



Sistema de visión artificial aplicado a la detección de anomalías en baldosas

Jacobo Matteucci Lopera

Luisa María Rodríguez Cadavid

Monografía presentada para optar al título de Especialista en Analítica y Ciencia de Datos

Asesores

Álvaro Jaramillo Duque, PhD

Walter Mauricio Villa Acevedo, PhD

Universidad de Antioquia

Facultad de Ingeniería

Especialización en Analítica y Ciencia de Datos

Medellín, Antioquia, Colombia

2024

Sistema de visión artificial aplicado a la detección de anomalías en baldosas.

Cita

(Matteucci Lopera & Rodríguez Cadavid, 2024)

Referencia

Matteucci Lopera, J., & Rodríguez Cadavid, L. M. (2023). *Evolución PIXAI: Sistema de visión artificial aplicada a la inspección de baldosas*. Universidad de Antioquia, Medellín, Colombia.

Estilo APA 7 (2020)



Especialización en Analítica y Ciencia de Datos, Cohorte VI.

Centro de Investigación Ambientales y de Ingeniería (CIA).



Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano: Julio Cesar Saldarriaga Molina

Jefe departamento: Diego José Luis Botia Valderrama

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Dedicamos este trabajo a nuestras familias y personas más cercanas, las cuales nos motivaron a realizar la especialización en Analítica y Ciencia de Datos y quienes además fueron nuestro soporte en momentos difíciles y nuestro combustible para seguir transitando este camino interminable del aprendizaje.

Agradecimientos

Agradecemos a todas las personas, maestros y compañeros que aportaron a nuestro proceso de aprendizaje. También extendemos nuestro agradecimiento a la Universidad de Antioquia y a todo su equipo de trabajo por abrirnos las puertas del programa y permitirnos crecer en este campo. Por último le damos las gracias a la compañía Corona por hacernos parte de este reto y poner a nuestra disposición la información necesaria para realizar este trabajo.

Tabla de contenido

Resumen	7
Abstract	8
1. Descripción del problema	9
1.1. Problema de negocio	10
1.2. Aproximación desde la analítica de datos	11
1.3. Origen de los datos	11
1.4. Métricas de desempeño	12
2. Objetivos	16
2.1. Objetivo general	16
2.2. Objetivos específicos	16
3. Datos	17
3.1. Datos originales	17
3.2. Datasets	17
3.3. Analítica descriptiva	19
4. Proceso de analítica	20
4.1 Pipeline principal	20
4.2 Preprocesamiento	22
4.3 Modelos	26
4.4 Métricas	27
5. Metodología	30
5.1. Baseline	30
5.2. Validación	31
5.3. Iteraciones y evolución	32
Herramientas	34
6. Resultados y discusión	35
6.1. Métricas	35
6.2. Evaluación cualitativa	37
6.3. Consideraciones de producción	37
7. Conclusiones	39
8. Recomendaciones	41
9. Referencias	42

Lista de tablas

Tabla 1	Datos iniciales referentes a indicadores económicos en la producción de baldosas	12
Tabla 2	Indicadores de cantidad de falsos positivos y su impacto económico asociado	13
Tabla 3	Indicadores de cantidad de falsos negativos y su impacto económico asociado	13
Tabla 4	Costos de inversión para equipos del sistema actual	14
Tabla 5	Beneficios obtenidos por sistema actual en 2023	14
Tabla 6	Retorno esperado de la inversión y los beneficios del sistema	15
Tabla 7	Impacto económico proyectado con nuevo modelo	37

Lista de figuras

Figura 1 Mapa de procesos de baldosa con énfasis en el sistema actual de detección.	10
Figura 2 Ejemplos de imágenes capturadas en momento de ajustes o mantenimiento y que por lo tanto no son útiles para el proyecto.	17
Figura 3 Diferencia de brillo entre imagen de la pieza en proceso (izquierda) vs imagen capturada por el sistema de detección de anomalías (derecha).	18
Figura 4 Aplicación de transformaciones para mejorar condiciones de iluminación.	18
Figura 5 Imágenes con metadata de fecha y hora de captura.	19
Figura 6 Imágenes con metadata de fecha y hora de captura.	19
Figura 7 Flujo general de trabajo de los datos.	20
Figura 8 Pasos de preprocesamiento de las imágenes.	22
Figura 9 Muestra ejemplo del paso de eliminación de imágenes irrelevantes.	23
Figura 10 Muestra ejemplo del paso de organización de imágenes en carpetas.	23
Figura 11 Muestra ejemplo del paso de ajustes de iluminación.	24
Figura 12 Muestra ejemplo del paso de reducción de la resolución.	24
Figura 13 Muestra ejemplo del paso de eliminación de ruido de fondo.	25
Figura 14 Muestra ejemplo del paso de ajustes y recorte del fondo.	25
Figura 15 Muestra de imagen de prueba y su predicción por el modelo.	28
Figura 16 Muestra de los cálculos para métricas de desempeño en modelos.	29
Figura 17 Ejemplo de cálculos de las métricas de desempeño de los modelos.	30
Figura 18 Comparación de los modelos según métricas de desempeño.	35
Figura 19 Comparación del modelo actual y el modelo propuesto.	36

Resumen

El proyecto "Sistema de visión artificial aplicado a la detección de anomalías en baldosas" se centró en desarrollar y evaluar un modelo para la detección de anomalías en baldosas de cerámica. Utilizando un dataset de imágenes de baldosas, se implementó el modelo DFR (Deep Feature Reconstruction) en su versión basada en la red VGG19, ajustando y preprocesando las imágenes para mejorar la exactitud comparado con el modelo que actualmente se usa en Corona, llamado PIXAI. En este trabajo se realizaron múltiples iteraciones, se probaron diversas técnicas de preprocesamiento y ajustes del modelo, culminando en el modelo 044_Modelo_Recortadas_PCA, que demostró un rendimiento superior en todas las métricas clave. Los resultados obtenidos indican una mejora significativa en la reducción de falsos positivos y un aumento en la precisión de detección de anomalías comparado con PIXAI, lo que se traduce en importantes beneficios económicos y operacionales para la empresa. Este modelo no solo mejora el proceso de clasificación de baldosas, sino que también ofrece un enfoque práctico para su implementación en un entorno de producción real.

Palabras clave: visión artificial, detección de anomalías, preprocesamiento de imágenes, VGG19, Deep Feature Reconstruction, análisis de datos.

Repositorios GitHub:

https://github.com/luisamariarodriguez/F_monografia_esp_analitica_ciencia_datos_2024

Abstract

The project "Artificial vision system applied to the detection of anomalies in tiles" focused on developing and evaluating an efficient model for detecting anomalies in ceramic tiles. Using a dataset of tile images, the DFR (Deep Feature Reconstruction) model was implemented based on the VGG19 network, adjusting and preprocessing the images to enhance model accuracy. Through multiple iterations, various preprocessing techniques and model adjustments were tested, culminating in the 044_Modelo_Recortadas_PCA model, which demonstrated superior performance across all key metrics. The results indicate a significant improvement in reducing false positives and an increase in anomaly detection accuracy, translating into substantial economic and operational benefits for the company. This model not only optimizes the tile classification process but also offers a robust and practical approach for implementation in a real production environment.

Keywords: artificial vision, anomaly detection, image preprocessing, VGG19, Deep Feature Reconstruction, data analysis

GitHub Repository:

https://github.com/luisamariarodriguez/F_monografia_esp_analitica_ciencia_datos_2024

1. Descripción del problema

Corona es una reconocida empresa en el sector de la manufactura de productos cerámicos y derivados la cual se caracteriza por la calidad y variedad de oferta de todo su catálogo. Dentro de los negocios principales en los que participa la empresa están los de baños y cocinas, vajillas, materiales para la construcción, aisladores, cementos, pinturas y revestimientos siendo en este último negocio en donde se hace enfoque, para desarrollar la monografía, específicamente en el proceso de fabricación de baldosas de la planta de Girardota, Antioquia.

En la Figura 1 se presenta el flujo de procesos para la fabricación de una baldosa. El primer paso es la Recepción de materias primas (1), donde se reciben y almacenan los materiales necesarios para la producción. Los procesos de fabricación de matrices (2), fabricación de moldes (5) y preparación de esmalte (3) se realizan en paralelo en otros momentos del proceso, asegurando que todos los componentes y herramientas estén listos cuando se necesiten. A continuación, se lleva a cabo la preparación de pasta (4), donde se elaboran las mezclas que conformarán el cuerpo de la baldosa. Seguidamente, se realiza el prensado de baldosas (6), donde se da forma a las baldosas utilizando los moldes y matrices preparados anteriormente. Posteriormente, las baldosas pasan por el proceso de engobado y esmaltado (7), donde se aplican capas de engobe y esmalte para darles la apariencia y características deseadas. A continuación, se realiza el decorado (8) de las baldosas, si es necesario, para añadir diseños específicos. Para hacer este decorado se utilizan unas máquinas llamadas Inkjet, las cuales imprimen el diseño mediante combinaciones de tintas especiales. Una vez decoradas, las baldosas se llevan a la carga al horno y cocción (9), donde se someten a altas temperaturas para fijar el esmalte y consolidar el material. Después de la cocción, se realiza la clasificación final (10), donde se inspeccionan y clasifican las baldosas según su calidad. Finalmente, las baldosas se empacan en el paso de empaque (11) y están listas para su distribución y venta.

