

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA

SEDE VIÑA DEL MAR - JOSÉ MIGUEL CARRERA

**“DESARROLLO DE UN MODELO DE INSPECCIÓN EN
SUPERFICIES GRANALLADAS, MEDIANTE LA INTELIGENCIA
ARTIFICIAL Y VISIÓN COMPUTACIONAL.”**

Trabajo de Titulación para optar al Título de
Ingeniero en Mantenimiento Industrial.

Alumno: Franco Domingo Cruz Lago.

Profesor Guía: Mg. Ing. Pablo Andrés Duque Ramírez.

2025

DEDICATORIA

Este trabajo está dedicado con profundo amor y gratitud a mi familia, quienes han sido mi mayor apoyo en cada etapa de este camino. A mi madre, cuya fortaleza, ejemplo y sacrificio constante han sido el motor que impulsa cada uno de mis logros. A mis hermanos, quienes con su compañía, cariño y palabras de aliento han sido pilares fundamentales para mí, recordándome siempre la importancia de la unión y el esfuerzo. A mi novia Carolina, quien me brindó su apoyo y amor incondicional en todo momento, especialmente en los más cruciales. Te amo.

A mis queridas tías, Tía Tala y Tía Mery, y a mis queridos tíos, Tío Antonio y Tío Lalo, quienes representan para mí mucho más que simples familiares; son un pilar de fortaleza y amor incondicional en mi vida. A ustedes, que siempre han estado ahí, acompañándome en cada etapa de este camino, les debo tanto. Su cariño incondicional ha sido un refugio cálido en los momentos difíciles, llenándome de fuerzas cuando sentía que las dudas y los desafíos podían superarme.

Sus sabios consejos, siempre oportunos y llenos de experiencia, han sido una brújula que me ha guiado cuando la incertidumbre nublaba mi horizonte. Cada palabra de aliento, cada gesto de comprensión y cada muestra de apoyo me han recordado lo importante que es tener personas tan maravillosas a mi lado. En cada uno de mis logros, puedo ver el reflejo de su amor y confianza en mí, esa fe inquebrantable que siempre me han demostrado.

A mi primo Diego, cuyo apoyo incondicional, cariño y sabias palabras han sido fundamentales para que este logro se haga realidad. Su presencia ha sido un aliento invaluable en mi camino, recordándome siempre la importancia de la perseverancia y la fortaleza. A mi madrina Maca y a mi padrino Gonzalo, cuya guía y respaldo constante me han reafirmado que nunca estoy solo en este recorrido, brindándome seguridad y motivación en cada paso.

Este logro es tanto suyo como mío, porque cada palabra escrita y cada meta alcanzada llevan consigo el reflejo de su amor, confianza y esfuerzo. Gracias por estar siempre ahí, celebrando mis triunfos, alentándome a superar los desafíos y llenándome de esperanza. Este trabajo es el resultado de nuestra historia compartida, y cada uno de ustedes ocupa un lugar especial en él.

RESUMEN

Keywords: Inteligencia Artificial, Visión Computacional, Granallado, Redes Neuronales Convolucionales, Inspección Industrial, Normas SSPC/NACE, ISO 8501-1, Clasificación de Superficies.

Este trabajo presenta el desarrollo de un modelo de inteligencia artificial basado en redes neuronales convolucionales (CNNs) para la inspección y clasificación de superficies metálicas granalladas. El objetivo principal es automatizar el proceso de evaluación superficial, garantizando precisión y cumplimiento con normas internacionales como SSPC VIS 1, NACE e ISO 8501-1. El modelo clasifica superficies en cuatro grados de limpieza, desde grado A hasta el grado D, comparado con las diferentes limpiezas de superficies SA 1 (SP7) hasta SA 3 (SP5) en las superficies granalladas, respondiendo a las necesidades de la industria para mejorar la calidad y reducir los errores asociados con inspecciones manuales.

El dataset utilizado fue construido con imágenes reales que representan las diferentes condiciones de las superficies metálicas, abarcando variaciones en iluminación, texturas y ángulos de captura. Estas imágenes se dividieron en conjuntos de entrenamiento, validación y prueba, permitiendo entrenar el modelo de manera robusta y evaluar su desempeño de forma confiable. La matriz de confusión obtenida durante las pruebas revela un desempeño sobre el 87% de precisión en las clasificaciones de las categorías evaluadas del modelo.

El modelo demostró ser altamente eficiente en pruebas controladas, logrando clasificar correctamente todas las superficies en sus respectivas categorías. Sin embargo, el análisis también destacó la necesidad de mantener un dataset representativo y controles estrictos en la captura de imágenes para asegurar la generalización del modelo en escenarios más complejos y variables.

Finalmente, este proyecto establece una base sólida para la implementación de inteligencia artificial en inspecciones industriales, mostrando cómo la automatización puede optimizar los procesos de evaluación superficial. Las aplicaciones futuras incluyen la ampliación del dataset y el desarrollo de modelos más robustos para abordar condiciones ambientales aún más exigentes, consolidando esta tecnología como una herramienta esencial en la industria.

ÍNDICE

INTRODUCCIÓN	9
OBJETIVO GENERAL	10
OBJETIVOS ESPECÍFICOS	10
CAPÍTULO 1: ANÁLISIS DE LAS NORMAS PARA LA INSPECCIÓN DE SUPERFICIES GRANALLADAS Y DESCRIPCIÓN DEL MODELO DE INTELIGENCIA ARTIFICIAL	11
1.1 OPORTUNIDAD DE INTEGRAR TECNOLOGÍAS AVANZADAS EN LA INSPECCIÓN DE SUPERFICIES GRANALLADAS	12
1.2 SELECCIÓN DE NORMAS NACE / SSPC E ISO 8501	13
1.2.1 PREPARACIÓN DE SUPERFICIES	16
1.2.2 LOS GRADOS MÁS COMUNES DE LA NORMA	17
1.2.3 PREVENIR LA CORROSIÓN	22
1.3 TÉCNICAS Y TECNOLOGIAS RELEVANTES PARA LA INSPECCIÓN DE SUPERFICIES GRANALLADAS	23
1.3.1 VISIÓN COMPUTACIONAL PARA LA CAPTURA Y ANÁLISIS DE IMÁGENES	23
1.3.2 SINERGIA ENTRE VISIÓN COMPUTACIONAL E INTELIGENCIA ARTIFICIAL	23
1.3.3 OTRAS TECNOLOGÍAS COMPLEMENTARIAS	24
1.4 MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN	24
CAPÍTULO 2: DISEÑO DE LA ARQUITECTURA DEL MODELO DE INTELIGENCIA ARTIFICIAL PARA LA INSPECCIÓN DE SUPERFICIES DE GRANALLADAS.....	26
2.1 FUNDAMENTOS DEL DISEÑO DE LA ARQUITECTURA DEL MODELO	27
2.2 RELACIÓN ENTRE LAS NORMAS INTERNACIONALES Y LOS PARÁMETROS DEL MODELO	28
2.3 CONSTRUCCIÓN DEL DATASET Y SU RELEVANCIA PARA EL MODELO	29
2.3.1 ESTRUCTURA DEL DATASET BASADA EN NORMAS DE GRANALLADO	29

2.3.2	PREPARACIÓN Y PREPROCESAMIENTO DEL DATASET	30
2.3.3	RELEVANCIA DEL DATASET PARA EL MODELO.....	31
2.4	ARQUITECTURA DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	32
2.4.1	ENTRADA DEL MODELO.....	33
2.4.2	PARAMETROS DE LAS IMÁGENES	33
2.4.3	CAPAS CONVULCIONALES	34
2.4.4	CAPAS DE POOLING	35
2.4.5	CAPAS DENSAS Y DE SALIDA	35
2.4.6	OPTIMIZACIÓN DEL MODELO	35
2.5	IMPLENTACIÓN DEL CÓDIGO Y PROCESO DE ENTRENAMIENTO .	36
2.5.1	ESTRUCTURA DEL CÓDIGO	36
2.6	VALIDACIÓN DEL MODELO	38
2.6.1	IMPORTANCIA DE LA VALIDACIÓN	40
2.7	EVALUACIÓN DEL CÓDIGO IMPLEMENTADO Y SU IMPACTO EN LA CLASIFICACIÓN DE SUPERFICIES	40
2.7.1	MÉTRICAS DE EVALUACIÓN UTILIZADAS	41
2.7.2	RESULTADOS BASADOS EN LAS MÉTRICAS	43
2.8	MATRIZ DE CONFUSIÓN.....	46
2.9	LIMITACIONES DEL MODELO.....	47
CAPÍTULO 3: EVALUACIÓN DE LAS PRUEBAS DE CAMPO Y RESULTADOS DEL MODELO		50
3.1	JUSTIFICACIÓN Y OBJETIVO DE LAS PRUEBAS DE CAMPO.....	51
3.2	DESCRIPCIÓN DE LOS ESCENARIOS INDUSTRIALES.....	52
3.3	METODOLOGÍA DE EVALUACIÓN EN CAMPO	52
3.4	RESULTADOS DE LAS PRUEBAS DE CAMPO.....	56
3.5	LIMITACIONES DETECTADAS EN LAS PRUEBAS DE CAMPO	57
3.6	PROPUESTAS DE MEJORA PARA EL MODELO	59
3.7	REFLEXIÓN FINAL SOBRE LA EVALUACIÓN DEL MODELO.....	61
CONCLUSIONES Y RECOMENDACIONES		62
BIBLIOGRAFÍAS		63
ANEXOS		65

ÍNDICE DE ILUSTRACIONES

Ilustración 1 - Plancha metálica previa al proceso.....	14
Ilustración 2 – Granalla.....	17
Ilustración 3 - Grado SA 1	18
Ilustración 4 - Grado SA 2	19
Ilustración 5 - Grado SA 2 ½.....	20
Ilustración 6 - Grado SA 3	21
Ilustración 7 - Plancha metálica posterior al proceso.....	22
Ilustración 9 - Matriz de Confusión	45
Ilustración 11 - Grado A Norma SSPC VIS 1.....	65
Ilustración 12 - Grado B Norma SSPC VIS 1.....	65
Ilustración 13 - Grado C Norma SSPC VIS 1	66
Ilustración 14 - Grado D Norma SSPC VIS 1.....	66
Ilustración 15 - SP 5 Grado A Norma SSPC VIS 1	67
Ilustración 16 - SP 10 Grado A Norma SSPC VIS 1	67
Ilustración 17 - SP 5 Grado B Norma SSPC VIS 1	68
Ilustración 18 - SP 6 Grado B Norma SSPC VIS 1	68
Ilustración 19 - SP 7 Grado B Norma SSPC VIS 1	69
Ilustración 20 - SP 10 Grado B Norma SSPC VIS 1	69
Ilustración 21 - SP 5 Grado C Norma SSPC VIS 1	70
Ilustración 22 - SP 6 Grado C Norma SSPC VIS 1	70
Ilustración 23 - SP 7 Grado C Norma SSPC VIS 1	71
Ilustración 24 - SP 10 Grado C Norma SSPC VIS 1	71
Ilustración 25 - SP 5 Grado D Norma SSPC VIS 1	72
Ilustración 26 - SP 6 Grado D Norma SSPC VIS 1	72
Ilustración 27 - SP 7 Grado D Norma SSPC VIS 1	73
Ilustración 28 - SP 10 Grado D Norma SSPC VIS 1	73
Ilustración 29 - Grados de limpiezas en superficies.....	74

ÍNDICE DE TABLAS

Tabla 1 - Preparación de superficies	15
Tabla 2 - Tabla de grados.....	39

ÍNDICE DE DIAGRAMAS

Diagrama 1 - Estructura general del programa	43
Diagrama 2 - Estructura de construcción y prueba del programa	55

SIGLA Y SIMBOLOGÍA

SIGLA

AI:	Artificial Intelligence (Inteligencia Artificial)
CNN:	Convolutional Neural Network (Red Neuronal Convulcional)
NACE:	National Association of Corrosion Engineers (Asociación Nacional de Ingenieros de Corrosión)
SP:	Surface Preparation (Preparación de Superficies)
SSPC:	Society for Protective Coatings (Sociedad para Recubrimientos Protectores)
ISO 8501-1:	International Organization for Standardization (Organización Internacional de Normalización)
SVM:	Support Vector Machines (Máquinas de Soporte Vectorial)

TERMINOLOGÍA

Dataset:	Conjunto de datos utilizados para entrenar y evaluar modelos de inteligencia artificial.
Matriz de confusión (Confusion Matrix):	Herramienta utilizada para evaluar el rendimiento de los modelos clasificadores.
Precisión:	Métrica que mide la proporción de clasificaciones correctas en una categoría específica.
Recall (Sensibilidad):	Métrica que evalúa la capacidad del modelo para identificar correctamente todas las instancias de una categoría.
F1-Score:	Between Bearing (Entre cojinetes o rodamientos), referencia la forma constructiva de una bomba de 2 etapas.

PyTorch: Biblioteca de machine learning utilizada para el desarrollo de modelos de inteligencia artificial.

Normas SSPC/NACE: Estándares internacionales para la preparación y limpieza de superficies metálicas.

ISO 8501-1: Norma internacional que clasifica los grados de oxidación y preparación de superficies.

SP 5/10/6/7: Grados de limpieza de superficies metálicas según las normas SSPC.

Redes Neuronales Convolucionales (CNN): Arquitectura utilizada para el análisis de imágenes en el modelo.

Data Augmentation: Técnicas de aumento de datos para mejorar la diversidad del dataset.

Transformaciones Geométricas: Cambios en las imágenes como rotaciones, escalado y ajustes de brillo/contraste.

