supervisadas

A pesar del potencial demostrado por las técnicas supervisadas, su implementación a escala industrial enfrenta obstáculos fundamentales. Un desafío crítico es la escasez de grandes conjuntos de datos públicos y etiquetados, necesarios para entrenar modelos supervisados robustos y generalizables (Imran et al., 2023). El proceso de etiquetado manual de miles de imágenes de corrosión requiere expertise técnico especializado, resulta costoso, consume tiempo considerable y es inherentemente propenso a inconsistencias y sesgos humanos.

Para superar estas limitaciones, el campo del aprendizaje automático ha desarrollado técnicas de **Deep Clustering** (clustering profundo). Según (Leiber and Plant, 2025), estas técnicas integran algoritmos de aprendizaje profundo con métodos de agrupamiento no supervisado, utilizando redes neuronales convolucionales para aprender representaciones latentes no lineales de baja dimensión optimizadas específicamente para la tarea de agrupamiento. La revisión de (Lu et al., 2024) destaca la evolución desde el uso de conocimiento previo (*priors*) basado en suposiciones estructurales simples hacia *priors* dinámicos basados en invariancia y aumentos de datos complejos (para información detallada sobre métodos de Deep Clustering y su rendimiento, consulte Tabla 5 en Anexos).

De acuerdo con (Qian, 2023), el método Stable Cluster Discrimination (SeCu) alcanzó en CIFAR-10 una exactitud del 88.1 %, Información Mutua Normalizada (NMI) del 79.4 % y un Índice de Rand Ajustado (ARI) del 77.6 %, validando la estabilización de discriminación sin etiquetas mediante restricciones de tamaño flexibles. En aplicaciones críticas, (Elfatimi et al., 2025) lograron exactitud del 98 %, precisión del 96.15 % y recall del 100 % en detección de tumores cerebrales combinando CNNs con clustering difuso y verificación formal mediante Model Checking.

En enfoques especializados, (Stephan et al., 2024) desarrollaron Text-Guided Alternative Image Consensus Clustering (TGAICC), utilizando Modelos de Lenguaje de Gran Escala (LLMs) para guiar el agrupamiento mediante *prompts* de usuario, superando métodos tradicionales en flexibilidad semántica. Por su parte, (Ling et al., 2022) propusieron Vision Transformer for Contrastive Clustering (VTCC), unificando Transformers con aprendizaje contrastivo para capturar dependencias globales de largo alcance. Adicionalmente, (Bjerger et al., 2025) aplicaron Model-Agnostic Meta-Learning (MAML) para escenarios con escasa data, optimizando la separación

entre clases con mínimos ejemplos.

Los trabajos fundacionales de (Caron et al., 2018) establecieron las bases del campo con Deep-Cluster, proponiendo aprendizaje iterativo entre k-means y actualización de pesos de CNN. Enfoques más recientes incluyen el clustering basado en difusión generativa de (Uziel et al., 2025), la detección gradual de comunidades de (Cheng and Chen, 2025), el Information Bottleneck diferenciable de (Yan et al., 2024) para clustering multi-vista, la extracción jerárquica de información de (Zhang et al., 2025), y las redes calibradas de (Jia et al., 2025) que redujeron la tasa de falsos positivos (FPR95) en 19.5 % en detección de anomalías fuera de distribución.

1.7 Propuesta Metodológica

Ante la naturaleza reactiva, subjetiva y limitada de los métodos tradicionales de inspección visual y ultrasónica, junto con la escasez de grandes conjuntos de datos etiquetados requeridos por enfoques supervisados, este trabajo desarrolla una metodología que integra imagen hiperespectral en el infrarrojo cercano (NIR, 895–1718 nm) con técnicas de Deep Clustering no supervisado. La elección del rango espectral NIR/SWIR permite capturar firmas químicas distintivas de productos de corrosión (óxidos de hierro) que resultan imperceptibles para sistemas RGB convencionales, mientras que la adopción de Deep Clustering elimina la dependencia de etiquetado manual costoso y propenso a sesgos humanos. La metodología combina reducción dimensional mediante PCA, extracción de representaciones profundas con ResNet-50 pre-entrenada usando aprendizaje contrastivo SimCLR, y agrupamiento adaptativo basado en densidad mediante UMAP+HDBSCAN, constituyendo la primera aplicación documentada de este enfoque integrado para clasificación espectral de corrosión marina y estableciendo un paradigma escalable en inspección no destructiva automatizada.

2 Objetivos

2.1 Objetivo General

Desarrollar una metodología basada en visión artificial y técnicas de reducción dimensional para la detección y caracterización automática de estados de corrosión en recubrimientos metálicos, a partir del análisis de imágenes hiperespectrales.

2.2 Objetivos Específicos

Los objetivos específicos de este trabajo son:

1. Reducir la dimensionalidad espectral de las imágenes hiperespectrales mediante Análisis de Componentes Principales (PCA), tras una normalización estándar, y transformar los datos para su procesamiento con arquitecturas de visión artificial pre-entrenadas, generando una representación compacta de 3 componentes que preserve la información espectral relevante.
2. Desarrollar un modelo de inteligencia artificial basado en aprendizaje auto-supervisado (ResNet-50 + SimCLR) para extraer características principales de las imágenes analizadas, generando un espacio de embedding de alta dimensionalidad con representaciones semánticas robustas.
3. Segmentar el espacio latente mediante algoritmos de clustering no supervisado (UMAP + HDBSCAN) para identificar y agrupar patrones de datos correspondientes a los distintos estados de corrosión de la superficie del material.
4. Validar la segmentación generada mediante métricas cuantitativas de clustering (Silhouette Score, Davies-Bouldin, Calinski-Harabasz) y correlacionar los clústeres identificados con modos de fallo físicos mediante inspección visual sistemática y análisis de coherencia entre conjuntos de entrenamiento y testeo.

3 Metodología

El desarrollo de una metodología para la segmentación automática de corrosión en recubrimientos surge como respuesta a las limitaciones identificadas en los sistemas de inspección convencionales. Como se estableció en la introducción, los métodos tradicionales de inspección visual y ultrasónica son reactivos, subjetivos, requieren contacto físico y resultan incapaces de detectar corrosión en etapas incipientes bajo recubrimientos protectores. De acuerdo con (Imran et al., 2023), estas limitaciones han motivado el desarrollo de sistemas automatizados de detección que superen las restricciones de los métodos convencionales. Adicionalmente, los enfoques de aprendizaje profundo supervisado enfrentan la escasez de grandes conjuntos de datos públicos etiquetados, cuya generación es costosa, consume tiempo y es propensa a inconsistencias humanas (Imran et al., 2023). Ante estos desafíos, se propone un pipeline que integra imagen hiperespectral en el infrarrojo cercano con técnicas de Deep Clustering no supervisado, combinando reducción dimensional mediante PCA, extracción de representaciones mediante ResNet-50 pre-entrenada con SimCLR, y agrupamiento adaptativo con UMAP y HDBSCAN (ver Figura 1). A continuación se detallan las etapas del pipeline, justificando las decisiones metodológicas con base en la literatura especializada y los problemas identificados.

La Figura 1 muestra esquemáticamente el pipeline completo, desde la adquisición hiperespectral NIR (344 bandas espectrales) hasta la segmentación final. El proceso inicia con la reducción dimensional mediante PCA, que transforma las 344 bandas a 3 componentes pseudo-RGB. Estas imágenes se procesan con ResNet-50 pre-entrenada mediante SimCLR para extraer embeddings de 2048 dimensiones. Finalmente, UMAP reduce estos embeddings a 32 dimensiones, sobre las cuales HDBSCAN identifica clusters correspondientes a diferentes estados de corrosión.




Figura 1: Diagrama esquemático del pipeline metodológico completo mostrando las etapas de procesamiento y las dimensionalidades en cada paso.

3.1 Descripción de Materiales

3.1.1. Sistema de Adquisición Hiperespectral

Para la captura de información espectral en el rango del infrarrojo cercano (NIR), se utilizó la cámara hiperespectral Pika IR+-1060 (Resonon Inc., EE.UU.). Este sistema permite la adquisición de imágenes en el rango espectral de 895 a 1718 nm, capturando 344 bandas espectrales contiguas con una resolución espectral de 2.4 nm. La configuración de adquisición se estableció con un tiempo de exposición de 9.072 ms y una velocidad de captura de 77 fotogramas por segundo, operando a una temperatura controlada de 25°C.

La selección del rango espectral NIR responde directamente a la limitación de los métodos de inspección visual tradicionales, que resultan incapaces de detectar corrosión bajo recubrimientos protectores. Como se documenta en la introducción, (Enguita et al., 2025) demostraron que sistemas HSI en el rango VNIR (400-1000 nm) permiten identificar óxidos específicos como hematita ($\alpha\text{-Fe}_2\text{O}_3$), goethita ($\alpha\text{-FeOOH}$) y lepidocrocita ($\gamma\text{-FeOOH}$) mediante sus firmas espectrales distintivas, con capacidad demostrada para diferenciar condiciones superficiales (corrosión, recubrimientos, metal desnudo) y variaciones en el espesor de recubrimientos protec-

tores. El rango NIR extendido (895-1718 nm) permite penetrar capas superficiales y revelar propiedades químicas y estructurales no detectables en el espectro visible, caracterizando la composición de recubrimientos y detectando productos de corrosión temprana. Adicionalmente, (Imran et al., 2023) señalan que este rango espectral mitiga el efecto de la iluminación ambiental y la textura superficial irrelevante, aspectos críticos en inspección industrial. Información adicional sobre aplicaciones de HSI en corrosión se presenta en la Tabla ?? del Anexo.

Las imágenes se almacenaron en formato ENVI Standard con interleave BIL (Band Interleaved by Line) y tipo de dato float32, asegurando precisión numérica para análisis cuantitativos posteriores.

3.1.2. Descripción de las Probetas

El conjunto de datos comprende 103 probetas de acero con diferentes formulaciones de recubrimiento anti-corrosivo, sometidas a exposición marina controlada durante 156 días. Las probetas fueron proporcionadas por estudios previos de (Rivera, 2023) y (Belmar, 2023), y corresponden a cuatro formulaciones principales:

1. Blanco (control sin aditivos protectores).
2. Z40Cu8 (recubrimiento con zinc y cobre).
3. Z40Cu8CPS1.5 (formulación anterior con inhibidor CPS).
4. Capsaicina (recubrimiento con compuesto bioactivo natural).

