



Sistema web de identificación colorantes textiles mediante inteligencia artificial automática

Web System for Identifying Textile Dyes Using Automatic Artificial Intelligence

R. A. Sánchez González ^{a*}, L. A. Castillo-Suárez ^a, M. G. Pineda-Arizmendi ^a

^a *Tecnológico Nacional de México/Tecnológico de Estudios Superiores de Tianguistenco, División de Ingeniería en Sistemas Computacionales. Carretera Tenango, Santiago-La Marquesa 22, 52650 Santiago Tilapa, Estado de México, México.*

Resumen

Las aguas residuales generadas durante el lavado y de mezclilla presentan una coloración azul intensa debido al colorante índigo, lo que exige métodos de monitoreo accesibles y eficientes. El objetivo del presente trabajo fue desarrollar y validar un sistema web basado en inteligencia artificial capaz de cuantificar visualmente la concentración del colorante azul índigo. Se entrenó un modelo YOLOv5 con 217 imágenes etiquetadas correspondientes a seis concentraciones (10–60 mg/L), usando Roboflow para anotación y almacenando el modelo en formato *best.pt*. El desempeño se evaluó con métricas estándar de detección. La precisión (0.93) reflejó la proporción de detecciones correctas respecto a todas las predicciones correctas, mientras que el recall (0.91) indicó la capacidad para identificar correctamente las muestras presentes. El mAP@0.5 de 0.94 y el mAP@0.5 de 0.95 evidencian la robustez del modelo. Estos resultados evidencian un desempeño confiable para el monitoreo del colorante azul índigo, siendo una herramienta accesible en la medición de color de aguas.

Palabras Clave: Azul índigo, detección de objetos, redes neuronales convolucionales, sistema web, YOLOv5.

Abstract

Wastewater generated during denim washing exhibits an intense blue coloration due to indigo dye, creating the need for accessible and efficient monitoring methods. The objective of this study was to develop and validate a web-based artificial intelligence system capable of visually quantifying the concentration of indigo blue dye. A YOLOv5 model was trained using 217 labeled images corresponding to six concentrations (10–60 mg/L), with annotation performed in Roboflow and the final model stored as *best.pt*. Performance was evaluated using standard detection metrics. The precision score (0.93) reflected the proportion of correct detections, while the recall value (0.91) indicated the model's ability to correctly identify the samples present. The mAP@0.5 (0.94) and mAP@0.5:0.95 metrics demonstrated strong accuracy and robustness across different intersection-over-union thresholds. These results show that the proposed system provides reliable performance for monitoring indigo dye and represents an accessible tool for color measurement in water samples.

Keywords: Indigo blue, object detection, convolutional neural networks, web system, YOLOv5.

1. Introducción

La industria textil es uno de los sectores con mayor demanda de recursos hídricos y generación de efluentes coloreados, especialmente debido al uso de colorantes sintéticos como lo es el azul índigo. Este tipo de compuestos presenta una elevada estabilidad química y baja biodegradabilidad, lo que dificulta su eliminación, por lo que es necesario su monitoreo y tratamiento (R. Holkar, J. Jadhav, V. Pinjari, M. Mahamuni, & B. Pandit, 2016). Técnicas

instrumentales como la espectrofotometría UV-Vis permiten cuantificar estas sustancias con precisión, sin embargo, su implementación suele ser costosa y requiere personal especializado, lo que limita su aplicación en industrias pequeñas y medianas (Holkar, 2012).

El avance de la inteligencia artificial ha permitido desarrollar herramientas capaces de analizar imágenes con alta

*Autora para la correspondencia: maria_pa@test.edu.mx

Correos electrónicos: ricardo_202123022@test.edu.mx (R.A. Sánchez-González), luis_cs@test.edu.mx (L.A. Castillo-Suárez), maria_pa@test.edu.mx (M.G. Pineda-Arizmendi)

precisión, posicionando a las redes neuronales convolucionales (CNN) como métodos altamente eficientes para la extracción de patrones visuales, incluso bajo variaciones de iluminación, tono o ruido experimental (Tansel Ersavas, 2024). La aplicación de CNN en la clasificación de materiales, soluciones químicas y patrones ópticos ha crecido de manera significativa, demostrando su utilidad (Sarika H. Vithalkar, 2020).

Uno de los desafíos actuales es la accesibilidad de los modelos de Inteligencia Artificial (IA) para usuarios no expertos. Muchos desarrollos permanecen confinados a entornos de laboratorio o plataformas de programación, lo que limita su adopción en el sector industrial. En este sentido, la integración de modelos entrenados en aplicaciones web representa un puente clave hacia la transferencia tecnológica, permitiendo un uso inmediato sin requerimientos de hardware especializado (Abubakar Abid, 2019).

Este trabajo tuvo como objetivo el desarrollo de un modelado de aprendizaje profundo entrenado para identificar concentraciones de colorante azul indigo (AI) a partir de imágenes de soluciones estándar en formato best.pt, este modelo fue integrado a una aplicación web mediante la plataforma Gradio, la cual permite cargar imágenes, procesarlas y visualizar la concentración etiquetada de manera automática. Esta combinación entre aprendizaje profundo y plataformas accesibles plantea una solución de bajo costo, escalable y de fácil adopción para el monitoreo digital en la industria textil.

1.1 Colorantes textiles y características del azul indigo

Los colorantes textiles son compuestos orgánicos diseñados para presentar alta afinidad y estabilidad frente a diversos sustratos, lo que también contribuye a su persistencia en las aguas residuales industriales.

