

Clasificación de defectos en tableros melamínicos mediante imágenes multispectrales y redes neuronales convolucionales
Defect classification in melamine-faced boards using multispectral images and convolutional neural networks

Cristhian Aguilera¹<https://orcid.org/0000-0003-0230-2945>

Cristhian Aguilera²<https://orcid.org/0000-0003-2504-9305>

Samuel Bustos Puentes¹<https://orcid.org/0009-0003-8037-1572>

Christopher A. Flores¹<https://orcid.org/0000-0003-0994-5919>*

¹Universidad del Bío-Bío. Facultad de Ingeniería. Departamento de Ingeniería Eléctrica y Electrónica. Concepción, Chile.

²Universidad San Sebastián. Facultad de Ingeniería. Puerto Montt, Chile.

*Autor de correspondencia: cfloresj@ubiobio.cl

Resumen:

La industria manufacturera de la madera requiere cada vez más sistemas automáticos e inteligentes para la detección de defectos, dado que el control de calidad basado en inspección visual por operadores humanos presenta variabilidad y limitaciones en su desempeño. Este trabajo aborda dicha necesidad mediante la evaluación de redes neuronales convolucionales para la clasificación automática de defectos en tableros revestidos con melamina. Para ello, se capturaron imágenes multispectrales en las bandas visible (VIS) e infrarroja cercana (NIR), utilizando un sistema de cámaras instalado en una línea de producción industrial. Se evaluaron los modelos Residual Network 18 y Visual Geometry Group 16, obteniendo niveles de precisión comparables a los alcanzados por operadores expertos. Los resultados superaron el 92 % de precisión en todas las tareas de clasificación, lo que sugiere la aplicabilidad práctica del enfoque propuesto en sistemas automatizados de control de calidad.

Palabras clave: Clasificación de defectos, clasificación multiclase, imágenes multispectrales, tableros melamínicos, redes neuronales convolucionales, visión por computador.

Abstract:

The wood manufacturing industry increasingly requires automated and intelligent systems for defect detection to ensure consistent and reliable quality control. Traditionally, this process has relied on visual inspection by human operators, which introduces variability and limits performance. This study addresses this challenge by evaluating convolutional neural networks for automatic defect classification in melamine-faced boards. Multispectral images in the visible (VIS) and near-infrared (NIR) bands were captured under real production conditions using an industrial imaging system. The Residual Network 18 and Visual Geometry Group 16 models were tested on the dataset and achieved accuracy levels comparable to those of expert human inspectors. The

proposed method consistently reached over 92% accuracy across all classification tasks, indicating its practical potential for industrial quality control applications.

Keywords: Defect classification, multiclass classification, multispectral imaging, melamine-faced board, convolutional neural networks, computer vision.

Received: 15.05.2024

Accepted: 07.11.2025

Introducción

El control de calidad en la industria manufacturera es una tarea cada vez más crítica y que incorpora mayor tecnología. Los avances tecnológicos y, en particular, en el ámbito de la Industria 4.0, posibilitan la generación e integración de sistemas cada vez más inteligentes y acordes a los procesos productivos. Los defectos en los productos finales, el cumplimiento de normativas y estándares de calidad, no solo repercuten en los índices de productividad de las empresas, sino que también juegan un rol notable en el posicionamiento de las empresas en el mercado, en la disminución de rechazos y sobre todo en la fidelización de clientes. Tradicionalmente, el control de calidad se ha realizado mediante inspección visual por operadores humanos, con consecuencias inevitables en variabilidad y bajo desempeño (Wang *et al.* 2017).

En las últimas décadas, se han implementado sistemas automáticos de detección de defectos, basados en visión por computador en diversas industrias como la metalúrgica, textil, agrícola y forestal (Arnia y Munadi 2015, Gao *et al.* 2020, Kamal *et al.* 2017, Liu *et al.* 2019, Wu *et al.* 2019).

No obstante, antes de la adopción de técnicas avanzadas de aprendizaje automático, su desempeño era limitado, lo que dejaba espacio para una mejora significativa (Aguilera *et al.* 2018). La disponibilidad creciente de hardware de alto rendimiento y los avances en algoritmos de

aprendizaje han impulsado una nueva generación de sistemas automatizados de inspección con mayor precisión y velocidad, alineados con los estándares actuales de la industria.

En la industria forestal, la producción de tableros de madera procesada ha tenido un crecimiento sostenido en los últimos años. Diferentes estudios muestran lo dinámico que es este mercado, generando ingresos anuales del orden de los USD 198 mil millones a nivel mundial en 2024 en el segmento de tableros derivados de madera, lo que refleja su relevancia dentro del conjunto de productos forestales (Grand View Research 2024). Productos tales como tableros de media densidad (MDF), de hojuelas orientadas (OSB), terciados, entre otros, ofrecen una gran variedad de formatos, ampliamente utilizados en la industria de la construcción y la mueblería. De acuerdo con Research and Markets (2020), el mercado de paneles de madera fue proyectado a crecer un 7 % hacia 2027.

Uno de los productos representativos de esta industria es el tablero melamínico, que consiste en paneles de partículas aglomeradas, recubiertos con una lámina de resina melamínica. La detección y clasificación de defectos en estos tableros constituye una tarea crítica durante el control de calidad. Esto permite generar estadísticas para mejorar procesos, como también categorizar la calidad final. Entre los defectos más comunes se encuentran manchas, rayas, y desprendimientos de material. Otros defectos, como el papel pegado, son más complejos de identificar en presencia de condiciones adversas como bajo contraste, iluminación variable o diseños complejos (Aguilera *et al.* 2018).

En la literatura científica se han propuesto diversas técnicas para la clasificación de defectos en madera. Por ejemplo, Yong-Hua y Jin-Cong (2015) emplearon matrices GLCM para segmentar nudos; Yuce *et al.* (2014) han utilizado redes neuronales convolucionales (CNN) para identificar defectos en chapas. Adicionalmente, se ha demostrado que el uso de información en el espectro

del infrarrojo cercano (NIR) aporta ventajas significativas frente al espectro visible (VIS) en condiciones difíciles (Bigdeli y Süssstrunk 2019, Salamati *et al.* 2012). Estudios recientes han integrado visión multispectral con aprendizaje profundo para mejorar la detección en materiales complejos como textiles, silicio y madera (Kim 2013, Hamdi *et al.* 2017, Yu *et al.* 2019).