La selección de estas formulaciones refleja las estrategias contemporáneas de mitigación discutidas en la introducción. Como se estableció, la investigación actual transita desde enfoques tradicionales basados en recubrimientos epóxicos y biocidas tóxicos hacia estrategias sostenibles. (Dalmora et al., 2025) documentan que las metodologías de prevención de corrosión han evolucionado significativamente en las últimas décadas. La incorporación de productos naturales como la capsaicina representa esta tendencia hacia alternativas sostenibles (Kobisy et al., 2025), mientras que las formulaciones con zinc mantienen su vigencia como estándar de protección galvánica. La Tabla 2 en Anexos detalla las metodologías de prevención, sus mecanismos de acción y limitaciones. Este conjunto permite evaluar comparativamente la efectividad de diferentes estrategias, desde controles negativos hasta inhibidores ecológicos avanzados.

3.2 Preprocesamiento y Reducción Dimensional

3.2.1. Justificación de la Reducción Dimensional

Los datos hiperespectrales presentan un desafío computacional y estadístico conocido como la maldición de la dimensionalidad (*curse of dimensionality*). Con 344 bandas espectrales, las imágenes contienen una redundancia espectral considerable debido a la alta correlación entre bandas adyacentes. La reducción de dimensionalidad de los canales espectrales es necesaria para compatibilizar los datos hiperespectrales con arquitecturas de redes neuronales convolucionales pre-entrenadas, que típicamente esperan entradas de 3 canales (RGB). Este preprocesamiento permite aprovechar el conocimiento transferible de modelos como ResNet-50 pre-entrenado con SimCLR para la extracción de representaciones semánticas visuales de alta dimensión (*embeddings*), sobre las cuales posteriormente se aplicará el clustering no supervisado.

Para abordar este problema, se implementó una reducción dimensional mediante Análisis de Componentes Principales (PCA), técnica ampliamente utilizada en Deep Clustering para transformar datos de alta dimensión preservando la máxima varianza (Lu et al., 2024). PCA identifica las direcciones ortogonales que maximizan la varianza en los datos, permitiendo una representación compacta sin pérdida significativa de información. En el presente estudio, la aplicación de PCA permitió reducir las 344 bandas espectrales originales a 3 componentes principales, reteniendo más del 99 % de la varianza acumulada (ver análisis detallado en Sección de Resultados). Esta transformación no constituye la reducción dimensional para el clustering final, sino un paso previo necesario para generar imágenes pseudo-RGB compatibles con el extractor de características basado en ResNet-50 (ver Figura 2).

3.2.2. Pipeline de Reducción Espectral

Para garantizar un proceso de reducción robusto, se realizó un muestreo de píxeles de todas las imágenes hiperespectrales disponibles, aplanándolos en una matriz donde cada fila representa el espectro de un píxel. Sobre esta matriz, se entrenó un pipeline secuencial compuesto por:

1. StandardScaler: Se aplicó una normalización estándar (Z-score) a los datos espectrales mediante la transformación:

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (1)$$

Esta operación centra los datos en una media de cero y una desviación estándar de uno, asegurando que las bandas espectrales con mayor reflectancia no dominen el análisis de componentes principales. (Qian, 2023) documentan que la estandarización es un requisito previo para PCA, ya que previene sesgos introducidos por diferencias de escala entre variables.

2. **Análisis de Componentes Principales (PCA):** Se realizó un análisis de varianza explicada que demostró que los dos primeros componentes capturan más del 98% de la varianza espectral. Se decidió retener 3 componentes principales (capturando más del 99% de la varianza) para generar una representación pseudo-RGB compatible con la arquitectura ResNet-50 pre-entrenada, que espera entradas de 3 canales. Esta transformación permite aprovechar las capacidades de extracción de características visuales de modelos pre-entrenados con SimCLR, generando embeddings de 2048 dimensiones que posteriormente serán reducidos a 32 dimensiones mediante UMAP para el clustering final con HDBSCAN. La efectividad de esta decisión se fundamenta en el principio de parsimonia: retener solo los componentes que capturan información no redundante mientras se maximiza la compatibilidad con arquitecturas estándar de redes neuronales convolucionales. Esta representación pseudo-RGB facilita además la visualización de los datos transformados y el aprovechamiento de conocimiento transferible de modelos pre-entrenados en dominios visuales naturales.

La Figura 2 ilustra el proceso de transformación espectral: las imágenes hiperespectrales originales (izquierda) con 344 bandas se procesan mediante el pipeline Scaler + PCA, resultando en imágenes pseudo-RGB de 3 canales (derecha). Visualmente, las imágenes transformadas muestran diferentes texturas y patrones de intensidad que corresponden a las variaciones espectrales capturadas por los tres componentes principales, donde cada canal RGB representa una componente que explica varianza en el espacio espectral original.




Figura 2: Transformación de imágenes hiperespectrales (344 bandas) a representaciones pseudo-RGB (3 canales) mediante PCA.

3.2.3. Proyección de Imágenes

El pipeline entrenado (Scaler y PCA) se guardó y se aplicó a cada imagen hiperespectral completa. Este proceso transformó cada imagen de un tensor de $(H, W, 344)$ a uno de $(H, W, 3)$, generando una representación pseudo-RGB donde cada canal corresponde a una componente principal. Estas imágenes transformadas se almacenaron en caché para acelerar las fases posteriores.

3.3 Data Augmentation

La incorporación de estrategias de data augmentation responde a la necesidad de aumentar la robustez del modelo ante variaciones en las condiciones de adquisición, un desafío inherente en aplicaciones de inspección industrial. Como se establece en la introducción, los enfoques de Deep Clustering modernos han evolucionado hacia el uso de *priors* dinámicos basados en invariancia y aumentos de datos complejos. (Lu et al., 2024) muestran que estos métodos contemporáneos aprenden dinámicamente la estructura latente mediante transformaciones sofisticadas. En particular, los métodos de aprendizaje contrastivo como SimCLR dependen críticamente de la calidad y diversidad de las transformaciones aplicadas para aprender representaciones invariantes.

Las transformaciones de data augmentation se aplicaron sobre los parches ya extraídos de dimensiones $(3, 224, 224)$ píxeles (pseudo-RGB después de la reducción PCA). Se implementaron

dos categorías de transformaciones:

1. Transformaciones Geométricas:

- Rotaciones aleatorias en el rango $[-15, +15]$.
- Reflexiones horizontales y verticales con probabilidad $p = 0,5$.
- Recortes aleatorios (*random crops*) del 80-100 % del área original, redimensionados a 224×224 píxeles.

2. Transformaciones Espectrales:

- Adición de ruido gaussiano con $\sigma \in [0,01, 0,05]$ para simular variabilidad instrumental.
- Escalado de intensidad espectral en el rango $[0,9, 1,1]$ para emular cambios en iluminación.

Estas transformaciones fueron seleccionadas para preservar la invariancia semántica de las texturas de corrosión, evitando distorsiones que pudieran alterar las propiedades físicas representadas en el espacio espectral (Uziel et al., 2025). La Figura 3 muestra ejemplos de parches extraídos y sus versiones aumentadas: en la parte superior se observa un parche original de 224×224 píxeles, mientras que en la parte inferior se muestran múltiples variaciones del mismo parche con rotaciones, reflexiones, recortes aleatorios, adición de ruido gaussiano y escalado de intensidad. Estas variaciones generan diferentes vistas de la misma textura de corrosión, preservando su contenido semántico mientras aumentan la diversidad del conjunto.




Figura 3: Ejemplos de parches originales y sus transformaciones geométricas y espectrales aplicadas para data augmentation.

3.4 Extracción de Características con Aprendizaje Auto-Supervisado

3.4.1. Limitaciones del Aprendizaje Supervisado y Justificación del Transfer Learning

Como se estableció en la introducción, un desafío crítico en la implementación a escala industrial de técnicas supervisadas es la escasez de grandes conjuntos de datos públicos etiquetados. (Imran et al., 2023) documentan que el etiquetado manual de millones de píxeles en imágenes hiperespectrales requiere expertise técnico especializado, resulta costoso, consume tiempo considerable y es inherentemente propenso a inconsistencias y sesgos humanos. Para superar esta limitación fundamental, se empleó un enfoque de aprendizaje por transferencia (*transfer learning*) utilizando un modelo pre-entrenado con métodos auto-supervisados.

El objetivo es convertir parches de imagen en vectores de características de alta dimensión (*embeddings*) que capturen su contenido semántico visual, sin requerir anotaciones explícitas. (Imran et al., 2023) demuestran que las capas convolucionales tempranas de redes pre-entrenadas aprenden características visuales genéricas (bordes, texturas, gradientes) que son transferibles a dominios diversos, incluyendo imágenes médicas, satelitales e industriales.

3.4.2. Muestreo y Preprocesamiento de Parches

De las imágenes pseudo-RGB generadas en la etapa anterior, se extrajeron aleatoriamente 10,000 parches de 224×224 píxeles. Esta dimensión corresponde al tamaño de entrada estándar para la arquitectura ResNet-50 pre-entrenada en ImageNet.

Cada parche fue sometido a una transformación de normalización utilizando la media y la desviación estándar del conjunto de datos ImageNet:

$$\text{mean} = [0,485, 0,456, 0,406], \quad \text{std} = [0,229, 0,224, 0,225] \quad (2)$$

Si bien los componentes principales de entrada ya estaban estandarizados mediante StandardScaler (media=0, desviación estándar=1), la aplicación de las estadísticas de ImageNet es una práctica estándar en transfer learning para alinear el dominio de entrada con los rangos de activación para los cuales la red fue pre-entrenada. (Leiber and Plant, 2025) documentan que este paso de normalización reescala los valores al rango de distribución específico que maximiza la respuesta de los filtros convolucionales de ResNet-50, optimizando la extracción de características.

3.4.3. Vectorización mediante ResNet-50 Pre-entrenada

Se utilizó como extractor de características una red neuronal con arquitectura ResNet-50 cuyos pesos fueron pre-entrenados mediante la estrategia de aprendizaje auto-supervisado SimCLR (Simple Framework for Contrastive Learning of Visual Representations) sobre un conjunto masivo de imágenes naturales. Es importante enfatizar que el modelo ResNet-50 no fue entrenado con los datos de este estudio, sino que se empleó directamente como extractor de características en modo de inferencia, aprovechando las representaciones visuales genéricas aprendidas durante su pre-entrenamiento.

