

TECNOLÓGICO DE ESTUDIOS SUPERIORES DE TIANGUISTENCO

DIVISIÓN DE INGENIERÍA EN SISTEMAS COMPUTACIONALES

**Modelo de Inteligencia artificial por reconocimiento de
imágenes aplicada en la predicción de Color en soluciones
acuosas de azul índigo**

TESIS

Para obtener el título de
INGENIERO EN SISTEMAS COMPUTACIONALES

Presenta:

Ricardo Alejandro Sánchez González

Asesor(a):

Mtra. María Guadalupe Pineda Arizmendi

Revisores:

Dr. Luis Antonio Castillo Suárez

Santiago Tianguistenco, Estado de México, junio 2026

RESUMEN

La industria textil constituye uno de los sectores productivos de mayor relevancia económica a nivel global. No obstante, sus procesos de teñido y acabado generan efluentes con altas concentraciones de color, lo que representa un problema ambiental significativo. Debido a ello, la normativa vigente establece límites estrictos para la descarga de aguas residuales, regulando especialmente el parámetro de color como indicador de contaminación.

Los métodos tradicionales empleados para su cuantificación, como la espectrofotometría ultravioleta-visible (UV-Vis), si bien ofrecen alta precisión, implican costos elevados tanto en equipamiento como en mantenimiento, además de requerir personal capacitado para su correcta operación y análisis.

Los métodos convencionales para la cuantificación de color tienen una dependencia tecnológica que requieren estos equipos especializados que cuestan demasiado dinero para adquisición de estos y tienen una logística de mantenimiento compleja, ya que las micro y medianas empresas no cuentan con el presupuesto o el personal capacitado para operar espectrofotómetros de forma rutinaria. Ante esta problemática tenemos como objetivo diseñar y evaluar un modelo de inteligencia artificial basado en reconocimiento de imágenes para la detección de color en unidades de platino-cobalto.

Se diseñó un prototipo capaz de analizar muestras mediante imágenes bajo condiciones controladas como iluminación y así reunir un conjunto de datos. Se desarrolló un modelo de aprendizaje en el entorno de Google Colab mediante el uso de una red neuronal convolucional, el cual fue entrenado con las imágenes recopiladas que previamente fueron etiquetadas según la concentración en unidades de platino-cobalto y mg/L del colorante azul índigo, a través de una curva de calibración realizada con un espectrofotómetro DR600 a 330 nm.

Para los primeros resultados en un etiquetado de clase se introdujo un conjunto de datos que contenía 50 imágenes para la clase de 10 mg/l y 20 imágenes para la clase 20 mg/L con una configuración de la red a 50 épocas para 30% de entrenamiento y validación del 70% obteniendo resultados significativos pero que debía mejorarse el modelo para analizar el total de clases. Por lo que se mejoró el modelo y para la segunda prueba esta contiene un data set

de 348 imágenes en total para hacer el entrenamiento para la primera clase contiene 66 imágenes en la primera solución de 10 mg/L, 42 para la solución de 20 mg/L, 60 para la de 30 mg/L, 17 para la de 60 mg/L, 22 para la de 60 mg/L y 60 para la de 60 mg/L, esto nos permitió una mejora significativa en el entrenamiento del modelo ya que la configuración de la red a 100 épocas con un batch de 16 para obtener resultados superiores a 0.95 en cada una de las soluciones

Utilizamos redes neuronales convolucionales (CNN), estas son las encargadas de entender la composición de la imagen a través de capas especializadas que imitan la vista humana, a diferencia de una red neuronal simple, la CNN conserva la relación de píxeles que esta puede llegar a tener por que el color no es un punto único si no que es una distribución de intensidades en una sola matriz. La extracción de características que hace la CNN son capas iniciales que detecta bordes, las intermedias detecta texturas de color y las finales interpretan la concentración de Platino-Cobalto.

El detector de objetos utilizado es YOLOv5 por que la CNN analiza y Yolo es el especialista de localizar y clasificar en tiempo real la imagen, A diferencia de los modelos antiguos que se escaneaba la imagen, Yolo solo hace una pasada que hace ideal este modelo para obtener una respuesta inmediata. Gracias a las etiquetas utilizadas con Roboflow, Yolo aprende a crear delimitación para que no se confunda con el ruido que llegue a tener el modelo.

En conclusión, el estudio aporta una propuesta innovadora, económica y sostenible para el monitoreo de aguas residuales en la industria textil ya que esta investigación aporta una alternativa más económica y si se cumple con los requerimientos específicos, el modelo puede tener una alta confiabilidad, esto abre paso a más investigaciones y también se le puede dar un enfoque totalmente diferente y ser igual de preciso.

ABSTRACT

The textile industry is one of the most economically important production sectors globally. However, its dyeing and finishing processes generate effluents with high concentrations of color, which represents a significant environmental problem. Therefore, current regulations establish strict limits for wastewater discharge, specifically regulating color as an indicator of pollution.

Traditional methods used for color quantification, such as ultraviolet-visible (UV-Vis) spectrophotometry, while offering high precision, involve high costs in both equipment and maintenance, as well as requiring trained personnel for their correct operation and analysis.

Conventional methods for color quantification are technologically dependent on specialized equipment that is prohibitively expensive to acquire and has complex maintenance logistics, since micro and small businesses lack the budget or trained personnel to operate spectrophotometers routinely. To address this problem, our objective is to design and evaluate an artificial intelligence model based on image recognition for color detection in platinum-cobalt units.

A prototype was designed to analyze samples using images under controlled conditions, such as lighting, to gather a dataset. A machine learning model was developed in the Google Colab environment using a convolutional neural network. This model was trained on the collected images, which had been previously labeled according to the concentration of indigo blue dye in platinum-cobalt units and mg/L, using a calibration curve obtained with a DR600 spectrophotometer at 330 nm.

For initial results in class labeling, a dataset containing 50 images for the 10 mg/L class and 20 images for the 20 mg/L class was used. The network was configured with 50 epochs for 30% training and 70% validation, yielding significant results. However, the model needed improvement to analyze all classes. Therefore, the model was improved, and for the second test, it contains a dataset of 348 images in total. For training, the first class contains 66 images in the first solution of 10 mg/L, 42 for the 20 mg/L solution, 60 for the 30 mg/L solution, 17 for the 60 mg/L solution, 22 for the 60 mg/L solution, and 60 for the 60 mg/L solution. This

allowed us to significantly improve the model training, since the network configuration of 100 epochs with a batch of 16 yielded results greater than 0.95 in each of the solutions.

We used convolutional neural networks (CNNs). These are responsible for understanding the image composition through specialized layers that mimic human vision. Unlike a simple neural network, the CNN preserves the pixel ratio because color is not a single point but rather a distribution of intensities. Single matrix. The CNN's feature extraction involves initial layers that detect edges, intermediate layers that detect color textures, and final layers that interpret the Platinum-Cobalt concentration.