En la salida de las decoradoras Inkjet, mencionadas anteriormente, se evidenciaba una cantidad significativa de baldosas con defectos estéticos, las cuales eran clasificadas como rotura y no había manera de reparar o resanar. Muchas de estas piezas no se detectaban sino hasta el proceso de clasificación y empaque, generando así una pérdida directa de costos para la empresa. A finales de 2022 se implementó un modelo de visión artificial en la compañía, llamado PIXAI, el cual es capaz de detectar anomalías presentes en las baldosas de la línea con mayor índice de

productos defectuosos. El sistema se ubicó estratégicamente entre la decoradora Inkjet y el horno de cocción de las baldosas (un proceso con alto consumo energético), con el fin de detectar las baldosas con algún defecto para evitar que éstas continúen en la línea de producción y generen sobrecostos innecesarios. Esta intervención ha servido para disminuir las cantidad de piezas defectuosas que llegan al final del proceso, sin embargo, se ha evidenciado que el sistema de detección de anomalías arroja muchos casos de falsos positivos y falsos negativos, dando la oportunidad de hacer mejoras para aumentar la precisión y los beneficios asociados para la compañía.

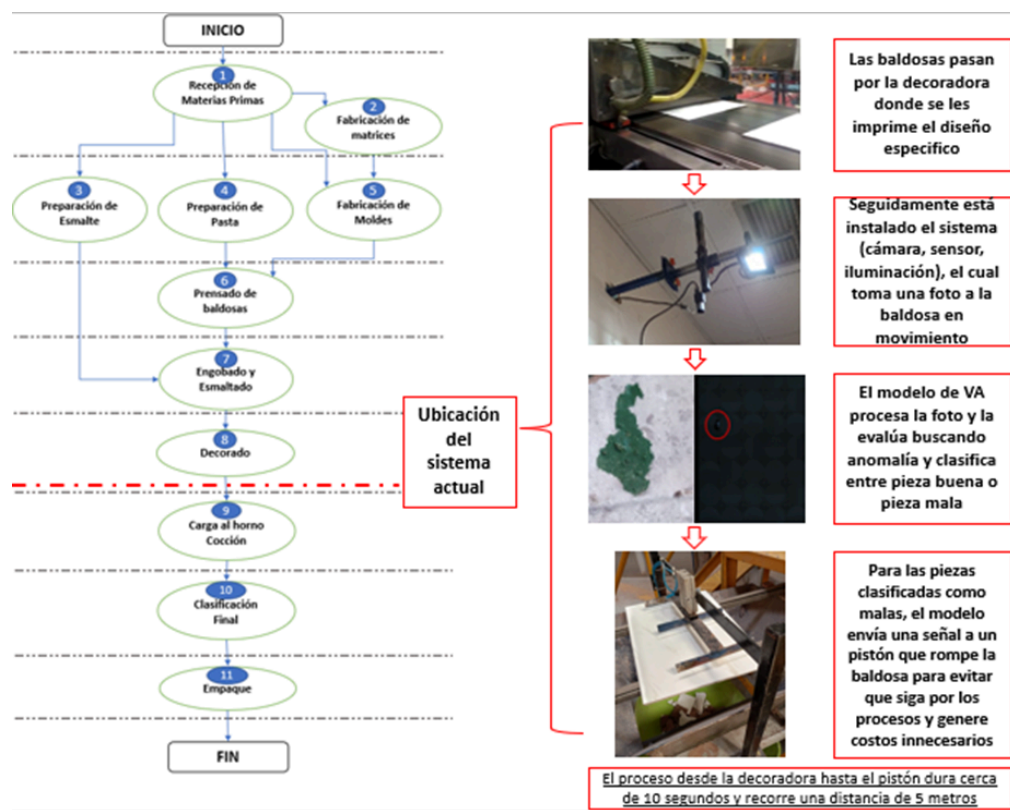


Figura 1. Mapa de procesos de baldosa con énfasis en el sistema actual de detección de anomalías

1.1. Problema de negocio

La compañía Corona busca mejorar el control de calidad de baldosas en su línea de producción. Actualmente, la compañía dispone de un sistema de visión artificial que distingue entre baldosas buenas y malas basado en la detección de anomalías. Sin embargo al hacerle

monitoreo al sistema, aproximadamente dos años que lleva en ejecución, se han recolectado evidencias de que se genera un número considerable de casos con los falsos positivos. Es decir, baldosas que se descartan y destruyen considerando que tienen defectos, pero que en realidad no los tienen. El sistema también presenta casos de falsos negativos, o sea baldosas con defectos que siguen en la línea de producción. En cualquiera de los dos escenarios genera pérdidas directas para la empresa, por lo que se hace necesaria una mejora del sistema actual, donde se analice cuáles son sus puntos débiles y a partir de ahí proponer mejoras, ya sea en las técnicas para procesar las imágenes o probar otros modelos disponibles que puedan asegurar mejores resultados. Finalmente se pretende entregar un paquete de sugerencias que le sirvan a la empresa para robustecer el sistema actual para reducir las pérdidas en el proceso, hacer un uso eficiente de los recursos y maximizar los beneficios económicos de la compañía.

1.2. Aproximación desde la analítica de datos

Se aplicarán modelos para la clasificación de defectos en baldosas de la línea de producción de Corona. El proceso estándar implica analizar y sanear la base de datos original, preprocesar las imágenes para mejorar su calidad, aplicar segmentación para identificar las regiones de interés (defectos) y extraer características que permitan consolidar datasets que sirvan para entrenar, evaluar y ajustar los modelos. Esto con el objetivo de entregar una propuesta con un modelo final que se pueda implementar posteriormente en un ambiente de producción, junto con otras sugerencias desde el control y configuración del sistema. En casos de datos insuficientes, se pueden explorar técnicas de balance como sobremuestreo (Over-sampling), SMOTE (Synthetic Minority Over-sampling Technique) o modificaciones en los argumentos de generación de datos de los modelos analizados (Wongvorachan, He, & Bulut, 2023; Rustogi & Prasad, 2019). Estas técnicas son cruciales para manejar la clasificación de datos desequilibrados y mejorar la precisión del modelo (Wongvorachan, He, & Bulut, 2023).

1.3. Origen de los datos

Los datos están contenidos en una carpeta que contiene 46.015 imágenes relacionadas con la detección de defectos en diversos formatos de baldosas. Estas imágenes fueron capturadas entre el 03 de Septiembre del 2023 y el 05 de abril del 2024. Es importante mencionar que todas

estas imágenes fueron obtenidas del sistema actual de detección de la compañía, llamado PIXAI. El cual, siempre que clasifica una baldosa como defectuosa, guarda una foto para llevar trazabilidad del proceso de clasificación.

1.4. Métricas de desempeño

Métricas del negocio:

Al tratarse de la clasificación de defectos en baldosas, los resultados de un modelo tendrán consecuencias directas en la línea de producción, y en última instancia, en el rendimiento financiero del negocio. A continuación, se detallan los KPIs¹ (Todos estos cálculos se hacen bajo el hecho de que la producción ya está sobrevenida, es decir que una vez sale del proceso de empaque ya tiene cliente esperando), y consideraciones para la evaluación del modelo desde la perspectiva empresarial:

- **Datos iniciales:** En la Tabla 1 se muestran los datos iniciales sobre los costos, ganancias, cantidad, entre otros alrededor del impacto del sistema de detección actual.

Tabla 1. Datos iniciales referentes a indicadores económicos en la producción de baldosas

Rubro	Valor
Costo de baldosa desde el inicio hasta el sistema de detección	\$ 1.075,5
Costo de baldosa desde el sistema de detección hasta el final del proceso	\$ 999,0
Costo total por baldosa	\$ 2.074,6
Precio de venta	\$ 3.432,6
Ganancia por baldosa	\$ 1.358,1

- **Costo de falsos positivos:** Cada baldosa clasificada incorrectamente como defectuosa, lleva a pérdidas por la ganancia que podría recogerse una vez se consolide la venta. En este caso, analizando los datos, se encontró que varias imágenes clasificadas como

¹ Key Performance Indicator (KPI), conocido también como indicador clave o medidor de desempeño o indicador clave de rendimiento.

baldosas con defecto, no lo eran y se rompían. Este tipo de casos corresponde al 3,72% de las imágenes tomadas, que al final son baldosas descartadas y destruidas. En la Tabla 2 se pueden ver los indicadores asociados al número de falsos positivos al mes y su impacto económico

Tabla 2. *Indicadores de cantidad de falsos positivos y su impacto económico asociado*

Rubro	Valor	Observaciones
Precisión	96,3%	Cifra estimada del análisis de datos
Cantidad detectada al mes	5130	Baldosas promedio que detecta y descarta el sistema
Cantidad de falsos positivos	191	Mensual
Ganancia esperada	\$1.358,1	Por cada baldosa
Costo mensual	\$259.393	Costo por falsos positivos
Costo anual por falsos positivos	\$3'112.710	Costo por falsos positivos proyectados a un año

- **Costo de falsos negativos:** Si una baldosa defectuosa es clasificada como buena, implica que la pieza sigue el proceso y solo se detecta al final de la cadena, en el proceso de empaque. Por lo que se genera una pérdida por todo el costo desde el sistema de detección hasta el empaque, que se pudo evitar. La implementación del sistema de detección de anomalías redujo el promedio mensual de defectos del 0,940% en 2022 al 0,305% en 2023 respecto al total de defectos de la planta. La Tabla 3 muestra los indicadores de falsos negativos y su impacto económico.