El AI es ampliamente utilizado en la producción de mezclilla y prendas de algodón debido a su tonalidad características y resistencia al lavado (Uluçay, 2024). Este colorante posee una estructura química altamente estable y soluble en agua, lo que dificulta su biodegradación y favorece su acumulación en los efluentes (Castillo-Suárez, 2023). La presencia de los colorantes en el agua afecta no solo la estética del medio ambiente, impiden la penetración de la luz, la actividad fotosintética y afectan la calidad general del ecosistema acuático. Por estas razones diversas normativas ambientales exigen controlar y monitorear los niveles de color descargados por la industria textil (Castillo-Suárez, 2023). Su presencia afecta la estética del medio ambiente, impide la penetración de la luz, la actividad fotosintética y genera impactos en la calidad de los ecosistemas acuáticos.

1.2 Determinación de color

El análisis del color en soluciones químicas se ha basado tradicionalmente en espectrofotometría UV-Vis, donde la absorbancia se correlaciona directamente con la concentración

del colorante. Aunque este método ofrece alta precisión, requiere condiciones controladas e instrumentación especializada (Susawaengsup, 2024). Con el desarrollo de la visión computacional, se ha demostrado que las imágenes digitales pueden ser procesadas para extraer información cualitativa sobre concentraciones de color mediante análisis de sus canales RGB (Red, Green y Blue), histogramas o transformaciones de espacio de color. Esta capacidad permite utilizar métodos de IA para identificar patrones visuales directamente con variaciones en la concentración de los colorantes.

1.3 Redes neuronales convolucionales (CNN)

Las redes CNN de acuerdo con Nie (Nie, 2025) constituyen una de las arquitecturas más efectivas para la clasificación y reconocimiento de imágenes. Su estructura se basa en capas convolucionales capaces de aprender patrones especiales locales, tales como bordes, texturas y variaciones de color, sin requerir un procesamiento complejo. Las CNN se componen típicamente de:

- Capas convolucionales: Extraen características visuales
- Capas de activación: Reducen la dimensionalidad manteniendo información relevante
- Capas fully-connected: Clasifican los patrones aprendidos

Su efectividad para reconocer variaciones sutiles en imágenes ha impulsado su aplicación en campos como inspección industrial, química analítica, control de calidad y análisis de materiales. Debido a su capacidad de generalización, las CNN resultan adecuadas para identificar tonalidades y concentraciones de colorantes bajo diferentes condiciones de iluminación o fondo (Malashin, 2024).

1.4 Interfaces accesibles para modelos de IA: Gradio

Gradio es una plataforma de código abierto diseñada para crear interfaces gráficas interactivas que permiten desplegar modelos de aprendizaje automático sin necesidad de desarrollos web complejos. Proporciona componentes como carga de imágenes, Botones de procesamiento y visualización de resultados lo que facilita la navegación rápida de prototipos y aplicaciones funcionales desde cualquier navegador (Abid, 2019). Esta funcionalidad permite que los modelos sean accesibles desde cualquier dispositivo o a través de una URL, lo que facilita su uso en entornos industriales o de monitoreo.

1.5 Digitalización del color y percepción computacional

La digitalización del color constituye un elemento central en los sistemas de visión artificial utilizados para la cuantificación de colorantes en medios acuosos. A diferencia de la percepción humana, que depende de mecanismos fisiológicos y adaptativos, las cámaras capturan información numérica basada en la intensidad de luz registrada en cada canal del sensor.

Esta diferencia permite obtener mediciones consistentes, repetibles y cuantificables, necesarias para establecer correlaciones con la concentración de compuestos químicos (Afifi, 2020). Para mejorar la estabilidad cromática, las

imágenes suelen transformarse a espacios de color más uniformes, los cuales ofrecen mayor separación entre componentes perceptuales y luminancia. Estas transformaciones resultan útiles al analizar variaciones de tonalidad asociadas a cambios en concentración, reduciendo la influencia de factores como sombras o diferencias en el balance de blancos. De igual modo, técnicas modernas como constancia de color permiten corregir desviaciones producidas por fuentes de iluminación no controladas (Joze, 2020), lo que incrementa la confiabilidad en la extracción automática de características visuales. En aplicaciones industriales, el uso de sensores digitales ha demostrado ser una alternativa sólida para reemplazar parcialmente técnicas espectrofotométricas, especialmente cuando se busca rapidez, bajo costo y facilidad de implementación.

1.6 Aumento de datos y robustez en modelos de visión

El aumento de datos constituye un componente fundamental en el entrenamiento de modelos de visión por computadora, particularmente en aplicaciones donde las variaciones de iluminación, sombras, reflejos y diferencias entre cámaras pueden afectar la consistencia visual del dataset. En estudios basados en colorantes, estas variaciones pueden alterar la percepción cromática y, por lo tanto, comprometer la capacidad del modelo para generalizar adecuadamente.

Técnicas como el ajuste de brillo y contraste, desbalance de blancos, recortes aleatorios o desenfoques suaves permiten simular condiciones reales de captura y mejorar la resiliencia del modelo frente a escenarios no vistos durante el entrenamiento (Yun, 2019). Además, combinan imágenes o segmentos de ellas para mejorar la generalización y evitar que el modelo dependa excesivamente de patrones locales o ruido específico del dataset. Estas estrategias han demostrado ser especialmente útiles en modelos basados en CNN, donde la representación efectiva del color depende fuertemente del número de ejemplos y de la diversidad visual incluida en el proceso de entrenamiento. De esta forma, el aumento de datos constituye un factor clave para obtener modelos robustos y aplicables en entornos operativos reales.