The object detector used is YOLOv5 because the CNN analyzes the image, and YOLO is the specialist in locating and classifying it in real time. Unlike older models that scanned the image, YOLO only performs one pass, making it ideal for obtaining an immediate response. Thanks to the labels used with Roboflow, YOLO learns to create bounding boxes so it doesn't get confused by any noise the model might have.

In conclusion, the study provides an innovative, economical, and sustainable proposal for wastewater monitoring in the textile industry. This research offers a more cost-effective alternative, and if the specific requirements are met, the model can have high reliability. This opens the door to further research, and it can also be approached in a completely different way while remaining equally accurate.

AGRADECIMIENTOS

A dios por siempre guiarme en cada paso que he dado.

A mi madre que siempre estuvo para mí y el apoyo que siempre me brindo.

A mis asesores por su dedicación y orientación que me brindaron.

Al departamento de Investigación y Desarrollo Tecnológico y a Dirección General del Tecnológico Estudios Superiores de Tianguistenco por el apoyo y finamiento para la participación en el 1° congreso internacional de agua limpia y saneamiento del TecNM realizado en la Ciudad de Tijuana, Baja California, cuya participación contribuyó a la difusión de los resultados de esta investigación.

Al Consejo Mexiquense de Ciencia y Tecnología (COMECYT) por el financiamiento otorgado a través del proyecto C-SINERGIA-FICDTEM-25-027 destinado a la ejecución de las pruebas experimentales de dicha investigación y por el apoyo financiero destinado a estudiantes que participan en el proyecto.

AL LABORATORIO DE INVESTIGACIÓN DEL TEST.

DEDICATORIA

Dedico este trabajo de tesis a Dios por darme la vida y la fuerza para superar cada reto. A mi madre por su amor infinito y por ser mi mayor motivación cada día, que me da ánimos y nunca me ha dejado solo, a mi hermano por su apoyo que me ha dado.

A mis asesores agradezco profundamente su guía, paciencia y conocimientos que dieron forma a esta investigación. Finalmente, a mis amigos y a todas las personas que creyeron en mí, les doy las gracias por acompañarme en este camino y por ser el impulso necesario para llegar a la meta.

ÍNDICE GENERAL

APROBACIÓN DE IMPRESIÓN DE TESIS	II
REPORTE DE SIMILITUD	III
RESUMEN	IV
ABSTRACT	VI
HOJA DE ORIGINALIDAD	VIII
HOJA DE PERMISO DE DATOS	IX
AGRADECIMIENTOS	XI
DEDICATORIA	XII
ÍNDICE DE TABLAS	XVI
ÍNDICE DE ILASTRACIONES	XVII
1. INTRODUCCIÓN	1
1.1. CONTEXTO	2
2. ANTECEDENTES	4
2.1 El color en aguas residuales	4
2.2 La industria de la mezclilla	6
2.3 Impacto del Color en el ambiente	9
2.4 Impacto de los colorantes en la salud humana	11
2.5 Regulación del color	12
2.6 Unidades de Pt-Co	13
2.7 Inteligencia Artificial	14
2.8 CNN	16
2.9 Visión por computadora	17
2.10 Conjunto de datos	18

2.11 Roboflow	19
2.12 Yolo V5	19
2.13 Crisp/DM	20
2.14 Arduino	21
2.15 Componentes	22
3. PLANTEAMIENTO DEL PROBLEMA	23
4. JUSTIFICACIÓN	24
5. OBJETIVOS	25
5.1 Objetivo general	25
5.2 Objetivos específicos	25
6. HIPÓTESIS	26
7. METODOLOGÍA	26
7.1 Diseño y construcción de un dispositivo para la captura de imágenes de las muestras líquidas.	27
7.2 Curva de calibración Pt-Co de soluciones acuosas de un estándar del colorante azul índigo.	32
7.3 Base de datos de concentración conocida en unidades de Pt-Co e imagen.	33
7.4 Modelo de inteligencia artificial para la predicción de las concentraciones de estándar azul índigo Color Pt-Co.	34
7.5 Diseño y desarrollo de una interfaz gráfica para la identificación de soluciones.	35
8. RESULTADOS Y DISCUSIÓN	36
8.1 Curva de calibración Pt-Co de soluciones	38
8.3 Modelo de inteligencia medición de color	39
8.4 Sistema web de análisis de imagen de color	40
8.5 Validación del método de cuantificación	64

8.5 Productos académicos	67
9. CONCLUSIONES	76
10. RECOMENDACIONES	76
11. FUENTES BIBLIOGRÁFICAS	78
12. ANEXOS	83
Anexo 1 A Descripción del código (app.py)	83
Anexo 1 B Descripción del código(html)	87
13. ANEXO FOTOGRÁFICO	89

ÍNDICE DE TABLAS

Tabla 1 Estructura química de los colorantes más usados en la industria de la mezclilla.....	5
Tabla 2 Empresas, regiones y producción de mezclilla a nivel global.	8
Tabla 3 Estados donde se producen textiles y sus principales impactos ambientales..	10
Tabla 4 Muestra niveles de concentración de color según diversas normas oficiales..	12
Tabla 5 Muestra las principales industrias y aplicaciones donde se determina el color.	13
Tabla 6 Comparativa entre las ventajas y desventajas de usar unidades de Pt-Co para la medición de color en aguas.....	14
Tabla 7 Numero de imágenes por solución.	19
Tabla 8 Resultados del entrenamiento en Google Colab.	37
Tabla 9 Resultado de entrenamiento en Google Colab	59
Tabla 10 Validación de mediciones en pruebas de reproducibilidad y repetibilidad usando soluciones acuosas	65
Tabla 11 evidencia fotográfica	89

ÍNDICE DE ILASTRACIONES

1 a) Indigotina (Azul Índigo).....	6
2 b) Indigo Blanco (Leuco-Indigo).....	6
3 c) Colorantes Reactivos (Remazol Brilliant Blue R)	6
4 d) Colorantes de Azufre (Negro de Azufre)	6
Ilustración 5 esquematización de perceptrón multicapa. Recuperado de (Nielsen, 2015).....	16
Ilustración 6 etapas de un sistema de visión artificial.....	18
Ilustración 7 Metodología Crisp/DM. Imagen recuperada de (Peralta, 2014)	21
Ilustración 8 metodología Crisp DM	26
Ilustración 9 Cámara fotográfica con el recipiente de almacenamiento de muestra...	28
Ilustración 10 prototipo de la caja.....	29
Ilustración 11 implementación del Arduino	30
Ilustración 12 ubicación y funcionamiento de las bombas.....	31
Ilustración 13 muestra de la conexión de los botones con el Arduino.....	31
Ilustración 14 interfaz de Roboflow	34
Ilustración 15 Página web implementada en Colab.....	36
Ilustración 16 identificación de las soluciones en Roboflow	36
Ilustración 17 Curva de calibración con espectrofotómetro DR6000	38
Ilustración 18 soluciones de 10 hasta 60 mg/L.....	39
Ilustración 19 Pagina web	45
Ilustración 20 agregar imagen.....	46
Ilustración 21 Identificar la imagen	46
Ilustración 22 Muestra del resultado.....	47
Ilustración 23 Resultado.....	47
Ilustración 24 botón de limpiar el resultado.....	48
Ilustración 25 botón de limpiar	48
Ilustración 26 dirección ip.....	48
Ilustración 27 Cragar una imagen.....	49
Ilustración 28 Resultado de la imagen identificada	49
Ilustración 29 Resultado.....	50
Ilustración 30 Métricas de identificación	50
Ilustración 31 Instrucciones de uso	51
Ilustración 32 Botón limpiar el resultado	52
Ilustración 33 Página web corriendo	54
Ilustración 34 dirección ip desde py	54
Ilustración 35 Modelo del Código.....	55
Ilustración 36 Inferencia del Código	56
Ilustración 37 Estructura del Código	57