Tabla 3 . *Indicadores de cantidad de falsos negativos y su impacto económico asociado*

Rubro	Valor	Observaciones
Disminución de los defectos en la producción	67,5%	Logrado con la implementación del sistema
Oportunidad de mejora	32,5%	

Baldosas totales con defectos (mancha)	7534	Estimado con el % de disminución
Cantidad de baldosas defectuosas detectadas al mes	4939	Baldosas promedio que detecta y rompe el sistema correctamente
Cantidad de baldosas defectuosas no detectadas al mes (falsos negativos)	2.595	Baldosas promedio que no detecta el sistema
Costo de producción de baldosa (pérdida por cada falso negativo)	\$999,0	Desde sistema de detección hasta el final del proceso
Costo mensual de falsos negativos	\$2'592.506	Costo mensual por baldosas no detectadas por el sistema
Costo anual de falsos negativos	\$31'110.070	Costo anual proyectado por baldosas no detectadas

- Retorno de la Inversión (ROI):** Se deben calcular los costos asociados con la inversión del sistema actual y compararlos con los ahorros generados (en caso de que se quieran implementar en otra de las líneas bajo el supuesto de que se encuentra en los mismos estados de defecto y piezas producidas). En la Tabla 4 se muestra la inversión estimada con los precios aproximados para la empresa de la implementación del sistema PIXAI.

Tabla 4 . Costos de inversión para equipos del sistema actual

Elemento	Cantidad	Costo aproximado por unidad
Cámara USB 3.0	1	\$5'000.000
Computador de escritorio	1	\$5'000.000
Sistema de iluminación	1	\$300.000
Arduino	1	\$100.000
Fotocelda	1	\$100.000
Pistón	1	\$1'200.000
Total		\$11'700.000

Para los costos del entrenamiento y mantenimiento del modelo, no se tienen datos por lo que no se tendrán en cuenta para el cálculo. Lo siguiente es analizar los beneficios que ha traído el sistema en la línea implementada, en la Tabla 5 se muestran los beneficios económicos obtenidos en 2023.

Tabla 5. Beneficios obtenidos por sistema actual en 2023

Mes	Beneficios
ene-23	\$ 2.784.262
feb-23	\$ 1.353.097
mar-23	\$ 80.396
abr-23	\$ 2.946.158
may-23	\$ 1.540.896
jun-23	\$ 2.732.455
jul-23	\$ 4.267.234
ago-23	\$ 4.144.192
sep-23	\$ 4.817.682
oct-23	\$ 5.381.082
nov-23	\$ 4.578.075
dic-23	\$ 2.985.014
Total 2023	\$ 37.610.543

Con estos supuestos y los datos obtenidos se procede a calcular el retorno esperado de la inversión, tal como se presenta en la Tabla 6:

Tabla 6. Retorno esperado de la inversión y los beneficios del sistema

Rubro	Valor	Observaciones
Inversión Inicial	\$ 11.700.000	Solo por compra de equipos
Beneficio Mensual	\$ 3.134.212	Beneficio promedio a partir de datos reales

Beneficio anual	\$ 37.610.543	
ROI mensual	26,8%	
ROI anual	321,5%	

2. Objetivos

2.1. Objetivo general

Desarrollar y evaluar modelos de visión artificial y técnicas de procesamiento de imágenes para mejorar el desempeño del sistema de clasificación de baldosas actual, con el fin de incrementar la precisión en la detección de defectos y así contribuir al logro de los objetivos económicos y de sostenibilidad de la empresa.

2.2. Objetivos específicos

Selección y preparación de datos:

- Construir el conjunto de datos de imágenes para su uso en el entrenamiento y validación del modelo de visión artificial para la clasificación de defectos en baldosas.

Preprocesamiento y características:

- Determinar las características clave que permitan identificar los defectos en las baldosas y las oportunidades de mejora en el sistema actual de detección de anomalías.
- Aplicar técnicas de procesamiento para mejorar la calidad de las imágenes y el proceso de detección de anomalías.

Modelado y entrenamiento:

- Identificar y seleccionar un modelo de visión artificial que se adapte mejor a la detección de anomalías en baldosas.

Evaluación y ajuste:

- Validar el rendimiento del modelo utilizando métricas de desempeño que permitan evaluar la efectividad en el problema de detección de anomalías en baldosas
- Analizar los resultados obtenidos y sugerir mejoras en el proceso de captura, procesamiento y ejecución del modelo para aumentar el desempeño del sistema actual de detección de anomalías en baldosas.

3. Datos

3.1. Datos originales

El conjunto de datos empleado en este estudio proviene de la detección de defectos en varios diseños de baldosas dentro de la línea de producción de la empresa Corona. Las imágenes fueron recopiladas durante el periodo comprendido entre el 03 de Septiembre del 2023 y el 05 de abril del 2024, bajo condiciones de iluminación similares. Se cuenta un total de 46.015 imágenes para su análisis, las cuales se almacenaron en formato JPG con una resolución de 800 x 1120 píxeles.

3.2. Datasets

El proceso de construcción de los datasets de entrenamiento y validación comienza con un análisis detallado de la base de datos. Se identificaron imágenes tomadas durante mantenimientos o ajustes que carecen de defectos, tal como se ve en la Figura 2, este tipo de imágenes no son pertinentes para el proyecto, siendo eliminadas y quedando con un total de 45.453.



Figura 2. Ejemplos de imágenes capturadas en momento de ajustes o mantenimiento y que por lo tanto no son útiles para el proyecto.

Luego de desechar las imágenes que no aportan a los objetivos del proyecto, se revisó la base de datos restante, imagen por imagen, buscando construir un dataset adecuado. Este conjunto de datos se compone de imágenes de baldosas en buen estado y baldosas con anomalías, en ambos casos, de diferentes referencias. Del total de 45.453 imágenes, se seleccionaron 1603, que se dividen en 653 imágenes de baldosas en buen estado y 950 baldosas con anomalías, para 4 referencias con las que se probarán los modelos. Estas carpetas se suben a un espacio de Google Drive desde donde se sacarán muestras y se procesarán según el interés de cada fase del proyecto.



Figura 3. Diferencia de brillo entre imagen de la pieza en proceso (izquierda) vs imagen capturada por el sistema de detección de anomalías (derecha).

En el conjunto de datos, se observó que, aunque la resolución de las imágenes es adecuada, el brillo y la iluminación podrían afectar la identificación precisa de los defectos, tal como se ve en la Figura 3. Para abordar esto, se exploraron varios tipos de procesamiento y ajuste de imágenes, generando un dataset adecuado para entrenar y probar los modelos. En la Figura 4 se presentan algunos de los ajustes realizados. Se decidió emplear una combinación básica pero funcional, ajustando el brillo y el contraste de cada imagen para mejorar la visibilidad y el balance de colores. Además, se aplicó un filtro bilateral para suavizar la imagen y eliminar el ruido sin perder detalles importantes.




Figura 4. Aplicación de transformaciones para mejorar condiciones de iluminación.

Finalmente, se almacenan las imágenes transformadas en carpetas organizadas en Google Drive para facilitar las pruebas usando Python en la plataforma Colab de Google. Adicionalmente, se destaca que las imágenes carecen de etiquetas (aunque están divididas en carpetas que se organizaron en “buenas” y “anómalas”), pero cuentan con metadatos que incluyen la fecha de captura, tal como se ve en la Figura 5. Esta información se considera valiosa y se podría usar para sacar estadísticos que permitan describir el fenómeno y a su vez ayudar a construir técnicas de control sobre el mismo.



Figura 5. Imágenes con metadata de fecha y hora de captura

3.3. Analítica descriptiva

Tamaño de imágenes:

Cada imagen en el conjunto de datos resultante se encuentra representada por un arreglo tridimensional de la forma (800, 1120, 3). Esto indica que cada imagen posee una resolución de 800 x 1120 píxeles y está compuesta por tres canales de color (rojo, verde y azul conocido como por sus siglas en inglés RGB) para cada píxel. Sin embargo este tamaño se puede tratar de reducir buscando que el costo computacional no sea tan elevado, para esto se buscaría un método que permita reducir el tamaño, sin afectar la calidad de las imágenes.

Visualización de muestras representativas:

A continuación en la Figura 6, se presentan 10 imágenes de piezas seleccionadas aleatoriamente después del proceso de ajuste. Este conjunto se presenta con el propósito de brindar una visión más completa y facilitar la comprensión de la diversidad presente en el conjunto de datos. Se destaca que existe una predominancia de ciertas referencias sobre otras.