La selección de ResNet-50 se fundamenta en su rendimiento documentado en la introducción. (Yu et al., 2025b) demostraron que arquitecturas ResNet-50 pre-entrenadas lograron rendimiento perfecto con 100 % de exactitud, precisión y F1-Score en clasificación binaria de corrosión marina, procesando conjuntos de 9,000 imágenes de alta resolución (512×512 píxeles), superando a InceptionV3 (99 %) y VGG16/19 (96-97 %). Información comparativa detallada se presenta en la Tabla 4 del Anexo.

SimCLR, el método utilizado para pre-entrenar ResNet-50, aprende representaciones visuales robustas al maximizar la similitud entre diferentes vistas aumentadas de una misma imagen (pares positivos) y minimizarla con las de otras imágenes (pares negativos). Este paradigma, conocido como *contrastive learning*, elimina la dependencia de etiquetas manuales. (Lu et al., 2024; Caron et al., 2018) demuestran que el contrastive learning es especialmente efectivo para aprender representaciones robustas sin supervisión, generando extractores de características transferibles a dominios diversos.

Cada parche normalizado de (224, 224, 3) se procesó a través de la red ResNet-50 pre-entrenada, generando un vector de características (*embedding*) de 2048 dimensiones. La efectividad de este extractor de características, a pesar de la diferencia de dominio entre las imágenes naturales usadas en el pre-entrenamiento y los datos hiperespectrales NIR de este estudio, se valida mediante el análisis de la estructura del espacio de embeddings y la coherencia de los clústeres resultantes, como se documenta en la sección de Resultados.

La arquitectura ResNet-50 fue seleccionada por su capacidad demostrada para capturar jerarquías visuales complejas mediante conexiones residuales, superando problemas de degradación en redes profundas (Yu et al., 2025b). Las representaciones aprendidas mediante SimCLR son particularmente adecuadas para tareas de clustering donde la separabilidad en el espacio de características es crítica (Qian, 2023).

La Figura 4 ilustra conceptualmente el método SimCLR utilizado para pre-entrenar ResNet-50. El diagrama muestra cómo dos vistas aumentadas de una misma imagen se procesan a través de la red para generar embeddings que deben ser similares (pares positivos, indicados con conexiones verdes), mientras que embeddings de imágenes diferentes deben ser disímiles (pares negativos, indicados con conexiones rojas). Este proceso de aprendizaje contrastivo, realizado sobre millones de imágenes naturales, genera la ResNet-50 pre-entrenada que posteriormente se aplica a nuestras imágenes pseudo-RGB de corrosión.




Figura 4: Esquema conceptual del método SimCLR usado para pre-entrenar ResNet-50 mediante aprendizaje contrastivo.

3.5 Análisis de Clustering y Segmentación No Supervisada

El espacio de características de 2048 dimensiones, aunque semánticamente rico, es demasiado grande para un clustering directo y eficiente debido nuevamente a la maldición de la dimensionalidad. Por ello, se construyó un pipeline de clustering avanzado para agrupar los embeddings en clústeres significativos.

3.5.1. Pipeline de Clustering: UMAP + HDBSCAN

Se entrenó un pipeline secuencial sobre los 10,000 embeddings de 2048 dimensiones:

1. **StandardScaler:** Primero, los embeddings fueron normalizados para asegurar que cada característica tuviera una contribución equitativa en los cálculos de distancia posteriores. (Leiber and Plant, 2025) documentan que esta normalización es particularmente importante cuando se combinan representaciones de diferentes capas de la red para mantener la estabilidad de los algoritmos de clustering subsecuentes.
2. **Reducción Dimensional con UMAP:** Se utilizó UMAP (Uniform Manifold Approximation and Projection) para realizar una reducción de dimensionalidad no lineal de 2048 a 32 dimensiones.

UMAP es una técnica de aprendizaje de variedades (*manifold learning*) que preserva la estructura topológica de los datos, agrupando puntos similares en el espacio de baja dimensión. A diferencia de métodos lineales como PCA, UMAP captura relaciones no lineales complejas en los datos, lo cual es crucial para espacios de características generados por redes neuronales profundas. (Zhang et al., 2025) demuestran que las técnicas de manifold learning como UMAP son especialmente efectivas para preservar información jerárquica en embeddings de alta dimensión (ver Figura 5).

Los hiperparámetros `n_neighbors` y `n_components` fueron optimizados utilizando Grid-SearchCV de scikit-learn, explorando rangos de 10 a 50 y de 10 a 200 respectivamente, con el objetivo de encontrar la configuración óptima para el algoritmo de clustering subsecuente.

La Figura 5 muestra esquemáticamente cómo UMAP preserva la estructura topológica: en el espacio de alta dimensión (izquierda), puntos cercanos representan embeddings similares, y UMAP proyecta estos puntos a un espacio de baja dimensión (derecha) manteniendo las relaciones de vecindad local mientras separa grupos distintos. Las conexiones entre puntos representan las relaciones de similitud que UMAP intenta preservar durante la proyección, agrupando puntos similares y separando grupos diferentes.



Figura 5: Representación esquemática de la proyección UMAP de 2048 a 32 dimensiones preservando estructura topológica.

3. Clustering con HDBSCAN: Sobre el espacio reducido de 32 dimensiones, se aplicó HDBSCAN (Hierarchical Density-Based Spatial Clustering of Applications with Noise).

Este algoritmo basado en densidad es ideal para este problema por las siguientes razones (ver Figura 6):

- No requiere predefinir el número de clústeres: A diferencia de k-means, HDBSCAN descubre automáticamente el número óptimo de grupos basándose en la densidad local de los datos. (Leiber and Plant, 2025) señalan que esto es fundamental en un contexto no supervisado donde no se conoce a priori cuántos estados de corrosión distintos existen.
- Identifica ruido: Puede marcar puntos atípicos como ruido (etiqueta -1), lo cual es crítico para filtrar píxeles anómalos o zonas de transición entre estados de corrosión (Qian, 2023).
- Detecta formas arbitrarias: No asume geometrías esféricas como k-means, adaptándose mejor a la distribución natural de texturas de corrosión en el espacio de características (Cheng and Chen, 2025).

La Figura 6 ilustra el funcionamiento de HDBSCAN: el algoritmo construye una jerarquía de densidad y detecta regiones de alta concentración de puntos como clusters separados (indicados con diferentes colores), mientras que puntos aislados o de baja densidad se marcan como ruido (puntos grises). El diagrama muestra cómo HDBSCAN puede identificar clusters de formas arbitrarias sin asumir geometrías específicas, adaptándose a la distribución natural de los embeddings en el espacio de 32 dimensiones.




Figura 6: Esquema del clustering basado en densidad con HDBSCAN mostrando detección automática de clusters y ruido.

3.5.2. Optimización del Hiperparámetro `min_cluster_size`

Para determinar el valor óptimo del hiperparámetro `min_cluster_size` de HDBSCAN, se realizó un análisis de sensibilidad sistemático evaluando valores en el rango [50, 75, 100, 125, 150, 200]. Los resultados demostraron que:

- Valores menores a 75 generan sobre-segmentación con múltiples micro-clústeres redundantes (hasta 22 clusters con `min_size=50`).
- Valores superiores a 125 producen sub-segmentación fusionando fenómenos distintos (solo 7 clusters con `min_size=200`).

Se seleccionó `min_cluster_size = 100` como el valor óptimo que logra el mejor balance entre granularidad de la segmentación y estabilidad de los clusters identificados. Esta configuración genera 12 clusters con métricas de calidad superiores:

- Silhouette Score: 0.617 (indicando buena separación inter-cluster).
- Davies-Bouldin Index: 0.409 (baja superposición intra-cluster).
- Porcentaje de ruido: Solo 5.23 %.

El parámetro `prediction_data` se estableció en verdadero para permitir la clasificación de nuevos puntos en la fase de inferencia, facilitando la segmentación de imágenes completas no vistas durante el entrenamiento.

3.6 Métricas de Evaluación de Clusters

Para evaluar cuantitativamente la calidad de los clústeres generados por el modelo no supervisado, se utilizaron tres métricas estándar que miden diferentes aspectos de la cohesión y separación de los grupos (Lu et al., 2024).

3.6.1. Silhouette Score (Coeficiente de Silueta)

Mide qué tan similar es un objeto a su propio clúster (cohesión) en comparación con otros clústeres (separación).

- Rango: de -1 a +1. Un valor cercano a +1 indica que los clústeres están densos y bien separados. Un valor cercano a 0 indica clústeres superpuestos, y un valor negativo sugiere que las muestras pueden haber sido asignadas al clúster incorrecto.
- Fórmula: Para una muestra i , el coeficiente de silueta $s(i)$ es:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (3)$$

donde $a(i)$ es la distancia media intra-clúster y $b(i)$ es la distancia media al clúster más cercano.

3.6.2. Davies-Bouldin Score (Índice de Davies-Bouldin)

Calcula la similitud promedio de cada clúster con su clúster más similar. Se prefiere un valor más bajo, ya que indica que los clústeres están más separados entre sí.

- Rango: de 0 a ∞ . Un valor de 0 representa el mejor resultado posible.
- Fórmula: El índice se define como:

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{\sigma_i + \sigma_j}{d(c_i, c_j)} \right) \quad (4)$$

donde k es el número de clústeres, σ_i es la dispersión intra-clúster i , y $d(c_i, c_j)$ es la distancia entre los centroides de los clústeres i y j .

3.6.3. Calinski-Harabasz Score (Índice de Calinski-Harabasz)

También conocido como el criterio de Ratio de Varianza (VRC), mide la relación entre la dispersión entre clústeres y la dispersión intra-clúster. Un puntaje más alto indica clústeres más densos y mejor separados.

- Rango: de 0 a ∞ . No tiene un límite superior absoluto, pero valores más altos son mejores.
- Fórmula: El puntaje se calcula como:

$$CH = \frac{SS_B}{SS_W} \times \frac{N - k}{k - 1} \quad (5)$$

donde SS_B es la suma de cuadrados entre clústeres, SS_W es la suma de cuadrados intra-clúster, N es el número total de puntos y k es el número de clústeres.

4 Resultados

4.1 Reducción Dimensional y Espacio Latente

El primer paso crítico del pipeline consistió en la reducción de la dimensionalidad espectral. La aplicación del Análisis de Componentes Principales (PCA) permitió transformar las imágenes hiperespectrales de 344 bandas a solo 3 componentes principales. Como se observa en la Figura 7, estos tres primeros componentes retienen más del 99 % de la varianza acumulada de los datos originales. Esta compresión eficiente valida la estrategia metodológica de reducir la redundancia espectral manteniendo la información discriminativa necesaria para la identificación de firmas químicas de óxidos, tal como sugieren Enguita et al. (2025) para aplicaciones en el rango NIR.