Ilustración 38 Entrenamiento en Colab.....	58
Ilustración 39 Repositorios de descarga para Yolo V5	60
Ilustración 40 Código para el entrenamiento	60
Ilustración 41 Flask.....	61
Ilustración 42 Ruta.....	62

1. INTRODUCCIÓN

Actividades industriales como la producción textil generan un alto impacto en contaminación de ríos, lagos y mantos acuíferos, principalmente debido al uso de grandes volúmenes de agua y a la descarga de esta misma. Uno de los principales colorantes es el azul índigo ampliamente utilizado en la fabricación de la mezclilla, ya que es un contaminante que persistente en el agua, su dificultad de degradarse y provocar efectos severos como la disminución de la penetración de la luz solar en cuerpos de agua y alteración de los procesos fotosintéticos de plantas acuáticas (Kant, Textile dyeing industry an environmental hazard., 2012)

La utilización de métodos convencionales como son los espectrofotómetros ofrece resultados exactos, aunque estas presentan limitaciones como son los altos costos de los equipos y la dependencia de infraestructura especializada como lo es personal capacitado y el constante mantenimiento. Una alternativa más accesible es el uso de la inteligencia artificial aplicada para el reconocimiento de imágenes surge como una propuesta innovadora a desarrollar sistemas más económicos, accesibles y automatizados, capaces de analizar en tiempo real la concentración de color en soluciones acuosas (Worood A., y otros, 2021).

Este trabajo ofrece una alternativa tecnológica e innovadora para la evaluación de aguas residuales en industrias textiles, sino que también busca la contribución a la generación de conocimiento científico y a la implementación de prácticas más sostenibles.

1.1. CONTEXTO

La calidad del agua es uno de los desafíos más grandes que podemos tener hoy en día. La industria textil es uno de los sectores con mayor impacto ambiental por la contaminación que esta genera día con día, esto se debe al elevado consumo de agua en sus procesos y la descarga de colorantes entre ellos el azul índigo que es utilizado de mayor manera en la producción de la mezclilla, este colorante presenta una baja biodegradabilidad y persistencia ambiental, afectando la penetración de la luz solar en cuerpos de agua lo que disminuye la fotosíntesis de plantas acuáticas y puede provocar toxicidad en especies como peces y microorganismos. (Esther, Tibor , & Gyula, 2004)

La aplicación de aprendizajes automáticos específicamente en la clasificación del agua es destacado por su capacidad de mejorar la precisión frente a los procesos tradicionales que son ocupados en industrias textiles, su enfoque es hacia la gestión, la calidad del agua potable y la protección ambiental ya que analiza los parámetros físicos, químicos y microbiológicos que se emplean para clasificar diferentes tipos de agua potable así como los enfoques tradicionales basados en el aprendizaje automático ha mejorado exactitud y eficiencia (Figueroa, Silvas, & Hidalgo, 2025).

El diseño y el desarrollo de un sistema capaz de agua jabonosa tratada proveniente de ciclos de lavado domestico utilizando redes neuronales implementadas en un Raspberry pi 4 junto a sensores de pH y turbidez. El uso de un modelo así permitió la clasificación de las muestras en categorías que realizo, demostrando que los enfoques basados en un aprendizaje automático pueden automatizar y mejorar procesos en la gestión de procesos hídricos (Ibarra, Castillo, & Montelongo, 2021).

La presentación de un sistema que es capaz de clasificar contaminantes en muestras de agua mediante aprendizaje automático. Este proyecto se centra en la construcción de un modelo de machine learning entrenado con imágenes categorizadas empleando la herramienta de entrenamiento lobe. Este modelo se descarga y se integra en un Raspberry pi 4 para realizar la clasificación en tiempo real, esto demuestra la viabilidad de emplear visión por

computadora y machine learning para tareas de monitoreo ambiental en sustitución a métodos tradicionales que suelen ser costosos (Ramírez Quiroga, 2022).

Con este problema de la contaminación de la industria textil, se hace necesaria la implementación de métodos innovadores para la cuantificación y el monitoreo del color en medios acuosos. Mientras que las técnicas convencionales, como la espectrofotometría UV-Vis, son confiables pero costosas y poco accesibles (James Holler & Stanley R. , 2015), la incorporación de herramientas de inteligencia artificial abre la posibilidad de realizar análisis más rápidos, económicos y automatizados mediante el uso de imágenes digitales.

Esta investigación resulta relevante, ya que surge del poder contar con métodos accesibles y confiables para la cuantificación de colorantes en soluciones acuosas, específicamente en la industria textil. El monitoreo del color es un factor clave para el control y detección de contaminantes en cuerpos acuíferos. Desde el punto de vista científico, el trabajo contribuye al análisis del uso de modelos de inteligencia artificial y visión por computadora como una alternativa a técnicas tradicionales, ampliando el conocimiento sobre su aplicabilidad en la cuantificación de color (Franco, Ramos, Ovando-Javier, & Monte, 2023).

Asimismo, la investigación aborda el problema identificado: la dependencia de espectrofotómetros UV-Vis las cuales son precisas y confiables, pero requieren equipos de alto costo y condiciones de operación específicas. Esta situación limita su adquisición por parte de micro y medianas empresas, así como la implementación de sistemas de monitoreo continuo que ronda desde los 10k USD en adelante (Moreno-Villalba & Ávila-Camacho, 2021). El estudio se enfoca en la evaluación de la viabilidad de un modelo de inteligencia artificial basado en imágenes para la identificación de concentración de azul índigo, considerando aspectos de precisión, robustez y accesibilidad, lo que justifica plenamente la realización de la presente

2. ANTECEDENTES

2.1 El color en aguas residuales

Las aguas residuales son aquellas las cuales se generan después de ser usadas y cuyas propiedades físicas y químicas cambian ya han sido manipuladas por el ser humano, es decir, su calidad cambio derivado de una actividad antropogénica. Pueden ser de origen doméstico, que son las que se generan en casas, comercios o lugares de trabajo las cuales son usadas para actividades del hogar como lavado de trastes, ropa, preparación de comida. El color de estas aguas puede ser de un tono café o amarillento, esto se debe por la materia orgánica, jabones, heces, etc (ferrovial, 2024).