INTRODUCCIÓN

En el entorno industrial, la preparación de superficies y la aplicación de recubrimientos en materiales metálicos representan un desafío constante. La falta de uniformidad en estos procesos puede conducir a defectos estructurales, deterioro prematuro y riesgos para la seguridad. En este contexto, la norma NACE / SSPC han surgido como una respuesta crucial para establecer directrices claras y garantizar la calidad en cada etapa, desde la preparación hasta la protección de superficies metálicas.

A pesar de la existencia de estas normas, persisten desafíos en su implementación efectiva. La complejidad de las superficies, la diversidad de condiciones operativas y la necesidad de inspecciones continuas plantean obstáculos significativos para garantizar el cumplimiento constante y la calidad óptima. Además, las inspecciones manuales tradicionales son costosas, laboriosas y propensas a errores humanos.

Entre la necesidad de cumplir con las normas y la demanda de eficiencia operativa donde emerge una oportunidad para la aplicación de tecnologías avanzadas. La inteligencia artificial y la visión computacional ofrecen herramientas para mejorar la precisión en la inspección de superficies metálicas. La capacidad de estos sistemas para analizar grandes volúmenes de datos y detectar patrones sutiles puede proporcionar una evaluación más completa y rápida, reduciendo los costos y mitigando los riesgos asociados con defectos y fallas.

En este contexto operacional, se plantea el desarrollo de un modelo de inspección que integre las normas con técnicas de inteligencia artificial y visión computacional. Esta metodología estructurada aprovechará la riqueza de información proporcionada por las normas para entrenar algoritmos de Inteligencia artificial, permitiendo una evaluación precisa y eficiente de la conformidad con los estándares de calidad y seguridad. De este modo, se espera no solo mejorar la calidad de los procesos de preparación y recubrimiento, sino también optimizar los recursos y reducir los tiempos de inactividad, impulsando así la excelencia operativa en la industria.

OBJETIVO GENERAL

Desarrollar un modelo de inspección de superficies granalladas, mediante la integración de técnicas de inteligencia artificial y visión computacional, mejorando la precisión en la identificación de la calidad en las superficies.

OBJETIVOS ESPECÍFICOS

- Analizar las normas internacionales para la inspección de superficies granalladas, identificando las técnicas y tecnologías relevantes para el desarrollo del modelo de inteligencia artificial y visión computacional.
- Diseñar una arquitectura para el modelo de inteligencia artificial y visión computacional, integrando técnicas y tecnologías para la detección de la calidad en las superficies en el proceso de granallado, considerando las normas internacionales para granallado.
- Evaluar la funcionalidad del modelo mediante pruebas de campo en diferentes escenarios industriales, verificando en condiciones reales.

**CAPÍTULO 1: ANÁLISIS DE LAS NORMAS PARA LA INSPECCIÓN DE
SUPERFICIES GRANALLADAS Y DESCRIPCIÓN DEL MODELO
DE INTELIGENCIA ARTIFICIAL**

1.1 OPORTUNIDAD DE INTEGRAR TECNOLOGÍAS AVANZADAS EN LA INSPECCIÓN DE SUPERFICIES GRANALLADAS

La preparación y el recubrimiento de superficies metálicas son etapas críticas en múltiples industrias, particularmente en sectores como la minería, la construcción, y la fabricación de equipos industriales. Estos procesos no solo garantizan la adherencia de los recubrimientos protectores, sino que también determinan la resistencia de las estructuras frente a condiciones ambientales adversas como la humedad, la corrosión y la exposición a productos químicos. Sin embargo, la falta de uniformidad en estos procedimientos puede resultar en defectos significativos que comprometen la integridad estructural, generan altos costos de mantenimiento y, en algunos casos, ponen en riesgo la seguridad de los usuarios finales.

Tradicionalmente, las inspecciones de superficies granalladas se han llevado a cabo de forma manual, donde técnicos especializados evalúan visualmente el estado de las superficies metálicas y verifican su adherencia a estándares normativos como los definidos por SSPC e ISO 8501-1. Aunque este enfoque ha sido funcional, presenta limitaciones importantes. Las inspecciones manuales suelen ser lentas, dependientes de la experiencia del inspector, y pueden estar sujetas a errores humanos, especialmente en ambientes con condiciones desfavorables como baja iluminación o accesibilidad limitada. Además de la evaluación visual, la norma requiere la realización de pruebas complementarias para garantizar la calidad de la superficie antes del recubrimiento, tales como la medición del perfil de anclaje, la verificación de contaminación por sales solubles, la detección de polvo residual y la evaluación del espesor del recubrimiento, asegurando así el cumplimiento de los estándares de preparación de superficies.

En este contexto, la integración de tecnologías avanzadas como la inteligencia artificial (IA) y la visión computacional emerge como una solución disruptiva. Estas tecnologías tienen la capacidad de transformar la inspección de superficies granalladas al automatizar y optimizar procesos que antes dependían únicamente de la habilidad humana. Por ejemplo:

- **Precisión mejorada:** Los modelos de visión computacional pueden analizar características superficiales que son difíciles de identificar a simple vista, como microfisuras, niveles de oxidación o adherencias irregulares.
- **Velocidad de análisis:** A diferencia de las inspecciones manuales, que pueden tomar varias horas o días dependiendo del tamaño de la estructura, estas tecnologías pueden

procesar grandes volúmenes de datos en tiempo real, reduciendo significativamente los tiempos de inspección.

- **Reducción de costos:** Al minimizar la necesidad de intervenciones manuales extensivas y detectar problemas en etapas tempranas, estas tecnologías pueden reducir costos asociados al retrabajo, reparaciones y fallas inesperadas.
- **Consistencia y objetividad:** Mientras que las inspecciones manuales pueden variar dependiendo de la percepción y experiencia del técnico, la IA garantiza un análisis uniforme y basado en datos, disminuyendo la variabilidad entre evaluaciones.

La implementación de estas tecnologías está alineada con las tendencias globales de digitalización industrial y la adopción de conceptos como la Industria 4.0, donde la integración de sistemas inteligentes y la conectividad juegan un papel crucial en la mejora de la eficiencia operativa. En el caso específico de las superficies granalladas, herramientas como modelos de redes neuronales convolucionales (CNNs) permiten evaluar imágenes en tiempo real, clasificando las superficies según los grados normativos establecidos (SP5, SP10, SP6, etc.).

Otro aspecto relevante es la posibilidad de desarrollar sistemas de inspección portátiles o integrados en dispositivos industriales, lo que facilitaría su implementación en entornos difíciles como obras en altura o zonas de acceso limitado. Esto no solo mejora la accesibilidad del análisis, sino que también permite monitorear la calidad en diferentes etapas del proceso de preparación y recubrimiento, asegurando que las superficies cumplan con los estándares antes de proceder a recubrimientos costosos o críticos. (Lee, 2015)

1.2 SELECCIÓN DE NORMAS NACE / SSPC E ISO 8501

La elección de las normas NACE / SSPC (SP-5, SP-6, SP-7, SP-10) se basa en su reconocimiento y aceptación global en la industria de recubrimientos y protección de superficies. Estas normas establecen directrices claras para la limpieza y preparación de superficies metálicas, asegurando que los recubrimientos se adhieran correctamente y proporcionen la protección necesaria. La SP-5, que exige una limpieza a metal blanco, es ideal para aplicaciones donde se requiere una adherencia máxima del recubrimiento. La SP-6 permite una limpieza comercial, adecuada para situaciones donde la limpieza extrema no es crítica. La SP-7 se enfoca en la eliminación de contaminantes sueltos, y la SP-10 ofrece una limpieza casi a metal blanco,

permitiendo ligeras manchas. Estas normas proporcionan un marco estructurado que puede ser integrado en modelos de inteligencia artificial y visión computacional, garantizando inspecciones precisas y consistentes. (Society for Protective Coatings (SSPC) / NACE International, 2007)

- **SP-5 (Arenado a metal blanco):** Esta norma específica que la superficie metálica debe estar libre de todos los contaminantes visibles. Es el grado más alto de limpieza y se utiliza en aplicaciones donde la máxima adherencia del recubrimiento es esencial.

- **SP-6 (Arenado – Granallado comercial):** Esta norma permite la presencia de manchas ligeras de óxido, recubrimiento o contaminantes en no más del 33% de cada unidad de superficie. Es menos riguroso que el SP-5 y se aplica en situaciones donde una limpieza extrema no es crítica.

- **SP-7 (Arenado – Granallado rápido):** Se enfoca en la eliminación de la mayor parte de los contaminantes sueltos y no adheridos. Es el grado menos riguroso y se utiliza cuando se requiere una limpieza mínima.

- **SP-10 (Arenado – Granallado cercano a metal blanco):** Esta norma permite un máximo del 5% de manchas ligeras de contaminantes. Es más estricto que el SP-6 pero menos que el SP-5, y se utiliza en aplicaciones donde se necesita una alta adherencia del recubrimiento, pero no al nivel del SP-5.



Ilustración 1 - Plancha metálica previa al proceso

Fuente: Elaboración propia

Las normas definen la terminación deseada o sea el grado de granallado a alcanzar, pero en ningún caso se tiene en cuenta la rugosidad final en la superficie granallada o chorreada. Es decir, cuando hablamos por ejemplo de una acabado SA 2 ½ lo que se desea obtener con el granallado es una terminación limpia sin óxidos ni herrumbre, incluso la norma permite una pequeña cantidad de impurezas. Pero no es algo que podamos medir con un rugosímetro o con otro aparato de medición de superficies, la comprobación es visual y sujeta al criterio de los inspectores o expertos.

Es importante recalcar que cuando se utilizan los patrones de comparación visual se debe tener presente que el resultado no tiene por qué ser exacto al de la ilustración que marca la norma. Toda superficie una vez granallada puede diferir en su aspecto y color conforme el tipo de abrasivo utilizado (silicato de aluminio, corindón, granalla de acero, etc) además del metal base que se limpió. Es importante en estos casos remitirse al grado de eliminación de óxidos que marca la norma. Si está interesado en comprar abrasivos para su negocio, puede contactar con nuestro equipo de expertos.

En la siguiente tabla se muestran las normas más importantes de preparación de superficies:

Norma Sueca	Norma americana	Norma SSPC	Norma Francesa	Norma Inglesa	Norma NACE
SA 3	Metal Blanco	SP 5	DS 3	1st Quality	Nace 1
SA 2 1/2	Semi Blanco	SP 10	DS 2,5	2nd Quality	Nace 2
SA 2	Comercial	SP 6	DS 2	3rd Quality	Nace 3
SA 1	Cepillado granallado ligero	SP 7	DS 1		Nace 4

Tabla 1 - Preparación de superficies

Fuente: Granallado – Normas de preparación de superficies CYM

1.2.1 PREPARACIÓN DE SUPERFICIES

Tan importante es conocer la norma que tenemos que cumplir como el grado de suciedad en la pieza original antes de ser tratada. Por eso en todas las normas tienen en cuenta el grado de óxido y herrumbre de la superficie antes de ser limpiada con granalla. Grados de herrumbre o grado de oxidación:

- **Grado A.** Superficie de acero con la capa de laminación intacta en toda la superficie y prácticamente sin corrosión. Superficie de acero revestido de calamina adherente y prácticamente sin corrosión
- **Grado B.** Superficie de acero con principio de corrosión y en la cual la capa de laminación comienza a desprenderse. Superficie de acero con oxidación residual y donde la calamina empieza a desprenderse.
- **Grado C.** Superficie de acero en donde la capa de laminación ha sido eliminada por la corrosión o la capa de laminación puede ser eliminada por raspado, pero en la cual no se han formado en gran escala cavidades visibles. Hay leves picadas visibles.
- **Grado D.** Superficie de acero en donde la capa de laminación ha sido eliminada por la corrosión y se han formado en gran escala cavidades visibles. Superficie de acero cuya calamina ha desaparecido por acción de la oxidación y en la que se ven numerosas picadas.

La norma **ISO 8501-1** identifica también ciertos grados de limpieza visual (denominados grados de preparación) tras la preparación de la superficie de acero no revestido y de las superficies de acero después de eliminar totalmente cualquier revestimiento anterior. Nosotros haremos más énfasis en la norma sueca ya que es la más común y utilizada en industria en el tratamiento de superficies metálicas. La gran mayoría de perfiles, vigas, estructuras metálicas que van a ser pintadas se requiere un acabado Sa 2 ½ antes de la capa de imprimación y pintura. (International Organization for Standardization, 2007) (Chattopadhyay, 2019)



Ilustración 2 – Granalla

Fuente: Elaboración propia

1.2.2 LOS GRADOS MÁS COMUNES DE LA NORMA

A continuación, describimos los grados más comunes que dice la norma:

- **Grado SA 1.** Arenado, chorreado o granallado ligero. Hay que eliminar la capa suelta de laminación, el óxido suelto y las partículas extrañas sueltas. Hay bastante óxido en la superficie, no es un grado óptimo de limpieza y no es el adecuado cuando se requiere un tratamiento posterior exigente. Este grado de limpieza se puede conseguir con pistolas de chorreado, cabinas de granallar, arenadoras portátiles y máquinas de chorreo. Se suele usar silicatos de aluminio, silicato de hierro, microesferas de vidrio, escoria de cobre, etc.



Ilustración 3 - Grado SA 1

Fuente: BLASTONE Surface Preparation Guide

- **Grado SA 2.** Arenado, chorreado o granallado minucioso. Se elimina casi toda la capa de laminación y de óxido y casi todas las partículas extrañas. Deberá adquirir entonces un color grisáceo. Todavía hay algo de óxido y suciedad, pero la superficie empieza a estar limpia. Chorreado hasta que al menos los 2/3 de cualquier porción de la superficie total estén libres de todo residuo visible. Este grado de limpieza se obtiene usando equipos de chorreado, cabinas de mangas de granallar, granalladoras portátiles y granalladoras de turbina. Se suele usar corindón marrón, silicato de aluminio, granalla de hierro, etc.