1.7 Modelo YOLOv5 detection para clasificación y análisis cromático

YOLOv5 y sus variantes recientes se han consolidado como una de las arquitecturas más utilizadas en tareas de visión artificial debido a su equilibrio entre precisión, velocidad y eficiencia computacional. A diferencia de los modelos de clasificación convencionales, YOLOv5 está diseñado principalmente para detección de objetos, permitiendo identificar simultáneamente la ubicación espacial y la categoría del objeto dentro de una imagen.

Las capacidades de extracción de características profundas de YOLOv5 facilitan el reconocimiento de variaciones sutiles de tonalidad dentro de la región detectada, lo cual resulta especialmente útil en aplicaciones de análisis químico visual, donde pequeñas diferencias de color pueden corresponder a cambios en la concentración o comportamiento fisicoquímico de una sustancia. En este contexto, la detección funciona como

un mecanismo de localización precisa, mientras que el análisis cromático dentro de la región detectada permite inferir la categoría de la solución.

YOLOv5 incorpora bloques convolucionales optimizados que mejoran la propagación del gradiente y la estabilidad del entrenamiento, favoreciendo el aprendizaje de patrones visuales finos incluso con conjuntos de datos moderados

(Jocher, 2022). Su capacidad de inferencia en tiempo real y su facilidad de implementación en entornos como Google Colab lo convierten en una herramienta adecuada para el desarrollo de sistemas accesibles basados en inteligencia artificial.

La evolución de la familia YOLO, incluyendo arquitecturas como YOLOv7, ha introducido mejoras en la estabilidad del entrenamiento y en la representación de características visuales, fortaleciendo el reconocimiento de texturas, bordes y variaciones cromáticas. Estas propiedades han impulsado su adopción en aplicaciones de control de calidad, monitoreo industrial, inspección automatizada y sistemas de análisis visual en tiempo real, donde la detección precisa y consistente resulta crítica. (Wang, 2023).

2. Unidad experimental

La unidad experimental utilizada para la adquisición de imágenes estuvo conformada por un sistema de entrada de muestra, una celda de contención, una fuente de iluminación constante y una cámara fotográfica de 64 MP con capacidad HDR utilizando una caja oscura diseñada para alojar la cámara fotográfica y garantizar condiciones controladas de iluminación durante la captura de imágenes, posicionada de manera fija para mantener un ángulo constante de registro. El sistema incorporó dos bombas peristálticas: una destinada a la inyección de la muestra en la celda y la otra para su extracción. La entrada de la muestra se realizó mediante una botella de pequeño volumen especialmente modificada con un orificio superior que permite el flujo controlado hacia el sistema. Para asegurar la uniformidad en las condiciones de captura, se incorporó un conjunto de luces LED de alta intensidad y bajo consumo, distribuidas estratégicamente dentro de la caja oscura. Estas proporcionaron una iluminación estable, homogénea y libre de interferencias externas, mejorando la reproducibilidad de las imágenes y su posterior procesamiento por el modelo de IA.


La Figura 1 a, b presenta el montaje empleado. Las muestras con sus distintas concentraciones de colorante se colocaron en la celda mediante tubos de borosilicato, garantizando estabilidad óptica y evitando distorsiones durante la toma de imágenes. La toma de imágenes constituye la base sobre la cual se entrena cualquier modelo de visión artificial, por lo que se desarrolló un sistema experimental diseñado para reducir la variabilidad lumínica y maximizar la reproducibilidad en cada captura. Este sistema consistió en una caja oscura, equipada con: Una cámara fotográfica de 64 MP con HDR, orientada frontalmente hacia el tubo contenedor de la muestra. Iluminación LED blanca de espectro uniforme, ubicada en los laterales para evitar sombras duras y mejorar la

homogeneidad de la luz. Dos bombas controladas por Arduino, destinadas a manejar el flujo de las soluciones:

- bomba 1 para ingresar la muestra,
- bomba 2 para evacuarla,
- Botonera integrada en el exterior de la caja, que permitió controlar el proceso sin abrir la estructura:
 - botón de inicio de ingreso de muestra,
 - botón de vaciado, botón de paro total.

Un pequeño contenedor o botella con orificio superior, que funcionó como depósito para el suministro de la solución a analizar, garantizando un flujo regulado hacia la unidad experimental. La cámara permaneció fija dentro de la caja, lo que eliminó variaciones por distancia focal o ángulos de captura. La presencia de iluminación controlada fue fundamental para estabilizar la apariencia del colorante, minimizando los efectos de la luz ambiente y las sombras. Gracias a este montaje físico, se logró generar un conjunto de imágenes con características consistentes, condición clave para el entrenamiento del modelo de visión artificial.

a)



b)




Fig. 1 Esquema general del sistema usado a) distribución interna de la cámara y dispositivos de llenado, b) diagrama de bloques de los componentes del dispositivo, a) micro Arduino, b) regulador y un botón de encendido para la luz LED, c) cámara, d) bomba de entrada de muestra, e) bomba de salida de muestra, f) lámpara LED, g) salida de muestra y h) entrada de muestra.

3. Adquisición del conjunto de datos

Para el desarrollo del modelo se empleó un conjunto de imágenes correspondientes a distintas concentraciones y tonalidades del estándar de azul índigo. El proceso incluyó la recopilación de datos, preprocesamiento y preparación del dataset para asegurar la calidad y variabilidad necesarias en la fase de entrenamiento. El preprocesamiento contempló ajustes de brillo y contraste, así como técnicas de aumento de datos orientadas a incrementar la diversidad visual del conjunto. Estas transformaciones contribuyeron a mejorar la robustez del modelo ante variaciones en iluminación, posición o intensidad del color. El modelado y entrenamiento de la CNN se llevó a cabo en Google Colab, aprovechando aceleradores GPU para reducir los tiempos computacionales.