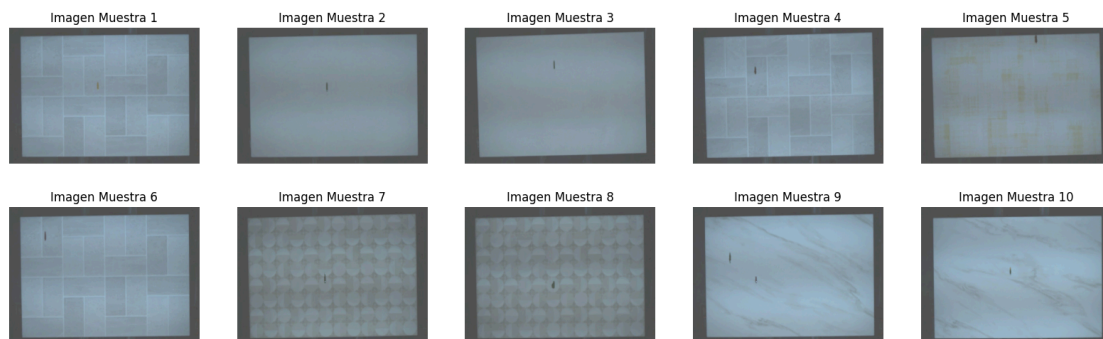


Figura 6. Imágenes con metadata de fecha y hora de captura

4. Proceso de analítica

4.1 Pipeline principal

En la Figura 7 se muestra el flujo que describe las etapas clave en el manejo de datos para el proyecto. Comienza con el preprocesamiento de datos en su primera etapa, donde los datos crudos son limpiados y preparados. Luego, se realiza la obtención de datos desde diversas fuentes. En la segunda etapa de preprocesamiento de datos, se transforman y escalan los datos. A continuación, se lleva a cabo la generación de datos personalizada para aumentar datos y mejorar el modelo. Posteriormente, se procede con la construcción y entrenamiento de modelos utilizando técnicas de Machine Learning. Finalmente, se realiza la evaluación del rendimiento del modelo para asegurar su eficacia y precisión.




Figura 7. Flujo general de trabajo de los datos

1. **Preprocesamiento de datos (primera etapa):** Se aplican diferentes transformaciones para el ajuste del brillo y el fondo de las imágenes para mejorar la calidad visual y estandarizar la apariencia de los datos.
2. **Obtención de datos:** Para facilitar tareas de ingesta y el entrenamiento de los modelos de Machine Learning, las imágenes preprocesadas se almacenan en un repositorio de datos con la siguiente estructura:
 - a. Pixai
 - i. Train
 1. Good
 - ii. Test
 1. Good
 2. Anomaly

3. **Preprocesamiento de datos (segunda etapa):** Las imágenes se redimensionan a un tamaño uniforme y se normalizan. Además, se aplican transformaciones aleatorias para balancear el número de imágenes y se dividen en conjuntos de entrenamiento y validación.
4. **Generación de datos personalizada:** Se utiliza una clase específica para gestionar el flujo de datos durante el entrenamiento del modelo. Esta clase aplica diversas transformaciones a las imágenes originales, tales como acercamientos, desplazamientos y giros, generando así nuevas imágenes a partir de las existentes. Estas imágenes adicionales se integran al conjunto de entrenamiento, permitiendo al modelo entrenar con un conjunto de datos más amplio y variado, y en algunos casos, mejora la robustez y la capacidad del modelo para generalizar y enfrentarse a datos nuevos.
5. **Construcción del modelo:** Se construye un modelo no supervisado basado en VGG19 (Simonyan, K., & Zisserman, A. 2014) para la extracción de características y un autoencoder para la reconstrucción de estas características, con el objetivo de detectar anomalías. Este modelo se entrena utilizando únicamente imágenes sin anomalías para identificar patrones normales en las imágenes. La detección de anomalías se realiza al identificar desviaciones significativas de estos patrones normales en las imágenes de prueba.
6. **Entrenamiento del modelo:** Se entrena el modelo utilizando los datos de entrenamiento y se pone a prueba con los datos de validación. Además se aplican técnicas de ajuste de hiperparámetros y se guardan los valores de la combinación que tuvo mejor desempeño de todos los modelos y arquitecturas consideradas en este proyecto.
7. **Predicción y evaluación en datos de prueba:** El modelo genera mapas de calor de las anomalías detectadas sobre las imágenes de prueba y se comparan las predicciones, con las etiquetas verdaderas, visualizando los resultados.
8. **Evaluación del rendimiento:** Se calculan métricas de rendimiento, se construye y visualiza una matriz de confusión para evaluar el desempeño de los modelos.

Este flujo de trabajo permite que los modelos sean entrenados de manera efectiva con datos no etiquetados y sea capaz de detectar anomalías en nuevas imágenes con un alto grado de precisión.

Más adelante, en la sección “4.3 Modelos”, se profundizará en las características del modelo seleccionado en relación con el tratamiento de los datos.

4.2 Preprocesamiento

Se exploraron múltiples técnicas para asegurar de que los datos sean lo más relevantes y útiles posible para el análisis. Esto incluye la eliminación de datos no pertinentes, la organización de imágenes por categorías, y la aplicación de técnicas de balance de datos para mejorar la calidad visual y la consistencia del conjunto de datos. En la Figura 8 se presentan muestras gráficas de estos pasos en el orden aplicado.

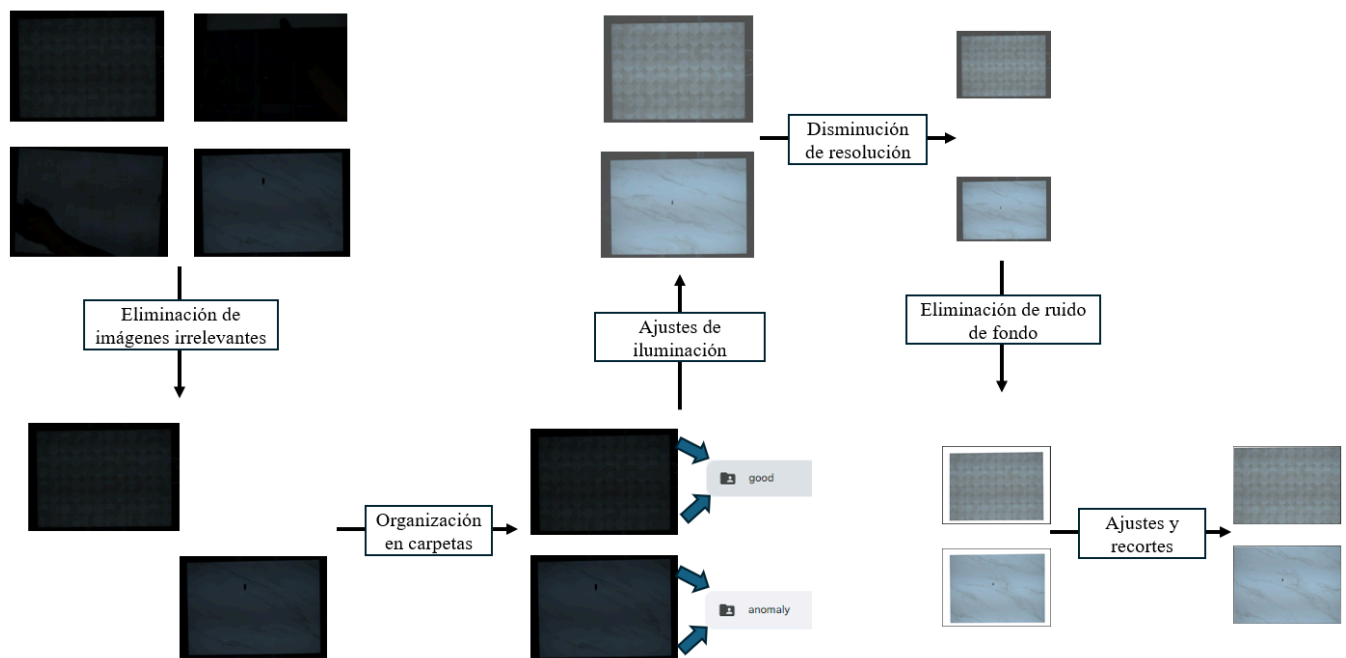


Figura 8. Pasos de preprocesamiento de las imágenes.

A continuación se listan cada uno de los preprocesamiento de datos realizados en el orden que fueron aplicados y presentados en la Figura 8:

- **Eliminación de imágenes irrelevantes:** Se eliminaron imágenes que contenían personas, manos o escenas de mantenimiento, ya que no aportan valor al conjunto de datos destinado a la detección de anomalías. Esta limpieza asegura que el modelo no sea

entrenado con datos que podrían introducir ruido y disminuir su precisión. En la Figura 9 se muestra un ejemplo de este paso.




Figura 9. Muestra ejemplo del paso de eliminación de imágenes irrelevantes.

- **Organización de imágenes:** Las imágenes se organizaron en carpetas separadas según presentaban anomalías o no. Esta estrategia permitió omitir el paso de etiquetar cada imagen individualmente, facilitando el proceso al simplemente clasificar las imágenes en carpetas de "buenas" o "anómalas". En la Figura 10 se muestra un ejemplo de este paso.

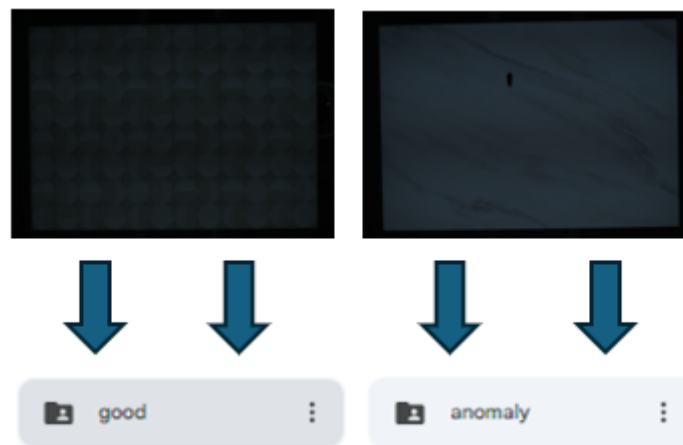


Figura 10. Muestra ejemplo del paso de organización de imágenes en carpetas.