COMMERCIAL
SSPC-SP6
(NACE No 3 / SA 2)



Ilustración 4 - Grado SA 2

Fuente: BLASTONE Surface Preparation Guide

- **Grado SA 2 ½.** Arenado, chorreado o granallado muy minucioso (granallado a fondo). Las capas de laminación, óxido y partículas extrañas se quitan de una manera tan perfecta que los restos sólo aparezcan como ligeras manchas o rayas. El metal parece blanco y en perfectas condiciones para un recubrimiento posterior. Aquí ya no encontramos restos de óxido. Por lo menos el 95% de cada porción de la superficie total queda libre de cualquier residuo visible y se elimina el polvo de abrasivo con un aspirador. Este grado de limpieza se puede conseguir con el uso de chorreadoras, cuartos y salas de granallar, arenadoras portátiles y equipos de granallado en automático. Los abrasivos más usados son las granallas metálicas, óxido de aluminio, corindón marrón, etc.

NEAR-WHITE
METAL
SSPC-SP10
(NACE No 2 / SA 2 ½)



Ilustración 5 - Grado SA 2 ½

Fuente: BLASTONE Surface Preparation Guide

- **Grado SA 3.** Arenado, chorreado o granallado a metal blanco (chorreado muy intenso). Toda la capa de laminación, todo el óxido y todas las partículas extrañas se quitan sin dejar ningún resto de contaminante. Deberá adquirir un color metálico uniforme. Es el nivel más exigente de limpieza mediante chorro abrasivo, ideal cuando existe una especificación muy estricta de limpieza. Para obtener este grado de limpieza lo más común es usar granallas mediante el granallado automático por turbina, aunque también se puede realizar de forma manual con arenadoras. Una vez chorreada o granallada la superficie debe limpiarse con un aspirador de granalla.

WHITE METAL
SSPC-SP5
[NACE No 1 / SA 3]



Ilustración 6 - Grado SA 3

Fuente: BLASTONE Surface Preparation Guide

El proceso de granallado es un método fundamental en la preparación de superficies metálicas, garantizando la remoción de contaminantes, óxidos y residuos adheridos. Este tratamiento es esencial para cumplir con los estándares de limpieza exigidos en la industria, como los definidos por la norma SSPC VIS 1. Tras la aplicación del granallado, las superficies metálicas presentan una textura uniforme y una limpieza adecuada que favorece la adhesión de recubrimientos protectores.

En la siguiente imagen se observa una plancha metálica luego de haber sido sometida al proceso de granallado, evidenciando la eliminación de impurezas y la obtención de un acabado homogéneo, listo para la aplicación de recubrimientos anticorrosivos.



Ilustración 7 - Plancha metálica posterior al proceso

Fuente: Elaboración propia

1.2.3 PREVENIR LA CORROSIÓN

Prevenir la corrosión en la superficie tratada es el objetivo que se consigue mediante el chorreo con arena (sandblasting), y es que no existe mejor pretratamiento que el granallado de piezas y superficies metálicas con el objetivo de limpiar las superficies y crear un perfil de anclaje suficiente para los recubrimientos posteriores.

Si se analiza la información disponible sobre las normas de preparación de superficies, se puede concluir que es fundamental determinar el grado de limpieza requerido y el método de tratamiento más adecuado para alcanzarlo. Para ello, evaluar el nivel de suciedad y la presencia de óxidos en la superficie permite seleccionar entre un chorreado con pistola a presión o un proceso de granallado mediante turbinas, asegurando así una limpieza eficiente. La elección del abrasivo y del equipo adecuado desempeña un papel crucial en la efectividad del tratamiento, por lo que el asesoramiento especializado en el uso de abrasivos y sus impactos se vuelve esencial en la preparación de superficies metálicas.

NORMA (ISO 8501-1:2007) preparación de superficies metálicas antes de pintar. Preparación de sustratos de acero previa a la aplicación de pinturas y productos relacionados. Evaluación visual de la limpieza de las superficies. Chorreado y granallado antes de pintar o imprimir. Grados de óxido y de preparación de sustratos de acero no pintados después de eliminar totalmente los recubrimientos anteriores. Grado de preparación sa, chorro de arena sa 2 ½, acabado superficial sa 2 ½, grado de preparación st2, limpieza st2. (Abrasivos y maquinarias, s.f.)

1.3 TÉCNICAS Y TECNOLOGÍAS RELEVANTES PARA LA INSPECCIÓN DE SUPERFCIES GRANALLADAS

El desarrollo de un modelo eficiente y confiable para la inspección de superficies granalladas requiere el uso de técnicas y tecnologías avanzadas que aborden las limitaciones de los métodos ya existentes. Estas tecnologías no solo permiten mejorar la velocidad y precisión de las inspecciones, sino que también permiten cumplir con los exigentes estándares internacionales de calidad, tales como las normas SSPC VIS 1 e ISO 8501-1 en este caso, que establecen grados específicos de limpieza y preparación superficial.

1.3.1 VISIÓN COMPUTACIONAL PARA LA CAPTURA Y ANÁLISIS DE IMÁGENES

La visión computacional es una herramienta fundamental para el programa ya que, a la hora del análisis de superficies metálicas, permitiendo capturar y procesar las imágenes con alta precisión. Mediante cámaras especializadas y algoritmos avanzados, es posible identificar defectos en estas superficies tales como la microfisuras, porosidad, oxidación o adherencias que podrían pasar desapercibidos en una inspección manual, regularidad en los resultados de las pruebas, evitando variaciones causadas por factores como la iluminación o la fatiga del inspector. Otra ventaja relevante es la capacidad de procesar imágenes en tiempo real, lo que optimiza la evaluación de la calidad superficial y reduce los tiempos de inspección. (Mourtzis, 2016)

1.3.2 SINERGIA ENTRE VISIÓN COMPUTACIONAL E INTELIGENCIA ARTIFICIAL

La integración de estas dos, la inteligencia artificial y la visión computacional, ofrecen una solución robusta y eficiente para la inspección de superficies granalladas. Mientras que la

visión computacional se enfoca en la captura de los datos visuales, la inteligencia artificial analiza los datos para extraer la información útil y tomar decisiones precisas como se requiere, por ejemplo:

- Las imágenes capturadas por cámaras especializadas se normalizan y procesan para garantizar su consistencia.
- Los algoritmos de la IA clasifican las imágenes en cada categoría específica ya designada, basándose en los estándares internacionales de las normas.
- Este proceso combinado crea una sinergia que permite una evaluación más completa, considerando todas las características visuales, así también como ciertos patrones complejos que podrían indicar defectos.

1.3.3 OTRAS TECNOLOGÍAS COMPLEMENTARIAS

Existen otras tecnologías complementarias que fortalecen el proceso de inspección en las superficies:

- **Aumento de Data:** Técnicas tales como las rotaciones, ajustes de brillo y contraste en las imágenes, se utilizan para enriquecer el dataset, aumentando su diversidad y mejorando la capacidad del modelo para generalizar las imágenes.
- **Sensores Avanzados:** En ciertos casos, existen unos sensores avanzados o cámaras infrarrojas que se pueden acoplar para evaluar características que no están a simple vista, como la composición química de las superficies o la detección de defectos debajo del recubrimiento de las superficies.
- **Plataformas en la Nube:** La implementación de modelos en plataformas en la nube facilita el acceso remoto a los datos, permitiendo la supervisión y análisis en tiempo real desde cualquier ubicación.

1.4 MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN

Los modelos de inteligencia artificial juegan un papel crucial en la inspección de superficies granalladas ya que pueden permitir la identificación automática de defectos. Los modelos más comunes incluyen:

Redes Neuronales Convolucionales (CNN): Se diseñaron para el procesamiento de imágenes, estas redes son capaces de detectar patrones complejos y de clasificar defectos con alta precisión debido a que su arquitectura de capas convolucionales, que extraen características

fundamentales de las imágenes, es ideal para identificar discontinuidades en las superficies granalladas.

Máquinas de Soporte Vectorial (SVM): Eficaces para la clasificación de datos en múltiples dimensiones, funcionan bien cuando las clases de defectos están claramente definidas, separando las diferentes clases mediante hiperplanos en un espacio de características de alta dimensión.

Árboles de Decisión y Bosques Aleatorios: Estos modelos toman decisiones basadas en características específicas de los datos. Los bosques aleatorios combinan múltiples árboles de decisión para mejorar la precisión y reducir el riesgo de sobreajuste, lo que los hace capaces de manejar grandes volúmenes de datos y realizar una clasificación precisa de discontinuidades en las superficies granalladas.

La matriz de confusión es una herramienta fundamental para corroborar el rendimiento de los modelos de clasificación que existen mediante la inteligencia artificial, ya que permite comparar las predicciones del modelo con los resultados reales. A través de diferentes métricas como la exactitud, precisión, fiabilidad y especificidad, facilita la identificación de errores para prevenir falsos positivos y negativos, permite realizar ajustes necesarios para mejorar la fiabilidad del sistema en la detección de las discontinuidades.

Esta herramienta proporciona una visión clara de las fortalezas y debilidades del modelo, lo que implica que la optimización del sistema sea continua para la inspección de superficies granalladas, sino que también garantiza el cumplimiento de los estándares internacionales de calidad y seguridad. Por estas razones, la matriz de confusión es una herramienta esencial en el desarrollo de sistemas de inspección basados en inteligencia artificial.

**CAPÍTULO 2: DISEÑO DE LA ARQUITECTURA DEL MODELO DE
INTELIGENCIA ARTIFICIAL PARA LA INSPECCIÓN DE
SUPERFICIES DE GRANALLADAS**

2.1 FUNDAMENTOS DEL DISEÑO DE LA ARQUITECTURA DEL MODELO

El diseño de la arquitectura del modelo de IA para la inspección de superficies granalladas requiere la integración de principios normativos, tecnológicos y prácticos. Normas internacionales reconocidas, cuales son la norma SSPC VIS 1, NACE e ISO 8501-1, estas establecen las “*directrices para definir los parámetros técnicos del modelo*”, garantizando una clasificación confiable y alineada con los estándares industriales.

El objetivo principal del modelo es diferenciar de manera precisa los diferentes grados de limpieza superficial que rige la norma y detectar los defectos en las superficies granalladas. Para ello, se emplean redes neuronales convolucionales (CNNs), una tecnología altamente eficiente en el análisis de imágenes. Estas redes permiten que el modelo sea capaz de identificar patrones complejos en el algoritmo que se presentan en las diferentes superficies y también de asociarlos con las categorías normativas, tales como:

- **SP5 (Metal Blanco):** Superficie completamente limpia, sin rastros de óxido ni contaminantes visibles.
- **SP6 (Comercial):** Hasta un 33% de residuos adheridos aceptables.
- **SP7 (Rápidamente limpiada):** Eliminación superficial de contaminantes sueltos, dejando óxidos adheridos. Ideal para mantenimiento rápido y económico.
- **SP10 (Casi Blanco):** Hasta un 5% de manchas residuales permitidas.

PRINCIPALES CONSIDERACIONES DEL DISEÑO

El desarrollo del modelo se fundamenta en la comprensión de las características a los procesos de granallado y sus implicaciones visuales. Entre los factores más relevantes considerados están:

1. **Variabilidad en las superficies metálicas:** Las propiedades del material base, como su composición y textura, afectan la apariencia superficial tras el proceso de limpieza.
2. **Tipos de abrasivos utilizados:** El uso de diferentes materiales tales como la granalla metálica, óxido de aluminio o escoria de cobre influye en el acabado final, generando texturas y tonalidades distintas en la superficie.

3. **Condiciones en la captura de imágenes e iluminación:** Los cambios en la intensidad de la luz, diferentes ángulos en la captura de la imagen y las sombras pueden provocar una confusión en el modelo que se refleja en la matriz, lo cual el modelo exige que sea robusto y confiable para controlar las diferentes variaciones mencionadas en las imágenes.

2.2 RELACIÓN ENTRE LAS NORMAS INTERNACIONALES Y LOS PARÁMETROS DEL MODELO

Las normas internacionales establecen estándares visuales y un marco técnico que permite traducir las condiciones físicas de las superficies granalladas en parámetros cuantificables. Este enfoque facilita el desarrollo del modelo de inteligencia artificial, asegurando que la clasificación rígida por la norma y generadas por el modelo se ajusten a los requisitos establecidos.

El modelo ha sido diseñado para identificar y clasificar las características específicas asociadas a los grados de limpieza definidos por las normas, entre los que se incluyen:

- **Eliminación total de contaminantes visibles (SP5):** Superficies con un acabado metálico uniforme, libres de óxido y residuos.
- **Residuos adheridos hasta un 33% de la superficie (SP6):** Incluye superficies con manchas significativas y contaminantes aún presentes.
- **Limpieza superficial de contaminantes (SP7):** Eliminación rápida de óxidos sueltos y contaminantes superficiales, dejando óxidos firmemente adheridos.
- **Presencia limitada de manchas residuales (SP10):** Hasta un 5% de manchas ligeras permitidas, visibles como variaciones menores en la tonalidad.

Estos criterios se transforman en patrones visuales que el modelo detecta y analiza mediante las capas convolucionales. Mientras que las Superficies de tipo SP5 exhiben un acabado homogéneo, las de tipo SP10 presentan irregularidades suaves que la IA identifica mediante el análisis de texturas y tonalidades de las superficies.

IMPORTANCIA DE LAS NORMAS EN EL AJUSTE DEL MODELO

Además de guiar la clasificación, las normas ayudan a establecer los criterios de éxito del modelo. Una predicción precisa ocurre cuando las imágenes etiquetadas por los inspectores como

SP10 son clasificadas correctamente por el sistema. Para alcanzar este nivel de precisión, es fundamental el ajuste de los **hiperparámetros del modelo**, el cual se enfoca en identificar como la tasa de aprendizaje del modelo y que la arquitectura de las capas se calibre cuidadosamente y junto a una **selección y construcción de un dataset representativo**, la diversidad y la calidad de los datos con los cuales se entrenó el modelo son esenciales para garantizar que reconozca variaciones propias las diferentes categorías normativas.