Para el etiquetado inicial se analizaron un total de 217 imágenes recolectadas, organizadas en clases correspondientes a diferentes concentraciones de la curva estándar. Para mejorar la robustez del modelo, se aplicaron diversas técnicas de preprocesamiento:

- Corrección de balance de blancos.
- Ajuste de brillo y contraste.
- Recortes para centrar el área de interés.
- Aumento de datos mediante variaciones ligeras en iluminación y transformaciones espaciales.

Este procesamiento permitió mejorar la variabilidad del conjunto de datos sin comprometer la fidelidad visual de las tonalidades representadas. La Tabla 1 resume la distribución de las imágenes por clase:

Número de imágenes	Clase de tonalidad
87	10 mg/L
31	20 mg/L
31	30 mg/L
20	40 mg/L
22	50 mg/L
26	60 mg/L

Para la etapa de anotación se utilizó la plataforma Roboflow, donde se asignó a cada imagen la clase correspondiente a su concentración, manteniendo coherencia con el patrón cromático establecido en la curva estándar. Posteriormente, la plataforma generó los conjuntos de entrenamiento, validación y prueba automatizados y listos para su uso en YOLOv5 permitiendo estandarizar las etiquetas bajo diferentes condiciones registradas durante la adquisición, tales como iluminación variable, ángulos de captura y cambios en el entorno. Con base en la curva estándar, se definieron dos clases principales que representan los patrones de tonalidad correspondientes a las concentraciones utilizadas.

La red neuronal convolucional se entrenó utilizando el modelo YOLOv5 como arquitectura base. El conjunto de datos

se dividió en un 80 % para entrenamiento orientado al aprendizaje de los patrones visuales y un 20 % para prueba, destinado a evaluar el desempeño del modelo y mitigar el riesgo de sobreajuste. Se trabajó con un batch size de 32 imágenes por iteración y un total de 100 épocas de entrenamiento dentro del entorno de Google Colab (Muñoz, 2022).

4. Resultados preparación del conjunto de datos

Durante el proceso de entrenamiento, el modelo mostró una disminución progresiva en la función de pérdida, alcanzando estabilidad después de la época 60. Las métricas finales indicaron un desempeño adecuado:

- Precisión general: 0.93
- Recall: 0.91
- mAP@0.5: 0.94

En la Tabla 2, se muestran las métricas demostraron que la CNN aprendió correctamente a distinguir patrones cromáticos relacionados con cada concentración del colorante, incluso frente a las variaciones generadas artificialmente mediante las técnicas de aumento de datos.

Tabla 2. Métricas de colab.

Class	img	P	R	mAP50	mAP 50-95
all	217	0.997	1	0.995	0.793
10 mgL	87	0.998	1	0.995	0.777
20 mgL	31	0.995	1	0.995	0.815
30 mgL	31	0.997	1	0.995	0.772
40 mgL	20	0.999	1	0.995	0.818
50 mgL	22	0.997	1	0.995	0.777
60 mgL	26	0.997	1	0.995	0.799

5. Integración del sistema de detección en una plataforma web

Para garantizar la operatividad del modelo CNN fuera del entorno de desarrollo y facilitar su uso por parte de usuarios no especializados, se creó una plataforma web funcional que integra el sistema de detección basado en YOLOv5. La implementación se diseñó con el propósito de permitir la carga de imágenes, la inferencia en tiempo real y la visualización inmediata del resultado de clasificación de tonalidades del colorante azul índigo. La arquitectura se dividió en dos componentes principales: el backend de procesamiento y la interfaz gráfica de usuario.

El backend se desarrolló en Python utilizando el framework Flask por su ligereza y facilidad de integración con modelos de machine learning. Dentro del servidor, el modelo entrenado se cargó en memoria para minimizar los tiempos de respuesta, permitiendo que cada imagen enviada fuera preprocesada, analizada y clasificada en fracciones de segundo.

El sistema aplica un pipeline similar al utilizado durante el entrenamiento: normalización, redimensionamiento y conversión a tensores, lo que garantiza coherencia entre el comportamiento del modelo en entrenamiento y en implementación real (Santana Santana, 2024). Paralelamente, la interfaz web fue construida con HTML de Gradio, priorizando una experiencia intuitiva. Se habilitó un módulo de carga de imágenes en el cual el usuario puede seleccionar archivos directos desde su dispositivo. Una vez enviada la imagen, el sistema establece comunicación con el servidor mediante solicitudes HTTP tipo POST, enviando la imagen para procesarse y recibiendo como respuesta la clase predicha y el nivel de confianza.

Un aspecto clave del diseño fue la optimización del tiempo de respuesta, ya que un sistema destinado a soporte de decisiones rápidas como la cuantificación del colorante requiere una inferencia ágil y confiable. Además, se incorporó un sistema de almacenamiento temporal que permite guardar las imágenes analizadas junto con su respectiva predicción, lo que abre la puerta a auditorías, análisis posteriores y trazabilidad del proceso. Finalmente, se añadió una sección visual donde se muestran en la figura 2 y Figura 3 se lleva a cabo la identificación correcta de los colorantes, así como la etiqueta generada por la red neuronal, junto con un indicador numérico de probabilidad. Esto convierte a la plataforma en una herramienta integral que no sólo ejecuta el modelo, sino que facilita su uso, interpretación y adopción como método alternativo de cuantificación.