El sector agrícola y ganadero es el mayor consumidor de agua potable, las aguas de la industria agrícola y ganadera se tiñen de un tono, verde, marrón o amarillento por los fertilizantes, pesticidas y sedimentos de la tierra que por arrastre se concentran (Cano, 2020) suelen contaminar ríos y lagos por escurrimiento, y estimulan la contaminación de pozo y del agua subterránea (Calixto, Nelson & Carrillo-Soto, 2022). El color verde de este tipo de aguas se debe a los compuestos orgánicos metálicos de cromo y a la clorofila que se origina de los desechos de las hojas de los cultivos (Mena Bolaños, 2019).

Los tonos amarillos se deben a los colorantes cromo hexavalentes o taninos, que suelen usarse en los textiles, curtiduría, en la industria alimentaria y química. Colores en tono marrón en las aguas son por la presencia de materia orgánica, lignina y compuestos de hierro que son principalmente derivados de la industria alimentaria, papelera, cervecera y agrícola. Las tonalidades en negro principalmente se pueden deber a compuestos de manganeso, aceites, grasas, sulfuros que son producto de la metalúrgica, automotriz, alimentaria y petrolera (Mena Bolaños, 2019).


La industria requiere grandes volúmenes de agua para el funcionamiento de sus procesos, el agua que es desechada o genera después de su uso (agua residual) contiene contaminantes tóxicos como metales pesados, colorantes, entre otros que son peligrosos para el ser humano. El color de las aguas industriales es muy diverso, podemos encontrar aguas de color azul, verde, rojo, amarillo, marrón por los colorantes, metales pesados, químicos y demás que se

mezclan en el agua después de ser usadas (Ortiz Pérez, 2021). Los tonos rojizos se deben a los colorantes rojos, compuestos de hierro o sangre, que se usan principalmente en la industria textil, alimentaria, metalúrgica y cosmética (Campos Ruiz, 2017).


Si bien, las aguas producidas por la lluvia no son aguas residuales pueden contener contaminantes de la atmosfera, su color puede ser grisáceo o negro por los sedimentos, aceites y contaminantes urbanos (Morales, Gutiérrez, & Andrade,, 2010). El tono blanco que se basa en partículas en suspensión yeso, cal, caolín, lechada de cal son uy comunes en construcción, cerámica y química.

En la industria de la mezclilla, el tono del agua puede variar, sin embargo, el tono azul se debe a los colorantes que se ocupan principalmente en los basado en cobre, azul de metileno, indico carmín y azul índigo, la Tabla 1 muestra la estructura química de los principales colorantes usados en la fabricación de pantalones de mezclilla.


Tabla 1 Estructura química de los colorantes más usados en la industria de la mezclilla.




1 a) Indigotina (Azul Índigo)



2 b) Indigo Blanco (Leuco-Indigo)



3 c) Colorantes Reactivos (Remazol Brilliant Blue R)



4 d) Colorantes de Azufre (Negro de Azufre)

El color es el resultado de la interacción entre la luz, los objetos y el sistema visual humano. La luz blanca como lo es la solar contiene todos los colores del espectro visible desde el violeta hasta el rojo. Cuando esta luz incide sobre un objeto, una parte es absorbida y otra es reflejada, determinando el color que percibimos. Desde otro enfoque, el color es una percepción del ser humano generada en el cerebro al interpretar señales nerviosas que le envían los fotorreceptores de la retina del ojo (Günther Wyszecki & S. , 2020)

2.2 La industria de la mezclilla

El denim es el proceso en el cual se le da el color o tonalidad de color que se desea tenga la prenda de mezclilla. Uno de los colores que es muy común en la mezclilla es el azul índigo el cual es insoluble a la naturaleza porque es teñido bajo condiciones especiales (Castro Astudillo, 2023).

Un reciente estudio en Tepetitla de Lardizábal, Tlaxcala, México, se evaluaron los impactos sociales como lo son los cambios económicos y ambientales en el municipio. A pesar de las dificultades para el trabajo los talleres y lavanderías funcionan de una manera clandestina, se concluyó que la contaminación del río Atoyac se ha intensificado por los talleres de confección y lavanderías de mezclilla, tanto formales como informales que generan altos niveles de contaminación. Las soluciones a corto y mediano plazo se han visto limitada por la falta de regulaciones. Para la mayoría de la población estos talleres representan la única fuente de ingresos, lo que dificulta enfrentar el problema de la contaminación, aunque las consecuencias en salud y medio ambiente son cada vez más notorias (Román, 2016).

La fabricación textil en México, principalmente la fabricación de mezclilla en Almoloya del río que la mayoría de estas empresas son familiares sustentan el comercio, importación e importación de algunas prendas de mezclilla específicamente los pantalones de mezclilla, la importación dentro del país puede llegar a monterrey, Cuernavaca, entre otras, pero para el teñido de la mezclilla se utilizan cierto tipo de sustancias y colores que son altamente peligrosas que se descargan en la laguna de Chignahuapan una de estas es el azul índigo para los pantalones de mezclilla, los colorantes directos también son muy utilizados pero estos requieren de sal para fijar el color, la laguna esta está ubicada en 52540 Almoloya del Río, Méx, ya que estos colorantes provocan severos daños a la salud y ambiente (Jiménez, 2023).

La actividad pesquera de especies como el charal, carpa, tilapia y *Girardinichthys* en el nacimiento del río Lerma se encuentra bajo amenaza. La disminución de oxígeno en el embalse está vinculada al incremento de la temperatura y a la acumulación de materia orgánica. De acuerdo con los pescadores locales, la causa principal es la degradación de la calidad del agua provocada por el vertido directo de aguas residuales sin tratar. (CONAPESCA, 2015).

La planta Kaltex, en San Juan del Río, Querétaro y la planta Lavamex, ubicada en Aguascalientes están involucradas en la producción y lavado de productos textiles en México, ambas fabricas realizan el lavado de mezclilla esta es una de las plantas más grandes de kaltex en todo México ya que produce fibras sintéticas, tejidos de algodón y mezclilla procesos de teñido, acabado y confección. El mercado al que provee es a marcas de moda rápida como lo

es zara, levi's, Walmart entre otras, así como la exportación de EE. UU, centro América y Asia, pero la presión por los costos bajos frente a productores chinos y bangladesíes (Economista, Alma Córdova / El, 2014).

Tabla 2 Empresas, regiones y producción de mezclilla a nivel global.