Figura 7: Varianza explicada por los componentes principales. La retención de ¿99 % de información con solo 3 componentes justifica la reducción dimensional para el procesamiento con CNNs. (Ver versión ampliada en Anexo 17)

La Figura 8 ilustra visualmente el proceso de reducción dimensional aplicado a una probeta representativa. La imagen RGB original (primera columna) se transforma mediante PCA en tres componentes principales, cada una capturando diferentes aspectos espectrales de la superficie. El primer componente (PCA - Comp. 1) predominantemente captura la estructura de base y variaciones globales de reflectancia, el segundo componente (PCA - Comp. 2) resalta transiciones y contrastes espectrales asociados a cambios químicos superficiales, mientras que el tercer componente (PCA - Comp. 3) captura detalles finos y heterogeneidades locales. Esta descomposición permite que las CNNs procesen información espectral discriminativa sin la redundancia de las 344 bandas originales, facilitando la identificación de firmas espectrales únicas asociadas a diferentes estados de corrosión.

Posteriormente, la proyección en 2D de los embeddings extraídos mediante ResNet-50 (Figura




Figura 8: Visualización de la proyección PCA aplicada a una imagen hiperespectral de probeta corroída. De izquierda a derecha: imagen RGB original y las tres componentes principales extraídas. Cada componente captura diferentes características espectrales: estructura global (Comp. 1), transiciones químicas (Comp. 2) y heterogeneidades locales (Comp. 3). (Ver versión ampliada en Anexo 18)

9) revela una estructura topológica con grupos bien definidos y separables. Esto confirma que el modelo pre-entrenado con SimCLR logró extraer representaciones semánticas robustas capaces de distinguir diferentes estados de la superficie sin necesidad de etiquetas, superando el desafío de la escasez de datos anotados discutido por Imran et al. (2023).

4.2 Segmentación y Validación de Clústeres

4.2.1. Optimización de Hiperparámetros mediante Grid Search

La selección de los hiperparámetros óptimos para UMAP y HDBSCAN es crítica para la calidad del clustering no supervisado. Se implementó una búsqueda exhaustiva mediante GridSearchCV sobre dos dimensiones clave: `n_neighbors` (vecindad local en UMAP, rango 5-50) y `n_components` (dimensionalidad del espacio reducido, rango 8-64). La Figura 10 muestra el mapa de calor del Silhouette Score para todas las combinaciones evaluadas.

Los resultados revelan patrones significativos: (1) **Zona óptima bien definida:** El máximo global (Silhouette=0.569) se alcanza con `n_neighbors`=25 y `n_components`=32, indicando que existe una configuración óptima claramente identificable; (2) **Robustez local:** La región amarilla/verde alrededor del óptimo muestra que variaciones moderadas (± 5 vecinos, ± 8 compo-




Figura 9: Proyección UMAP 2D de los embeddings de 2048 dimensiones. Los colores representan los clústeres asignados por HDBSCAN, evidenciando la capacidad del modelo para separar semánticamente los estados de corrosión. (Ver versión ampliada en Anexo 19)




Figura 10: Análisis de sensibilidad de hiperparámetros UMAP mediante GridSearchCV. El mapa muestra el Silhouette Score en función de `n_neighbors` y `n_components`. La configuración óptima (`n_neighbors=25`, `n_components=32`, Silhouette=0.569) se marca en rojo. (Ver versión ampliada en Anexo 20)

mentes) mantienen un desempeño competitivo ($\text{Silhouette} > 0.55$), evidenciando estabilidad del modelo; (3) **Degradación en extremos**: Configuraciones extremas ($\text{n_neighbors} < 10$ o $\text{n_components} < 16$) producen clustering de baja calidad (azul oscuro, $\text{Silhouette} < 0.50$), confirmando la necesidad de una búsqueda sistemática; y (4) **Trade-off dimensionalidad-vecindad**: El desempeño óptimo no está en los límites del espacio de búsqueda, sugiriendo un balance entre preservación de estructura local (vecindad) y capacidad representacional (componentes).

Este análisis demuestra que el GridSearchCV no solo identificó los hiperparámetros óptimos, sino que también validó la robustez del pipeline ante perturbaciones paramétricas, un requisito esencial para la implementación práctica en entornos industriales donde la reproducibilidad es crítica.

4.2.2. Métricas de Calidad del Clustering


El algoritmo HDBSCAN identificó automáticamente **12 clústeres** distintos y una clase de ruido. La calidad de esta segmentación se valida mediante métricas cuantitativas que indican una buena separación y compacidad de los grupos, consistentes con los estándares para Deep Clustering revisados por Lu et al. (2024):

- **Silhouette Score**: 0.569
- **Davies-Bouldin Index**: 1.19
- **Calinski-Harabasz Score**: 16059.53


La robustez y escalabilidad del modelo se evidencian al comparar la distribución de muestras entre el conjunto de entrenamiento (10,000 muestras) y el conjunto de testeo (103,000 muestras). La Figura 11 muestra que las proporciones relativas de cada clúster se mantienen notables, confirmando que el modelo generaliza correctamente y no está sobreajustado a los datos de entrenamiento.

4.3 Caracterización de Estados de Corrosión

La inspección visual de los parches agrupados revela una fuerte correlación entre los clústeres semánticos identificados por la IA y los modos de fallo físicos estandarizados (ISO 4628) repor-



(a) Entrenamiento (10k muestras)



(b) Testeo (103k muestras)

Figura 11: Distribución de muestras por clúster. La similitud entre (a) y (b) confirma la estabilidad y escalabilidad del modelo ante nuevos datos. (Ver versiones ampliadas en Anexo 21)

tados en la validación experta de las mismas probetas por Belmar (2023). A continuación, se presentan los resultados agrupados por tipología de deterioro.

4.3.1. Estados de Referencia y Defectos Incipientes

Los Clústeres 7, 5 y 0 (Figura 12) representan superficies con mínima degradación. El **Clúster 7** corresponde al estado de referencia con recubrimiento intacto. Los **Clústeres 5 y 0** capturan variaciones texturales leves o deformaciones incipientes que, aunque detectables espectralmente, no comprometen aún la integridad funcional de la barrera protectora.



(a) C7: Intacto

(b) C5: Leve

(c) C0: Textural

Figura 12: Estados de referencia. (a) Recubrimiento intacto. (b) y (c) Alteraciones superficiales menores sin fallo estructural. (Ver versiones ampliadas en Anexo 22)

4.3.2. Fallas Físicas del Recubrimiento (Ampollamiento y Agrietamiento)

Este grupo (Figura 13) captura defectos estructurales críticos validados por normas ISO. Los **Clústeres 2 y 8** identifican el fenómeno de *blistering* (ampollamiento, ISO 4628-2), donde la presión osmótica levanta la película de pintura (Belmar, 2023). El **Clúster 6** detecta *cracking* (agrietamiento, ISO 4628-4), evidenciando fisuras que exponen el sustrato y facilitan la entrada de agentes corrosivos.



Figura 13: Defectos físicos. (a) y (b) Ampollamiento (Blistering). (c) Agrietamiento (Cracking) con exposición de sustrato. (Ver versiones ampliadas en Anexo 22)

4.3.3. Oxidación y Exposición de Sustrato

Los clústeres más poblados (Figura 14) corresponden a la pérdida total de protección. El **Clúster 4** muestra metal desnudo con alta reflectancia en el NIR. El **Clúster 3**, que agrupa más del 25 % de las muestras, presenta la firma espectral característica de los óxidos de hierro (tonalidades rojizas/anaranjadas), coincidiendo con la categoría de *rusting* (ISO 4628-3) (Belmar, 2023). El **Clúster 10** representa una transición con metal expuesto y oxidación localizada.




Figura 14: Pérdida de integridad. (a) Sustrato expuesto brillante. (b) Oxidación activa. (c) Agrietamiento con oxidación incipiente. (Ver versiones ampliadas en Anexo 22)

4.3.4. Fallas Críticas y Múltiples

Finalmente, los **Clústeres 1, 9 y 11** (Figura 15) agrupan las condiciones más severas. El **Clúster 1** detecta corrosión por picado (*pitting*), un ataque localizado altamente destructivo. Los **Clústeres 9 y 11** muestran la convergencia de múltiples modos de fallo (ampollamiento + grietas + oxidación), representando las zonas de mayor prioridad de mantenimiento según los criterios de gestión de activos discutidos por Yu et al. (2025b).




Figura 15: Modos de fallo críticos. (a) Corrosión por picado. (b) y (c) Degradación avanzada con múltiples mecanismos simultáneos. (Ver versiones ampliadas en Anexo 22)

4.3.5. Detección de Ruido

El **Clúster -1** (Figura 16) agrupa solo el 5.23 % de las muestras, correspondientes a artefactos de adquisición, desenfoque o bordes de cinta. La capacidad de HDBSCAN para aislar este ruido es fundamental para la fiabilidad del sistema, evitando falsos positivos en la detección de corrosión y asegurando que los clústeres principales representen fenómenos físicos reales.



Figura 16: Clúster -1: Ruido y artefactos filtrados automáticamente. (Ver versión ampliada en Anexo 22)

4.4 Comparación con el Estado del Arte en Deep Clustering

Para contextualizar el desempeño del sistema propuesto, se realiza una comparación cuantitativa con los métodos más relevantes de Deep Clustering reportados en la literatura reciente. La Tabla 1 resume esta evaluación.