- **Ajustes de iluminación:** Se realizaron correcciones de brillo y contraste, para mejorar la visibilidad y calidad de las imágenes. Estas mejoras son cruciales para asegurar que las características relevantes de las imágenes sean claras y distinguibles, lo que facilita la

posterior clasificación y análisis por parte del modelo. En la Figura 11 se muestra un ejemplo de este paso.




Figura 11. Muestra ejemplo del paso de ajustes de iluminación.

- **Reducción de resolución:** Se redujo la resolución de las imágenes de 800 x 1120 a 400 x 560 píxeles. Esto se hizo para disminuir el tamaño de los archivos y reducir los tiempos de cómputo, sin perder detalles significativos, permitiendo un procesamiento más rápido y manejable de los datos. En la Figura 12 se muestra un ejemplo de este paso.




Figura 12. Muestra ejemplo del paso de reducción de la resolución.

- **Eliminación de ruido de fondo:** Se identificaron esquinas y bordes en las imágenes para rellenar el fondo, utilizando un color fijo, en este caso, blanco. Esto ayudó a disminuir el ruido causado por elementos externos y asegurarse de que el modelo se enfoque en las

características relevantes del objeto de interés; Mejorando así la precisión de la detección de anomalías. En la Figura 13 se muestra un ejemplo de este paso.




Figura 13. Muestra ejemplo del paso de eliminación de ruido de fondo.

- **Ajustes geométricos y recorte de fondo:** Se vio la necesidad de recortar el fondo de las imágenes para disminuir aún más la probabilidad de que el modelo capturara características no representativas, mejorando así la precisión en la detección de anomalías. Para hacer este recorte más efectivo, se realizaron rotaciones de las imágenes con una inclinación significativa, buscando que quedaran lo más horizontales posible. Esto permitió un recorte más preciso del fondo. En la Figura 14 se muestra un ejemplo de este paso.




Figura 14. Muestra ejemplo del paso de ajustes y recorte del fondo.

4.3 Modelos

En esta sección se describe el modelo utilizado para la detección y segmentación de anomalías, explicando la configuración y las razones detrás de la elección de este enfoque sobre los otros considerados.

Elección del modelo

Se decidió implementar el modelo basado en el enfoque **DFR: Deep Feature Reconstruction for Unsupervised Anomaly Segmentation** (Yang, J., Shi, Y., & Qi, Z. 2020, December 13). La elección de este modelo fue motivada por varias razones específicas a la naturaleza del problema y las limitaciones del conjunto de datos disponible:

- **Naturaleza de las imágenes:** Las imágenes de baldosas suelen tener texturas uniformes y patrones repetitivos, lo que hace que cualquier anomalía, por pequeña que sea, sea significativa. El modelo DFR es particularmente efectivo en este tipo de escenarios, ya que se basa en la reconstrucción de características profundas extraídas de imágenes normales y la detección de anomalías.
- **Tamaño de las anomalías:** Las anomalías en las baldosas suelen ser de pequeño tamaño y pueden pasar desapercibidas fácilmente. El enfoque de DFR permite identificar estas pequeñas discrepancias mediante el análisis detallado de las características reconstruidas, ofreciendo una mayor sensibilidad para detectar defectos menores.
- **Disponibilidad de datos:** No se contaba con imágenes etiquetadas de anomalías, lo que hacía inviable el uso de modelos supervisados. DFR es un modelo no supervisado que solo requiere imágenes de baldosas normales para el entrenamiento, lo que se ajusta perfectamente a la disponibilidad de datos.
- **Comparación con SimpleNet:** Aunque SimpleNet es un modelo sencillo y eficiente para la detección de anomalías (Liu, Z., Zhou, Y., Xu, Y., & Wang, Z. 2023, March 27), requiere la generación de características anómalas sintéticas y puede no ser tan efectivo para detectar anomalías muy pequeñas debido a su enfoque basado en ruido gaussiano. El enfoque DFR, en cambio, se centra en la reconstrucción precisa de características, lo que es más adecuado para el tipo de imágenes y anomalías de este proyecto.

Descripción del modelo y configuración

El modelo implementado se basa en la reconstrucción de características profundas utilizando una red preentrenada (VGG19) y se configura de la siguiente manera:

- **Importación de bibliotecas:** Se importaron las bibliotecas necesarias, incluyendo TensorFlow, Keras, scikit-learn, scikit-image, y otras utilidades para la manipulación de imágenes y el entrenamiento del modelo.
- **Generador de datos personalizado:** Se implementó un generador de datos personalizado para cargar y preprocesar las imágenes de baldosas normales. Este generador utiliza ImageDataGenerator para aplicar transformaciones y normalizar las imágenes.
- **Estructura del modelo:** El modelo principal se construye utilizando la red VGG19 preentrenada como extractor de características. Las características extraídas se reconstruyeron mediante un autoencoder.
- **Entrenamiento del modelo:** El modelo se entrena utilizando solo imágenes normales, optimizando la reconstrucción de las características profundas. Se utilizan callbacks como ReduceLROnPlateau, EarlyStopping y ModelCheckpoint para controlar el proceso de entrenamiento y guardar el mejor modelo.
- **Evaluación y umbral de anomalía:** Después del entrenamiento, se calcula un umbral de anomalía basado en el error de reconstrucción para identificar áreas presumiblemente anómalas en las imágenes de prueba.

4.4 Métricas

Para determinar la efectividad del modelo se consideraron las siguientes métricas:

- **Accuracy:** Mide la proporción de baldosas clasificadas correctamente, ya sean defectuosas o no defectuosas.
- **Recall:** Es especialmente crítico en este contexto porque indica qué proporción de baldosas defectuosas fue identificada correctamente por el modelo. Un recall bajo podría significar que se están pasando por alto una cantidad significativa de baldosas defectuosas.

- **Precision:** Representa la proporción de baldosas identificadas como defectuosas que realmente lo están. Un valor bajo podría indicar que muchas baldosas sin defectos, están siendo clasificadas incorrectamente, lo que podría llevar a un desperdicio innecesario.
- **F1-Score:** Dado el posible desequilibrio entre baldosas defectuosas y no defectuosas, el F1-Score puede ser una métrica relevante porque combina precisión y recall en un solo valor.

Para calcular las métricas de desempeño, se utilizaron las bibliotecas TensorFlow y scikit-learn. Primero, se creó un generador de datos de prueba con `tensorflow.keras.preprocessing.image.ImageDataGenerator` para procesar las imágenes de entrada, normalizándolas y organizándolas en lotes. Luego, el modelo realizó predicciones sobre estas imágenes, generando valores booleanos (True o False) que indicaban la presencia de una anomalía. Estos resultados se clasificaron de forma binaria, asignando valores de 0 (no anomalía, "good") y 1 (anomalía, "anomaly"). Estos valores binarios se almacenaron junto con las etiquetas correspondientes. En la Figura 15 se muestra un caso en que se tiene una imagen de prueba con su etiqueta y la predicción del modelo, que luego se clasificaron según lo mencionado anteriormente.

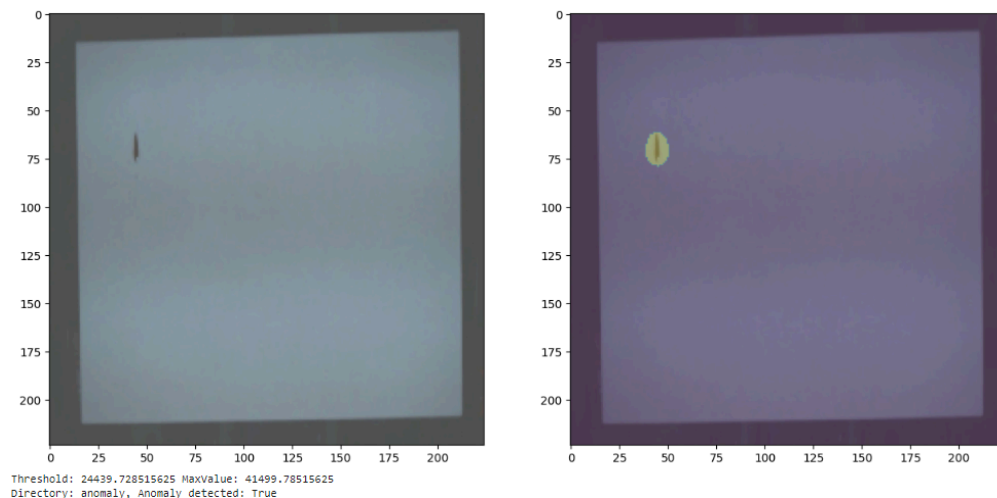


Figura 15. Muestra de imagen de prueba y su predicción por el modelo.

Posteriormente, se emplearon funciones de `sklearn.metrics` como `confusion_matrix`, `accuracy_score`, `precision_score`, `recall_score` y `F1_score` para calcular las métricas de rendimiento, evaluando así la precisión, la sensibilidad y la puntuación F1 del modelo, lo que proporcionó una visión completa de su efectividad, tal como se puede ver en la Figura 16.

5. Metodología

5.1. Baseline

En la primera iteración del proyecto, se trabajó con un dataset compuesto por imágenes sin aplicar ningún tipo de preprocesamiento. Este conjunto de datos sirvió como base para evaluar el rendimiento inicial del modelo DFR. La idea era entrenar el modelo utilizando imágenes normales para luego intentar detectar anomalías durante las pruebas.