Trabajos como los desarrollados por Sharma (2017) y Lee (2018), utilizando diferentes algoritmos, convergen en la mejora de imágenes en términos de iluminación, percepción de detalles y texturas (Lee *et al.* 2018, Sharma *et al.* 2017).

La detección de defectos en líneas de producción también se ha visto favorecida mediante contribuciones que hacen uso de imágenes en el espectro infrarrojo. Por ejemplo, Kim (2013) realiza un análisis del espectro NIR para la detección de micro defectos en obleas de silicio para celdas solares que por la naturaleza misma del material son difíciles de detectar (Kim 2013). Por otro lado, Hamdi *et al.* (2017) proponen un sistema de detección de defectos en una línea de productos textiles sobreponiéndose a las perturbaciones de iluminación propias del proceso (Hamdi *et al.* 2017). En trabajos de detección de nudos de madera, como el presentado por Yu *et al.* (2019) se busca mejorar los índices de desempeño evaluando un sistema de clasificación mediante el uso de imágenes VIS y NIR (Yu *et al.* 2019).

Desde el punto de vista de los algoritmos, el desarrollo de nuevos métodos en el área del aprendizaje automático ha abierto la puerta a nuevos enfoques para abordar esta problemática. Por ejemplo, Rudakov *et al.* (2019) comparan diferentes estructuras de redes neuronales convolucionales para la detección de defectos en tablas de madera tales como GoogleNet, AlexNet, Visual Geometry Group 16 (VGG16) y Residual Network 50 (ResNet50), (Rudakov *et al.* 2019). Además, Hu *et al.* (2019) también analizan tablas, utilizando el algoritmo ResNet18 enfocados no solo en la detección de defectos, sino también en la realización de dos tipos de clasificación

adicionales: una según la textura de las vetas de la tabla y la otra según la especie del árbol de origen (Hu *et al.* 2019). En otro trabajo He *et al.* (2019) proponen una red convolucional completamente conectada como alternativa para la detección de defectos típicos en tablas de madera (He *et al.* 2019). En el trabajo de Urbonas *et al.* (2019) se presenta un sistema automático de detección de defectos en la superficie de chapas de madera comparando los algoritmos AlexNet, VGG16, BN Inception y ResNet152, valiéndose además de técnicas clásicas del aprendizaje profundo, como es la transferencia de aprendizaje y el aumento de datos (Urbonas *et al.* 2019).

Por otro lado, Liu *et al.* (2025) proponen un modelo Transformer ligero, denominado MFWL-DETR (Multi-scale Feature Weighted Fusion and Detection Transformer), que mejora la detección de defectos mediante una fusión ponderada de características en múltiples escalas y el uso de convoluciones por Wavelets (Liu *et al.* 2025). El mecanismo de atención del Transformer permite enfocarse en regiones relevantes de la imagen, mejorando la detección de defectos pequeños. La Tabla 1a y Tabla 1b muestran un resumen de las ventajas y desventajas de los trabajos presentados para la detección de defectos en madera.

En este trabajo se presenta un estudio exploratorio para la clasificación de defectos en tableros de melamina, combinando tanto información multispectral como técnicas de aprendizaje profundo, con el objetivo de evaluar la efectividad de este enfoque para mejorar la detección automática de defectos superficiales. Las imágenes fueron obtenidas en una línea de producción de tableros de melamina por medio de un arreglo de múltiples cámaras capaces de capturar información VIS y NIR. Lo anterior, con el fin de analizar el desempeño de distintos clasificadores sobre distintos datos de entrada, que potencialmente fueran beneficiosos para la detección de defectos. Se evaluó el desempeño de clasificadores utilizando dos estructuras de redes convolucionales pre-entrenadas, VGG16 (Simonyan y Zisserman 2015) y ResNet18 (He *et al.* 2016). Se aplicaron estrategias de

transferencia de aprendizaje y se evaluó el efecto de cada banda espectral para así verificar el aporte de cada una en el desempeño final de los clasificadores, buscando determinar la combinación de modelo y bandas espectrales más efectiva para la tarea propuesta.

Tabla 1a: Tabla comparativa de técnicas usadas en detección de defectos en maderas.

Autores	Tipo de imagen	Modelos	Ventajas	Desventajas
Yuce <i>et al.</i> (2014)	Escala de grises	Redes neuronales + análisis de componentes principales (PCA) + método Taguchi	Buena precisión (80 % <i>accuracy</i>) en clasificación de defectos, reduciendo el tiempo de procesamiento en un 40 %	Requiere ajuste manual de hiperparámetros y selección adecuada de variables para obtener buen desempeño
YongHua y Jin-Cong (2015)	Escala de grises	Matriz de co-ocurrencia de nivel de gris (GLCM)+Tamura+redes neuronales	Método sencillo y rápido para texturas simples (<i>accuracy</i> 92 %)	Extracción manual de características tiene alto costo computacional
Aguilera <i>et al.</i> (2018)	VIS, NIR e infrarrojo de onda larga (LWIR)	<i>Extended Local Binary Patterns</i> (E-LBP)+ <i>Speeded-Up Robust Features</i> (SURF)+ <i>Support Vector Machine</i> (SVM)	Mejora la detección de defectos no visibles en espectro RGB (<i>accuracy</i> 96 %)	Mayor complejidad en adquisición y procesamiento de imágenes (tres tipos de cámara) e iluminación
Urbonas <i>et al.</i> (2019)	Escala de grises	Faster R-CNN + <i>Transfer Learning</i> (AlexNet, VGG16, BNInception y ResNet152) + <i>Data Augmentation</i>	Alta precisión predictiva en detección de defectos en chapas de madera (<i>accuracy</i> 96 %)	Requiere gran cantidad de datos etiquetados y recursos computacionales
Yu <i>et al.</i> (2019)	RGB + NIR	PCA+redes neuronales	Mejora en la precisión de detección de defectos en superficies de madera al usar NIR (<i>accuracy</i> 92 %)	Mayor complejidad en adquisición y procesamiento de imágenes (cámara industrial, espectrómetro NIR) e iluminación

Tabla 1b: Tabla comparativa de técnicas usadas en detección de defectos en maderas.