País	Producción	Regiones clave	Empresas destacadas
China	Más del 30% del denim mundial mayor exportador de telas y prendas terminadas.	Guangdong (centro de confección). Shandong (tejido de alta calidad).	Black Peony (uno de los mayores fabricantes de tela). Esquel Group (proveedor de marcas como Patagonia).
India	Segundo mayor productor de denim (15% del mercado global).	Ahmedabad (Gujarat): "La capital del denim de India". Tamil Nadu: Zonas de confección para exportación.	Arvind Mills (mayor fabricante de denim en India, proveedor de Levi's y Tommy Hilfiger). Nandan Denim.
Bangladesh	Enfoque: Prendas terminadas (jeans para H&M, Zara, GAP).	Exporta más de \$7 mil millones en denim al año. Más del 20% de las exportaciones textiles son jeans.	Square Denim. Pacific Jeans.
Pakistán	Tercer exportador mundial de tela de mezclilla.	Karachi (centro industrial). Faisalabad ("Manchester de Pakistán").	Crescent Bahuman. Artistic Denim Mills.
Turquía	Principal proveedor de denim premium para la UE. Marcas que producen allí: Diesel, Mavi, Colin's.	Uso de tecnología láser para acabados. Producción más sostenible (ahorro de agua).	ISKO Denim (uno de los mayores fabricantes del mundo). Bossa.

El prestigio de la marca Kaltex y el esfuerzo de sus aproximadamente 12,000 empleados han permitido que las exportaciones representen cerca del 30% de sus ventas totales. La empresa

se distingue por su innovación tecnológica, calidad y compromiso con la sostenibilidad, manteniendo un liderazgo consolidado en la industria textil global (Kaltex, s.f.).

2.3 Impacto del Color en el ambiente

Durante el proceso de lavado de la mezclilla, el agua residual generado contiene principalmente el azul índigo, puede tener formaldehído, cianuro e hidrosulfito de sodio que son altamente dañinos para la salud (Canchanya Balvim, 2021). Cabe mencionar que en el área textil se suele utilizar grandes cantidades de agua que incluyen colorantes, resistentes a la degradación que son difíciles de eliminar en plantas de tratamiento convencionales debido a su estructura química (Guzmán Gamboa, 2022). Revisión del estado de avance de las aplicaciones de la nanotecnología para la reducción de contaminantes presentes en los vertimientos de la industria textil.

En China se estima que el 70% de sus ríos se encuentran afectados por la contaminación, uno que se destaca es de la industria textil que estos son vertidos en ríos y llegan a grandes lagos causando severas consecuencias en la salud de china (Liu & Diamond, 2006).

En México los principales productores textiles son los estados de Guanajuato, Coahuila, Querétaro, Jalisco y el Estado de México, las industrias y sus principales impactos en estos estados son mostrados en la tabla 3.

En el estado de México, según estudios de la comisión nacional del agua (CONAGUA) se estima que al menos el 25% del agua residual que se descarga en la laguna de Chignahuapan, estado de México son provenientes de la industria y la ganadería (Rodríguez, Cedillo, & G. G, 2019).

Uno de los problemas que se tiene en el lavado de la mezclilla es la alteración en cuerpos hídricos lo que es el azul índigo, este no se degrada fácilmente, porque tiñe el agua de azul, reduciendo la penetración de luz solar en cuerpos de agua, lo que afecta la fotosíntesis de plantas acuáticas y algas, también la toxicidad para organismos acuáticos como los peces y microorganismos pueden sufrir estrés oxidativo y daño en branquias debido a los compuestos químicos asociados (Porkodi, Brahmane, Pathan, & Poojary, 2024).

Otro problema que se encuentra es el uso excesivo de agua para el lavado de la tela ya que Se requieren 10–100 L de agua por 1 kg de tela y van aumentando para los Lavados posteriores para lograr efectos "desgastados" que aumentan el consumo del agua (Francesco, , 2019).

Tabla 3 Estados donde se producen textiles y sus principales impactos ambientales.

Estado	Industria	Impactos	Ref
Guanajuato	Celaya y León: Grandes centros de producción textil con lavanderías que generan aguas con restos de índigo, sulfuros y metales pesados.	Contaminación del Río Lerma, uno de los más contaminados de México.	(Guanajuato, 2011)
Coahuila	Torreón y Saltillo: Zonas con industrias denim (Lavanderías de mezclilla para exportación).	Impacto: Presencia de colorantes en el Río Nazas.	(Gereffi, 2005)
Querétaro	San Juan del Río: Planta de Kaltex y otras textiles Descargas de agua con residuos de índigo en afluentes locales.	Posible contaminación del Río San Juan.	(Zambrano-Chacón, 2013)
Jalisco	El Salto y Juanacatlán: Aunque más conocido por contaminación industrial diversa	Algunas descargas de índigo llegan al Río Santiago.	(McCulligh, 2013)
Estado de México	Industria del lavado de la mezclilla.	Contaminación de la laguna Chignahuapan y río Lerma con aguas no tratadas con alto contenido de color, ha causado eutrofización y muerte de peces.	(Montes-Ortiz & L., 2024)

El uso de químicos peligrosos en la utilización de la elaboración del color azul índigo son el hidrosulfito de sodio que es un reductor tóxico que genera sulfuros en el agua al igual que álcalis fuertes, que elevan el pH del agua residual, dañando suelos y ríos. El impacto en los suelos también es muy importante ya que cuando el agua llega a la tierra y esta se convierte en lodo estos inhiben el crecimiento de plantas por bloqueo de nutrientes y pueden lixiviar metales pesados, si el índigo está mezclado con otro colorante (Maldonado Rogel & Molina Ayala, 2011).

La emisión de gases es por la producción de índigo sintético que se deriva del petróleo y emite compuestos orgánicos volátiles también la quema de residuos En algunas fábricas, la incineración de desechos textiles libera dioxinas que son compuestos químicos organoclorados que contaminan de forma persistente al medio ambiente. (Rosero Romero, 2024).

2.4 Impacto de los colorantes en la salud humana

Las enfermedades gastrointestinales por la contaminación de bacterias pueden tener como consecuencia diarrea, colera, disentería y gastroenteritis. El cáncer es un factor muy importante en el consumo de algunos químicos producidos por la mezclilla como los colorantes o los compuestos clorados. Los problemas dermatológicos son la causa del contacto directo con el agua contaminada, esto puede causar irritaciones, dermatitis, y otras infecciones de la piel (Hernández Cortez & Aguilera Arreola , 2011).

Intoxicaciones agudas o crónicas, daño hepático y complicaciones renales son la consecuencia por el contacto directo con las aguas residuales o la exposición de estos, ya que contienen metales pesados como plomo, cadmio, mercurio entre otros (Carlos & Liduvina, 2018).