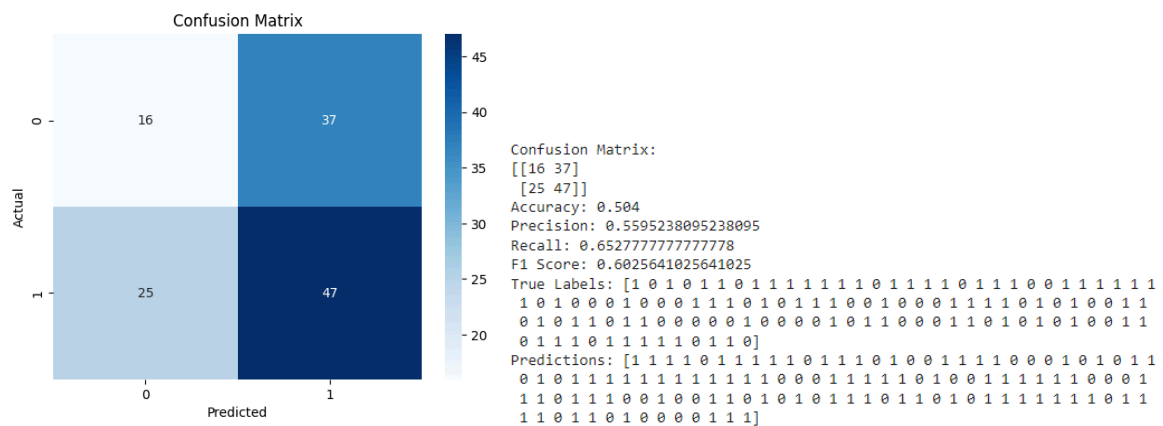


Figura 17. Ejemplo de cálculos de las métricas de desempeño de los modelos.

Los resultados de esta primera iteración fueron mixtos. Aunque el modelo logró identificar algunas áreas sospechosas en las imágenes de prueba, su precisión fue limitada, como se observa en la Figura 17. Esto se debió en parte a la falta de un preprocesamiento adecuado y la baja calidad de las imágenes. Las imágenes presentaban problemas de iluminación y brillo, lo que dificulta tanto el entrenamiento del modelo como la validación visual de los resultados.

Esta iteración proporcionó una base y permitió identificar áreas claves de mejora. A partir de estos resultados iniciales, se realizaron ajustes en el preprocesamiento de datos y la configuración del modelo, incluyendo técnicas de normalización, aumentación de datos y ajustes en la iluminación de las imágenes. Estas mejoras llevaron a resultados más precisos en las siguientes iteraciones del proyecto, como se abordará en secciones posteriores.

5.2. Validación

La estrategia de validación se centró en dividir el dataset en particiones adecuadas para entrenamiento y prueba, y en formar paquetes según las necesidades específicas del modelo.

Particiones de Train/Test

Para estructurar el dataset, se realizó una partición en dos conjuntos principales: entrenamiento y prueba. Este enfoque permitió evaluar el rendimiento del modelo de manera objetiva y asegurar que no hubiera sobreajuste. Las particiones se realizaron de la siguiente manera:

- **Entrenamiento:** Este conjunto incluyó imágenes de baldosas sin anomalías. Se utilizaron el 70% de las imágenes normales disponibles para entrenar el modelo, asegurando que el modelo aprendiera adecuadamente las características de las baldosas sin defectos.
- **Validación:** Se destinó el 20% de las imágenes normales para este conjunto. La validación se realizó durante el entrenamiento para ajustar hiperparámetros y evitar el sobreajuste, permitiendo monitorear el desempeño del modelo en datos no vistos.
- **Prueba:** El 10% restante de las imágenes normales se utilizó para probar el modelo. Además, se incluyó un conjunto separado de imágenes con anomalías. Este conjunto de pruebas mixto permitió evaluar la capacidad del modelo para distinguir entre baldosas normales y defectuosas.

Formación de paquetes de imágenes

Las imágenes se organizaron en tres paquetes según lo requería la configuración de entrada del modelo:

- **Carpeta de imágenes buenas para entrenamiento:** Contiene todas las imágenes normales destinadas al entrenamiento. Estas imágenes se utilizaron para ajustar los pesos del modelo y aprender las características de las baldosas sin defectos.
- **Paquete de imágenes buenas para test:** Otro conjunto de imágenes normales se reservó para la prueba del modelo. Estas imágenes permitieron evaluar cómo el modelo generaliza datos normales no vistos durante el entrenamiento.

- **Paquete de imágenes con anomalías para test:** Este paquete contenía imágenes de baldosas con defectos. La inclusión de estas imágenes fue crucial para evaluar la capacidad del modelo para identificar correctamente las anomalías y diferenciar entre baldosas buenas y defectuosas.

Validación y ajuste del modelo

Durante el proceso de validación, el modelo se entrenó y validó iterativamente para ajustar hiperparámetros y mejorar el rendimiento. Se utilizaron técnicas de aumento de datos y normalización para mejorar la calidad y ayudar al modelo a aprender de manera más robusta.

5.3. Iteraciones y evolución

Cada iteración se centró en diferentes aspectos del preprocesamiento y la configuración del modelo, con el objetivo de mejorar continuamente la precisión y el rendimiento en la detección de anomalías.

En la iteración denominada **020_Modelo_Brillo**, se preprocesaron las imágenes aumentando el brillo. El objetivo era mejorar la calidad visual de las imágenes y evaluar si este ajuste podría aumentar la precisión del modelo. Los resultados fueron los siguientes:

Accuracy: 0.768 || Precision: 0.864 || Recall: 0.708 || F1 Score: 0.779

El aumento de brillo ayudó a mejorar la precisión y la F1 Score, aunque el Recall fue moderado. Esto indicó que el ajuste de brillo era beneficioso pero no suficiente para alcanzar un rendimiento ideal.

En la iteración denominada **030_Modelo_FondoBlanco**, se añadieron fondos blancos a las imágenes de baldosas. El objetivo era simplificar las imágenes eliminando elementos distractores. Los resultados fueron los siguientes:

Accuracy: 0.616 || Precision: 0.616 || Recall: 1.000 || F1 Score: 0.762

Aunque el Recall fue perfecto, indicando que el modelo detectó todas las anomalías, la precisión y la F1 Score fueron bajas debido a un alto número de falsos positivos. Esto sugirió que el fondo

blanco simplificó las imágenes excesivamente, reduciendo la capacidad del modelo para discriminar correctamente entre imágenes normales y anómalas.

En la iteración denominada **040_Modelo_Recortadas**, se recortaron las imágenes para eliminar el fondo y enfocarse únicamente en la baldosa. Este preprocesamiento mejoró significativamente los resultados:

Accuracy: 0.814 || Precision: 0.802 || Recall: 0.915 || F1 Score: 0.855

El recorte del fondo resultó en una mejora considerable en todas las métricas, indicando que este preprocesamiento ayudó al modelo a enfocarse en las características relevantes de las baldosas.

En la iteración denominada **041_Modelo_Recortadas_Hiperparametros**, se aumentó el número de épocas de entrenamiento a 70 para mejorar la capacidad de aprendizaje del modelo, los resultados fueron los siguientes:

Accuracy: 0.832 || Precision: 0.826 || Recall: 0.922 || F1 Score: 0.871

El aumento en las épocas de entrenamiento mejoró ligeramente las métricas, especialmente la F1 Score, indicando que el modelo se benefició del entrenamiento extendido.

En la iteración denominada **042_Modelo_Recortadas_Arquitectura**, se modificó la arquitectura del modelo, introduciendo capas de Dropout para reducir el sobreajuste:

Accuracy: 0.424 || Precision: 0.519 || Recall: 0.578 || F1 Score: 0.547

La modificación de la arquitectura no fue exitosa, ya que todas las métricas disminuyeron. Esto sugirió que las nuevas capas introducidas no eran adecuadas para este problema específico, y se descartan.

En la iteración denominada **043_Modelo_Recortadas_Rotacion**, se rotaron las imágenes para aumentar la diversidad del dataset:

Accuracy: 0.835 || Precision: 0.810 || Recall: 0.941 || F1 Score: 0.871

La rotación de imágenes mejoró las métricas, especialmente el Recall, indicando que el aumento de datos a través de la rotación ayudó al modelo a generalizar mejor.

En la iteración denominada **044_Modelo_Recortadas_PCA**, se ajustó el valor de PCA para retener el 95% de la variancia en lugar del 90%:

Accuracy: 0.856 || Precision: 0.827 || Recall: 0.957 || F1 Score: 0.887

Este ajuste final de PCA resultó en las mejores métricas obtenidas, mostrando un balance óptimo entre precisión y Recall. La retención de más información relevante mediante PCA ayudó al modelo a identificar anomalías con mayor precisión.

En conclusión, las iteraciones iniciales se enfocaron en mejorar el preprocesamiento de las imágenes, las iteraciones posteriores se centraron en ajustar la configuración y arquitectura del modelo. Cada grupo de iteraciones proporcionó lecciones importantes y condujo a mejoras incrementales, culminando en un modelo robusto y preciso para la detección de anomalías en imágenes de baldosas.