Autores	Tipo de imagen	Modelos	Ventajas	Desventajas
Hu <i>et al.</i> (2019)	RGB	<i>Transfer Learning</i> (ResNet18)	Clasificación de defectos, textura y especie de madera con buen desempeño (<i>accuracy</i> promedio 96 %)	Uso de diferentes tipos de imagen requiere pre-procesamiento específico, solo es una prueba de concepto
Rudakov <i>et al.</i> (2019)	RGB	<i>Transfer Learning</i> (GoogleNet, AlexNet, VGG16, ResNet50) + <i>Data Augmentation</i>	Precisión de clasificación (<i>accuracy</i> 92 %) y localización precisa de daños mecánicos en la madera en las imágenes segmentadas en áreas de interés	La segmentación para clasificación puede ser menos precisa para daños mecánicos no periódicos, que son más variables
Liu <i>et al.</i> (2025)	RGB	ViT (MFWL-DETR)+ <i>Data Augmentation</i>	MFWL-DETR reduce parámetros (40,2 %), cómputo (40,5 %) y tamaño (36,1 %) sin perder precisión, eficaz en defectos pequeños para aplicaciones industriales	Datos limitados (poca variabilidad en tipos de defectos), requiere refinamiento para escenarios industriales complejos

Materiales y métodos

Planteamiento del problema

Un tablero de melamina es un panel hecho de partículas aglomeradas, recubierto con una lámina de resina melamínica (de Sá *et al.* 2022). El tablero está compuesto por pequeños fragmentos de

madera de pino, usualmente llamado viruta de pino, prensada y seleccionada para ser mezclada con adhesivos especiales; generalmente a base de agua, resina y químicos endurecedores. Después de que la mezcla está lista, el tablero particulado y la lámina son fusionados mediante un sistema de calentamiento y prensado para completar la fabricación del producto. Cada paso del proceso de fabricación está propenso a errores que pueden producir defectos que alterarán la calidad del producto.

En particular, y del interés de esta investigación, se distinguen cinco defectos superficiales comunes en la fusión de la lámina y el tablero: desprendimiento de material (DM), papel manchado (PM), papel corrido (PC), papel quebrado (PQ) y papel pegado (PP). Desprendimiento de material, Figura 1b y Figura 1h, ocurre cuando el tablero presenta un daño y queda expuesto sin lámina melamínica. Papel manchado, Figura 1c y Figura 1i, es cuando se presentan manchas sobre el producto final, por la mala manipulación de la lámina o la presencia de polvo y partículas en suspensión. Papel corrido, Figura 1d y Figura 1j, es cuando ocurre un desplazamiento indeseado de la lámina, evitando que el tablero quede completamente cubierto. Papel quebrado, Figura 1e y Figura 1k, es cuando la lámina se rompe y parte del tablero queda descubierto. Finalmente, papel pegado, Figura 1f y Figura 1l, es cuando aparece un trozo de lámina indeseado por debajo de la lámina a pegar.

Los defectos anteriormente descritos, representan más del 97 % de los tableros defectuosos en producción. Es por esto que la oportuna detección y clasificación de estos defectos es crucial para la comercialización de tableros en el mercado internacional. La siguiente sección, describe nuestra propuesta de solución para detectar y clasificar oportunamente cada uno de estos defectos.

Sistema de captura de datos

Se utilizaron cámaras de alta velocidad y de alta resolución VIS y NIR para la adquisición de imágenes inmediatamente después de que el tablero es fabricado. Además, un sistema de iluminación visible-infrarrojo es utilizado para iluminar el tablero mientras se desplaza en una correa transportadora. El conjunto de cámaras utilizadas en forma transversal junto con el desplazamiento longitudinal del tablero genera una imagen total que es analizada posteriormente en sub-imágenes.




Figura 1: Defectos en tableros. Espectro VIS: (a) sin defecto, (b) desprendimiento, (c) manchado, (d) papel corrido, (e) papel quebrado, (f) papel pegado. Espectro NIR: (g) sin defecto, (h) desprendimiento, (i) manchado, (j) papel corrido, (k) papel quebrado, (l) papel pegado.

Arreglo de cámaras multispectrales

Para la adquisición de imágenes multiespectrales se diseñó e implementó un sistema de múltiples cámaras y controladores industriales que permiten el disparo simultáneo, tanto de las cámaras de espectro visible, como de las cámaras de espectro infrarrojo. Un total de 3 cámaras de espectro visible y 3 cámaras de espectro infrarrojo para cada lado fueron utilizadas en una línea de fabricación de tableros melamínicos operando a una velocidad de 1 m/s. Todas las cámaras están conectadas por medio de una red Gigabit Ethernet y fueron disparadas sincrónicamente mediante un encoder digital. La Tabla 2 muestra las especificaciones técnicas del arreglo de cámaras.

Tabla 2: Especificaciones técnicas de las cámaras utilizadas en la adquisición de imágenes.

Modelo	Espectro	Resolución	Tamaño del píxel	Tamaño del sensor	FPS máx.
BASLER acA2000-50gm	NIR	2048 píxeles × 1088 píxeles	5,5 μm x 5,5 μm	11,26 mm × 5,98 mm	50
BASLER acA645-100gm	VIS	659 píxeles x 494 píxeles	9,9 μm x 9,9 μm	6,52 mm x 4,89 mm	100

Sistema de iluminación

Un sistema de iluminación LED para emisión en espectro visible e infrarrojo fue utilizado para iluminar un área de inspección de 250 mm x 2000 mm. Dos arreglos lineales de luces se ubican a una altura de 300 mm del tablero (Figura 2).