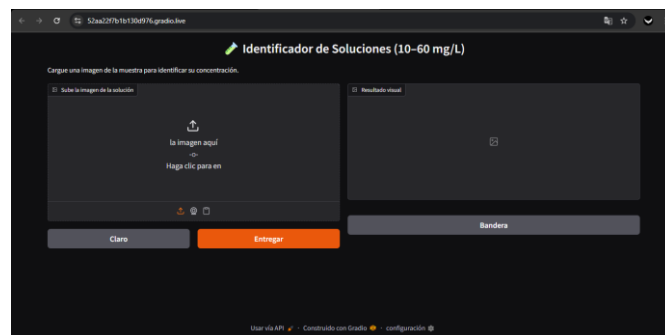


Fig 2. Interfaz de la Página web.

En la Fig 3a denominada identificación de colorantes en la página web 60 mg/L se genera un ingreso de imagen del conjunto de datos de la cual no da el resultado inmediato, con una etiqueta final, como se muestra en la imagen el resultado obtenido fue del 0.54 % de precisión según la imagen ingresada.

En la Fig 3b. denominada identificación de colorantes en la página web 50 mg/L se genera un ingreso de imagen del conjunto de datos de la cual no da el resultado inmediato fue del 0.60 % de precisión según la imagen ingresada. En la Fig. 4c, siendo una medida imagen ingresada de 40 mg/L, el resultado fue del 0.55 de precisión. La siguiente Fig. 4d, ingresada a la página web con una concentración del 30 mg/L, el resultado obtenido fue del 0.66. Para la solución en una

medida de 20 mg/L como se muestra en la Fig, 3e, el resultado obtenido fue del 0.52 de precisión. Finalmente, para la identificación de la Fig. 3 f, identificando la imagen con una solución de 10 mg/L, el resultado obtenido fue del 0.89 de precisión., siendo esta una prueba más alta de las anteriores.

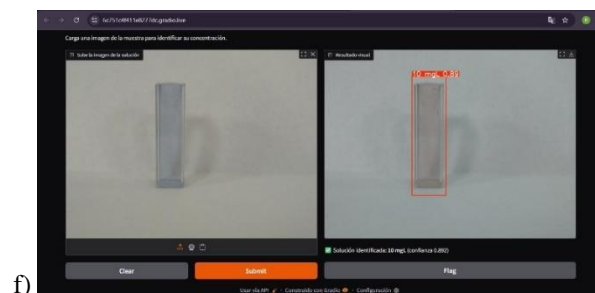
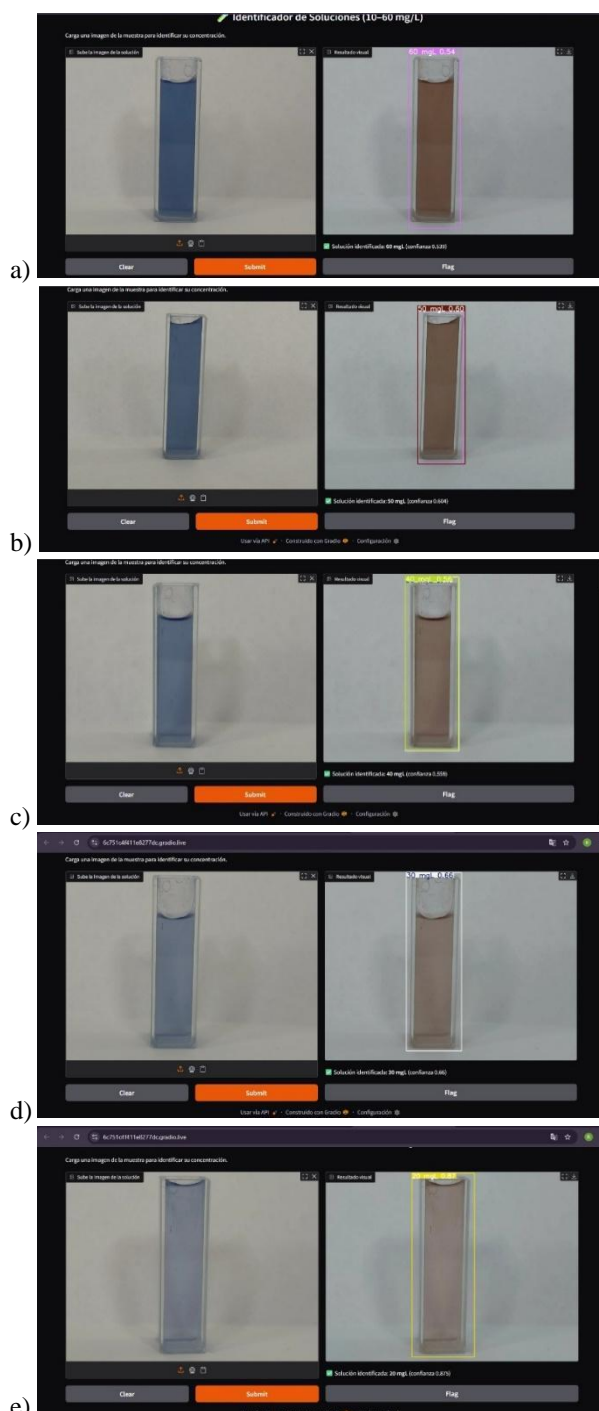


Fig 3. Identificación de los colorantes en la página web a diferentes concentraciones; a) 60 mg/L, b) 50 mg/L, c) 40 mg/L, d) 30 mg/L, e) 20 y f) 10 mg/L.

En las Figuras 3 a–e se observan valores de confianza entre 0.52 y 0.66 durante la inferencia en la interfaz web, los cuales aparentan contradecir la precisión global del modelo 90 %. Sin embargo, estos valores no representan la exactitud del sistema ni una probabilidad calibrada de clasificación, sino el confidence score de detección generado por YOLOv5. Este valor corresponde al producto entre la probabilidad de existencia del objeto y la probabilidad de la clase predicha, por lo que suele ser numéricamente menor que métricas globales como precisión, recall o mAP.