2.3 CONSTRUCCIÓN DEL DATASET Y SU RELEVANCIA PARA EL MODELO

El dataset es el pilar fundamental para entrenar, validar y evaluar el modelo de inteligencia artificial diseñado para la inspección de superficies granalladas. Su construcción sigue las normas internacionales más relevantes, como SSPC e ISO 8501-1, adaptándolas a los rangos de limpieza y calidad comúnmente utilizados en la industria chilena. Este enfoque asegura que el modelo esté alineado con los estándares globales mientras responde a las necesidades locales del sector.

2.3.1 **ESTRUCTURA DEL DATASET BASADA EN NORMAS DE GRANALLADO**

El diseño del dataset se fundamenta en los grados de limpieza definidos por las normas internacionales, proporcionando una base clara para clasificar las superficies metálicas tratadas. Las cinco categorías principales incluidas reflejan los distintos niveles de limpieza superficial observados en la práctica industrial:

1. **Superficie en buen estado (Grado SP5 / SA3):** Representa superficies completamente limpias a metal blanco, libres de óxidos, manchas y contaminantes visibles. Este grado asegura una máxima adherencia del recubrimiento y se aplica en condiciones críticas, como estructuras expuestas a ambientes marinos o químicos severos.

2. **Superficie cercana a metal blanco (Grado SP10 / SA 2 ½):** Permite hasta un 5% de manchas ligeras de contaminantes. Este es el grado más común en la industria chilena y se utiliza para estructuras metálicas generales que requieren alta adherencia del recubrimiento, como puentes y equipos industriales.

3. **Superficie comercial (Grado SP6 / SA 2):** Incluye superficies con hasta un 33% de residuos adheridos, como manchas de óxido o restos de recubrimientos. Este grado es adecuado para aplicaciones menos críticas, como estructuras internas o áreas con baja exposición a corrosión.

4. **Superficie rápidamente limpiada (Grado SP7 / SA 1):** Enfocado en la eliminación de contaminantes sueltos y no adheridos, permitiendo la presencia de óxidos firmemente adheridos. Este grado se aplica en situaciones donde el tiempo y los costos son factores prioritarios, sacrificando la calidad de limpieza.

5. **Superficie oxidada o sin preparar (Grado D según ISO 8501-1):** Representa superficies con niveles significativos de óxido, laminación suelta o contaminantes adheridos. Esta categoría es clave para identificar áreas que no cumplen con los estándares mínimos y requieren una nueva preparación antes de aplicar recubrimientos.

2.3.2 PREPARACIÓN Y PREPROCESAMIENTO DEL DATASET

Un dataset robusto y representativo es esencial para desarrollar un modelo confiable. Su construcción se dividió en dos etapas principales: preparación y preprocesamiento de las imágenes, garantizando que los datos cumplieran con los estándares necesarios para el entrenamiento, validación y prueba del modelo.

2.3.2.1 PREPARACIÓN DEL DATASET

Las imágenes incluidas en el dataset fueron capturadas directamente de superficies metálicas tratadas, abarcando los cinco grados de limpieza definidos. La organización del dataset siguió una estructura diseñada para optimizar el rendimiento del modelo:

- **Entrenamiento (20%):** Este subconjunto se utilizó para ajustar los pesos del modelo durante el aprendizaje.
- **Validación (8%):** Empleado para monitorear el rendimiento del modelo durante el entrenamiento, ayudando a prevenir el sobreajuste y asegurando una generalización adecuada.
- **Prueba (72%):** Reservado exclusivamente para evaluar la capacidad del modelo de generalizar a datos nuevos y no vistos previamente, ofreciendo una medida confiable de su desempeño en escenarios reales.

2.3.2.2 PREPROCESAMIENTO DE LAS IMÁGENES.

El preprocesamiento de imágenes es un paso esencial para garantizar la calidad, uniformidad y compatibilidad de los datos ingresados al modelo, maximizando su capacidad para identificar patrones relevantes. En este caso, se implementaron las siguientes etapas utilizando **PyTorch** y **Torchvision**:

- **Redimensionado:** Todas las imágenes fueron ajustadas a un tamaño uniforme de 500x500 píxeles utilizando la función “transforms.Resize”. Esto asegura una resolución consistente, optimizando la compatibilidad con las capas convolucionales del modelo.
- **Conversión a tensores:** Las imágenes en formato RGB fueron transformadas a tensores con la función “transforms.ToTensor()”, convirtiendo los valores de los píxeles al rango [0, 1] para que puedan ser procesados por el modelo.
- **Normalización:** Los valores de los tensores fueron escalados al rango [-1, 1] utilizando “transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5])”. Este paso estabiliza el proceso de entrenamiento, permitiendo que el modelo converja más rápido y minimizando problemas asociados a las diferencias de escala en los datos.

Estas transformaciones, combinadas en un pipeline con **Torchvision**, aseguran que las imágenes sean procesadas de manera uniforme y eficiente. Además, el preprocesamiento facilita la generalización del modelo, permitiéndole adaptarse a nuevas imágenes con características similares, y establece una base sólida para una clasificación precisa de las superficies granalladas en escenarios industriales reales. (PyTorch Developers, 2022)

2.3.3 RELEVANCIA DEL DATASET PARA EL MODELO

El dataset, diseñado siguiendo estándares reconocidos internacionalmente como SSPC e ISO 8501-1, asegura que el modelo esté perfectamente alineado con las expectativas industriales, tanto locales como globales. Cada categoría establecida refleja condiciones reales observadas en superficies metálicas, capturando además las variaciones específicas de los procesos industriales en Chile. Esto permite que el modelo sea entrenado para clasificar superficies con precisión y consistencia, brindando una solución confiable para la inspección en entornos operativos complejos.

Al estar alineado con las normativas internacionales, el dataset actúa como un puente efectivo entre la teoría normativa y la práctica industrial. Las imágenes etiquetadas con precisión en función de los grados de limpieza sirven como un recurso fundamental para evaluar la efectividad del modelo. Su diseño robusto también permite superar desafíos habituales, como variaciones en las condiciones de iluminación y diferencias en los abrasivos empleados, asegurando que el modelo sea capaz de generalizar a distintos escenarios.

Este dataset no solo entrena al modelo para operar bajo estándares globales, sino que también optimiza su adaptabilidad a las necesidades locales. Esto lo posiciona como una herramienta esencial para la automatización de inspecciones, permitiendo optimizar recursos, reducir tiempos de trabajo y garantizar la calidad en todas las etapas del proceso de granallado. El diseño y la organización del dataset consolidan este sistema como una innovación clave para satisfacer las demandas de precisión y eficiencia en la industria chilena.

2.4 **ARQUITECTURA DEL MODELO DE INTELIGENCIA ARTIFICIAL**

El diseño de la arquitectura del modelo de inteligencia artificial (IA) es un elemento central para asegurar un rendimiento confiable y preciso en la clasificación de superficies granalladas. Se implementaron **redes neuronales convolucionales (CNNs)** debido a su capacidad comprobada para procesar imágenes y extraer características visuales complejas, como texturas, tonalidades y patrones asociados a los diferentes grados de limpieza superficial. (Szeliski, 2022) (Zhao X. &, 2023)

Las CNNs son particularmente adecuadas para este tipo de tarea porque:

1. **Automatizan la extracción de características:** Identifican patrones visuales relevantes sin necesidad de una intervención manual, facilitando la clasificación de superficies en múltiples categorías.
2. **Manejan datos visuales complejos:** Procesan variaciones en texturas y detalles sutiles presentes en las superficies metálicas tratadas.
3. **Ofrecen robustez y generalización:** Gracias a su arquitectura basada en capas convolucionales y de pooling, las CNNs logran manejar diferencias en las condiciones de iluminación, ángulos de captura y niveles de ruido en los datos. (Ian Goodfellow, 2016) (Chollet, 2017) (TensorFlow Developers, s.f.)

“La elección de esta arquitectura no solo responde a la necesidad de cumplir con los estándares normativos, sino también a la posibilidad de optimizar los procesos industriales, reduciendo el tiempo de inspección y mejorando la precisión en la detección de defectos.”

2.4.1 ENTRADA DEL MODELO

IMPLEMENTACIÓN Y ENTORNO DE DESARROLLO

El desarrollo del modelo de inteligencia artificial para la clasificación de superficies granalladas se llevó a cabo en el entorno colaborativo de Google Colab, utilizando la integración con Google Drive para la gestión eficiente de datos y modelos. Esta combinación ofreció un entorno flexible, accesible y robusto, ideal para proyectos de machine learning e inteligencia artificial. (Google, s.f.)

```
from google.colab import drive
drive.mount('/content/gdrive')
!ls
```

VENTAJAS DEL ENTORNO DE DESARROLLO

Accesibilidad en la nube: Google Colab permite ejecutar y entrenar modelos en la nube, evitando las limitaciones de hardware local y asegurando el acceso a recursos de cómputo avanzados, como GPU y TPU, sin costo adicional.

Gestión de datos con Google Drive: La integración directa con Google Drive facilitó el almacenamiento y la organización del dataset, así como la persistencia de modelos entrenados. Esto permitió acceder y modificar archivos de manera eficiente durante todas las etapas del proyecto.

Entorno colaborativo: Al estar basado en la nube, Google Colab permitió compartir fácilmente el código y resultados con otros interesados en el proyecto, fomentando la colaboración y el intercambio de ideas.

Compatibilidad con PyTorch: Google Colab ofreció compatibilidad completa con PyTorch, el marco utilizado para la implementación del modelo. Esto incluyó acceso a bibliotecas de machine learning y herramientas para la visualización de datos y métricas.

2.4.2 PARAMETROS DE LAS IMÁGENES

El modelo recibe como entrada imágenes preprocesadas utilizando transformaciones implementadas con **Torchvision**, que incluyen redimensionado a 500x500 píxeles, normalización y conversión a tensores. Este preprocesamiento asegura la uniformidad de los datos, facilitando que el modelo identifique patrones y características específicas.

Las imágenes corresponden a las cinco categorías definidas en el dataset (desde superficies en buen estado hasta oxidadas), siguiendo los grados de limpieza establecidos por las normas internacionales. El formato y las transformaciones aplicadas garantizan que el modelo sea capaz de analizar y clasificar con precisión cada superficie, destacando los detalles relevantes asociados a cada grado de limpieza. (Gonzalez, 2018)

```
width_shape = 500
height_shape = 500
num_classes = 5
epochs = 60
batch_size = 16
```

Estos parámetros definen aspectos clave del modelo y su entrenamiento:

- **width_shape y height_shape (500x500):** Especifican el tamaño de las imágenes de entrada. Todas las imágenes se redimensionan a esta resolución para garantizar uniformidad y compatibilidad con la arquitectura del modelo.
- **num_classes (5):** Indica el número de categorías en las que el modelo clasifica las superficies (en este caso, cinco grados de limpieza o estados).
- **epochs (60):** Es la cantidad de ciclos completos de entrenamiento que el modelo realiza sobre el conjunto de datos. Más épocas pueden mejorar el aprendizaje, pero también aumentar el riesgo de sobreajuste.
- **batch_size (16):** Define cuántas imágenes se procesan en cada paso del entrenamiento. Un tamaño de lote pequeño reduce la demanda de memoria, aunque puede requerir más iteraciones.

2.4.3 CAPAS CONVULCIONALES

Las capas convolucionales son el núcleo del modelo de inteligencia artificial, encargadas de detectar patrones visuales específicos en las superficies metálicas, como texturas, bordes, manchas y variaciones de tonalidad. Estas capas están diseñadas para identificar características relacionadas con los grados de limpieza definidos por las normas SSPC e ISO. Su funcionamiento puede dividirse en tres etapas: (Said, 2020) (Jin, 2021)

- **Primeras capas:** Detectan características básicas como bordes y texturas simples.
- **Capas intermedias:** Analizan patrones más complejos, incluyendo manchas de óxido y cambios sutiles en la tonalidad.
- **Capas finales:** Extraen las características específicas necesarias para clasificar cada grado de limpieza con precisión.

Esta jerarquía progresiva permite que el modelo transforme la información visual desde detalles simples hasta representaciones complejas y específicas. (Kumbhar, 2023)

2.4.4 CAPAS DE POOLING

Para optimizar la eficiencia del modelo, se implementaron capas de **max-pooling**. Estas capas reducen la dimensionalidad de los datos al seleccionar los valores más relevantes en cada región, manteniendo las características críticas. Este enfoque no solo disminuye el tiempo de entrenamiento, sino que también reduce el riesgo de sobreajuste, al eliminar redundancias en los datos.

2.4.5 CAPAS DENSAS Y DE SALIDA

Las capas densas, también conocidas como capas completamente conectadas, integran las características extraídas por las capas convolucionales y las transforman en predicciones. La última capa utiliza una función de activación **softmax**, que asigna probabilidades a cada una de las categorías definidas (superficie en buen estado, cercana a metal blanco, comercial, rápidamente limpiada y oxidada). Esta estructura permite al modelo realizar clasificaciones precisas en función de los patrones detectados. (Zhang, 2017) (Zhang Y. L., 2024)

2.4.6 OPTIMIZACIÓN DEL MODELO

Para ajustar los pesos del modelo y minimizar el error en las predicciones, se empleó el optimizador **Adam**. Este optimizador combina las ventajas del descenso de gradiente estocástico con adaptaciones dinámicas en la tasa de aprendizaje, lo que lo hace especialmente adecuado para problemas complejos. La función de pérdida utilizada fue “**CrossEntropyLoss**”, que mide la discrepancia entre las predicciones del modelo y las etiquetas reales del dataset, guiando el aprendizaje hacia una mayor precisión.