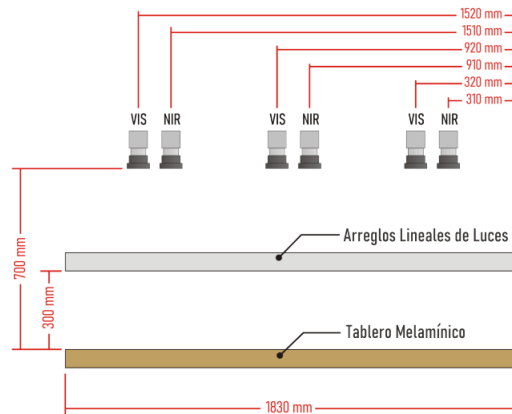


Figura 2: Ubicación de cámaras en línea de producción de tableros.

Adquisición sincrónica de imágenes

Un sistema de control industrial provisto con sensores de presencia y desplazamiento fue utilizado para determinar el momento exacto en que el tablero melamínico ingresa al sistema y se deben efectuar los disparos sincronizados de las cámaras multiespectrales ubicadas sobre la línea de producción. Mediante el avance del tablero se genera un conjunto de 25 sub- imágenes a lo largo del tablero y 3 sub-imágenes a lo ancho del tablero, para finalmente generar las imágenes de un

tablero completo de 3570 píxeles x 5770 píxeles, cuyas dimensiones reales son de 1830 mm x 2500 mm.

Todas las sub-imágenes resultantes son enviadas a un sistema computacional central donde se corrigen y se procesan para generar la imagen total del tablero. La Figura 3 presenta el esquema del sistema de control industrial para la adquisición sincrónica de imágenes. Se incluyen los sensores de presencia y desplazamiento, las cámaras multispectrales, el sistema de iluminación, el controlador lógico programable (PLC) que recibe las señales de los sensores y sincroniza el disparo de las cámaras, iluminación y desplazamiento, el panel interfaz humano-máquina (HMI) y la red de comunicación que conecta con el sistema de procesamiento central.

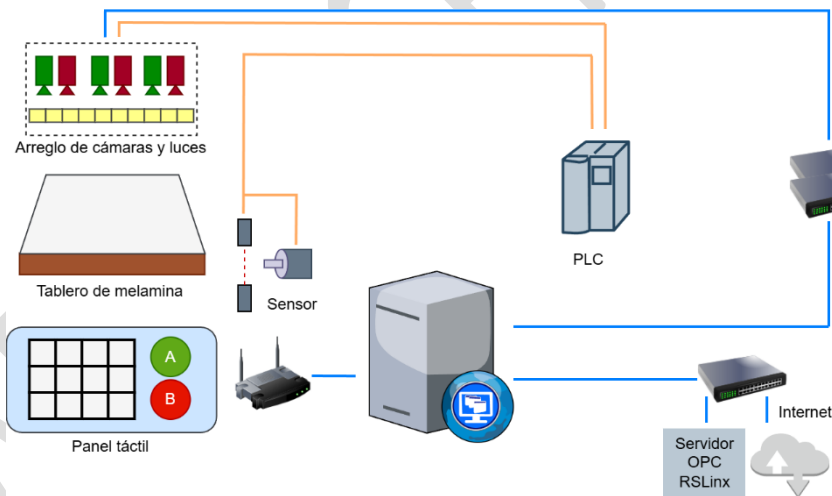


Figura 3: Sistema de control industrial para la adquisición sincrónica de imágenes VIS y NIR.

Corrección de imágenes

Cada sub-imagen que se envía desde las cámaras al sistema computacional central es procesada para corregir las distorsiones propias del sistema óptico, tales como la curvatura del lente, las alteraciones dimensionales de la perspectiva y la diferencia de intensidad que se produce inevitablemente por la iluminación.

Composición de imágenes

Cada sub-imagen adquirida por cada cámara es posteriormente procesada para obtener la región de interés y realizar una concatenación vertical y horizontal, con el objetivo de componer la imagen total del tablero. El resultado final de este proceso es la generación de una imagen de un tablero completo en el espectro visible y otra en el espectro infrarrojo, totalmente pareadas. El proceso completo se resume en la Figura 4, donde se ilustra el flujo desde la captura con el arreglo de cámaras e iluminación, pasando por la generación de sub-imágenes, las cuales se consideran en función del desplazamiento longitudinal y las tres cámaras NIR y VIS dispuestas a lo ancho del tablero, y su posterior reconstrucción en el sistema computacional para obtener las imágenes.

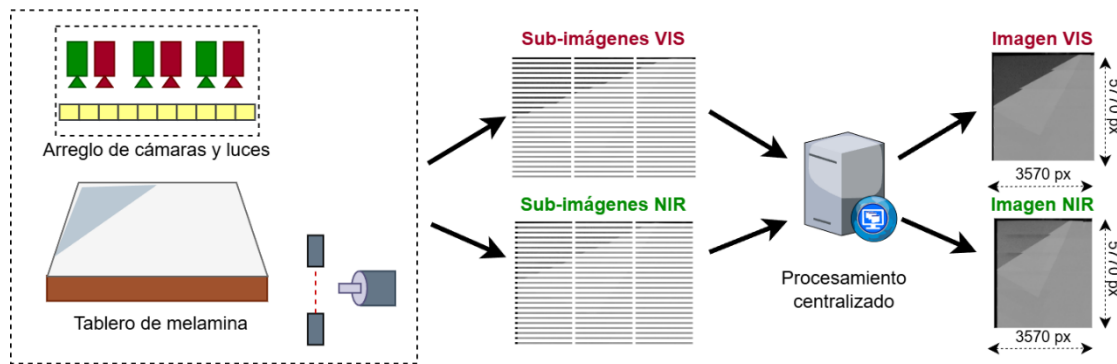


Figura 4: Ejemplo del proceso de composición de imágenes VIS y NIR para un defecto de papel quebrado. Se indican las dimensiones resultantes de las imágenes en píxeles (px).

Conjunto de datos

Una de las tareas críticas de este trabajo, que demandó una gran cantidad de tiempo, fue la generación de un conjunto de datos compuesto de imágenes etiquetadas de espectro visible e infrarrojo. Un sistema semi-automático de etiquetado fue desarrollado mediante la clasificación manual realizada por operadores expertos en tableros melamínicos.