Alteraciones endocrinas por los colorantes o los subproductos de estos, que tienen como consecuencia los cambios hormonales y problemas reproductivos (Kant, Textile dyeing industry an environmental hazard., 2011)

El azul índigo en este caso se fabrica a partir de derivados del petróleo, su síntesis y aplicación, se generan compuestos como anilina cancerígena y disruptora hormonal, N-nitrosaminas asociadas a infertilidad y cáncer. La alteración de hormonas tiroideas como lo es en estudios en peces expuestos a aguas residuales de tintorerías muestra disminución de T3 y T4 (Zhou, Guo, Xu, Wang, & Cui, 2015)

También los Estrógenos ambientales son algunos metabolitos del índigo actúan como xenoestrógenos, imitando el estradiol y afectando la fertilidad (Francisco, Moreira, & Albuquerque, 2023) Las vías de Exposición y Poblaciones en Riesgo Como a los trabajadores

de la Industria Textil cuando es exposición directa, la Inhalación de polvos de anilina o contacto dérmico con colorantes demuestra que un estudio en Bangladesh las Mujeres en fábricas de denim presentó desequilibrios menstruales y mayor tasa de abortos (Ahmed & Raihan, 2014)

2.5 Regulación del color

Según la NOM-001-SEMARNAT-2021, el parámetro de "Color verdadero" se incorpora para controlar la contaminación no biodegradable en las aguas residuales. Establece nuevos parámetros y límites para la regulación de contaminantes en las descargas de aguas residuales en cuerpos receptores propiedad de la nación. Uno de los cambios más importantes se encuentra la inclusión del parámetro "Color verdadero" para medir la contaminación de las aguas (Soto & Gonzalez_Gutierrez, 2025).

Tabla 4 Muestra niveles de concentración de color según diversas normas oficiales.

Normativa	Parámetro	Unidad	Límite máximo permisible
ANTEPROY-NTE-002-CTAEM-TAR-2020/ (Comisión Técnica del Agua Del Estado de México 2020b)	Color	Pt-Co	500
Effluent Standards Dated/ (Environmental Protection Administration Republic of China 2019)	Color	Pt-Co	550*
GB 4287-2012 + XG1-2015/	Color	Pt-Co	50-80
NOM-001-SEMARNAT-2021	Coefficiente de absorción espectral		
	Longitud de onda 436	m ⁻¹	7.0
	Longitud de onda 525	m ⁻¹	5.0
	Longitud de onda 620	m ⁻¹	3.0

Fuente: adaptado de (Castillo-Suárez, Sierra-Sánchez, & Linares, 2023)

En la Unión Europea, la Directiva Marco del Agua (2000/60/CE) establece estándares para la calidad del agua, incluyendo parámetros como el color. Las normativas nacionales de los países miembros pueden incluir límites específicos para el color en aguas residuales industriales menores de 50-100 unidades Pt-Co para descargas en cuerpos receptores (Casas, y otros, 2011).

En India, el Central Pollution Control Board (Junta Central de Control de la Contaminación) establece estándares para las descargas de aguas residuales textiles, donde el color es un parámetro importante. Las unidades Pt-Co se utiliza para medir el color y garantizar que las descargas cumplan con los límites permitidos, donde menos de 200 unidades Pt-Co son lo máximo permitido para descargas en ríos.

2.6 Unidades de Pt-Co

Las unidades de platino cobalto son una escala estándar utilizada para medir el color o intensidad de tonalidad amarillenta en líquidos, especialmente en aguas residuales, químicos industriales y productos derivados del petróleo (Fuga, 2006). Tabla 5 los principales usos de la determinación de color en aguas.

Tabla 5 Muestra las principales industrias y aplicaciones donde se determina el color.

Industria	Aplicación
Control de calidad en aguas potables y residuales	Evaluar contaminación por materia orgánica.
Industria textil.	Medir el color en efluentes de tintorerías de denim.
Petroquímica.	Analizar el color de combustibles y solventes.
Alimentos y bebidas.	Controlar la claridad de jarabes y aceites.

Fuente: (Bermeo Matute & Salazar Vallejo, 2013)

Lo que mide exactamente es el grado de coloración amarilla/marrón en un líquido, causada por compuestos orgánicos disueltos como lo son los taninos y lignina, también los subproductos industriales, así como tintes, residuos de anilina entre otros. (Marcó , Azario , Metzler, & Garcia, 2004)

El método Tradicional que es visual es por la comparación con soluciones estándar Pt-Co que se preparan diluciones de cloroplatinato de potasio y cloruro de cobalto en concentraciones conocidas (ej.: 500 U Pt-Co = color intenso). La muestra se compara en un colorímetro visual bajo luz estandarizada.

Tabla 6 Comparativa entre las ventajas y desventajas de usar unidades de Pt-Co para la medición de color en aguas.

Ventajas	Desventajas
Método reconocido internacionalmente (ISO, APHA, NMX-AA-045-SCFI-2001) que permite comparar resultados entre laboratorios.	No refleja variaciones cromáticas fuera del rango amarillo a marrón; colores azules, verdes o rojos no se cuantifican bien.
Fácil de aplicar en laboratorio con reactivos estándar de platino y cobalto.	Requiere preparación de soluciones patrón y condiciones controladas, lo que puede ser laborioso.
Útil para evaluar calidad de agua potable y detectar contaminación orgánica o inorgánica.	No distingue entre color aparente por sólidos en suspensión y color verdadero por compuestos disueltos sin pasos adicionales.

Fuente: (Romo, 2001)

2.7 Inteligencia Artificial

La inteligencia artificial tiene un objetivo que es, los ordenadores tienen que hacer la misma clase de cosas que la mente puede hacer.

La inteligencia artificial se manifiesta a través de capacidades fundamentales como razonamiento, visión, percepción, y la asociación. Estas facultades junto con la predicción, planificación y control suelen utilizarse para definir a las máquinas inteligentes. En conjunto, estos procesos son los que permiten a los seres humanos estructurar acciones para alcanzar sus objetivos. (Larson, 2022).

La inteligencia artificial no es algo que sea único, sino que también es un espacio profundamente estructurado capaz de hacer diversas acciones para procesar la información, así mismo la IA ha estado utilizando muchas técnicas diferentes para resolver una gran variedad de tareas que nosotros nos cuesta hacer o desarrollar en ciertos casos.

Las aplicaciones las podemos encontrar en las prácticas de Inteligencia artificial en el hogar, también en los vehículos sin conductores, oficinas, bancos, hospitales y principalmente en internet ya que puede conectar múltiples cosas a la vez tanto físicos como virtuales, algunas cosas se salen de nuestro entorno como los robots enviados a la luna y marte, también los satélites que orbitan en el espacio. Las animaciones que hay en las películas de Hollywood así como los videojuegos, juegos de ordenadores, sistemas de navegación por satélite y Google están basados en técnicas que son utilizadas para la inteligencia artificial, los sistemas que usan los sistemas financieros para hacer predicciones de los movimientos del mercado de valores y los gobiernos nacionales como guía para tomar decisiones tanto políticas como de salud, transporte, igual que las aplicaciones de los teléfonos móviles, también los avatares de la realidad virtual y los de la emoción experimentales creados para los robots de compañía (Oliver, 2021).