Cuadro 1: Comparación del desempeño de clustering con métodos del estado del arte

Método/Estudio	Dataset	Silhouette	Observaciones
Este trabajo	HSI NIR Corrosión (103k muestras)	0.569	Pipeline UMAP+HDBSCAN optimizado, 12 clústeres + ruido, correlación con ISO 4628
SeCu (Qian, 2023)	CIFAR-10 (imágenes RGB)	N/R	ACC: 88.1 %, NMI: 79.4 %, ARI: 77.6 %. Benchmark de visión general
Híbrido CNN+K-FCM (Elfatimi et al., 2025)	Tumores cerebrales (MRI)	N/R	Exactitud: 98 %, Recall: 100 %. Aplicación médica supervisada
VTCC (Ling et al., 2022)	ImageNet	N/R	Transformers + contrastivo. Dataset de escala masiva (1M+ imágenes)
CLUDI (Uziel et al., 2025)	Benchmarks estándar	N/R	Difusión generativa. Estado del arte en clustering puro

4.4.1. Análisis Comparativo

El Silhouette Score de 0.569 obtenido en este trabajo se ubica en el rango competitivo para problemas de clustering no supervisado. Según la literatura, valores de Silhouette superiores a 0.5 indican una estructura de clústeres bien definida con separación adecuada entre grupos (Lu et al., 2024). Los siguientes aspectos contextualizan este resultado:

(1) Complejidad del dominio de aplicación: A diferencia de benchmarks estándar como CIFAR-10 o ImageNet, donde las clases están definidas por objetos claramente diferenciables (perros, gatos, aviones), este trabajo enfrenta un problema de frontera difusa: los estados de corrosión forman un continuo espectral (desde recubrimiento intacto hasta oxidación severa) sin transiciones abruptas. La identificación automática de 12 clústeres + ruido en datos hiperespectrales NIR de 344 bandas representa un desafío significativamente mayor que la clasificación en RGB de 3 canales.

(2) Naturaleza no supervisada verdadera: Métodos como el CNN+K-FCM híbrido de Elfatimi et al. (2025) reportan métricas superiores (exactitud 98 %), pero operan en un contexto

semi-supervisado con etiquetas médicas de referencia. En contraste, este trabajo identifica estructuras latentes sin conocimiento previo de las clases, descubriendo automáticamente patrones que posteriormente se validan contra estándares ISO. El Silhouette Score mide exclusivamente la calidad geométrica del clustering, sin depender de etiquetas externas.

(3) Validación física con expertos: Un resultado clave es la *correspondencia semántica* entre los 12 clústeres descubiertos y los modos de fallo físicos estandarizados (ampollamiento ISO 4628-2, agrietamiento ISO 4628-4, oxidación ISO 4628-3) reportados por Belmar (2023). Esta concordancia demuestra que el modelo no solo encuentra grupos matemáticamente separables, sino que captura fenómenos físicos reales con relevancia ingenieril. En Deep Clustering puro (como CLUDI o VTCC), la interpretabilidad de los clústeres es típicamente post-hoc, mientras que aquí se valida contra conocimiento experto del dominio.

(4) Escalabilidad y robustez: La consistencia entre las distribuciones de entrenamiento (10k muestras) y testeo (103k muestras) evidencia una generalización superior a muchos métodos de la literatura que reportan resultados solo en conjuntos pequeños. La tasa de ruido del 5.23% es excepcionalmente baja comparada con aplicaciones industriales reales, donde el ruido instrumental y artefactos de adquisición suelen comprometer hasta el 15-20% de los datos (Imran et al., 2023).

(5) Optimización sistemática: A diferencia de trabajos que reportan métricas con hiperparámetros fijos o seleccionados manualmente, este proyecto implementó GridSearchCV exhaustivo (225 configuraciones evaluadas) sobre el espacio UMAP+HDBSCAN, garantizando que el Silhouette de 0.569 representa el óptimo alcanzable bajo las restricciones del problema. La región de robustez identificada (± 5 vecinos, ± 8 componentes mantienen Silhouette > 0.55) valida la estabilidad del sistema ante perturbaciones operacionales.

4.4.2. Posicionamiento del Trabajo

En síntesis, los resultados obtenidos son **altamente competitivos** considerando:

- La complejidad del dominio (estados de corrosión con fronteras espectrales difusas)
- La ausencia total de supervisión (descubrimiento automático de clases)
- La validación física independiente (concordancia con ISO 4628)

- La escala del dataset (103k muestras procesadas con consistencia)
- La reproducibilidad garantizada (GridSearchCV + análisis de sensibilidad)

El Silhouette de 0.569 no debe compararse directamente con métricas de exactitud (ACC) o NMI de benchmarks supervisados, sino evaluarse en el contexto de clustering no supervisado con datos industriales reales. La literatura especializada en NIR para corrosión (Enguita et al., 2025) reporta típicamente clasificaciones supervisadas (con etiquetas conocidas), posicionando este trabajo como pionero en aplicar Deep Clustering puro a imágenes hiperespectrales de corrosión con validación exitosa contra estándares internacionales.

5 Conclusiones

Este trabajo ha desarrollado y validado exitosamente un sistema de clasificación automática de estados de corrosión en recubrimientos metálicos mediante el análisis de imágenes hiperespectrales en el rango del infrarrojo cercano (NIR). La metodología propuesta integra técnicas avanzadas de visión artificial y aprendizaje no supervisado para transformar datos espectrales complejos en información procesable sobre la integridad de los materiales.

5.1 Cumplimiento de Objetivos

A continuación, se detalla el grado de cumplimiento de cada uno de los objetivos planteados al inicio de esta investigación:

- **Objetivo Específico 1: Reducción de dimensionalidad espectral. (Cumplido)** Se implementó exitosamente un pre-procesamiento mediante Análisis de Componentes Principales (PCA) tras una normalización estándar. Los resultados demostraron que es posible reducir la dimensionalidad de 344 bandas espectrales a solo 3 componentes principales, reteniendo más del 99 % de la varianza explicada. Esta transformación permitió generar representaciones RGB sintéticas ("falsos colores") aptas para el procesamiento con arquitecturas de redes neuronales convolucionales (CNN) estándar, sin pérdida significativa de información espectral crítica.
- **Objetivo Específico 2: Desarrollo de modelo de extracción de características. (Cumplido)** Se configuró y utilizó una arquitectura ResNet-50 pre-entrenada bajo el paradigma auto-supervisado SimCLR. El modelo fue capaz de procesar los parches de imágenes transformados y generar un espacio de embedding de 2048 dimensiones. La efectividad de estas representaciones se evidenció en la capacidad posterior del sistema para agrupar semánticamente parches con características visuales y espectrales similares, validando la robustez de las características extraídas.
- **Objetivo Específico 3: Segmentación del espacio latente. (Cumplido)** La aplicación secuencial de UMAP para la reducción de dimensionalidad no lineal y HDBSCAN para el clustering basado en densidad permitió segmentar eficazmente el espacio latente. El sistema identificó automáticamente 12 clústeres distintos, separando con claridad los

diferentes estados de la superficie. La capacidad del algoritmo para aislar el ruido (Clúster -1, 5.23 % de las muestras) demuestra la idoneidad de HDBSCAN para manejar datos reales con anomalías, evitando la asignación forzada de muestras atípicas.

- **Objetivo Específico 4: Validación y correlación física. (Cumplido)** La segmentación fue validada cuantitativamente obteniendo métricas de calidad satisfactorias para un entorno no supervisado (Silhouette Score: 0.569, Davies-Bouldin: 1.19, Calinski-Harabasz: 16059.53). Cualitativamente, se logró establecer una correlación directa entre los clústeres matemáticos y modos de fallo físicos estandarizados (como ampollamiento, oxidación, agrietamiento y metal desnudo), confirmando que la agrupación no es aleatoria sino que responde a fenómenos físicos reales de degradación del material. Además, la consistencia en la distribución de clases entre los conjuntos de entrenamiento y testeo validó la capacidad de generalización del modelo.

5.2 Conclusiones Generales e Impacto

La investigación demuestra que la combinación de imágenes hiperespectrales y técnicas de *Deep Clustering* constituye una herramienta poderosa para la evaluación objetiva de la corrosión. A diferencia de las inspecciones visuales tradicionales, sujetas a la subjetividad humana, el sistema propuesto ofrece una clasificación consistente y repetible.

Una ventaja fundamental del pipeline desarrollado reside en su escalabilidad y eficiencia operacional. Al implementar un enfoque no supervisado, el sistema no requiere etiquetado manual de datos para la detección de patrones de corrosión, eliminando un cuello de botella crítico en el desarrollo de sistemas de visión artificial. Esta característica permite que el modelo pueda ser mejorado y extendido simplemente mediante el aumento de la base de datos con nuevas mediciones de imágenes hiperespectrales NIR, sin necesidad de costosas campañas de anotación por parte de expertos. Esta propiedad reduce significativamente los costos de implementación y facilita la adaptación del sistema a diferentes contextos industriales y ambientes corrosivos. Se identificó que los estados de deterioro severo (clústeres 3, 4 y 11) representan una porción significativa de la superficie analizada, lo que permite cuantificar el daño de manera precisa. La metodología es capaz de distinguir sutiles diferencias espectrales que podrían pasar desapercibidas al ojo humano o en imágenes RGB convencionales, como la diferenciación entre distintos

tipos de óxidos o etapas tempranas de ampollamiento.

5.3 Limitaciones y Trabajo Futuro

A pesar de los resultados prometedores, se identifican limitaciones que abren vías para trabajos futuros:

1. **Generalización:** El modelo fue entrenado y validado con un conjunto de datos específico (103 probetas, 156 días de exposición). Su aplicación a nuevos esquemas de pintura o ambientes corrosivos diferentes requeriría un re-entrenamiento o técnicas de *transfer learning*. Para superar esta limitación, se recomienda expandir la base de datos con nuevas mediciones de imágenes hiperespectrales NIR que abarquen mayor variabilidad de condiciones operacionales, esquemas de recubrimiento y ambientes corrosivos.
2. **Validación Pixel a Pixel:** Aunque se correlacionaron los clústeres con modos de fallo, la falta de un *ground truth* etiquetado a nivel de píxel impide calcular métricas de precisión espacial (IoU) exactas.
3. **Exploración de Arquitecturas Avanzadas:** Como una extensión natural del presente trabajo, se propone investigar el uso de *autoencoders* basados en Operadores Neuronales de Fourier (*Fourier Neural Operators*, FNO). Esta arquitectura permitiría modelar dinámicamente las transformadas espectrales en el dominio de frecuencias, capturando patrones de absorción y reflexión característicos de procesos de corrosión. El enfoque consistiría en: (i) generar embeddings vectoriales de menor dimensionalidad a partir de los perfiles espectrales completos (344 bandas), (ii) entrenar un FNO que aprenda la función de mapeo entre el espacio espectral NIR y las características físico-químicas de la superficie, y (iii) correlacionar estos descriptores latentes con metadatos químicos o electroquímicos para, a posteriori, establecer etiquetas semánticas automáticas que faciliten la generalización a nuevos contextos sin necesidad de supervisión humana inicial. Esta metodología mantendría la filosofía no supervisada del pipeline actual, pero incrementaría la capacidad de interpretación física de los clústeres detectados.