2.5 IMPLEMENTACIÓN DEL CÓDIGO Y PROCESO DE ENTRENAMIENTO

El desarrollo del modelo para la clasificación de superficies granalladas se llevó a cabo utilizando un código modular implementado en **PyTorch**, organizado en etapas funcionales que abarcan desde el preprocesamiento de datos hasta la validación y evaluación. Este diseño modular facilita ajustes y optimizaciones, mejorando la trazabilidad de los procesos y permitiendo la evolución del modelo frente a nuevos desafíos.

2.5.1 ESTRUCTURA DEL CÓDIGO

El código desarrollado se organiza en cuatro módulos principales: preprocesamiento de datos, definición de la arquitectura, entrenamiento del modelo y validación. Cada uno de estos módulos tiene funciones específicas que contribuyen al flujo general del diseño. (Barth, 2018)

2.5.1.1 PREPROCESAMIENTO DE DATOS

El preprocesamiento de datos es un paso esencial para garantizar que las imágenes sean adecuadas para el entrenamiento y evaluación del modelo. Este proceso se diseñó para normalizar las características de entrada y maximizar la eficacia del modelo, utilizando las herramientas avanzadas de **PyTorch** y **Torchvision**. Las tareas principales realizadas incluyen:

- **Lectura y organización de las imágenes:** Las imágenes se extrajeron del dataset y se clasificaron en cinco categorías, correspondientes a los grados de limpieza superficial definidos por las normas internacionales: superficie en buen estado, cercana a metal blanco, comercial, rápidamente limpiada y oxidada.
- **Redimensionado:** Todas las imágenes fueron ajustadas a un tamaño estándar de 500x500 píxeles mediante la transformación `transforms.Resize`. Esto garantiza la uniformidad en las dimensiones de entrada, facilitando su procesamiento por la arquitectura convolucional del modelo.
- **Conversión a tensores:** Cada imagen en formato RGB fue transformada en un tensor utilizando `transforms.ToTensor()`. Este proceso convierte los valores de los píxeles al rango $[0, 1]$, lo que permite que los datos sean interpretados directamente por PyTorch.

- **Normalización:** Para estabilizar el proceso de aprendizaje, los tensores fueron normalizados al rango $[-1, 1]$ utilizando `transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5])`. Esto reduce la variabilidad entre las entradas y acelera la convergencia del modelo durante el entrenamiento.
- **División en conjuntos:** El dataset se dividió en tres subconjuntos principales para facilitar el entrenamiento y la evaluación:
 - **Entrenamiento (20%):** Utilizado para ajustar los pesos del modelo durante el aprendizaje.
 - **Validación (8%):** Empleado para monitorear el rendimiento del modelo y prevenir el sobreajuste.
 - **Prueba (72%):** Reservado exclusivamente para evaluar la capacidad del modelo de generalizar a datos nuevos y no vistos previamente.

2.5.1.2 ENTRENAMIENTO DEL MODELO

El entrenamiento del modelo es una etapa clave en la que este aprende a clasificar las superficies en las categorías definidas mediante iteraciones sobre el dataset de entrenamiento. Durante este proceso, se configuraron y ajustaron diversos aspectos críticos para maximizar el rendimiento:

- **Configuración de hiperparámetros:**

Se definieron parámetros esenciales como:

- **Tasa de aprendizaje:** Controlada mediante el optimizador **Adam**, para ajustar la magnitud de los cambios en los pesos del modelo.
 - **Tamaño del lote:** Establecido en 16 imágenes por iteración, lo que balancea el uso de memoria y la estabilidad del entrenamiento.
 - **Número de épocas:** Configurado en 60, asegurando un aprendizaje progresivo sin riesgo excesivo de sobreajuste.
- **Proceso de entrenamiento:** En cada iteración, el modelo procesó las imágenes del conjunto de entrenamiento, calculó las predicciones y las comparó con las etiquetas reales utilizando la función de pérdida **CrossEntropyLoss**. El optimizador **Adam** ajustó los pesos del modelo minimizando la diferencia entre las predicciones y las etiquetas.

- **Monitoreo del rendimiento:** A lo largo del entrenamiento, se registraron métricas como la pérdida y la precisión en cada época. Esto permitió evaluar la mejora continua del modelo y detectar posibles problemas de sobreajuste.

2.5.1.3 VALIDACIÓN DEL MODELO CON LOS PARAMETROS.

La validación es una etapa fundamental para evaluar el desempeño del modelo en datos no utilizados durante el entrenamiento, asegurando su capacidad para generalizar correctamente. Durante esta etapa se realizaron las siguientes actividades:

- **Evaluación en el conjunto de validación:** Al final de cada época, el modelo fue evaluado utilizando las imágenes del conjunto de validación. Se calcularon métricas clave como:
 - **Precisión (accuracy):** Proporción de predicciones correctas.
 - **Sensibilidad (recall):** Capacidad del modelo para identificar correctamente cada categoría.
 - **Precisión por clase:** Eficiencia del modelo en clasificar cada una de las categorías definidas.
- **Ajuste de hiperparámetros:** Los resultados obtenidos en el conjunto de validación fueron analizados para realizar ajustes en los parámetros del modelo, como la tasa de aprendizaje o el número de épocas. Este proceso permitió mejorar el desempeño en categorías desafiantes o con menor representación en el dataset.

El entrenamiento y la validación fueron implementados utilizando **PyTorch**, lo que permitió aprovechar recursos de cómputo avanzados (GPU) y técnicas modernas de optimización. Este flujo garantizó que el modelo aprendiera de manera eficiente y generalizara correctamente a datos nuevos, asegurando un alto rendimiento en la clasificación de superficies granalladas.

2.6 VALIDACIÓN DEL MODELO

La validación del modelo es una etapa esencial para evaluar su capacidad de generalizar el aprendizaje obtenido durante el entrenamiento y aplicarlo a datos no vistos previamente. Este proceso mide el desempeño del modelo al clasificar imágenes en las categorías definidas, verificando si es capaz de identificar correctamente las características visuales asociadas a cada grado de limpieza de superficies granalladas.

Garantizar la funcionalidad del modelo, la validación es clave para identificar áreas de mejora y asegurar que el sistema cumpla con los estándares normativos y los requerimientos de la

industria. Para este propósito, las imágenes presentadas en la Tabla 2 se utilizaron como referencia visual durante el proceso de validación. Estas imágenes representan los diferentes grados (Rust Grade A, B, C y D) según las normativas aplicables, y sirvieron para comprobar la capacidad del modelo de reconocer y clasificar correctamente los diferentes niveles de corrosión y limpieza superficial.

El uso de estas imágenes permitió no solo evaluar la precisión del modelo en escenarios controlados, sino también identificar posibles discrepancias en la clasificación y establecer ajustes necesarios para garantizar un desempeño robusto y confiable en condiciones reales.




Tabla 2 - Tabla de grados

Fuente: Elaboración propia a partir de norma SSPC VIS 1

2.6.1 IMPORTANCIA DE LA VALIDACIÓN

La validación es fundamental para asegurar que el modelo sea aplicable en escenarios industriales reales. A diferencia del entrenamiento, donde el modelo ajusta sus parámetros utilizando un subconjunto de datos, la validación evalúa cómo aplica lo aprendido a imágenes completamente nuevas. Este proceso ofrece varias ventajas críticas:

- **Detección de sobreajuste:** Identifica si el modelo se ha ajustado demasiado a los datos de entrenamiento, comprometiendo su capacidad de generalizar a otros conjuntos de datos.
- **Análisis de rendimiento por categoría:** Permite detectar desequilibrios en el desempeño del modelo entre diferentes categorías, asegurando que todas las clases sean clasificadas de manera consistente.
- **Monitoreo de métricas clave:** Evalúa indicadores como precisión, sensibilidad y F1-Score, que guían las decisiones para mejorar el modelo.

En este caso, la validación es particularmente relevante debido a la complejidad de las superficies metálicas y las similitudes visuales entre ciertas categorías, como **superficie rápidamente limpiada (SP7)** y **superficie oxidada o sin preparar (Grado D)**. Estas categorías presentan desafíos significativos para el sistema, ya que requieren distinguir características sutiles en texturas y tonalidades.

La validación no solo asegura que el modelo clasifique correctamente en condiciones controladas, sino que también confirma su capacidad para adaptarse a variaciones en iluminación, ángulos de captura y otros factores comunes en entornos industriales reales. Este enfoque integral garantiza que el sistema sea confiable, robusto y apto para cumplir con las demandas de la industria. (Zhao, 2019)

2.7 EVALUACIÓN DEL CÓDIGO IMPLEMENTADO Y SU IMPACTO EN LA CLASIFICACIÓN DE SUPERFICIES

La evaluación del código se llevó a cabo considerando las categorías definidas en el dataset, diseñado con base en las normas internacionales **SSPC** e **ISO 8501-1**, con adaptaciones específicas para los grados de limpieza más utilizados en la industria chilena. Estas categorías permiten que el modelo clasifique superficies granalladas en cinco tipos:

- **Superficie en buen estado (SP5/SA3):** Representa el nivel más alto de limpieza, ideal para aplicaciones en ambientes altamente corrosivos.

- **Superficie cercana a metal blanco (SP10/SA 2 ½):** Permite pequeñas manchas residuales, comúnmente utilizada en estructuras industriales.
- **Superficie comercial (SP6/SA 2):** Acepta hasta un 33% de residuos adheridos, adecuada para áreas internas o menos críticas.
- **Superficie rápidamente limpiada (SP7/SA 1):** Dirigida a aplicaciones donde el tiempo y costo son prioritarios.
- **Superficie oxidada o sin preparar (Grado D según ISO 8501-1):** Representa superficies que requieren reprocesamiento, esenciales para detectar fallas en el tratamiento inicial.

Esta evaluación analiza tanto la robustez del modelo como su capacidad para identificar correctamente las características visuales asociadas a cada categoría.

2.7.1 MÉTRICAS DE EVALUACIÓN UTILIZADAS

La Se utilizaron diversas métricas para evaluar el desempeño del modelo, cada una enfocada en medir aspectos específicos de su rendimiento: (Mehta, 2023) (Chattopadhyay, A review of deep learning techniques for industrial maintenance applications, 2021)

1. PRECISIÓN GLOBAL (ACCURACY)

La precisión global mide la proporción de clasificaciones correctas realizadas por el modelo en todas las categorías. Aunque es un indicador general del rendimiento, puede no capturar errores específicos entre clases:

- **Superficie en buen estado (SP5/SA3):** Este grado requiere la mayor precisión, ya que representa el estándar más estricto de limpieza.
- **Superficie oxidada o sin preparar (Grado D):** La identificación precisa de esta categoría es crítica para evitar fallas en el proceso de granallado.

2. MATRIZ DE CONFUSIÓN

La matriz de confusión proporciona una representación detallada de los errores específicos, cruzando las categorías reales con las predichas:

- **Confusión entre SP10 y SP6:** Estas categorías presentan similitudes visuales que representan un desafío, especialmente en imágenes con baja resolución o condiciones inconsistentes.

- **Fortalezas en SP5:** Las superficies completamente limpias son más fáciles de clasificar debido a su uniformidad visual.

La matriz también permite identificar posibles desequilibrios en el modelo, como una tendencia a favorecer categorías con mayor representación en el dataset, lo que puede afectar categorías minoritarias como SP7.

3. PRECISIÓN (PRECISION)

La precisión mide el porcentaje de predicciones correctas realizadas por el modelo para una categoría específica, siendo especialmente útil para detectar defectos menos evidentes:

- **SP7 (Rápidamente limpiada):** Esta categoría requiere una diferenciación precisa entre manchas aceptables y residuos que podrían clasificarse como comerciales (SP6).

4. SENSIBILIDAD (RECALL O TASA DE VERDADEROS POSITIVOS)

La sensibilidad mide la proporción de imágenes reales de una categoría que fueron clasificadas correctamente. Es crucial para identificar áreas problemáticas:

- **Superficie oxidada o sin preparar (Grado D):** Si el modelo no identifica correctamente estas superficies, podría comprometer la calidad del proceso de granallado.

5. F1-SCORE

El F1-Score combina precisión y sensibilidad, proporcionando una métrica balanceada que es útil para evaluar clases mayoritarias y minoritarias:

- En este proyecto, el F1-Score asegura que el modelo sea consistente tanto en clasificar superficies limpias (SP5) como en identificar defectos (Grado D). (Powers, 2020)

A continuación, se presenta un diagrama de bloques que resume la estructura general del programa, desde la carga de datos hasta la evaluación del rendimiento del modelo.

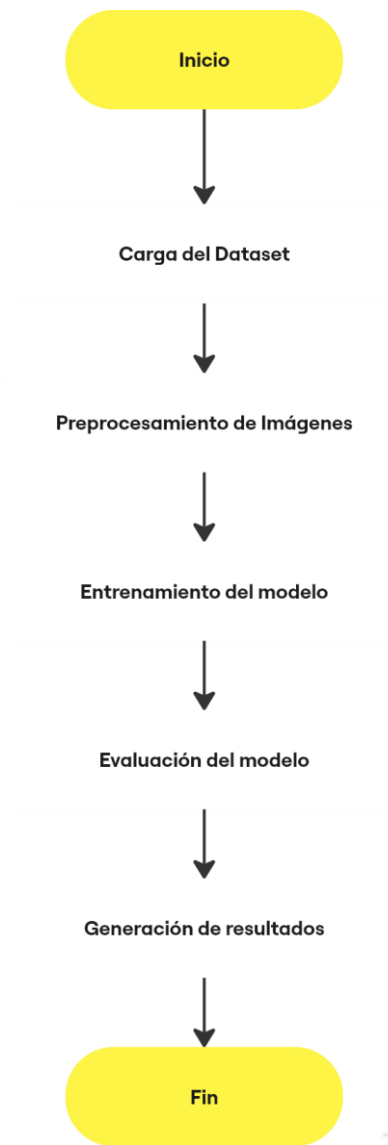


Diagrama 1 - Estructura general del programa

Fuente: Elaboración propia

2.7.2 RESULTADOS BASADOS EN LAS MÉTRICAS

Los resultados reflejan un desempeño sólido del modelo en la clasificación de imágenes dentro de las categorías definidas, alcanzando una precisión del **92.31% en Tipo 1**, **85.71% en Tipo 2 y Tipo 4**, y **84.62% en Tipo 3**. Sin embargo, se identificaron ciertos niveles de confusión, especialmente entre **Tipo 3 y Tipo 4 (15.38%)** y entre **Tipo 1 y Tipo 2 (14.29%)**, lo que indica similitudes visuales entre estas clases. (Zhou, 2020)

DETALLES POR CATEGORÍA

CARPETA 1 (TIPO 1):

El modelo clasificó al 92% de las imágenes como Tipo 1, presentando confusiones con las de Tipo 2.