Herramientas

Para el proyecto se utilizó el modelo VGG19 para la transferencia de aprendizaje, ejecutándose inicialmente en Kaggle (Del Río, D. 2020) con una GPU T4 gratuita. Sin embargo, debido a las complejidades de la arquitectura, la ejecución se trasladó a Google Colab Pro, utilizando diversas máquinas como T4, A100 y L4 según las necesidades específicas de cada caso. Las imágenes fueron almacenadas y accedidas desde Google Drive, lo que facilitó el manejo de grandes volúmenes de datos. Todas las bibliotecas utilizadas para este proyecto se implementaron en Python, que fue el entorno en el que se ejecutó todo el proyecto.

6. Resultados y discusión

Después de numerosas iteraciones y ajustes en los modelos mencionados, se observaron tanto aciertos como errores que reflejan una clara evolución en el desempeño. En la Figura 18, se presentan los resultados consolidados de las métricas de Machine Learning para cada modelo evaluado. Este gráfico permite comparar visualmente la efectividad de cada modelo y destaca la progresión hacia un mejor rendimiento en la detección de anomalías en baldosas.

6.1. Métricas

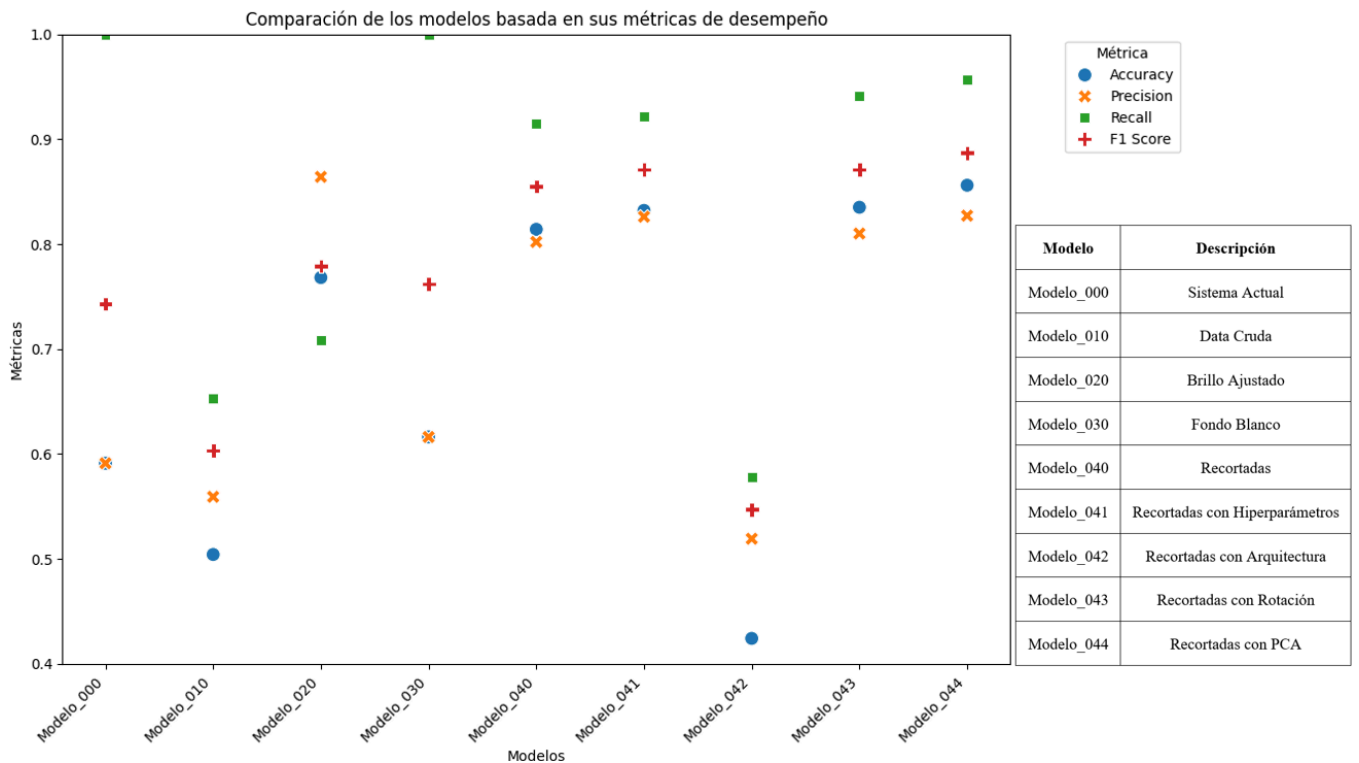


Figura 18. Comparación de los modelos según métricas de desempeño

Analizando los resultados presentados en la Figura 18, se concluye que el mejor modelo es el denominado **044_Modelo_Recortadas_PCA**, de aquí en adelante llamado 044. Según lo mencionado anteriormente, el enfoque debe centrarse en mejorar el desempeño de detección respecto a los falsos positivos, priorizando la métrica de precisión (Precision) para reducir estos casos. El modelo 044 mostró una alta precisión de 0.827, lo que indica su capacidad para

minimizar los falsos positivos y asegurar que las baldosas identificadas como defectuosas realmente lo sean (Encord, 2023). Además, es crucial mantener un equilibrio adecuado entre precisión y sensibilidad, reflejado en el F1-Score. Con un F1-Score de 0.887, el modelo 044 demuestra un excelente balance entre estas métricas. Aunque el enfoque principal sea reducir los falsos positivos, también es importante la exactitud (Accuracy) y el Recall para asegurar que las verdaderas anomalías sean detectadas eficientemente. El modelo 044 alcanzó una exactitud de 0.856 y un Recall de 0.957, destacándose en todas las métricas clave. Por lo tanto, el modelo 044_Modelo_Recortadas_PCA es la mejor opción para su implementación en un entorno de producción real.

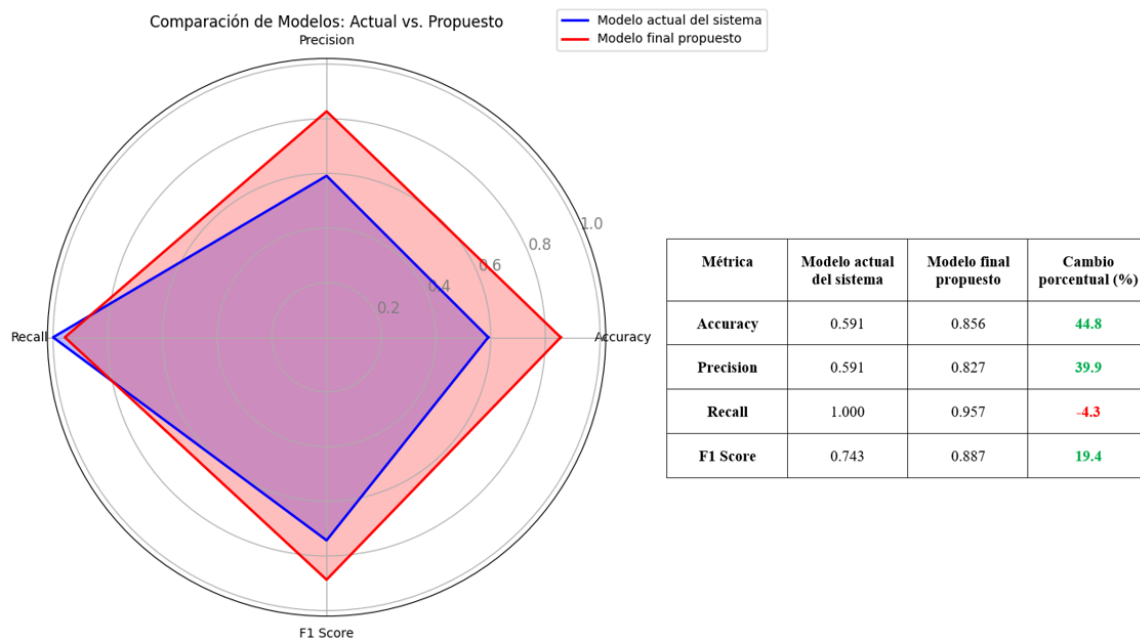


Figura 19. Comparación del modelo actual, llamado PIXAI, y el modelo propuesto

Si comparamos únicamente el desempeño del modelo PIXAI (modelo actual en la planta de Corona) con el del modelo final propuesto en este trabajo, Figura 19, se puede esperar un impacto significativo en los costos de producción relacionado con los falsos positivos; ya que para el conjunto de imágenes de prueba, había 48 imágenes de baldosas buenas. El modelo del sistema actual clasificó correctamente 0 de estas imágenes y el modelo final propuesto clasificó correctamente 34, es decir, el 70.83% de ellas.

Si se supone que este porcentaje de éxito se mantiene constante en el tiempo, se puede estimar que los 191 falsos positivos generados mensualmente por el sistema actual se reducirían a 55 baldosas con el modelo final propuesto. Esto representa una disminución de 136 baldosas destruidas incorrectamente al mes, lo que tendría un impacto positivo considerable en los costos de producción al reducir el desperdicio y mejorar la eficiencia del proceso de clasificación de baldosas. En la Tabla 7 se resume el impacto económico estimado que esto obtendría.