Como trabajo futuro complementario, se sugiere la creación de un dataset parcialmente etiquetado por expertos para validar cuantitativamente la correspondencia entre clústeres automáticos

y diagnósticos profesionales, habilitando enfoques semi-supervisados. Asimismo, la integración de este algoritmo en sistemas robóticos de inspección equipados con cámaras hiperspectrales NIR montadas en drones o brazos articulados podría automatizar completamente el monitoreo de infraestructuras críticas, generando mapas de deterioro en tiempo real y reduciendo significativamente los costos asociados a inspecciones manuales periódicas.

Anexos

Anexo Figuras: Imágenes Ampliadas de Resultados

Este anexo presenta las versiones ampliadas de las figuras mostradas en la sección de Resultados, permitiendo una visualización detallada de los análisis y caracterizaciones realizadas.




Figura 17: Versión ampliada: Varianza explicada por los componentes principales




Figura 18: Versión ampliada: Proyección PCA aplicada a imagen hiperespectral de probeta corroída




Figura 19: Versión ampliada: Proyección UMAP 2D de los embeddings




Figura 20: Versión ampliada: Análisis de sensibilidad de hiperparámetros UMAP mediante Grid-SearchCV




Figura 21: Versiones ampliadas: Distribución de muestras por clúster en entrenamiento y testeo



C7: Intacto



C5: Leve



C0: Textural



C2: Ampollamiento



C8: Ampollamiento Severo




C6: Agrietamiento



C4: Metal Desnudo




C3: Oxidación




C10: Mixto



C1: Picado



C9: Múltiple



C11: Severo



C-1: Ruido

Figura 22: Versiones ampliadas: Caracterización visual de todos los clústeres identificados

Anexo A: Estrategias de Prevención de la Corrosión en Ambientes Marinos

De acuerdo con la revisión sistemática de Dalmora et al. (2025), las estrategias de prevención de la corrosión marina se han diversificado significativamente en los últimos años, abarcando desde métodos tradicionales como recubrimientos metálicos hasta enfoques innovadores basados en nanotecnología y polímeros inteligentes. La Tabla 2 presenta una clasificación exhaustiva de las principales metodologías empleadas actualmente en la industria marítima, destacando sus mecanismos de acción, ventajas operacionales y limitaciones técnicas. Según Dalmora et al. (2025), cada categoría presenta un balance específico entre eficacia, costo y sostenibilidad ambiental, siendo fundamental considerar las condiciones particulares del ambiente marino para la selección del método más apropiado.

Cuadro 2: Metodologías de prevención de la corrosión para acero en ambientes marinos

Categoría	Método	Mecanismo de Acción	Ventajas Clave	Desafíos/Limitaciones
Recubrimientos Metálicos	Rociado Térmico	Barrera física y protección galvánica	Alta resistencia en zonas de salpicadura	Costoso, porosidad si no se sella
	Galvanizado en Caliente	Protección de sacrificio (Zinc)	Económico, protección integral	Vida útil limitada en alta salinidad
	Electrodeposición	Deposición de capa uniforme	Control preciso del espesor	Limitado por tamaño del tanque
Recubrimientos Orgánicos	Polímeros (Epoxi, Poliuretano)	Efecto barrera	Versatilidad, resistencia química	Degradación por UV
	Recubrimientos Inteligentes	Liberación controlada de inhibidores	Extensión de vida útil	Complejidad de formulación
Inhibidores	Ecológicos (Green)	Adsorción de compuestos orgánicos	Biodegradables, bajo costo	Estabilidad térmica limitada
Protección Electroquímica	Catódica (SACP/ICCP)	Polarización del metal	Efectiva si recubrimiento falla	Requiere monitoreo constante

Fuente: Adaptado de Dalmora et al. (2025)

Anexo B: Inhibidores Ecológicos y su Eficiencia

La transición hacia inhibidores de corrosión ecológicos representa un cambio paradigmático en la industria marina, impulsado por regulaciones ambientales más estrictas y la búsqueda de sostenibilidad. De acuerdo con Kumar et al. (2025), los inhibidores derivados de productos naturales han demostrado eficiencias comparables a los compuestos sintéticos tradicionales, con la ventaja adicional de su biodegradabilidad y bajo impacto ambiental. La Tabla 3 compila los resultados experimentales más recientes en esta área, donde destacan los trabajos de Kobisy

et al. (2025) con surfactantes de quitosano que alcanzaron eficiencias de 93-96 % contra bacterias reductoras de sulfatos, y los estudios de Mouez et al. (2025) utilizando nanotubos de carbono derivados de biomasa de naranja con una impresionante eficiencia del 99.4 %. Según Yu et al. (2025a), el enlace químico entre inhibidores naturales como el 2-mercaptobenzotiazol y matrices poliméricas de quitosano resulta en una protección superior y más estable a largo plazo. Por su parte, Li et al. (2025) demostraron que recubrimientos cerámicos inspirados en superficies naturales pueden reducir la densidad de corriente de corrosión en cuatro órdenes de magnitud, consolidando la viabilidad técnica de estos enfoques biomiméticos.

Cuadro 3: Investigaciones sobre metodologías ecológicas de inhibición de corrosión

Autor(es)	Inhibidor/Material	Sustrato	Medio Co- rrosivo	Eficiencia (%)
Dalmora et al. (2025)	Extractos vegetales	Acero al Carbono	NaCl 3.5 % / HCl 1M	Variable (80-98 %)
Kobisy et al. (2025)	Surfactantes de Quitosano	Acero X65	Agua de mar con SRB	93-96 %
Mouez et al. (2025)	Nanotubos de Carbono (Biomasa naranja)	Acero Maraging	Agua de mar sintética	99.4 %
Li et al. (2025)	Recubrimiento Cerámico	Aluminio 7075	NaCl 3.5 %	Reducción I_{corr} en 4 órdenes
Yu et al. (2025)	Quitosano-MBT	Acero	Agua de mar	Impedancia $> 10^5 \Omega cm^2$

Fuente: Adaptado de Dalmora et al. (2025), Kobisy et al. (2025), Mouez et al. (2025), Li et al. (2025) y Yu et al. (2025a)

Anexo C: Rendimiento de Modelos de Deep Learning en Detección de Corrosión

La aplicación de modelos de aprendizaje profundo en la detección automática de corrosión ha experimentado avances notables en el período 2024-2025. De acuerdo con Yu et al. (2025b), las arquitecturas basadas en redes residuales como ResNet-50 han establecido nuevos estándares de referencia, alcanzando rendimientos perfectos (100 % en exactitud, precisión y recall) en tareas

de clasificación binaria sobre conjuntos de datos de 9,000 imágenes de alta resolución. La Tabla 4 presenta una comparativa exhaustiva de los principales modelos reportados en la literatura reciente. Según Ali (2025), YOLOv5 demuestra superioridad en aplicaciones de tiempo real con ROVs, procesando video a 45 FPS con una precisión media (mAP@0.5) del 93 %, superando ampliamente los 15 FPS de Mask R-CNN. En aplicaciones especializadas, Son et al. (2024) reportan que el entrenamiento de Mask R-CNN con 35,753 imágenes permite no solo detectar áreas de corrosión sino también predecir su profundidad mediante algoritmos de regresión, habilitando la estimación de pérdida de material sin contacto físico. Por su parte, Liu et al. (2025) propusieron LFN-YOLO, una arquitectura ligera específicamente diseñada para detectar objetos pequeños (picaduras incipientes) con bajo costo computacional, mientras que Dhungana et al. (2025) demostraron que YOLOv11 mantiene capacidades de detección superiores en entornos de baja visibilidad donde versiones anteriores fallan. Los estudios de Espinoza Llanos (2023) y Jamaludin and Imran (2024) consolidan la viabilidad de estos sistemas para aplicaciones en estructuras marinas reales.

Cuadro 4: Comparativa de rendimiento de modelos de detección y clasificación de corrosión

Modelo/Estudio	Tarea Principal	Dataset	Métricas Clave	Observaciones
ResNet-50 [Yu et al., 2025]	Clasificación Binaria	9,000 imágenes (512 ²)	100 % Exactitud, Precisión, Recall	Estándar de referencia
InceptionV3 [Yu et al., 2025]	Clasificación Binaria	9,000 imágenes	99 % rendimiento global	Alternativa robusta
YOLOv5 [Ali, 2025]	Detección Tiempo Real	N/A	45 FPS, 93 % mAP@0.5	Superior en velocidad
Mask R-CNN [Ali, 2025]	Segmentación	N/A	15 FPS, 87 % mAP@0.5	Más lento pero preciso
Mask R-CNN [Son et al., 2024]	Área y Profundidad	35,753 imágenes	Alta precisión en regresión	Estimación sin contacto
LFN-YOLO [Liu et al., 2025]	Objetos pequeños	N/A	Alta precisión	Bajo costo computacional
YOLOv11 [Dhungana et al., 2025]	Tuberías submarinas	N/A	Mayor robustez	Entornos baja visibilidad

Fuente: Compilación de Yu et al. (2025b), Ali (2025), Son et al. (2024), Liu et al. (2025), Dhungana et al. (2025), Espinoza Llanos (2023) y Jamaludin and Imran (2024)

Anexo D: Arquitecturas de Deep Clustering

El campo del Deep Clustering ha experimentado una evolución significativa desde los trabajos fundacionales de Caron et al. (2018), quienes introdujeron el concepto de aprendizaje iterativo entre k-means y actualización de pesos de redes convolucionales. De acuerdo con la revisión sistemática de Leiber and Plant (2025), las técnicas actuales integran algoritmos de aprendizaje profundo con métodos de agrupamiento no supervisado, utilizando redes neuronales para aprender representaciones latentes optimizadas específicamente para la tarea de clustering. La Tabla 5 presenta el rendimiento cuantitativo de los métodos más relevantes reportados en el período 2023-2025. Según Qian (2023), el método Stable Cluster Discrimination (SeCu) alcanzó métricas excepcionales en CIFAR-10 (ACC: 88.1 %, NMI: 79.4 %, ARI: 77.6 %), validando la estabilización de discriminación sin etiquetas mediante restricciones de tamaño flexibles. En aplicaciones críticas, Elfatimi et al. (2025) lograron exactitud del 98 % y recall del 100 % en detección de tumores cerebrales combinando CNNs con clustering difuso y verificación formal mediante Model Checking. Los enfoques especializados incluyen el trabajo de Stephan et al. (2024) con TGAICC, que utiliza modelos de lenguaje de gran escala para guiar el agrupamiento mediante prompts de usuario; Ling et al. (2022) con VTCC, unificando Transformers con aprendizaje contrastivo para capturar dependencias globales; y Bjerger et al. (2025) con MAML, optimizando la separación entre clases mediante meta-aprendizaje con pérdida de dispersión multivariada. Los avances más recientes incluyen el clustering basado en difusión generativa de Uziel et al. (2025), la extracción jerárquica de información de Zhang et al. (2025), las redes calibradas de Jia et al. (2025) que redujeron la tasa de falsos positivos en 19.5 %, el Information Bottleneck diferenciable de Yan et al. (2024) para clustering multi-vista, y la detección gradual de comunidades propuesta por Cheng and Chen (2025).