Cada vez que un tablero llega a la zona de clasificación, un operador experto debe definir la calidad de este mediante un sistema de captura automatizado. El operador define, mediante una pantalla táctil, la calidad del tablero (A o B) y las zonas donde ha detectado los defectos. Para esta tarea, el tablero se divide en 12 secciones en un arreglo de 3 x 4 zonas. En cada sub-imagen de los tableros, se procedió a etiquetar una región de interés (ROI) correspondiente a los defectos identificados por los operadores, con un tamaño original de 205 píxeles x 201 píxeles. Esta ROI fue posteriormente redimensionada a 224 píxeles x 224 píxeles como parte del pre-procesamiento, con

el fin de cumplir con los requisitos de entrada de las redes ResNet18 y VGG16 (Ismail y Waseem 2023, Parés *et al.* 2022).

Este proceso de redimensionamiento no generó pérdida de información, ya que las imágenes fueron ajustadas sin ser reducidas, preservando así las características relevantes de los defectos. Posteriormente, los datos fueron organizados y divididos en conjuntos según la calidad (A o B) y los defectos, para su uso en las fases de entrenamiento y evaluación. Mediante este esquema, el operador registra la clasificación general del tablero y las zonas en las que se detectó algún defecto en particular. Estos registros de clase, zona y defectos son almacenados en una base de datos para las etapas posteriores de entrenamiento. La Figura 5 muestra el proceso de clasificación realizado por el operador a través de la pantalla táctil en un área de interés de 205 píxeles x 201 píxeles. En este ejemplo, se muestra la clasificación correspondiente a la clase papel quebrado, incluyendo el almacenamiento de la etiqueta, la delimitación de la zona afectada y la especificación del tipo de defecto.

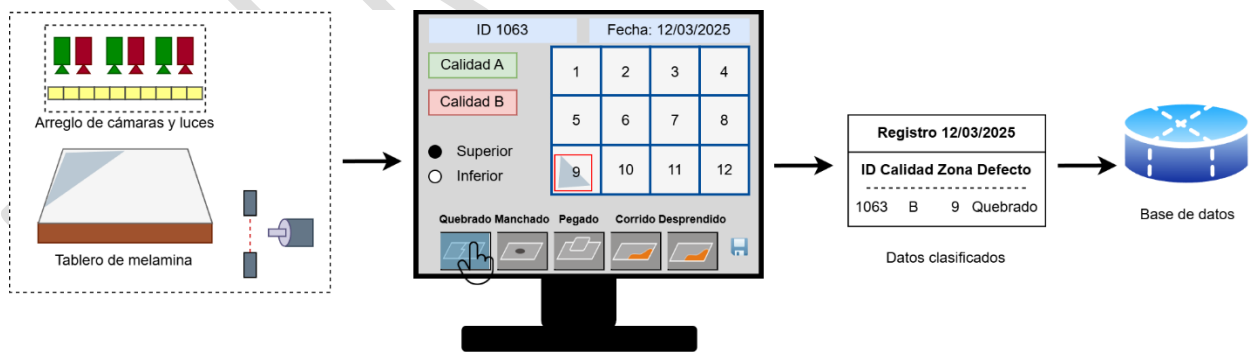


Figura 5: Clasificación del defecto “papel quebrado” (clase B). Se resalta en rojo la región de interés etiquetada, ubicada en la zona 9 de la sub-imagen correspondiente.

Un conjunto de datos fue generado obteniendo imágenes pareadas y registradas de los tableros para los espectros infrarrojos y visibles. En este conjunto de datos las cámaras son disparadas en forma sincrónica obteniendo imágenes registradas con la misma resolución en ambos espectros. Un total de 1368 imágenes fueron etiquetadas; su distribución por clase (A o B) y por tipo de defecto se presenta en la Tabla 3.

Tabla 3: Tableros etiquetados según calidad y defectos, imágenes pareadas VIS-NIR.

Calidad	Defecto
Clase A (530)	Sin defectos
Clase B (838)	Papel Quebrado (166), Manchado (264), Papel Pegado (54), Papel Corrido (308), Desprendimiento de Material (46)

Es importante hacer notar que algunos defectos como desprendimiento de material y papel pegado son los defectos menos frecuentes que aparecen en los tableros. El conjunto de datos es el resultado de 10 meses de captura de datos, en la línea de producción de una fábrica de tableros.

Clasificación

Dos tipos de esquemas de clasificación fueron utilizados. Por un lado, un esquema de clasificación de calidad de tableros, según las categorías de Tableros Clase A y Clase B, y por otro lado un clasificador multiclase considerando los defectos más comunes en el proceso de fabricación de

tableros. El primer esquema corresponde a las necesidades actuales de la industrial y el segundo esquema, corresponde a lo que nosotros creemos será una necesidad futura. La Figura 6 muestra de forma esquemática los dos esquemas de clasificación utilizados, destacando su relación jerárquica y propósito en el contexto del análisis de tableros: Esquema 1, que corresponde a la clasificación binaria de los tableros en Clase A y Clase B según su calidad; y Esquema 2, que utiliza un clasificador multiclase para identificar los defectos más comunes en el proceso de fabricación de los tableros.




Figura 6: Esquemas de clasificación jerárquico de los tableros: Primer esquema: clasificación binaria (calidad). Segundo esquema: clasificación multiclases (defectos).

Dos redes convolucionales pre-entrenadas fueron utilizadas en este trabajo como base, la primera una red de tipo ResNet18 y la segunda una red pre-entrenada VGG16 (He *et al.* 2016, Simonyan y Zisserman 2015). Estas redes neuronales fueron seleccionadas por su rendimiento comprobado en tareas de clasificación de imágenes mediante transferencia de aprendizaje, al estar pre-entrenadas en el conjunto de datos ImageNet, que incluye algunas clases relacionadas con la madera, como productos y estructuras, que podrían ser útiles como características de textura para la clasificación de los tableros (Sun *et al.* 2021). ResNet18, con su arquitectura eficiente y bloques

residuales que facilitan la propagación del gradiente en redes profundas, es ideal para tareas con limitaciones computacionales (11,4 M parámetros), mientras que VGG16, con su mayor profundidad y cantidad de parámetros (134,7 M parámetros), emplea un mayor número de etapas para la extracción de características y clasificación (Ismail y Waseem 2023).