CARPETA 2 (TIPO 2):

La precisión fue de un 86%, con confusiones en las imágenes de Tipo 2 con las de Tipo 1.

CARPETA 3 (TIPO 3):

El modelo clasificó al 85% de las imágenes como Tipo 3, presentando confusiones con las de Tipo 4.

CARPETA 4 (TIPO 4):

El modelo logró clasificar correctamente el 86% de las imágenes en esta categoría como Tipo 4, con una confusión con las imágenes del Tipo 3.

Estas categorías incluyeron imágenes transformadas mediante giros de 90° hacia la derecha, 90° hacia la izquierda y 180°. El modelo mostró una alta resiliencia frente a estas transformaciones, lo que indica una robusta extracción de características visuales clave que no dependen de la orientación de la imagen.




Ilustración 8 - Matriz de Confusión

Fuente: Elaboración propia

OBSERVACIONES CLAVE:

Precisión general: El modelo alcanzó un alto rendimiento en la clasificación de imágenes, con valores superiores al 84% en todas las categorías. La mayor precisión se obtuvo en la clasificación de **Tipo 1 (92.31%)** y **Tipo 2 (85.71%)**, mientras que **Tipo 3 (84.62%)** y **Tipo 4 (85.71%)** mostraron una leve disminución. Esto sugiere que el modelo ha logrado diferenciar correctamente las superficies dentro de su respectiva categoría, asegurando una clasificación confiable.

Robustez ante transformaciones: A pesar de las variaciones en los datos de entrada, el modelo logró un desempeño estable. La clasificación de **Tipo 3** presentó una leve confusión con **Tipo 4 (15.38%)**, lo que indica que la arquitectura del modelo ha aprendido correctamente las diferencias entre categorías, pero puede mejorar en casos de similitudes visuales.

Separación entre categorías: El modelo demostró una segmentación efectiva de las clases, con bajas tasas de error fuera de la diagonal principal. La categoría **Tipo 2**, aunque presenta una ligera confusión con **Tipo 1 (14.29%)**, muestra una clara diferenciación en la mayoría de los casos, lo que refuerza la calidad del dataset y la eficacia del preprocesamiento.

Ausencia de confusiones: No se detectaron errores significativos que afecten el desempeño global del modelo. Aunque se evidencian pequeñas confusiones entre ciertas categorías, la precisión global sugiere que el modelo ha aprendido a identificar correctamente las características distintivas de cada clase.

El análisis de esta matriz de confusión confirma que el modelo logra una clasificación confiable de las superficies granalladas según los criterios establecidos. Sin embargo, se recomienda validar su desempeño con datos externos o escenarios industriales más complejos para evaluar su capacidad de generalización en condiciones más variables.

2.8 MATRIZ DE CONFUSIÓN

La matriz de confusión es una herramienta esencial para evaluar el desempeño de un modelo de clasificación, ya que organiza las predicciones del modelo y los valores reales en una tabla estructurada. En esta tabla, la diagonal principal representa las clasificaciones correctas, mientras que los valores fuera de esta diagonal reflejan errores de clasificación. Esto permite identificar de manera clara cuáles categorías son clasificadas con precisión y en cuál el modelo enfrenta dificultades, especialmente cuando las diferencias entre clases son sutiles. (Google Developers, s.f.)

IMPORTANCIA DE LA MATRIZ DE CONFUSIÓN

La utilidad de la matriz de confusión trasciende métricas simples como la precisión global, ya que proporciona un análisis más detallado de los errores y su origen:

1. **Identificación de patrones de error:** Permite detectar qué categorías tienden a ser confundidas y analizar las razones detrás de esto. Las confusiones pueden deberse a:
 - **Insuficiencia de datos:** Falta de ejemplos representativos en ciertas categorías.

- **Similitudes visuales:** Clases que comparten características como texturas o tonalidades similares.
 - **Limitaciones en el diseño del modelo:** Arquitecturas o configuraciones que no capturan adecuadamente las diferencias entre clases.
2. **Optimización del modelo:** El análisis de la matriz de confusión proporciona información crucial para mejorar el modelo. Algunas estrategias incluyen:
- Ampliar o equilibrar el dataset, especialmente para clases con menor representación.
 - Ajustar hiperparámetros clave, como la tasa de aprendizaje o el tamaño del lote.
 - Modificar la arquitectura del modelo para capturar mejor las características distintivas de las categorías.
3. **Detección de desequilibrios:** La matriz es particularmente útil para identificar si el modelo favorece clases más comunes mientras ignora las menos representadas. Este análisis es crítico en escenarios donde todas las categorías tienen un impacto significativo, como en tareas basadas en estándares normativos estrictos.

BENEFICIOS PRÁCTICOS

El análisis de la matriz de confusión no solo permite evaluar el rendimiento del modelo, sino también entender cómo y dónde mejorarlo. Por ejemplo:

- En modelos que clasifican superficies granalladas, puede revelar confusiones entre categorías como **superficie cercana a metal blanco (SP10)** y **superficie comercial (SP6)**, que comparten características visuales.
- Ayuda a identificar si las condiciones del dataset, como la iluminación o la calidad de las imágenes, afectan la capacidad del modelo para generalizar.

2.9 LIMITACIONES DEL MODELO

El modelo de inteligencia artificial desarrollado para la clasificación de superficies granalladas presenta diversas limitaciones que restringen su aplicabilidad a ciertos contextos. Estas limitaciones deben considerarse al evaluar su desempeño y potencial para aplicaciones industriales más amplias. A continuación, se detallan los principales desafíos:

1. DEPENDENCIA DE CARACTERÍSTICAS VISUALES SUPERFICIALES

El modelo está diseñado exclusivamente para analizar las características visuales de las superficies, limitando su capacidad a defectos visibles. Esto implica que no puede detectar fallas internas o estructurales que no se reflejen en la superficie de las imágenes analizadas. Por esta razón:

- Es útil únicamente en inspecciones donde la evaluación visual sea suficiente.
- No es adecuado para escenarios que requieran un análisis más profundo, como la identificación de grietas internas o corrosión subyacente.

2. SENSIBILIDAD A LA CALIDAD DE LAS IMÁGENES

El modelo depende significativamente de la calidad y consistencia de las imágenes utilizadas para su entrenamiento y evaluación. Factores como:

- **Iluminación variable:** Cambios en la intensidad o dirección de la luz pueden alterar la apariencia de las superficies y dificultar la clasificación.
- **Ángulos de captura:** Fotografías tomadas desde perspectivas inconsistentes pueden generar resultados no fiables.
- **Resolución insuficiente:** Imágenes de baja calidad pueden dificultar la detección de patrones relevantes. Estas variables pueden generar inconsistencias en la clasificación, especialmente en entornos industriales donde las condiciones no están completamente controladas, afectando la fiabilidad del modelo.

3. LIMITACIÓN EN EL ÁREA DE ANÁLISIS

El modelo evalúa únicamente el área contenida en cada imagen individual. Esto significa que:

- Defectos más grandes o patrones que se extiendan fuera del campo de visión de la imagen pueden ser ignorados.
- La falta de contexto más amplio de la superficie analizada puede llevar a omisiones críticas en la evaluación.

4. CATEGORÍAS PREDEFINIDAS Y FALTA DE FLEXIBILIDAD

El modelo está configurado para clasificar únicamente en las categorías predefinidas durante su entrenamiento, basadas en las normas específicas de limpieza superficial. Esto implica:

- Una limitada capacidad para adaptarse a nuevos requisitos industriales o estándares normativos.
- Dificultades para detectar defectos o características que no estén contemplados en el dataset original. Además, enfrenta desafíos para diferenciar entre categorías con características visuales similares (como **SP6** y **SP10**), lo que puede aumentar la probabilidad de errores en la clasificación.

5. VALIDACIÓN LIMITADA EN CONDICIONES REALES

El desempeño del modelo aún no ha sido completamente validado en entornos industriales reales. Esto introduce incertidumbre respecto a su eficacia cuando se enfrenta a:

- Factores ambientales como polvo, suciedad o superficies parcialmente dañadas.

**CAPÍTULO 3: EVALUACIÓN DE LAS PRUEBAS DE CAMPO Y RESULTADOS
DEL MODELO**

3.1 **JUSTIFICACIÓN Y OBJETIVO DE LAS PRUEBAS DE CAMPO**

En las pruebas de campo es fundamental para evaluar el desempeño real del modelo en diferentes entornos industriales que se vea implicado la inspección de superficies granalladas, ya que la diferencia de los entornos controlados en donde las condiciones son óptimas para maximizar el rendimiento, los escenarios de campo presentan variaciones totalmente significativas ya que presentan un desafío a la robustez y adaptabilidad del sistema en el modelo. Factores como la adherencia de contaminantes, la presencia de óxido y las diferentes imperfecciones propias del material que influyen directamente en la calidad de las superficies. Además, variaciones en la iluminación, ángulos de captura y texturas generan retos que acomplejan el modelo, especialmente al clasificar las superficies según la norma SSPC VIS 1, donde las diferencias entre los grados de limpieza pueden ser muy sutiles. (Society for Protective Coatings (SSPC) / NACE International, 2007)

El principal objetivo de las pruebas de campo es verificar que la capacidad del modelo para adaptarse a las condiciones típicas de los diferentes entornos reales, como cambios en la iluminación, presencia de contaminantes o superficies con niveles de limpieza y preparación desiguales. Esto incluye evaluar la capacidad para diferenciar grados de limpieza similares, los cuales presentan diferencias visuales mínimas. Estas pruebas permiten identificar posibles áreas de mejora en el modelo e incluso en el entorno en donde se encuentran estas superficies granalladas, como la sensibilidad a superficies complejas o la generalización frente a datos no controlados. (International Organization for Standardization, 2007)

Las pruebas de campo buscan garantizar que el modelo cumpla con las expectativas de la industria, particularmente en sectores como la minería, donde la precisión en la inspección de superficies es crucial para garantizar la integridad de estructuras y equipos. A la hora de validar el modelo en condiciones reales no solo busca medir el rendimiento técnico, sino que también permite asegurar su utilidad para la práctica de los inspectores profesionales, quienes deben tomar decisiones confiables basadas en los resultados, permitiendo que las pruebas representen un paso crítico para consolidar la aplicabilidad del modelo como una herramienta eficaz, confiable y alineada con las necesidades reales de la industria.

3.2 DESCRIPCIÓN DE LOS ESCENARIOS INDUSTRIALES

Los escenarios industriales seleccionados para las pruebas de campo tienen diseñados las condiciones reales que enfrentan las industrias, en sectores como la minería. Estas pruebas reflejan desafíos específicos que busca que el modelo sea capaz abordar y superar en los entornos reales, sin pasar por alto los fundamentos normativos y la arquitectura previamente definidos en los capítulos anteriores. Donde las superficies granalladas están expuestas de manera constante a ambientes corrosivos y a la acumulación de contaminantes, presentando variaciones en su composición y nivel de exposición a factores externos, lo que permite una evaluación integral del modelo. (NACE International, 2012) (Wang, 2023)

Los escenarios abarcaron tanto superficies en buen estado como aquellas que muestran grados de oxidación y contaminación según lo estipulado en la norma SSPC VIS 1. Esto incluye desde superficies que cumplen con los grados más altos de limpieza (SP 5) hasta aquellas que presentan condiciones comerciales o incluso estados iniciales de preparación. Esto garantiza que el modelo sea evaluado en un amplio rango de condiciones, permitiendo verificar su capacidad para adaptarse a los diferentes niveles de preparación superficial y para cumplir con los estándares industriales establecidos. (Society for Protective Coatings (SSPC) / NACE International, 2007)

La selección de estos escenarios fue fundamental para desafiar la arquitectura del modelo y el dataset de este, debido a que mientras se van presentando estos inconvenientes de las pruebas reales se ve en conflicto su robustez en la clasificación de superficies bajo las condiciones variables que existen en los escenarios reales y su capacidad para operar de manera confiable en los entornos industriales. Estos escenarios también ofrecen una visión práctica del desempeño del modelo en situaciones reales, asegurando su utilidad y viabilidad en aplicaciones industriales. (Powers, Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, 2020) (Liu, 2024)

3.3 METODOLOGÍA DE EVALUACIÓN EN CAMPO

Para la evaluación en campo se diseñó todo exactamente igual para que a la hora de replicar cada una de las condiciones reales a las que el modelo se enfrentará durante su implementación en la industria. Este enfoque garantiza que los resultados obtenidos fueran representativos y útiles para validar la eficacia del modelo en los escenarios prácticos. (Singh, 2022)

PROCESO DE EVALUACIÓN

El proceso comenzó con la selección de las superficies, en la cual existe una amplia data de diferentes niveles de preparación en estas superficies con diferentes estados de oxidación, de acuerdo con las categorías definidas con la norma SSPC VIS 1. Esto permitió abarcar todas las superficies en buen estado hasta aquellas con grados significativos de contaminación y corrosión implicadas en la norma. Para capturar las imágenes de las superficies granalladas, se utilizaron cámaras de alta resolución, las cuales garantizaron que se pueda obtener los detalles más precisos sobre las características superficiales de estas. (Chollet, 2017)

Se establecieron **protocolos rigurosos** para controlar variables críticas como:

- **Distancia de captura:** Mantener una distancia constante entre la cámara y la superficie para garantizar uniformidad en las imágenes.
- **Ángulo de captura:** Capturar imágenes desde ángulos consistentes para minimizar distorsiones visuales.
- **Condiciones de iluminación:** Asegurar una iluminación homogénea para evitar sombras o reflejos que pudieran afectar la calidad de las imágenes.