La inteligencia artificial tiene 2 objetivos que son:

El uso tecnológico: Usar ordenadores para hacer cosas útiles que a veces empleando métodos muy distintos.

El uso científico: Usar conceptos y modelos de inteligencia artificial que puedan ayudar a resolver problemas de los seres humanos (Boden, 2017).

Las redes neuronales multicapa pueden organizar y agrupar todas las neuronas que constituye la red en niveles o capas, estas cuentan con una capa de entrada y otra de salida, pero entre ellas puede haber un sin número de capas ocultas o hidden layers.




Ilustración 5 esquematización de perceptrón multicapa. Recuperado de (Nielsen, 2015)

2.8 CNN

Las redes neuronales convolucionales en el campo del aprendizaje automático, la estadística y la visión artificial han atraído un creciente interés en todos los campos de investigación durante los últimos 10 años esto se debe a la capacidad que tiene de superar las técnicas convencionales que se tiene de hacer cada cosa. Los rendimientos y los desafíos que enfrentan estas técnicas que, en los términos de velocidad, precisión o simplicidad, en general, el rendimiento de velocidad que tiene YOLO es de 21 a 155 fps, que es el más rápido que ha llegado en su pico más alto y la precisión promedio de la máscara R-CNN es de 47,3, que supera a todas las demás técnicas (Bharat & Pramanik, 2019).

Al igual las redes neuronales convolucionales (CNN) tienen aplicaciones en videos, los sistemas de recomendación como son implementados en publicidad, la segmentación y la clasificación que pueden hacer estas mismas para que pueda aprender a diferenciar de cada una de las mismas, así como el análisis de imágenes médicas, el procesamiento del lenguaje natural, entre muchas otras (Casado Beinat, 2022).

Las redes neuronales convolucionales siguen una estructura específica, ya que dependen de 3 tipos de capas que son: convolutional layer, pooling layer y fully-Connected layer. Estas

se efectúan en una serie de convolucionales, submuestreos o reducciones alteradas para que estas mediante una serie de capas conectas entre si se obtendrá la salida especificada equivalente al número de clases.

La convolution efectua en una serie de sumas y productos entre la matriz que esta de partida y la matriz kernel o el filtro de tamaño (Martínez Llamas, 2018).

2.9 Visión por computadora

La percepción visual es algo que cada ser humano puede desarrollar desde el momento en que despierta hasta el momento que se vuelve a dormir. La visión por computador surge de la inspiración del sistema visual que tiene el ser humano, en el cual es la mayor fuente de información para las personas que hacen el tratamiento de información por medio de diferentes técnicas. Una de las metas que tiene el visón por computadora en el moldear y también los procesos de reconocimiento visual es decir o distinguir entre los objetos (Alonso & Jara, 2016).

La visión por computadora es relativamente algo nuevo comparado con las demás a pesar de que esta resulta muy compleja, porque se encuentra en constante desarrollo con el surgimiento de nuevas tecnologías. El reconocimiento es algo primordial y compleja a la vez ya que esta es capaz de aprender formas para que estas sean clasificados de forma correcta y no tenga errores en esta, mientras que por otra parte el seguimiento de objetos posibilita analizar y observar el comportamiento que tienen las trayectorias de los objetos (Cárdenas Díaz & Tirado Ballestas, 2004).

La visión artificial es también parte de la inteligencia artificial ya que esta necesita una serie de fases para que esta pueda dotar el ordenador de la capacidad de cómo se percibe y se comprende una imagen para imitar el proceso que realizan los seres humanos, la arquitectura y también las etapas son muy independientes de su aplicación y se muestra en la ilustración 6 (Alonso & Jara, 2016).




Ilustración 6 etapas de un sistema de visión artificial

2.10 Conjunto de datos

Para el conjunto de datos de la investigación se empleó una red neuronal convolucional, está basada en un modelo YOLOv5. Para el etiquetado de imágenes se utilizó Roboflow para etiquetar cada una de las soluciones tomando en cuenta la iluminación, posición, clima, ángulos, calidad de imagen, formato de la imagen, tipos de cámaras entre otras cosas y hacer el dataset compatible con Google Colab, para el etiquetado nos basamos en una curva de calibración de un espectrofotómetro llamado Hach para hacer la solución de 10 hasta los 60 miligramos sobre litro, posterior a eso se vació en recipientes para la toma de fotos con un fondo blanco. Para mejorar la capacidad de generalización del modelo se utilizaron técnicas de data argumentation, que son ajustes como rotación, ajuste de brillo, espejo y desenfoque dentro de robo Flow, esto para garantizar que el modelo pueda identificar las concentraciones incluso en condiciones que no son óptimas (Roboflow, 2023).

El conjunto de datos se muestra en la tabla 7.

Tabla 7 Numero de imágenes por solución.

Número de imágenes	Tonalidad
66	10 mg/L
42	20 mg/L
60	30 mg/L
60	40 mg/L
60	50 mg/L
60	60 mg/L

2.11 Roboflow

Es una plataforma integral de visión artificial que simplifica la creación, entrenamiento, gestión, e implementación de modelos de IA para tareas de detección de objetos, clasificación y segmentación, esto permite que los desarrolladores puedan subir imágenes y videos, estas puedan ser etiquetadas, procesadas aumentarlas y luego generar y desplegar modelos de personalización o usar la plataforma facilitando todo ciclo de vida de un proyecto de visión por computadora (Marín Balseca, 2024).

Alguna de las características que tiene Roboflow es la organización y gestión que tiene cuando se sube imágenes/videos, estos pueden ser etiquetados manualmente, por equipo y bloques que nosotros vayamos seccionando, otra de las características que tiene es la facilitación de en el entrenamiento de los modelos, su implementación en producción ya que se debe a su gran motor de inferencia (Borja Hernández & Cruz Escobar, 2024).

2.12 Yolo V5

Es un modelo de visión artificial para la detección de objetos en tiempo real ya sea en imágenes y videos con alta precisión, usa PyTorch para facilitar el uso y el entrenamiento del hardware variado, desde servidores hasta los dispositivos móviles, este es conocido por su eficiencia y su arquitectura que combina un backbone CSPDarknet y una red PANet para la fusión de características, siendo muy popular por su equilibrio entre velocidad y precisión, siendo el estándar de la industria para muchas aplicaciones (Romero Carrillo, 2025).

YOLOv5 surge como una evolución de la implementación de PyTorch de YOLOv3, esta se lanzó con YOLOv4. YOLOv5 se popularizó por la transacción de modelos de YOLOv3 para su implementación en producción.