Para la Clasificación final del tablero la siguiente regla es utilizada: Si todas las sub-secciones (12 sub-imágenes) del tablero son clasificadas sin defectos (SD), entonces el tablero completo se clasifica como primera calidad o Clase A. Si alguna de las sub-secciones del tablero presenta algún tipo de defecto, entonces el tablero es clasificado como tablero defectuoso o Clase B.

Resultados y discusión

Evaluación

Como se mencionó anteriormente, para el proceso de entrenamiento se utilizaron redes pre-entrenadas de tipo VGG16 y ResNet18 mediante transferencia de aprendizaje, removiendo la última capa de clasificación original de 1000 neuronas (Ismail y Waseem 2023). Las capas anteriores y sus pesos se mantuvieron para evitar sobreajuste, preservando las representaciones generales adquiridas durante el pre-entrenamiento. Para la clasificación del tablero, se reemplazó la última capa por una nueva capa de dos neuronas, utilizando la función de activación sigmoide para distinguir entre las clases A y B. Para la clasificación de defectos, se empleó una capa de

clasificación multiclase con cinco neuronas, utilizando la función softmax para manejar las diferentes clases de defectos presentes en las imágenes.

Se utilizó un esquema de aumento de datos, considerando únicamente rotaciones aleatorias dentro del intervalo de $\pm 5^\circ$, con el objetivo de simular pequeñas variaciones de orientación durante la adquisición sin alterar significativamente la morfología de los defectos. Para el proceso de aprendizaje se utilizó una tasa de aprendizaje $lr = 0,001$ con batches de tamaño 10 y detención temprana, evaluando el desempeño en el conjunto de validación para evitar problemas de sobreajuste (Ali *et al.* 2023). Un total de 1368 imágenes fueron seleccionadas para el proceso de aprendizaje, con una separación de 60 % de los datos para entrenamiento, 20 % de validación y 20 % de evaluación. Todos los algoritmos fueron programados en Python utilizando el framework Pytorch sobre un computador con Procesador Intel (R) Core (TM) i9-10900X CPU @ 3,70 GHz, Memoria Ram: 64 GB, Almacenamiento SSD, y GPU: NVIDIA Quadro RTX 4000.

Finalmente, se consideraron métricas de desempeño obtenidas desde la matriz de confusión de los valores predichos y verdaderos. En este sentido, se consideró la cantidad de aciertos (accuracy) y la media armónica entre la precisión (precision) y exhaustividad (recall), conocido como valor F1 (F1-score) (Wan y Shao 2023). De esta manera, la precisión evaluará cuántas imágenes clasificadas como clase A (o B) son correctas, mientras que la exhaustividad evaluará cuántas instancias verdaderas de clase A (o B) fueron identificadas correctamente. Para la clasificación multiclase de defectos en las imágenes, estas métricas se aplican a cada clase de manera individual. Finalmente, el F1-score proporcionará un balance entre ambas métricas, lo que es particularmente útil en situaciones de desbalance de clases.

Resultados de clasificación

Los resultados para cada una de las bandas en forma individual, considerando un esquema de dos clases, se muestra en la Tabla 4. Es posible observar que la combinación VGG16&VIS obtuvo un desempeño perfecto en ambas clases en todas las métricas de desempeño analizadas.

Los resultados para cada una de las bandas en forma individual, considerando un esquema de seis clases, se muestran en la Tabla 5. Es posible observar que, en la mayoría de los casos, la combinación ResNet18&VIS y VGG16&VIS obtuvo el mejor desempeño en términos de F1-score y accuracy. Particularmente, el uso de VGG16&VIS obtuvo un buen desempeño, incluso en la clase “Papel Pegado”, el cual es uno de los problemas más complejos de identificar en maderas (Aguilera *et al.* 2018). Es importante mencionar que estos resultados superan el desempeño obtenido en problemas similares que utilizan redes neuronales para la identificación de defectos en maderas (Hu *et al.* 2019, Rudakov *et al.* 2019, Urbonas *et al.* 2019).

En general, los resultados de clasificación indican que, a diferencia de otros dominios y defectos más complejos en madera que los superficiales, como es la clasificación de nudos, agujeros y grietas, el uso de información NIR no tiene un impacto significativo en el desempeño de los modelos (Bigdeli y Süssstrunk 2019, Salamati *et al.* 2012, Yu *et al.* 2019).

Respecto a los tiempos de clasificación de los algoritmos, 6,81 ms fue la media obtenida en cada sub-imagen del tablero. Considerando 24 sub-imágenes totales para la clasificación de un tablero, en el peor de los casos, un total de 163 ms son necesarios para clasificar un tablero en alguna de sus clases. Este último tiempo está muy por debajo de los requerimientos industriales para el proceso de clasificación y almacenaje de los tableros en plantas industriales.

Tabla 4: Resultados de clasificación de calidad utilizando una sola banda del espectro visible (VIS) o infrarrojo cercano (NIR) a la vez.

CNN	Banda espectral	Métrica	Clase A	Clase B	Accuracy
ResNet18	VIS	Precision	0,98	1	0,99
		Recall	1	0,99	
		F1-score	0,99	0,99	
	NIR	Precision	0,94	1	0,98
		Recall	1	0,97	
		F1-score	0,97	0,98	
VGG16	VIS	Precision	1	1	1
		Recall	1	1	
		F1-score	1	1	
	NIR	Precision	0,88	1	0,95
		Recall	1,00	0,93	
		F1-score	0,94	0,96	

Tabla 5: Resultados de clasificación de defectos utilizando una sola banda del espectro visible (VIS) o infrarrojo cercano (NIR) a la vez.