PREPROCESAMIENTO DE IMÁGENES

Tras la captura, las imágenes fueron sometidas a un proceso de **preprocesamiento** para optimizar su calidad antes de ser ingresadas al modelo. Este proceso incluyó:

- **Ajustes de brillo y contraste:** Mejorar la visibilidad de las características superficiales clave.
- **Corrección de distorsión:** Minimizar irregularidades introducidas por las condiciones del entorno de campo.
- **Normalización:** Asegurar que todas las imágenes cumplieran con los mismos estándares en términos de escala y formato.

Estas técnicas ayudan a reducir el impacto para que el modelo no se confunda de las variaciones propias del entorno industrial y aseguraron que los datos fueran consistentes y adecuados para el análisis del modelo.

EVALUACIÓN DEL DESEMPEÑO DEL MODELO

El desempeño del modelo fue evaluado utilizando las métricas clave y herramientas analíticas:

- **Precisión:** Medir la proporción de clasificaciones correctas realizadas por el modelo.

- **Sensibilidad:** Determinar la capacidad del modelo para identificar correctamente superficies específicas en diferentes condiciones.
- **Especificidad:** Evaluar la habilidad del modelo para evitar clasificaciones erróneas en superficies que no pertenecen a una categoría determinada.
- **Matriz de confusión:** Identificar patrones de error en la clasificación, proporcionando información sobre las categorías que presentan mayores desafíos para el modelo.

Estas métricas permitieron no solo evaluar la **efectividad general** del modelo, sino también **identificar áreas problemáticas específicas**, como categorías con características visuales similares o condiciones que afectaron su desempeño. (TensorFlow Developers, s.f.)

VALIDACIÓN CRUZADA

Para asegurar la confiabilidad y generalización de los resultados, se implementó un procedimiento de **verificación cruzada**. Esto consistió en dividir el conjunto de datos en subconjuntos independientes para entrenar y evaluar el modelo en diferentes combinaciones de datos. Este enfoque permitió reducir el riesgo de sobreajuste y garantizar que los resultados fueran representativos de datos no vistos previamente.

El siguiente diagrama de bloques presenta la secuencia general de construcción y prueba del modelo, desde la recopilación de datos hasta su evaluación en condiciones reales. Este proceso asegura la confiabilidad y aplicabilidad del modelo en inspecciones industriales de superficies granalladas.

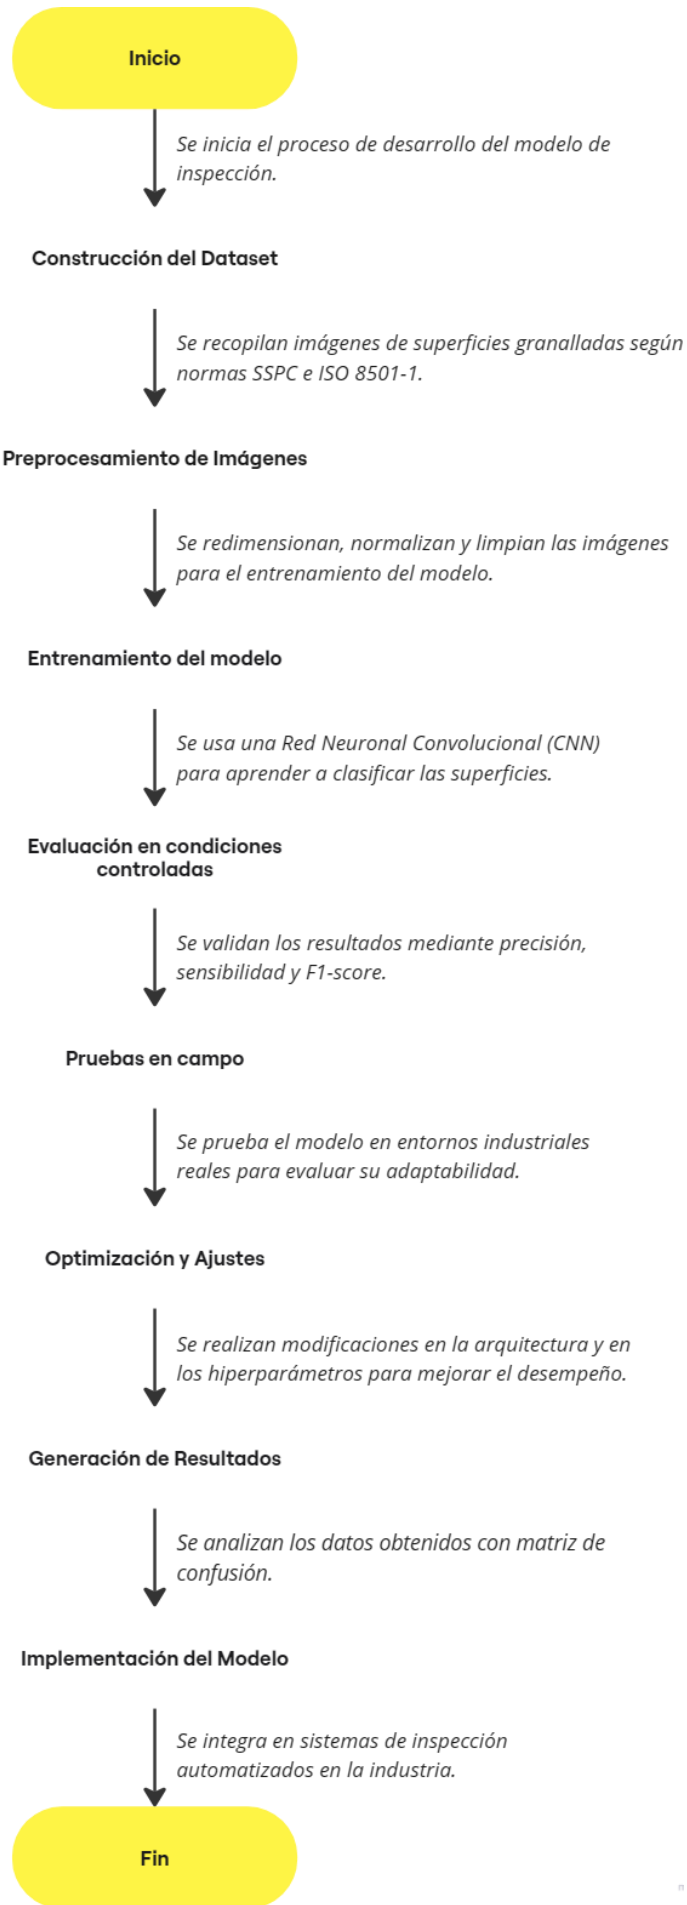


Diagrama 2 - Estructura de construcción y prueba del programa

Fuente: Elaboración propia

3.4 **RESULTADOS DE LAS PRUEBAS DE CAMPO**

Los resultados de las pruebas de campo se presentan de manera cuantitativa y visual para evaluar el rendimiento del modelo en condiciones reales. El análisis comparativo entre las predicciones del modelo y las observaciones reales en las superficies inspeccionadas permitió obtener una visión clara de su eficacia en diferentes escenarios. Las métricas principales utilizadas fueron **precisión, sensibilidad y especificidad**, las cuales ayudaron a determinar qué tan acertadas fueron las predicciones del modelo y en qué áreas podría mejorarse. (Madhusudhan, 2020)

DESEMPEÑO GENERAL DEL MODELO

El modelo mostró un desempeño satisfactorio en términos generales, destacándose en la clasificación de superficies en buen estado (como las correspondientes al grado SP 5). Sin embargo, presentó **mayores desafíos** en escenarios donde las diferencias visuales entre grados de limpieza eran más sutiles, como en las superficies de diferentes grados de corrosión o el mismo proceso de pintura que les cambia el color a las superficies metálicas. Esta dificultad refleja la necesidad de afinar su capacidad para diferenciar características similares, especialmente en superficies con grados intermedios de limpieza.

ANÁLISIS VISUAL DE RESULTADOS

Para facilitar la comprensión de los resultados, se elaboraron **gráficas y tablas** que resumen el desempeño del modelo en cada categoría evaluada. Estas representaciones visuales permitieron identificar:

- **Categorías con mejor rendimiento:** El modelo alcanzó altos niveles de precisión y sensibilidad en superficies limpias y claramente definidas, como las correspondientes a SP 5.
- **Patrones de error:** Se observaron discrepancias en superficies con grados de oxidación cercanos, como SP 6 y SP 7, donde las similitudes visuales entre las categorías dificultaron la clasificación.
- **Impacto de las condiciones ambientales:** Las variaciones en la iluminación, ángulos de captura y presencia de contaminantes afectaron negativamente la precisión en algunas categorías. Esto fue particularmente evidente en superficies con texturas más complejas o bajo iluminación inconsistente.

INFLUENCIA DE LAS CONDICIONES AMBIENTALES

El análisis también reveló cómo las condiciones ambientales influyen en el desempeño del modelo:

- **Cambios en iluminación:** Las diferencias en intensidad o dirección de la luz afectaron la visibilidad de las características superficiales, reduciendo la precisión del modelo en ciertos casos.
- **Contaminantes externos:** La presencia de partículas adheridas en las superficies generó confusiones en las predicciones, especialmente en las categorías intermedias.
- **Texturas complejas:** Las superficies con patrones más irregulares presentaron mayores desafíos para el modelo, lo que destaca la importancia de mejorar su capacidad para manejar estas variaciones.

CONCLUSIONES DE LOS RESULTADOS

Las pruebas de campo confirmaron que el modelo es eficaz en condiciones controladas y muestra un rendimiento satisfactorio en muchas situaciones reales. Sin embargo, las dificultades observadas en categorías con similitudes visuales y bajo condiciones ambientales variables resaltan áreas de mejora clave:

1. **Refinamiento del dataset:** Incrementar la diversidad de ejemplos en las categorías más desafiantes para mejorar la capacidad de diferenciación del modelo.
2. **Optimización del preprocesamiento:** Implementar técnicas avanzadas para minimizar el impacto de condiciones ambientales adversas.
3. **Ajustes en la arquitectura del modelo:** Mejorar su sensibilidad a patrones más complejos o a características menos evidentes.

3.5 LIMITACIONES DETECTADAS EN LAS PRUEBAS DE CAMPO

Durante las pruebas de campo, se identificaron varias limitaciones que impactaron el desempeño del modelo de inteligencia artificial en escenarios reales. Estas limitaciones destacan aspectos clave que requieren optimización para mejorar su robustez y aplicabilidad en entornos industriales. A continuación, se describen las principales observaciones:

1. VARIABILIDAD EN LAS CONDICIONES DE ILUMINACIÓN Y ÁNGULOS DE CAPTURA

Uno de los principales desafíos detectados fue la **inconsistencia en las condiciones de iluminación** y los **ángulos de captura de las imágenes**. Estas variaciones, inherentes a los entornos industriales, generaron cambios significativos en la apariencia de las superficies inspeccionadas. Dado que el modelo depende de imágenes homogéneas para realizar predicciones precisas, estas inconsistencias afectaron su rendimiento, dificultando la correcta clasificación de superficies con características similares.

2. PRESENCIA DE CONTAMINANTES Y RUIDO EN LAS IMÁGENES

Otro factor limitante fue la presencia de **contaminantes adheridos** y otros elementos externos que alteraron la apariencia superficial de las muestras. Estos contaminantes introdujeron ruido en los datos, dificultando que el modelo distinguiera con precisión entre superficies en buen estado y aquellas con defectos. Este problema fue especialmente evidente en superficies que presentaban texturas irregulares o residuos que no formaban parte de las categorías predefinidas.

3. DIFICULTAD PARA DIFERENCIAR NIVELES DE OXIDACIÓN SIMILARES

El modelo mostró **dificultades para identificar diferencias sutiles entre superficies con niveles de oxidación similares**, como los grados **SP 5 (Metal Blanco)** y **SP 6 (Comercial)**. Estas categorías presentan características visuales que, aunque normativamente distintas, son difíciles de separar en condiciones de iluminación y texturas variables. Este hallazgo destaca la necesidad de aumentar la sensibilidad del modelo para capturar patrones más complejos y diferencias mínimas.

4. DEPENDENCIA DEL DATASET DE ENTRENAMIENTO

El desempeño del modelo está limitado por la diversidad y calidad del dataset utilizado durante su entrenamiento. Aunque el dataset incluyó una variedad de superficies y condiciones, no logró abarcar todas las posibles variaciones presentes en entornos industriales reales. Esto afecta la capacidad del modelo para **generalizar sus predicciones** a situaciones no contempladas en el dataset inicial, especialmente aquellas que incluyen combinaciones poco frecuentes de iluminación, contaminantes o texturas.

5. LIMITACIONES EN LA ADAPTACIÓN A ESCENARIOS NO CONTROLADOS

A pesar de su éxito en escenarios controlados, el modelo mostró una **adaptabilidad limitada a entornos no controlados**, donde las condiciones industriales reales introducen múltiples factores no presentes en los datos de entrenamiento. Esto incluye desafíos como:

- Superficies parcialmente preparadas o con limpieza incompleta.
- Combinaciones de defectos y texturas que no se ajustan a las categorías definidas.