Tabla 7. Impacto económico proyectado con modelo propuesto

Rubro	Valor
Cantidad de falsos positivos con sistema actual	191
Reducción obtenida con sistema propuesto	70,8%
Reducción de baldosas destruidas incorrectamente	136
Ganancia esperada por venta de cada baldosa	\$ 1.358,1
Beneficio mensual por reducción de falsos positivos	\$ 184.698
Beneficio anual por reducción de falsos positivos	\$ 2.216.380

6.2. Evaluación cualitativa

Los resultados de las iteraciones revelaron que técnicas como el aumento de brillo y el recorte de imágenes mejoraron significativamente la precisión y la capacidad del modelo para enfocarse en características relevantes. Ajustes adicionales en los hiperparámetros y la inclusión de métodos como PCA y la rotación de imágenes contribuyeron a una mejor generalización y reducción de falsos positivos. Sin embargo, ciertas modificaciones en la arquitectura del modelo no fueron efectivas y resultaron en un rendimiento inferior, indicando casos de *underfitting*. En algunos modelos, el aumento de épocas de entrenamiento demostró ser beneficioso, evitando el *overfitting*. La relación entre las métricas de machine learning y las métricas de negocio fue clara, destacando la importancia de reducir los falsos positivos para mejorar los costos de producción. El modelo final propuesto (Modelo_044) demostró ser superior al modelo actual del sistema (Modelo_000 o PIXAI), ofreciendo un balance óptimo entre precisión y sensibilidad, y demostrando la utilidad práctica de los resultados en términos de eficiencia y reducción de costos.

6.3. Consideraciones de producción

En caso de poder implementar el modelo final propuesto (044_Modelo_Recortadas_PCA) en producción, se requeriría considerar varios aspectos técnicos y operativos para garantizar su efectividad:

- **Monitoreo del desempeño:**
 - Implementar sistemas de monitoreo continuo para evaluar el desempeño del modelo en tiempo real (Microsoft Learn, 2023; phData, 2023).
 - Levantar reglas duras para generar alarmas y parar la producción si se detecta una degradación significativa en la precisión o sensibilidad del modelo.
 - Utilizar dashboards en tiempo real para visualizar el rendimiento y tomar decisiones informadas.
- **Calidad de las imágenes:**
 - Recomendar mejoras en la manera de capturar las imágenes, como mejorar la iluminación y asegurar la consistencia en el ángulo de captura.
 - Asegurar que las baldosas siempre vengán alineadas para que el preprocesamiento del recorte de imagen sea más preciso y no se generen falsos positivos debido a recortes incorrectos.
 - Controlar elementos externos que el modelo podría considerar como defectuosos, como sombras, reflejos, vasos u otras baldosas, asegurando un entorno de captura controlado (phData, 2023).
- **Reentrenamiento del modelo:**
 - Implementar un sistema de reentrenamiento regular utilizando un conjunto de piezas buenas y defectuosas para mantener la precisión del modelo.
 - Sugerir una frecuencia de reentrenamiento, por ejemplo, cada seis meses o después de cambios significativos en el proceso de producción.
- **Respuesta ágil:**
 - Implementar mecanismos para asegurar una respuesta rápida desde la captura de la imagen hasta la acción de romper la baldosa.

- Optimizar el flujo de trabajo y reducir las latencias en el procesamiento de datos para minimizar el tiempo entre la detección de un defecto y la acción correctiva. (Microsoft Learn, 2023).

7. Conclusiones

El proyecto "Sistema de visión artificial aplicado a la detección de anomalías en baldosas" ha permitido desarrollar y evaluar un modelo robusto para la detección de anomalías en baldosas, logrando mejoras significativas en comparación con el sistema actual. A continuación, se presentan las conclusiones más relevantes:

- Con este proyecto se lograron desarrollar y evaluar modelos de visión artificial y técnicas de procesamiento de imágenes que mejoran el desempeño del sistema de clasificación de baldosas, incrementando la precisión en la detección de defectos y contribuyendo a los objetivos económicos y de sostenibilidad de la empresa. Esto incluyó la construcción de un conjunto de datos de imágenes, la identificación y aplicación de características clave y técnicas de preprocesamiento, la selección y entrenamiento del modelo más adecuado, y la validación y ajuste del modelo para mejorar continuamente su rendimiento.
- Las mejoras en el preprocesamiento, como el ajuste de brillo y el recorte de fondos, junto con una evolución iterativa a través de múltiples ajustes y modificaciones en la arquitectura del modelo, resultaron en una mejora significativa en la precisión y sensibilidad del modelo. Estas técnicas permitieron aplicar mejoras incrementales basadas en lecciones valiosas de cada iteración. Este enfoque combinado contribuyó a la evolución del modelo, obteniendo resultados más exactos y robustos en la detección de anomalías en baldosas.
- El modelo 044_Modelo_Recortadas_PCA mostró un rendimiento superior con métricas de Accuracy, Precision, Recall y F1 Score significativamente altas. Con una precisión de 0,856, un Recall de 0,957 y un F1 Score de 0,887; este modelo demostró ser el más efectivo en la detección de anomalías, minimizando los falsos positivos y manteniendo alta capacidad de detección de defectos.
- La reducción de falsos positivos tiene un impacto directo en los costos de producción. Se estimó que, con el modelo final propuesto, los 191 falsos positivos mensuales del sistema actual se reducirían a 55, lo que representa una disminución de 136 baldosas destruidas incorrectamente al mes. Esto se traduce en un beneficio económico esperado de \$2.216.380 al año por la reducción de falsos positivos.

- El modelo final propuesto es viable para su implementación en un entorno real de producción ya que su capacidad para equilibrar precisión y Recall lo hace adecuado para aplicaciones prácticas, mejorando la eficiencia y reduciendo costos.

En resumen, el proyecto logró desarrollar un modelo de visión artificial eficiente y efectivo para la inspección de baldosas, mejorando considerablemente el sistema de detección de anomalías actual y dando la posibilidad de generar beneficios económicos tangibles a la empresa.

8. Recomendaciones

Las recomendaciones a continuación se enfocan en futuras líneas de investigación y mejoras para mejorar aún más el sistema de detección de anomalías en baldosas:

- **Identificación de características clave:** Investigar e identificar características de mayor valor que permitan levantar indicadores útiles para la toma de decisiones. Esto podría incluir análisis de colores y posiciones de manchas, así como la relación con metadatos para realizar predicciones bajo diversas condiciones, como tipo de referencia, turno de producción y personal involucrado.
- **Modelo preventivo:** Evolucionar el enfoque del modelo de uno correctivo a uno preventivo, utilizando los datos recolectados para predecir y prevenir defectos antes de que ocurran. Esto podría implicar el uso de técnicas de machine learning para analizar patrones históricos y anticipar problemas de producción.
- **Mejoras en la captura de imágenes:** Implementar mejoras en la captura de imágenes, asegurando condiciones de iluminación constantes y un alineamiento adecuado de las baldosas. Esto reducirá el ruido en las imágenes y permitirá una detección más precisa de las anomalías.
- **Automatización y reentrenamiento regular:** Establecer un sistema automatizado para el reentrenamiento regular del modelo, utilizando un conjunto de piezas buenas y defectuosas actualizadas. Esto asegurará que el modelo mantenga su precisión y se adapte a posibles cambios en el proceso de producción.
- **Monitoreo y control en tiempo real:** Desarrollar dashboards en tiempo real para monitorear el rendimiento del modelo y tomar decisiones informadas de manera rápida. Implementar reglas duras para generar alarmas y detener la producción si se detecta una degradación significativa en el rendimiento del modelo.

Estas recomendaciones buscan no solo mejorar el rendimiento del modelo de detección de anomalías, sino también mejorar el proceso de producción de baldosas, contribuyendo al logro de los objetivos económicos y de sostenibilidad de la empresa.

9. Referencias

- Del Río, D. (2020). *Unsupervised Anomaly Segmentation of Screw Images*. Kaggle. <https://www.kaggle.com/code/danieldelro/unsupervised-anomaly-segmentation-of-screw-images>
- Liu, Z., Zhou, Y., Xu, Y., & Wang, Z. (2023, March 27). *SimpleNet: A Simple Network for Image Anomaly Detection and Localization*. arXiv. Retrieved June 16, 2024, from <https://arxiv.org/abs/2303.15140>
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv preprint arXiv:1409.1556. <https://arxiv.org/abs/1409.1556>
- Yang, J., Shi, Y., & Qi, Z. (2020, December 13). *DFR: Deep Feature Reconstruction for Unsupervised Anomaly Segmentation*. arXiv. Retrieved June 16, 2024, from <https://arxiv.org/abs/2012.07122>
- Arivazhagan, B., Sankara Subramanian, D. R. S., & Scholar, R. (2020). *A review of evaluation metrics in machine learning algorithms*. *Computing*, 104, 271-294. <https://doi.org/10.1007/s00607-021-00908-y>
- Wongvorachan, T., He, S., & Bulut, O. (2023). *A Comparison of Undersampling, Oversampling, and SMOTE Methods for Dealing with Imbalanced Classification in Educational Data Mining*. *Information*, 14(1), 54. <https://doi.org/10.3390/info14010054>
- Rustogi, R., & Prasad, A. (2019). *Swift imbalance data classification using SMOTE and extreme learning machine*. In *Second international conference on computational intelligence in data science (ICCIDS)*, vol 978, pp 1-8.

- Encord. (2023). *Accuracy vs. Precision vs. Recall in Machine Learning*. Encord Blog. <https://www.encord.com/blog/accuracy-vs-precision-vs-recall-in-machine-learning>
- Microsoft Learn. (2023). *Deploy machine learning models in production environments*. Microsoft Learn. <https://learn.microsoft.com>
- phData. (2023). *The 4 Pillars of MLOps: How to Deploy ML Models to Production*. phData. <https://www.phdata.io>