CNN	Banda Espectral	Métrica	SD	DM	PM	PC	PP	PQ	Accuracy
ResNet18	VIS	Precision	0,97	0,94	0,90	1	1	0,89	0,96
		Recall	1	0,88	0,95	0,99	0,78	0,91	
		F1-score	0,98	0,91	0,92	0,99	0,88	0,90	
	NIR	Precision	0,97	0,79	0,88	0,96	0,87	0,86	0,92
		Recall	1	0,81	0,82	0,97	0,87	0,78	
		F1-score	0,98	0,80	0,85	0,96	0,87	0,82	
VGG16	VIS	Precision	1	0,80	0,93	1	1	0,76	0,96
		Recall	1	0,85	0,93	0,97	0,97	0,85	
		F1-score	1	0,82	0,93	0,98	0,98	0,80	
	NIR	Precision	1	0,79	0,95	0,97	0,94	0,80	0,94
		Recall	1	0,84	0,86	1	0,97	0,75	
		F1-score	1	0,81	0,90	0,98	0,95	0,77	

Conclusiones

Este trabajo demuestra que el uso de redes neuronales convolucionales para la clasificación de tableros melamínicos en plantas industriales alcanza un nivel de desempeño comparable al de los operadores humanos expertos, al replicar de manera eficaz sus criterios de clasificación.

Los resultados obtenidos muestran que el desempeño de los modelos fue similar tanto con imágenes visibles como con imágenes en el espectro infrarrojo cercano para la detección de defectos superficiales en los tableros melamínicos. En general, los indicadores de precisión predictiva y velocidad sugieren que la propuesta metodológica satisface los requerimientos actuales de la industria en términos de control automatizado de calidad.

Como trabajo futuro se plantea la evaluación de modelos de clasificación basados en arquitecturas de transformadores de visión (ViT), así como la extensión del sistema a otros tipos de defectos en madera.

Declaración de autorías

C. A.: Conceptualización, análisis formal, investigación, metodología, validación, administración del proyecto, adquisición de fondos, recursos, redacción del borrador original, redacción, revisión y edición. C. A.: Análisis formal, investigación, metodología, validación, administración del proyecto, adquisición de fondos, recursos, redacción del borrador original, redacción, revisión y

edición. S. B. P: Redacción del borrador original, visualización, programa, preparación de datos.
C. A. F.: análisis formal, redacción, revisión y edición.

Agradecimientos

Este proyecto fue financiado por la Comisión Nacional de Investigación Científica y Tecnológica, a través del proyecto FONDEF ID14I20364, ANID FONDECYT 11180856 y por el proyecto Innovación UBB 19-27: Los autores agradecen gentilmente el aporte de la Red Temática TICs4CI: Aplicaciones TICS para Ciudades Inteligentes (REF-518RT0559) del CYTED: Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo, al Grupo de Investigación en Machine Learning y Visión por Computador 194810 GI/VC de la Universidad del Bío-Bío, y al proyecto UBB FAPEI FP2524107.

Declaración de conflictos de interés

Los autores declaran que no existen conflictos de interés relacionados con la publicación de este artículo.

Referencias:

- Aguilera, C.A.; Aguilera, C.; Sappa, A.D. 2018.** Melamine faced panels defect classification beyond the visible spectrum. *Sensors* 18(11). e3644. <https://doi.org/10.3390/s18113644>
- Ali, H.S.; Ismail, A.I.; El-Rabaie, E.S.M.; Abd El-Samie, F.E. 2023.** Deep residual architectures and ensemble learning for efficient brain tumour classification. *Expert Systems* 40(6). e13226. <https://doi.org/10.1111/exsy.13226>
- Arnia, F.; Munadi, K. 2015.** Real time textile defect detection using GLCM in DCT-based compressed images. In: Proceedings of the 6th International Conference on Modeling, Simulation, and Applied Optimization (ICMSAO). IEEE: Istanbul, Turkey. pp. 1-6. <https://doi.org/10.1109/ICMSAO.2015.7152203>
- Bigdeli, S.; Sússtrunk, S. 2019.** Deep semantic segmentation using NIR as extra physical information. In: Proceedings of the IEEE International Conference on Image Processing (ICIP). IEEE: Taipei, Taiwan. pp. 2439-2443. <https://doi.org/10.1109/ICIP.2019.8803242>

de Sá, F.P.; Aguilera, C.; Aguilera, C.A.; Conci, A. 2022. ICT Applications for Smart Cities. In: *ICT Applications for Smart Cities*. Springer: Cham, Switzerland. https://doi.org/10.1007/978-3-031-06307-7_9

Gao, Y.; Gao, L.; Li, X.; Yan, X. 2020. A semi-supervised convolutional neural network-based method for steel surface defect recognition. *Robotics and Computer-Integrated Manufacturing* 61. e101825. <https://doi.org/10.1016/j.rcim.2019.101825>

Grand View Research. 2024. Wood Based Panel Market (2025–2030): Size, Share & Trends Analysis Report By Product (Plywood, MDF, HDF, Particleboard, OSB, Softboard, Hardboard), By Application (Furniture, Construction, Packaging), By Region, And Segment Forecasts. Grand View Research: San Francisco, USA

Hamdi, A.A.; Fouad, M.M.; Sayed, M.S.; Hadhoud, M.M. 2017. Patterned fabric defect detection system using near infrared imaging. In: Proceedings of the 8th International Conference on Intelligent Computing and Information Systems (ICICIS). IEEE: Cairo, Egypt. pp. 111-117. <https://doi.org/10.1109/INTELCIS.2017.8260041>

He, K.; Zhang, X.; Ren, S.; Sun, J. 2016. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE: Las Vegas, NV, USA. pp. 770-778. <https://doi.org/10.1109/cvpr.2016.90>

He, T.; Liu, Y.; Xu, C.; Zhou, X.; Hu, Z.; Fan, J. 2019. A fully convolutional neural network for wood defect location and identification. *IEEE Access* 7: 123453-123462. <https://doi.org/10.1109/ACCESS.2019.2937461>