Cuadro 5: Rendimiento de métodos de Deep Clustering en benchmarks estándar

Método/Estudio	Dataset	Métricas	Innovación Principal
SeCu [Qian, 2023]	CIFAR-10	ACC: 88.1 %, NMI: 79.4 %, ARI: 77.6 %	Estabilidad discriminativa, evita colapso trivial
CDC [Jia et al., 2025]	CIFAR-10	FPR95: -19.5 %, AUROC: +2.9 %	Calibración de confianza para detección OOD
Híbrido CNN+K-FCM [Elfatimi et al., 2025]	Tumores cerebrales	Exactitud: 98 %, Precisión: 96.15 %, Recall: 100 %	Verificación formal con Model Checking
TGAICC [Stephan et al., 2024]	Varios	Superior a K-means	Guía textual con LLMs, consensus clustering
VTCC [Ling et al., 2022]	ImageNet	N/A	Transformers con aprendizaje contrastivo
MAML [Bjerger et al., 2025]	Few-shot	Adaptación rápida a nuevas clases	Meta-aprendizaje con pérdida de dispersión
CLUDI [Uziel et al., 2025]	Varios	Estado del arte	Clustering vía difusión generativa
InfoHier [Zhang et al., 2025]	Varios	Alta pureza	Clustering jerárquico con estructura de árbol

Fuente: Revisión sistemática de Leiber and Plant (2025), Lu et al. (2024), Qian (2023), Caron et al. (2018), Elfatimi et al. (2025), Stephan et al. (2024), Ling et al. (2022), Bjerger et al. (2025), Uziel et al. (2025), Zhang et al. (2025), Jia et al. (2025), Yan et al. (2024) y Cheng and Chen (2025)

Anexo E: Tecnologías de Detección Espectral

La detección espectral de corrosión mediante tecnologías de infrarrojo cercano e imagen hiperespectral representa una de las fronteras más prometedoras en la inspección no destructiva de estructuras marinas. De acuerdo con Enguita et al. (2025), la fusión de sensores LiDAR con cámaras hiperspectrales operando en el rango VNIR (400-1000 nm) permite identificar firmas

espectrales únicas de diferentes óxidos de hierro, alcanzando exactitudes del 98.5 % en clasificación binaria (corrosión vs. recubrimiento intacto) y del 92.3 % en graduación de severidad del daño, con una precisión espacial de localización inferior a 2 cm. La Tabla 6 compila los principales estudios en esta área tecnológica. Según Su et al. (2024), el desarrollo de métodos de corrección para espectrómetros Vis-NIR (400-2500 nm) que eliminan el efecto de fluctuación térmica ha permitido mediciones precisas de pH en agua de mar, reduciendo el error cuadrático medio de predicción de 0.45 a 0.08 y aumentando el coeficiente de determinación de 0.85 a 0.99, validando la viabilidad de sondas espectrales para monitoreo continuo y no invasivo de la agresividad química del medio marino. En el contexto del presente estudio, la cámara hiperespectral Pika IR+-1060 operando en el rango 895-1718 nm con 344 bandas espectrales permite detectar las firmas características de óxidos como hematita ($\alpha - Fe_2O_3$) y goethita ($\alpha - FeOOH$), fundamentales para la clasificación automática de estados de corrosión.

Cuadro 6: Rendimiento de sistemas hiperespectrales y NIR en detección de corrosión

Estudio/Tecnología	Rango Espectral	Rendimiento	Aplicación/Características
Enguita et al. (2025) LiDAR+HSI	VNIR 400-1000 nm	Clasificación binaria: 98.5 %; Severidad: 92.3 %	Inspección tanques de lastre, precisión espacial < 2 cm
Su et al. (2024) Vis-NIR	400-2500 nm	RMSEP pH: 0.08; R_p^2 : 0.99	Monitoreo ambiental, corrección térmica con PDS
Sivakumar et al. (2021) HSI+SVM	NIR	Precisión: 94 %	Clasificación acero corroído, metal desnudo, recubrimientos
Pika IR+-1060 [Este estudio]	895-1718 nm	344 bandas espectrales	Detección firmas espectrales óxidos ($\alpha - Fe_2O_3$, $\alpha - FeOOH$)

Fuente: Compilación de Enguita et al. (2025), Su et al. (2024) y estudios complementarios de detección espectral 2021-2025

Anexo F: Restauración de Imágenes Submarinas

La calidad de los datos visuales submarinos se ve severamente comprometida por la absorción de luz y la dispersión en la columna de agua, así como por el biofouling que genera un “efecto de gel” enmascarando la firma espectral de la corrosión subyacente. El pre-procesamiento mediante inteligencia artificial resulta vital para la fiabilidad de los sistemas de detección posteriores. De acuerdo con Cai et al. (2025), DUVR-Net representa un avance significativo al utilizar información temporal entre fotogramas (residuos de cuadros intermedios) para corregir distorsión de color y desenfoque de movimiento en videos dinámicos, superando los métodos tradicionales que procesan cada imagen de manera independiente. La Tabla 7 presenta las arquitecturas más innovadoras reportadas en el período 2024-2025. Según Guo et al. (2025), los marcos de restauración híbridos guiados por balance de color mediante priors multiescala permiten recuperar detalles finos perdidos por turbidez en aguas profundas, mejorando drásticamente la entrada para detectores CNN y manteniendo altas tasas de acierto donde métodos convencionales fallan. Por su parte, Zhang et al. (2024) integraron segmentación UNet en el bucle de control de robots de adsorción, combinada con controladores de rechazo de perturbaciones activas que aseguran estabilidad frente a corrientes marinas, demostrando la viabilidad de sistemas autónomos de inspección en condiciones operacionales reales.

Cuadro 7: Nuevas arquitecturas para restauración de video e imagen submarina

Modelo/Autor	Tecnología	Innovación/Aplicación
DUVR-Net [Cai et al., 2025]	Restauración dual-path de video	Usa información temporal entre fotogramas (residuos de cuadros intermedios) para corregir distorsión de color y desenfoque de movimiento
GuidedHybSensUIR [Guo et al., 2025]	Marco híbrido guiado	Prior de balance de color, recupera detalles finos en aguas profundas, mejora detección CNN
UNet+Robot [Zhang et al., 2024]	Segmentación UNet	Integrado en robot de adsorción con control de rechazo de perturbaciones activas para inspección de pilotes

Fuente: Avances de Cai et al. (2025), Guo et al. (2025) y Zhang et al. (2024) en restauración

Anexo G: Datos Económicos de Corrosión

La cuantificación del impacto económico de la corrosión marina es fundamental para justificar inversiones en nuevas tecnologías de detección y prevención. De acuerdo con Yu et al. (2025b), el costo global de la corrosión excede los 2.5 billones de dólares estadounidenses anuales, equivalente aproximadamente al 3.4 % del Producto Interno Bruto mundial. La Tabla 8 presenta una compilación de datos económicos a nivel global y nacional. Según Banco Mundial (2024), el PIB de Chile para 2024 asciende a 330.267 millones de dólares; aplicando la estimación global del 3.4 % como referencia conservadora, el costo anual estimado de la corrosión en el país alcanza aproximadamente 11.229 millones de dólares. Esta cifra cobra mayor relevancia al examinar los reportes financieros de empresas nacionales. De acuerdo con Camanchaca S.A. (2023), en el sector acuícola se reporta en el ítem de “otros resultados” del segmento de salmones un valor negativo de 4.538 miles de dólares estadounidenses (MUS\$) para el año 2023, directamente relacionado con el mantenimiento de jaulas y procesos operativos afectados por la corrosión submarina y el fouling. En el sector naval, según Astilleros y Maestranzas de la Armada (2023), los gastos asociados a la reparación de estructuras sumergidas alcanzan un monto cercano a los 63.428 MUS\$, consolidándose como una de las cifras más representativas del impacto directo de este fenómeno en la industria nacional. Un aspecto crítico, destacado por Kobisy et al. (2025) y Dalmora et al. (2025), es que entre el 20 % y el 40 % de la corrosión submarina en plantas offshore es impulsada por acción microbiológica (MIC), específicamente por bacterias reductoras de sulfatos, lo que subraya la necesidad de estrategias integradas de mitigación.

Cuadro 8: Impacto económico de la corrosión a nivel global y nacional

Ámbito	Cifra	Fuente/Observaciones
Costo global anual	2.5 billones USD	Yu et al. (2025), equivalente a 3.4 % del PIB mundial
Estimación Chile 2024	11.229 millones USD	Calculado como 3.4 % del PIB de Chile (330.267 millones USD, Banco Mundial 2024)
Camanchaca S.A. (2023)	4.538 MUS\$	Costos relacionados con corrosión submarina y fouling en jaulas (Memoria Anual 2023)
ASMAR (2023)	63.428 MUS\$	Gastos de reparación estructuras sumergidas (Memoria Anual 2022)
MIC en plantas offshore	20-40 % de corrosión submarina	Kobisy et al. (2025), Dalmora et al. (2025)

Fuente: Reportes corporativos de Camanchaca S.A. (2023) y Astilleros y Maestranzas de la Armada (2023), datos de Banco Mundial (2024), y literatura científica de Yu et al. (2025b), Kobisy et al. (2025) y Dalmora et al. (2025)

Anexo H: Firmas Espectrales de Óxidos de Hierro

La identificación precisa de los productos de corrosión mediante sus firmas espectrales constituye un pilar fundamental para el desarrollo de sistemas de inspección automatizada basados en imagen hiperespectral. De acuerdo con Enguita et al. (2025), cada óxido de hierro presenta un patrón de reflectancia característico en el espectro electromagnético, determinado por su estructura cristalina, composición química y grado de hidratación. La Tabla 9 presenta las características espectrales diagnósticas de los principales óxidos de hierro encontrados en ambientes marinos. Según Enguita et al. (2025), productos como la hematita ($\alpha - Fe_2O_3$), goethita ($\alpha - FeOOH$) y lepidocrocita ($\gamma - FeOOH$) exhiben baja reflectancia en el espectro visible (450-550 nm) pero muestran un aumento característico y diferenciable en la región del infrarrojo cercano (NIR > 750 nm), lo que permite su discriminación mediante algoritmos de clasificación espectral como el Spectral Angle Mapper (SAM). Esta biblioteca espectral específica para el

entorno marino, desarrollada por Enguita et al. (2025), ha sido validada en condiciones operacionales reales, alcanzando exactitudes superiores al 98 % en la clasificación de estados de corrosión en tanques de lastre de buques. La magnetita (Fe_3O_4), por su parte, presenta reflectancia muy baja en todo el espectro, siendo diagnóstica particularmente en la región SWIR (short-wave infrared), lo que permite su identificación inequívoca en mezclas complejas de productos de corrosión.