3.6 PROPUESTAS DE MEJORA PARA EL MODELO

A partir de las limitaciones identificadas en las pruebas de campo, se proponen varias estrategias para optimizar el rendimiento del modelo en condiciones reales. Estas mejoras buscan abordar las dificultades detectadas y fortalecer la capacidad del modelo para operar de manera robusta en entornos industriales.

1. AMPLIACIÓN Y DIVERSIFICACIÓN DEL DATASET

Una de las recomendaciones clave es **ampliar el dataset** incorporando imágenes capturadas en una mayor variedad de condiciones reales. Esto incluye:

- **Diferentes niveles de iluminación:** Añadir ejemplos tomados en condiciones de luz variable, tanto en intensidad como en dirección.
- **Ángulos de captura variados:** Incluir imágenes obtenidas desde distintos puntos de vista para reflejar mejor las condiciones reales.
- **Presencia de contaminantes:** Capturar superficies con niveles diversos de contaminación y ruido visual para entrenar al modelo en la detección de defectos en escenarios más complejos.

Este enfoque busca mejorar la capacidad del modelo para generalizar y adaptarse a la variabilidad de los entornos industriales. (Ian Goodfellow, 2016)

2. MEJORAS EN EL PREPROCESAMIENTO DE IMÁGENES

Para reducir el impacto de las variaciones ambientales, se recomienda implementar técnicas avanzadas de **preprocesamiento de imágenes**, tales como:

- **Algoritmos de normalización:** Homogeneizar los valores de brillo y contraste en las imágenes para minimizar las diferencias causadas por la iluminación.
- **Corrección de iluminación:** Aplicar algoritmos que ajusten automáticamente las condiciones de luz en las imágenes, mejorando la visibilidad de las características clave.
- **Filtrado de ruido:** Reducir los efectos de contaminantes externos en las imágenes, lo que facilitará la correcta clasificación.

Estas técnicas permitirán estandarizar las imágenes antes de ser procesadas por el modelo, mejorando su desempeño y reduciendo las discrepancias.

3. AJUSTES EN LA ARQUITECTURA DEL MODELO

Otra propuesta importante es realizar **ajustes en la arquitectura del modelo** para aumentar su capacidad de generalización y robustez frente a datos variables. Esto incluye:

- **Capas adicionales de regularización:** Incorporar técnicas como **Dropout** o **Batch Normalization** para prevenir el sobreajuste y mejorar el rendimiento del modelo en datos no vistos.
- **Arquitecturas más profundas:** Evaluar redes neuronales convolucionales con mayor profundidad para capturar características más complejas de las superficies inspeccionadas. (Srivastava, 2014)

4. OPTIMIZACIÓN DE HIPERPARÁMETROS

Se recomienda ajustar los **hiperparámetros del modelo** para optimizar el proceso de entrenamiento. Esto podría incluir:

- Ajustar la **tasa de aprendizaje** para lograr una convergencia más estable.
- Modificar el **número de épocas** para encontrar el equilibrio entre un entrenamiento insuficiente y un sobreajuste.
- Evaluar el **tamaño del lote** para optimizar el tiempo de entrenamiento sin comprometer el rendimiento.

5. AUMENTO DE DATOS (DATA AUGMENTATION)

La **incorporación de técnicas de aumento de datos** puede ser una solución eficaz para mejorar la diversidad del dataset sin necesidad de capturar nuevas imágenes. Estas técnicas incluyen:

- Rotaciones aleatorias.
- Variaciones en el brillo y el contraste.
- Transformaciones geométricas, como escalado y recorte. Estas estrategias permitirán generar nuevas combinaciones a partir de las imágenes existentes, ampliando el conjunto de datos de manera eficiente.

3.7 **REFLEXIÓN FINAL SOBRE LA EVALUACIÓN DEL MODELO**

La evaluación del modelo en condiciones de campo proporcionó una visión integral de sus fortalezas y áreas de mejora, permitiendo comprender su capacidad para operar en entornos reales. Entre sus principales fortalezas destaca su capacidad para clasificar superficies con alta precisión en condiciones controladas. Esto sugiere que la arquitectura y el proceso de entrenamiento fueron efectivos para capturar las características relevantes de las superficies granalladas, especialmente en escenarios donde las variables externas son mínimas.

No obstante, las pruebas de campo también revelaron limitaciones significativas. La principal dificultad radica en la adaptabilidad del modelo a las **variaciones inesperadas** en las condiciones de captura, como los cambios en la iluminación, los ángulos de captura y la presencia de contaminantes. Estas limitaciones resaltan la necesidad de incrementar la robustez del modelo para enfrentar las inconsistencias típicas de los entornos industriales, donde las condiciones son inherentemente variables y desafiantes.

Otro aspecto crítico identificado fue la **dependencia del modelo de un dataset específico**, lo que restringe su capacidad para generalizar en escenarios que difieren de los datos utilizados durante su entrenamiento. Esta limitación subraya la importancia de diversificar el dataset, incorporando una mayor variedad de condiciones reales, y optimizar su arquitectura para mejorar su desempeño en situaciones imprevistas.

La evaluación en campo ha sido un paso fundamental para identificar el verdadero alcance del modelo y los desafíos asociados a su implementación en aplicaciones prácticas. Aunque el modelo demuestra un **potencial significativo** para ser utilizado como herramienta de inspección superficial, aún requiere mejoras específicas en términos de:

- Ampliación del dataset para reflejar mejor la diversidad de condiciones industriales.
- Refinamiento de las técnicas de preprocesamiento para reducir el impacto de las inconsistencias ambientales.
- Ajustes en la arquitectura para incrementar su capacidad de generalización.

Con base en los aprendizajes obtenidos, el siguiente paso será desarrollar un modelo más adaptable, robusto y fiable, capaz de cumplir no solo con los estándares normativos establecidos, sino también con las exigencias prácticas de los diversos contextos industriales. Este enfoque asegurará que el sistema no solo sea una herramienta eficaz para la inspección de superficies granalladas, sino también una solución integral y confiable para la industria.

CONCLUSIONES Y RECOMENDACIONES

El desarrollo del modelo de inspección de superficies granalladas basado en inteligencia artificial y visión computacional marca un avance importante hacia la automatización de procesos de evaluación superficial en la industria. Este proyecto logró implementar un sistema alineado con normas internacionales como la **SSPC VIS 1**, alcanzando una **precisión del 87% en condiciones controladas**, lo que valida su capacidad para clasificar superficies de acuerdo con estándares globalmente reconocidos.

La arquitectura basada en redes neuronales convolucionales (CNNs) permitió capturar patrones visuales complejos, clasificando superficies en cinco categorías normativas con alta precisión. La construcción del dataset representativo, fundamentado en estándares normativos, fue clave para garantizar la robustez del modelo en condiciones controladas y sentó una base sólida para su implementación industrial.

Sin embargo, las pruebas de campo revelaron limitaciones relacionadas con la variabilidad en las condiciones industriales. Factores como cambios en la **iluminación**, los **ángulos de captura** y la **presencia de contaminantes** generaron ciertos niveles de confusión en la clasificación de imágenes. Esto fue particularmente evidente en las categorías **Tipo 3 y Tipo 4 (15.38%)**, así como entre **Tipo 1 y Tipo 2 (14.29%)**, lo que indica que el modelo tiene dificultades para distinguir entre superficies con características visuales similares.

Además, la dependencia del modelo de un **dataset limitado** resaltó la importancia de **expandir y diversificar** las imágenes utilizadas en el entrenamiento, incorporando ejemplos con mayor variabilidad de condiciones industriales. Esta estrategia permitiría fortalecer su capacidad de generalización y mejorar el desempeño en escenarios no controlados.

A pesar de estos desafíos, los resultados obtenidos reflejan un rendimiento sólido, con **precisiones superiores al 87% en general**, lo que indica un **alto potencial** para que el modelo se convierta en una herramienta confiable y eficiente para la **inspección superficial automatizada**.

Este trabajo representa un paso significativo hacia la automatización de la inspección de superficies granalladas, ofreciendo una solución innovadora que combina precisión técnica con

alineación normativa. Con las mejoras sugeridas, el modelo puede evolucionar para enfrentar de manera más efectiva los desafíos de los entornos industriales, consolidándose como una herramienta fiable, adaptable y alineada con las necesidades de la industria moderna.

BIBLIOGRAFÍAS

SSPC/NACE Standards. (2007). *Guide to Surface Preparation Standards*. Society for Protective Coatings (SSPC).

International Organization for Standardization. (2007). *ISO 8501-1: Preparation of Steel Substrates before Application of Paints and Related Products*. Geneva, Switzerland.

PyTorch Developers. (2022). *PyTorch Documentation*. PyTorch. Retrieved May 15, 2022, from <https://pytorch.org/docs/>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org>

Chollet, F. (2017). *Deep Learning with Python*. Manning Publications.

TensorFlow Developers. *Convolutional Neural Networks (CNNs)*. TensorFlow Documentation. Retrieved from <https://www.tensorflow.org>

Colaboratory (Google Colab): A Collaborative Python Environment. Google Research. Retrieved from <https://colab.research.google.com>

NACE International. (2012). Standard Recommended Practice for Surface Preparation and Coating Application.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*.

Blastone Surface Preparation Guide. Grades of blast cleaned steel. https://issuu.com/kateklem/docs/b3089_surface-prep-guide-chart

Szeliski, R. (2022). *Computer Vision: Algorithms and Applications* (2nd ed.). Springer.

Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson.

Chattopadhyay, A. (2019). **Abrasive Blasting: Optimizing Surface Roughness for Improved Coating Performance**. *Surface Engineering*.

Zhou, Y., Zhang, H., & Li, W. (2020). *Deep learning-based visual inspection for surface defect detection: A review*.

Lee, J., & Bagheri, B. (2015). *Cyber-physical systems in future maintenance*.

Zhao, R., Yan, R., Wang, J., Mao, K., & Shen, F. (2019). *Machine health monitoring using deep learning: A survey*.

Zhang, Z., Liu, Q., & Wang, Y. (2017). *Road crack detection using deep convolutional neural network*.

Said, A., Mazumder, M. M., & Ferzli, R. (2020). *Real-time surface inspection in manufacturing using deep learning*.

Powers, D. M. (2020). *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation.* *Journal of Machine Learning Technologies.*

Barth, E., & Schraufstetter, M. (2018). *CNN-based visual inspection system for weld seam quality control.*

Mourtzis, D., Vlachou, E., & Milas, N. (2016). *Industrial big data as a result of IoT adoption in manufacturing.*

Kumbhar, A., Chouzele, A., Lokhande, P., Navgane, S., Burud, A., & Nimbalkar, S. (2023). *DeepInspect: An AI-Powered Defect Detection for Manufacturing Industries.* *arXiv.* <https://arxiv.org/abs/2311.03725>

Jin, Y., Zhang, H., Sun, J., & Wu, Q. (2021). *Welding seam recognition using Mask R-CNN in industrial manufacturing.* *Journal of Intelligent Manufacturing,* <https://doi.org/10.1007/s10845-020-01566-3>

Liu, Y., Zhang, J., & Huang, X. (2024). *Real-time defect detection on steel surfaces using lightweight convolutional networks.* *IEEE Transactions on Industrial Informatics,* <https://doi.org/10.1109/TII.2023.3285589>

Mehta, D., Sinha, S., & Roy, P. P. (2023). *Surface defect anomaly localization using unsupervised convolutional autoencoders.* *Expert Systems with Applications,* <https://doi.org/10.1016/j.eswa.2022.119268>

Zhang, Y., Li, W., & Chen, G. (2024). *Vision transformer with multi-scale information for surface defect classification in steel industry.* *Pattern Recognition Letters,* <https://doi.org/10.1016/j.patrec.2023.11.008>

Wang, J., Li, X., & Zhang, H. (2023). *Welding seam detection and location: Deep learning network-based methods.* *Journal of Manufacturing Processes.* <https://doi.org/10.1016/j.jmapro.2023.01.008>

Chattopadhyay, A. (2021). *A review of deep learning techniques for industrial maintenance applications.* *Journal of Manufacturing Processes,* <https://doi.org/10.1016/j.jmapro.2021.03.002>

Madhusudhan, A., & Bhuvanesh, G. (2020). *Application of Convolutional Neural Networks in Predictive Maintenance of Industrial Systems.* *International Journal of Advanced Manufacturing Technology.* <https://doi.org/10.1007/s00170-020-05672-7>

Singh, P., & Rathi, A. (2022). *Integration of CNNs for Industrial Surface Defect Detection and Quality Assurance.* *Computational Intelligence and Neuroscience,* 2022, <https://doi.org/10.1155/2022/8398292>

Zhao, X., & Zhang, T. (2023). *Vision-based Industrial Defect Detection using Convolutional Neural Networks: A Comprehensive Review.* *Journal of Industrial Engineering and Management.* <https://doi.org/10.3926/jiem.3737>

ANEXOS




Ilustración 9 - Grado A Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1




Ilustración 10 - Grado B Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1




Ilustración 11 - Grado C Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1




Ilustración 12 - Grado D Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 13 - SP 5 Grado A Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1




Ilustración 14 - SP 10 Grado A Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 15 - SP 5 Grado B Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 16 - SP 6 Grado B Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 17 - SP 7 Grado B Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1




Ilustración 18 - SP 10 Grado B Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 19 - SP 5 Grado C Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 20 - SP 6 Grado C Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 21 - SP 7 Grado C Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 22 - SP 10 Grado C Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 23 - SP 5 Grado D Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 24 - SP 6 Grado D Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 25 - SP 7 Grado D Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 26 - SP 10 Grado D Norma SSPC VIS 1

Fuente: Norma SSPC VIS 1



Ilustración 27 - Grados de limpiezas en superficies

Fuente: BLASTONE Surface Preparation Guide