Hu, J.; Song, W.; Zhang, W.; Zhao, Y.; Yilmaz, A. 2019. Deep learning for use in lumber classification tasks. *Wood Science and Technology* 53: 505-517. <https://doi.org/10.1007/s00226-019-01086-z>

Ismail, L.; Waseem, M.D. 2023. Towards a deep learning pain-level detection deployment at UAE for patient-centric-pain management and diagnosis support: framework and performance evaluation. *Procedia Computer Science* 220: 339-347. <https://doi.org/10.1016/j.procs.2023.03.044>

Kamal, K.; Qayyum, R.; Mathavan, S.; Zafar, T. 2017. Wood defects classification using Laws texture energy measures and supervised learning approach. *Advanced Engineering Informatics* 34: 125-135. <https://doi.org/10.1016/j.aei.2017.09.007>

Kim, G.B. 2013. Micro defect detection in solar cell wafer based on hybrid illumination and near-infrared optics. In: Proceedings of the 9th Asian Control Conference (ASCC). IEEE: Istanbul, Turkey. pp. 1-5. <https://doi.org/10.1109/ASCC.2013.6606013>

Lee, J.; Park, Y.; Jeon, B. 2018. Low intensity RGB texture enhancement based on near infrared image using perceptual information. In: Proceedings of the 10th International Conference on Communications, Circuits and Systems (ICCCAS). IEEE: Chengdu, China. pp. 422-425. <https://doi.org/10.1109/ICCCAS.2018.8769208>

Liu, C.; Chen, K.; Wang, N.; Shi, W.; Jia, N. 2025. A lightweight multi-scale feature fusion method for detecting defects in water-based wood paint surfaces. *Measurement* 235. e117505. <https://doi.org/10.1016/j.measurement.2025.117505>

Liu, Z.; Wu, J.; Fu, L.; Majeed, Y.; Feng, Y.; Li, R.; Cui, Y. 2019. Improved kiwifruit detection using pre-trained VGG16 with RGB and NIR information fusion. *IEEE Access* 8: 2327-2336. <https://doi.org/10.1109/ACCESS.2019.2962513>

Parés, F.; Arias-Duart, A.; Garcia-Gasulla, D.; Campo-Francés, G.; Viladrich, N.; Ayguadé, E.; Labarta, J. 2022. The MAMe dataset: on the relevance of high resolution and

variable shape image properties. *Applied Intelligence* 52(10): 11703-11724.

<https://doi.org/10.1007/s10489-021-02951-w>

Research and Markets. 2020. Wood Based Panel Market Size, Share & Trends Analysis Report by Product. Research and Markets: Dublin, Ireland

Rudakov, N.; Eerola, T.; Lensu, L.; Kälviäinen, H.; Haario, H. 2019. Detection of mechanical damages in sawn timber using convolutional neural networks. In: Proceedings of the 40th German Conference on Pattern Recognition (GCPR). Springer: Stuttgart, Germany. pp. 115-126. https://doi.org/10.1007/978-3-030-12939-2_9

Salamati, N.; Larlus, D.; Csurka, G.; Süssstrunk, S. 2012. Semantic image segmentation using visible and near-infrared channels. In: Proceedings of the European Conference on Computer Vision (ECCV). Springer: Florence, Italy. pp. 461-471. https://doi.org/10.1007/978-3-642-33868-7_46

Sharma, V.; Hardeberg, J.Y.; George, S. 2017. RGB-NIR image enhancement by fusing bilateral and weighted least squares filters. In: Proceedings of the Color and Imaging Conference (CIC). Society for Imaging Science and Technology: Lillehammer, Norway. pp. 330-338. <https://doi.org/10.2352/J.ImagingSci.Technol.2017.61.4.040409>

Simonyan, K.; Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. In: Proceedings of the 3rd International Conference on Learning Representations (ICLR). ICLR: San Diego, CA, USA. <https://doi.org/10.48550/arXiv.1409.1556>

Sun, Y.; Lin, Q.; He, X.; Zhao, Y.; Dai, F.; Qiu, J.; Cao, Y. 2021. Wood species recognition with small data: A deep learning approach. *International Journal of Computational Intelligence Systems* 14(1): 1451-1460. <https://doi.org/10.2991/ijcis.d.210423.001>

Urbonas, A.; Raudonis, V.; Maskeliūnas, R.; Damaševičius, R. 2019. Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. *Applied Sciences* 9(22). e4898. <https://doi.org/10.3390/app9224898>

Wan, Z.; Shao, X. 2023. Disease classification model based on multi-modal feature fusion. *IEEE Access* 11: 27536-27545. <https://doi.org/10.1109/ACCESS.2023.3252011>

Wang, J.; Li, Q.; Gan, J.; Yu, H. 2017. Fabric defect detection based on improved low-rank and sparse matrix decomposition. In: Proceedings of the IEEE International Conference on Image Processing (ICIP). IEEE: Beijing, China. pp. 2776-2780. <https://doi.org/10.1109/ICIP.2017.8296788>

Wu, Y.; Liu, J.; Zhang, Y.; Yu, L.; Wu, J. 2019. Detection algorithm of aluminum surface defects using machine vision. In: Proceedings of the International Conference on Image, Video and Signal Processing (IVSP). ACM: Shanghai, China. pp. 16-22. <https://doi.org/10.1145/3317640.3317661>

Yong-Hua, X.; Jin-Cong, W. 2015. Study on the identification of the wood surface defects based on texture features. *Optik* 126(19): 2231-2235. <https://doi.org/10.1016/j.ijleo.2015.05.101>

Yu, H.; Liang, Y.; Liang, H.; Zhang, Y. 2019. Recognition of wood surface defects with near infrared spectroscopy and machine vision. *Journal of Forestry Research* 30(6): 2379-2386. <https://doi.org/10.1007/s11676-018-00874-w>

Yuce, B.; Mastrocinque, E.; Packianather, M.S.; Pham, D.; Lambiase, A.; Fruggiero, F. 2014. Neural network design and feature selection using principal component analysis and Taguchi method for identifying wood veneer defects. *Production and Manufacturing Research* 2(1): 291-308. <https://doi.org/10.1080/21693277.2014.892442>