Cuadro 9: Características espectrales de productos de corrosión en ambiente marino

Compuesto	Fórmula Química	Rango Espectral	Características de Reflectancia
Hematita	$\alpha - Fe_2O_3$	450-1000 nm	Baja reflectancia 450-550 nm, aumento característico en NIR > 750 nm
Goethita	$\alpha - FeOOH$	450-1000 nm	Baja reflectancia visible, incremento diferenciable en NIR
Lepidocrocita	$\gamma - FeOOH$	450-1000 nm	Patrón similar a goethita con variaciones en pendiente NIR
Magnetita	Fe_3O_4	400-2500 nm	Reflectancia muy baja en todo el espectro, diagnóstica en SWIR

Fuente: Enguita et al. (2025), biblioteca espectral para entorno marino

Referencias

- Ali, S. A. K. (2025). Artificial intelligence applications in corrosion inhibition: Future directions. *Research Square*. Preprint.
- Astilleros y Maestranzas de la Armada (2023). Memoria anual y estados financieros consolidados 2022. Technical report, ASMAR, Valparaíso, Chile. Consultado en memoria corporativa.
- Banco Mundial (2024). Pib (us\$ a precios actuales) - chile. Base de datos de Indicadores del Desarrollo Mundial.
- Belmar, J. B. C. (2023). Evaluación y caracterización de recubrimiento para el control del crecimiento de micro y macroorganismos basado en agentes hidrofóbicos y biocidas naturales después de inmersión en medio marino. Memoria de título, Universidad de Concepción, Concepción, Chile. Caracterización experimental post-inmersión (156 días) con validación experta de defectos (ampollamiento, oxidación, agrietamiento) según normas ISO 4628.
- Bjerge, K., Bodesheim, P., and Karstoft, H. (2025). Deep image clustering with model-agnostic meta-learning. In *Proceedings of SCITEPRESS*. Scitepress.
- Cai, X., Wang, Y., Wang, T., Yang, Y., Lv, J., Lau, K.-T., and Gao, Y. (2025). DUVR-Net: A dual-path underwater video restoration network based on middle-frame residual and transformation convolution kernel. *Preprints.org*. Preprint.
- Camanchaca S.A. (2023). Memoria integrada 2023. Technical report, Salmones Camanchaca, Santiago, Chile. Véase ítem de otros resultados del segmento salmones.
- Caron, M., Bojanowski, P., Joulin, A., and Douze, M. (2018). Deep clustering for unsupervised learning of visual features. In *Proceedings of the European Conference on Computer Vision (ECCV)*.
- Cheng, T. and Chen, Q. (2025). Deep clustering via gradual community detection. *arXiv preprint arXiv:2501.02036*.
- Dalmora, G. P. V., Borges Filho, E. P., Conterato, A. A. M., Roso, W. S., Pereira, C. E., and Dettmer, A. (2025). Methods of corrosion prevention for steel in marine environments: A review. *Results in Surfaces and Interfaces*, 18:100430.

- Dhungana, P., Fresta, M., Tamrakar, N., and Dhungana, H. (2025). YOLO-based pipeline monitoring in challenging visual environments. *arXiv preprint arXiv:2507.02967*.
- Elfatimi, E., Elfatimi, L., and Bouchaneb, H. (2025). A hybrid deep learning and model-checking framework for accurate brain tumor detection and validation. *arXiv preprint arXiv:2501.01991*.
- Enguita, S. P., Jiang, J., Chen, C.-H., Kovacic, S., and Lebel, R. (2025). Potential of lidar and hyperspectral sensing for overcoming challenges in current maritime ballast tank corrosion inspection. *Electronics*, 14:3065.
- Espinoza Llanos, J. A. (2023). Modelo de clasificación de corrosión basado en deep learning. *Revista de Marina*, 1002:92.
- Guo, X., Chen, X., Wang, S., and Pun, C.-M. (2025). Underwater image restoration through a prior guided hybrid sense approach and extensive benchmark analysis. *arXiv preprint arXiv:2501.02701*.
- Imran, M. M. H., Jamaludin, S., Ayob, A. F. M., Ali, A. A. I. M., Ahmad, S. Z. A. S., Akhbar, M. F. A., Suhrab, M. I. R., Zainal, N., Norzeli, S. M., and Mohamed, S. B. (2023). Application of artificial intelligence in marine corrosion prediction and detection. *Journal of Marine Science and Engineering*, 11(2):256.
- Jamaludin, S. and Imran, M. M. H. (2024). Artificial intelligence for corrosion detection on marine structures. *The Journal of Ocean Technology*, 19(2):19–24.
- Jia, Y., Cheng, J., Liu, H., and Hou, J. (2025). Towards calibrated deep clustering network. In *Proceedings of the International Conference on Learning Representations (ICLR)*.
- Kobisy, A. S., Guan, F., Duan, J., Tawfik, S. M., and Guo, D. (2025). Mitigation of marine microbial corrosion using natural products based on chitosan polymer. *International Journal of Biological Macromolecules*, 321:145429.
- Kumar, A. S., Sivakumar, L., Rajadesingu, S., Sathish, S., Malik, T., and Parthipan, P. (2025). Sustainable corrosion inhibition approaches for the mitigation of microbiologically influenced corrosion - a systematic review. *Frontiers in Materials*, 12:1545245.

- Leiber, C. and Plant, C. (2025). An introductory survey to autoencoder-based deep clustering - sandboxes for combining clustering with deep learning. *arXiv preprint arXiv:2504.02087*.
- Li, P., Wang, S., Xiao, Z., Li, Y., Zhang, L., and Wang, G. (2025). Preparing a superhydrophobic coating with anti-corrosion and drag-reduction properties on an aluminum substrate. *Journal of Materials Engineering and Performance*, 34:23435–23451.
- Ling, H.-B., Zhu, B., Huang, D., Chen, D.-H., Wang, C.-D., and Lai, J.-H. (2022). Vision transformer for contrastive clustering. *arXiv preprint arXiv:2206.12925*.
- Liu, M., Wu, Y., Li, R., and Lin, C. (2025). LFN-YOLO: precision underwater small object detection via a lightweight reparameterized approach. *Frontiers in Marine Science*, 11:1513740.
- Lu, Y., Li, H., Li, Y., Lin, Y., and Peng, X. (2024). A survey on deep clustering: From the prior perspective. *arXiv preprint arXiv:2406.19602*.
- Lv, M., Li, X., and Du, M. (2020). The effect of cathodic polarization on the corrosion behavior of x65 steel in seawater containing sulfate-reducing bacteria. *Materials and Corrosion*, 71:1–11.
- Mouez, F. A., Halfa, H., Yahia, A., Hussien, H. M., Gaber, M., and Ali, H. H. (2025). Development and evaluation of superhydrophobic carbon nanotube coatings on maraging steel: Corrosion protection, and anti-fouling characteristics. *Journal of Alloys and Metallurgical Systems*, 10:100188.
- Qian, Q. (2023). Stable cluster discrimination for deep clustering. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*.
- Rivera, I. A. M. (2023). Desarrollo de recubrimientos multifuncionales para el control del crecimiento de micro y macroorganismos marinos, basados en agentes hidrofóbicos y biocidas naturales. Memoria de título, Universidad de Concepción, Concepción, Chile. Formulación y caracterización inicial de recubrimientos (Blanco, Z40Cu8, Z40Cu8CPS1.5, Capsaicina) con pruebas mecánicas, EIS y antibacterianas.
- Son, E.-Y., Jeong, D., and Oh, M.-J. (2024). Corrosion area detection and depth prediction

- using machine learning. *International Journal of Naval Architecture and Ocean Engineering*, 16:100617.
- Stephan, A., Miklautz, L., Leiber, C., Araujo, P. H. L., Répás, D., Plant, C., and Roth, B. (2024). Text-guided alternative image consensus clustering. *arXiv preprint arXiv:2406.18589*.
- Su, H., Li, L., and Hu, X. (2024). Correction methods for visible near-infrared spectroscopy in water ph detection to mitigate temperature influence. *Spectroscopy Letters*, 57(10):565–579.
- Uziel, R., Chelly, I., Freifeld, O., and Pakman, A. (2025). Clustering via self-supervised diffusion. *arXiv preprint arXiv:2507.04283*.
- Yan, X., Jin, Z., Han, F., and Ye, Y. (2024). Differentiable information bottleneck for deterministic multi-view clustering. *arXiv preprint arXiv:2403.15681*.
- Yu, D., Li, Z., Li, C., Liang, X., Dutta, J., Yang, J.-L., and Ye, F. (2025a). Chemical linkage in bifunctional chitosan-mercaptopbenzothiazole (mbt) coatings for enhanced corrosion prevention and antifouling activities. *Sustainable Materials and Technologies*, 44:e01371.
- Yu, J., Mashaija, B. A., and Mwankefu, C. N. (2025b). Binary classification of marine corrosion using deep learning: A benchmark study on the full marine_corrosion_dataset. *Regional Studies in Marine Science*, 90:104476. Versión publicada aceptada. También disponible como Preprint en Research Square (doi:10.21203/rs.3.rs-7190234/v1).
- Zhang, T., Ju, L., Singh, P., and Toor, S. (2025). InfoHier: Hierarchical information extraction via encoding and embedding. *arXiv preprint arXiv:2501.08717*.
- Zhang, W., Zhu, K., Yang, Z., Ye, Y., Ding, J., and Gan, J. (2024). Development of an underwater detection robot for the structures with pile foundation. *Journal of Marine Science and Engineering*, 12:1051.