Las métricas de evaluación (Precisión = 0.93, Recall = 0.91, mAP@0.5 = 0.94) se calcularon sobre el conjunto de validación completo y reflejan el desempeño estadístico del modelo en múltiples muestras, mientras que el confidence score mostrado en la interfaz corresponde únicamente a una predicción individual en tiempo real y no está calibrado como probabilidad absoluta. Por ello, valores de confianza moderados no implican bajo desempeño, sino una estimación relativa de certeza del modelo bajo condiciones específicas de iluminación de captura y variabilidad cromática.

6. Resultados del entrenamiento, evaluación y desempeño del sistema

El entrenamiento del modelo CNN basado en la arquitectura YOLOv5 generó un conjunto de resultados que permiten evaluar su capacidad para clasificar adecuadamente las tonalidades del colorante azul índigo en función de su concentración. La curva de aprendizaje obtenida durante las 100 épocas demostró un comportamiento estable y con tendencia clara hacia la convergencia. Desde las primeras iteraciones, la función de pérdida presentó una disminución acelerada, indicando que la red neuronal logró identificar los patrones tonales distintivos presentes en los datos de entrenamiento. Conforme avanzaron las épocas, el descenso de la pérdida se volvió más progresivo hasta alcanzar una zona de estabilidad alrededor de la época 70, momento en el cual el modelo mostró un equilibrio entre ajuste adecuado y mitigación del sobreajuste.

La métrica de precisión global (precisión) superó el 90 %, lo que sugiere que el modelo es altamente competente para distinguir entre las seis clases de concentración definidas. Las clases intermedias (20 mg/L, 30 mg/L y 40 mg/L) fueron las que presentaron mejores resultados, con valores de precisión entre 92 % y 95 %, debido a que presentan diferencias tonales más evidentes y con mayor contraste entre ellas. En contraste, las clases extremas particularmente 10 mg/L mostraron una ligera disminución de precisión, atribuida a la sutileza de los cambios tonales en bajas concentraciones y a la sensibilidad del sensor de la cámara ante condiciones mínimas de iluminación.

No obstante, la disminución en estas clases específicas no representa una falla del modelo, sino una característica inherente a la propia naturaleza del fenómeno físico: las soluciones más diluidas tienen un contraste visual más tenue y altamente dependiente de la iluminación. De hecho, esta observación refuerza la importancia del diseño de la unidad experimental y la inclusión de múltiples escenarios lumínicos durante el preprocesamiento y el aumento de datos. La red neuronal, aun en estas condiciones desafiantes, logró mantener niveles de clasificación aceptables, lo que demuestra su robustez frente a variabilidad visual. Durante la evaluación con el conjunto de prueba (20 % del dataset total), la red neuronal mantuvo valores altos de recall, lo cual indica que no solo logra clasificar correctamente imágenes representativas, sino también casos menos comunes dentro de cada categoría. La matriz de confusión generada para la última época mostró que la mayoría de los errores correspondieron a confusiones entre clases contiguas, lo que es coherente con la continuidad natural del gradiente tonal del colorante. La ausencia de errores graves, por ejemplo, confundir 10 mg/L con 60 mg/L evidencia que la red realmente aprendió la estructura interna de los patrones de color y no meras correlaciones superficiales.

Cuando el modelo se integró en la plataforma web, los resultados de inferencia mantuvieron coherencia con los obtenidos durante la etapa de entrenamiento. El tiempo promedio de respuesta osciló entre 200 y 300 milisegundos en CPU, dependiendo del tamaño de la imagen, lo que demuestra que el sistema puede utilizarse en escenarios operativos sin comprometer la experiencia del usuario. En un entorno con GPU, este tiempo disminuyó incluso por debajo de los 150 milisegundos, habilitando la posibilidad de escalamiento hacia aplicaciones industriales o de monitoreo continuo.

Un análisis comparativo cualitativo entre las predicciones del modelo y los valores de absorbancia obtenidos mediante espectrofotometría reveló una correspondencia lógica entre la clase asignada por el modelo y la intensidad tonal esperada en función de la concentración. Este hallazgo permite sostener que, aunque el sistema no reemplaza la medición cuantitativa continua que proporciona un espectrofotómetro, sí constituye un método alternativo funcional para clasificación automática, rápida y de bajo costo. El modelo demuestra potencial para futuras extensiones, como la estimación continua de concentración mediante redes regresivas o la integración con

sensores IoT para monitoreo autónomo, sobre todo en procesos continuos donde el criterio de aceptación se enfoque en el cumplimiento de un patrón estándar.

En conjunto, los resultados obtenidos muestran que la arquitectura YOLOv5, junto con un diseño experimental controlado y un proceso de preprocesamiento adecuado, puede identificar diferencias tonales sutiles en soluciones químicas. Esto abre la puerta al desarrollo de sistemas de análisis basados en visión artificial que permitan automatizar procesos de cuantificación visual en entornos donde la instrumentación convencional es costosa, compleja o inaccesible.

7. Limitaciones del estudio

Aunque el sistema desarrollado demuestra un desempeño sólido en la clasificación de tonalidades del colorante AI mediante visión e inteligencia artificiales, es importante reconocer las limitaciones inherentes tanto al diseño experimental como a la arquitectura del modelo. En primer lugar, el tamaño del conjunto de datos, compuesto por 217 imágenes, representa una muestra relativamente reducida para entrenar modelos basados en detección y clasificación, especialmente considerando las variaciones de iluminación, ángulo y ruido que pueden presentarse en entornos industriales reales. Si bien las técnicas de aumento de datos contribuyeron a mejorar la generalización, un mayor volumen de muestras reales permitiría capturar variabilidad más amplia y reducir las confusiones entre clases contiguas. Otro aspecto que considerar es la sensibilidad del sistema ante cambios sutiles de iluminación. A pesar del uso de una caja oscura e iluminación LED controlada, incluso pequeñas variaciones en la intensidad luminosa pueden afectar los valores capturados, especialmente en las concentraciones más bajas. Esta dependencia lumínica limita parcialmente la reproducibilidad del método en ambientes no controlados o con sensores fotográficos de menor calidad. Asimismo, la clasificación basada en clases discretas restringe la capacidad del modelo para estimar concentraciones intermedias o valores continuos. Aunque YOLOv5 mostró eficiencia en la identificación por categorías, su estructura no está optimizada para tareas de regresión directa. Esto implica que el sistema no puede sustituir completamente la precisión cuantitativa de un espectrofotómetro, sino que actúa como un método alternativo de clasificación rápida. Finalmente, la integración del modelo en la plataforma web mediante Gradio depende del rendimiento del servidor y del hardware disponible. En implementaciones locales con CPU, el tiempo de respuesta puede aumentar bajo cargas elevadas o con imágenes de gran resolución. Para aplicaciones industriales en tiempo real, estos factores deben considerarse cuidadosamente.

8. Trabajo a futuro

A partir de los resultados obtenidos y de las limitaciones identificadas, se presentan diversas líneas de trabajo que permitirían robustecer, escalar y mejorar el sistema propuesto. En primer lugar, la expansión del dataset es un paso

fundamental, por lo tanto, la recolección de imágenes adicionales bajo diferentes configuraciones lumínicas, temperaturas de color, variaciones de cámara, óptica y condiciones ambientales permitiría entrenar modelos más generalizables y menos sensibles a fluctuaciones experimentales. Esto podría complementarse con cámaras especializadas o sensores ópticos calibrados que minimicen el ruido en bajas concentraciones. Una segunda línea de avance consiste en la transición desde un modelo de clasificación hacia un modelo de regresión continua. Arquitecturas como EfficientNet, ResNet o incluso versiones modificadas de YOLO podrían adaptarse para predecir directamente la concentración del colorante en mg/L. Este enfoque permitiría generar un sistema más comparable con un espectrofotómetro, capaz de estimar valores puntuales y no únicamente categorías discretas. De igual forma, el sistema podría beneficiarse de una integración más profunda con tecnologías IoT. La automatización completa del proceso incluyendo el llenado, vaciado, almacenamiento de datos y toma de imágenes permitiría convertir la unidad experimental en un módulo autónomo de monitoreo continuo. Esta integración habilitaría aplicaciones en líneas de producción textil, plantas de tratamiento de agua o laboratorios de control de calidad. En cuanto a la plataforma web, una futura implementación podría migrar desde Gradio hacia una infraestructura más robusta basada en frameworks como Flask, FastAPI o Django, permitiendo autenticación de usuarios, historiales de mediciones, visualización avanzada de datos y escalamiento mediante GPUs en la nube.

Finalmente, se plantea como trabajo futuro la validación del sistema con otros colorantes, matrices químicas o contaminantes industriales. Si el modelo demuestra capacidad de adaptación mediante transferencia de aprendizaje, podría convertirse en una herramienta versátil para el análisis colorimétrico basado en visión artificial, reduciendo costos y democratizando el acceso a tecnologías de cuantificación óptica.

9. Resultados, discusión y curva de calibración

La Figura 4, se muestra la curva de calibración obtenida a partir de las soluciones acuosas de azul índigo. Los datos espectrofotométricos mostraron una relación lineal altamente significativa entre la concentración del colorante y la absorbancia ($r = 0.9991$, $R^2 = 0.9982$, R^2 ajustado = 0.998, $p < 0.001$). Esta linealidad confirma que el azul índigo presenta un comportamiento óptico estable en el rango evaluado, lo que lo convierte en un candidato adecuado para ser cuantificado mediante métodos alternativos como visión computacional, donde habitualmente se busca replicar esta relación referencia respuesta. El aumento de absorbancia se acompañó de un incremento visible en la intensidad y profundidad de color en los tubos estándar, lo que concuerda con lo reportado respecto a la consistencia cromática del colorante en soluciones acuosas.

La implementación de la caja oscura modificada que integra una cámara fija, iluminación LED constante, tres bombas controladas desde Arduino, botones de operación y un

contenedor para la muestra lo que permitió generar una base de datos visual sustancialmente más homogénea que capturas realizadas sin control de iluminación. Desde una perspectiva experimental, el control del ambiente redujo el ruido causado por: variaciones en la intensidad lumínica, efectos de sombras, reflejos superficiales, cambios en el balance de blancos de la cámara.

Este control mejoró la discriminación visual entre concentraciones cercanas y redujo la variabilidad, fortaleciendo la calidad del dataset que se usó para entrenar el modelo CNN. En estudios previos, este tipo de control óptico ha demostrado ser crucial para la reproducibilidad en tareas de clasificación basadas en color (Valdez Torres, 2022), y los resultados de este trabajo refuerzan dicha observación.

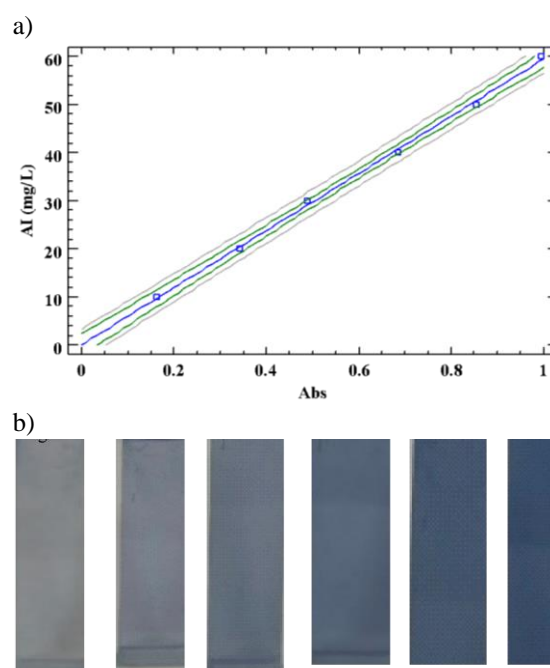


Fig. 4 Curva de calibración de las soluciones acuosas, $R^2=0.9982$.

10. Modelo CNN

La red neuronal convolucional entrenada con las imágenes capturadas en la caja negra logró una precisión superior al 90% en la clasificación de las muestras por concentración. Este resultado indica que el modelo fue capaz de aprender patrones visuales asociados a los niveles de colorante y que la variabilidad cromática introducida por la concentración se refleja de forma consistente en los píxeles capturados. No obstante, el uso de clasificación introduce una limitación importante.

El modelo distingue categorías de concentración, pero no estima valores continuos. En otras palabras, la CNN replica la forma cualitativa de la curva de calibración, pero no su

- Malashin, I. T. (2024). Optimizing neural networks for chemical reaction prediction: Insights from Methylene Blue reduction reactions. *International Journal of Molecular Sciences*.
- Mayer-Schinberger, V. (Enero de 2013). Obtenido de ResearchGate: El concepto de Big Data se sostiene en la gestión y análisis de grandes volúmenes de información heterogénea, generada a alta velocidad y con un enfoque en la veracidad y valor de los datos (Mayer-Schönberger & Cukier, 2013). En el ámbito sanitario, Big D
- Muñoz, E. R. (2022). Redes neuronales convolucionales profundas con transferencia de aprendizaje para la detección y clasificación automatizada de tumores en imágenes de tomosíntesis. *Doctoral dissertation, Instituto Nacional de Astrofísica, Óptica y Electrónica*.
- Nie, Y. C. (2025). An improved CNN model in image classification application on water turbidity. *Scientific Reports*.
- OMS. (18 de agosto de 2021). Obtenido de World Health Organization: <https://www.who.int/publications/i/item/9789240020924>
- OPS. (2022). Obtenido de Organización Panamericana de la salud: <https://www.paho.org/es/temas/sistemas-informacion-para-salud>
- R. Holkar, C., J. Jadhav, A., V. Pinjari, D., M. Mahamuni, N., & B. Pandit, A. (01 de Noviembre de 2016). A critical review on textile wastewater treatments: Possible approaches. (Elsevier, Ed.) *Journal of Environmental Management*, 351-366. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S0301479716305266?via%3Dihub>
- rootstack. (2025). Obtenido de rootstack: <https://rootstack.com/es/blog/nodejs-vs-react-crear-sitio-web>
- Salud, O. M. (18 de agosto de 2021). Obtenido de World Health Organization: <https://www.who.int/publications/i/item/9789240020924>
- Saludbydiaz. (7 de marzo de 2025). Obtenido de Monitorización y diagnóstico de la salud mediante métodos de deep learning: <https://saludbydiaz.com/2025/03/07/monitorizacion-y-diagnostico-de-la-salud-mediante-metodos-de-deep-learning/>
- Santana Santana, J. C. (2024). Framework para la implementación de arquitecturas de redes neuronales. *Bachelor's thesis*.
- Sarika H. Vithalkar, R. M. (2020). Adsorptive removal of crystal violet from aqueous solution by cross-linked chitosan coated bentonite. ScienceDirect, 1025-1032. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S221478532033538?via%3Dihub>
- Shaik, T. (5 de enero de 2023). Obtenido de Wires : https://wires-onlinelibrary-wiley-com.translate.goog/doi/10.1002/widm.1485?cookieSet=1&_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc
- Studio, C. d. (9 de 10 de 2025). Obtenido de Código de Visual Studio: <https://code.visualstudio.com/>
- Susawaengsup, C. C. (2024). Phytochemical and pharmacological properties of a traditional herb. *Molecular Biotechnology*.
- Tansel Ersavas, M. A. (01 de mayo de 2024). Novel applications of Convolutional Neural Networks in the age of Transformers. *Scientific Reports*. Obtenido de <https://www.nature.com/articles/s41598-024-60709-z?fromPaywallRec=true>
- TensorFlow. (2024). Obtenido de TensorFlow: https://www.tensorflow.org/model_optimization?hl=es todos, I. I. (19 de mayo de 2025). Obtenido de Inteligencia los artificial desarrolladores para todos: <https://ai.google.dev/edge/litert>
- Topol, D. E. (12 de Marzo de 2019). Obtenido de Basic Books: <https://www.hachettebookgroup.com/titles/eric-topol/deep-medicine/9781541644632/?lens=basic-books>
- Topol, E. J. (7 de Enero de 2020). Obtenido de nature medicine: <https://www.nature.com/articles/s41591-018-0300-7>
- Uluçay, A. C. (2024). Investigation of Dyestuff Recycled from Wastewater Containing Indigo/Sulfur Dyes. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*.
- Valdez Torres, D. I. (2022). Diseño e implementación de un Prototipo para un Sistema de despaletización de cajas con clasificación por color utilizando visión artificial y Cloud data transfer. *Bachelor's thesis*.
- Wang, C. Y. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*.
- Yun, S. H. (2019). Cutmix: Regularization strategy to train strong classifiers with localizable features. In *Proceedings of the IEEE/CVF international conference on computer vision*.