Reconociendo la utilidad de esta misma basado en PyTorch, Ultralytics se desarrolló la trayectoria para el desarrollo mejorado de YOLOv3 y las metodologías de entrenamiento dentro del framework de Pytorch. Este proyecto buscaba empoderar una comunidad más amplia para los desarrolladores para que estos mismos pudieran implementar detectores de objetos personalizados (Moreira Ramos, 2021).

2.13 Crisp/DM

La metodología Crisp/DM es un modelo de trabajo estándar y flexible para proyectos de minería de datos y ciencia de datos, que guía el proceso en seis fases la primera es:

1. **Comprensión empresarial:** En esta se hace una comprensión completa de las necesidades del cliente, ya que se basa en determinar los objetivos del negocio, evaluar la situación, determinar los objetivos de la minería de datos y elaborar un plan de negocios
2. **Comprensión de datos:** Esta se centra en la identificación, recopilación y análisis de datos que puedan ayudar a alcanzar el propósito del proyecto, esta consta de recopilar datos, describir datos, explorar datos, verificar la calidad de los datos.
3. **Preparación de los datos:** Es una fase llamada depuración de datos ya que consta de seleccionar, limpiar, construir, integrar y formatear datos.
4. **Modelado:** Es considerado el trabajo más importante ya que en esta fase se construirá y evaluará diversos modelos basados en diferentes técnicas de modelado por que consta de seleccionar técnicas de modelado, generar prueba de diseño, construir modelo y evaluar el modelo.
5. **Evaluación:** Esta se centra en la técnica del modelado y analiza la evaluación de una forma más amplia ya que se evaluará los pasos, los procesos de evaluación y determina los próximos pasos.

6. Despliegue: En esta fase consta de la implementación del plan, planifica el seguimiento y el mantenimiento, produce el informe final, revisa el proyecto (Galán Cortina, 2016).




Ilustración 7 Metodología Crisp/DM. Imagen recuperada de (Peralta, 2014)

2.14 Arduino

Es una empresa de hardware y software informático de código abierto, esta puede ser utilizada para proyectos y también los usuarios que diseñan y utilizan las placas para el desarrollo de prototipos o estructuras basadas en microcontroladores ya que estas placas se conocen comúnmente como módulos de Arduino, estas son en código abierto y utilizan lenguaje C, esto permite acceder a grandes librerías gracias a open-source community (Gomez, Vargas, & CHECA, 2020).

Las placas se pueden ensamblar físicamente o bien también pueden ser preensambladas, hay un software que se puede descargar gratuitamente para facilitar el uso del mismo, ofrece ventajas que otras herramientas de desarrollo, Arduino se caracteriza por lo barato ya que

estas son muy costeables comparadas con otras plataformas de microcontroladores, es de igual forma multiplataforma, este puede ser ejecutado en sistemas operativos como Windows, Macintosh OSX y GNU/Linux por que los demás están solo limitados a Linux.

Tiene un entorno de desarrollo muy fácil de programar y es de código abierto, esto para los que están empezando a utilizarlo y suficientemente flexible para los usuarios avanzados (Herrador, 2009).

2.15 Componentes

Bombas de agua: Se utilizaron 2 bombas de agua controladas por Arduino que son excelentes para el control de la muestra, esta es utilizada usando un microcontrolador por Arduino es muy factible ya que son muy pequeñas, compactas y desarrollan bien el trabajo deseado (Villar, Garcia, & Hiyo, 2020).

Botones: Hay 3 botones, uno es para el inicio de la bomba que ingresa la muestra al recipiente, otro botón es para vaciar la muestra y por último botón es para el paro total.

Luz led: Hay una tira led para la iluminación de la muestra y que esta misma pueda ser fotografiada de una manera excelente sin ruido, para ello se colocó de manera específica ya que no necesita reflejar y debe de ser fría.

PUENTE H/: Es un circuito que permite el control de la dirección de un motor de corriente continua, haciéndolo gira hacia la derecha, izquierda o incluso frenarlo completamente.

RELE: Es un interruptor eléctrico accionado eléctricamente que da una señal de muy baja potencia para controlar un circuito, este permite abrir o cerrar el circuito ya que protege sistemas eléctricos, controla motores y luces.

CAMARA: Es un dispositivo que captura luz y la convierte en una imagen usando una lente para poder enfocar.

NOM-001-SEMARNAT-2021: Estable los límites máximos para la descarga de aguas residuales en cuerpos receptores

3. PLANTEAMIENTO DEL PROBLEMA

El colorante azul índigo es una sustancia altamente utilizada en la industria textil ya que, en el proceso de teñido de la mezclilla, donde el color constituye una variable y la estandarización del producto. Una cuantificación precisa del color resulta fundamental para que esta sea garantizada en la consistencia y confiabilidad en la industria textil.

Las actividades en la industria textil generan un gran impacto ambiental, principalmente el uso excesivo de agua y la descarga de esta, que contienen colorantes residuales. El azul índigo, presenta una alta resistencia a la degradación, y esta presenta una persistencia en matos acuíferos, ya que altera la penetración de la luz solar, esto implica procesos fotosintéticos de plantas acuíferas, lo que evidencia la necesidad de mecanismos para el monitoreo.

Los métodos convencionales utilizados para la detección y cuantificación de colorantes en soluciones acuosas, como son la espectrofotometría presentan limitaciones relacionadas con costos inaccesibles, condiciones de operación, personal capacitado, mantenimiento costoso, estas restricciones dificultan la implementación de monitoreo continuo.

La cuantificación de colorantes se realiza comúnmente mediante técnicas de espectrofotometría que ofrecen alta precisión, pero requieren equipos especializados. Esta dependencia representa una barrera significativa en las industrias textiles, lo que dificulta la detección temprana de contaminantes.

¿Puede un modelo de inteligencia artificial basado en reconocimiento de imágenes predecir con precisión las concentraciones de azul índigo en soluciones acuosas?

¿Qué diferencias de costo y operación existen entre un sistema de cuantificación de azul índigo basado en inteligencia artificial y un sistema basado en espectrofotometría UV-Vis para su aplicación en empresas del sector textil?

¿Qué impacto tienen las variaciones en las condiciones de iluminación sobre la precisión del modelo de inteligencia artificial en la cuantificación de azul índigo en soluciones acuosas?

4. JUSTIFICACIÓN

Esta investigación se justifica de una perspectiva académica, practica, económica y principalmente ambiental porque se aborda en la problemática de la industria textil relacionada a los colorantes que son utilizados específicamente el azul índigo, mediante el uso de inteligencia artificial que se basa en el reconocimiento de imágenes.

Desde un punto de vista académico, este estudio contribuye a tener más alternativas entre la visión por computadora, el aprendizaje automático y el análisis de la calidad del agua que propone un nuevo método. La espectrofotometría UV-Vis es ampliamente reconocida en la industria por su precisión y también por su limitación a ser adquirida por empresas que son incapaces de costear dispositivos así, hay una limitación en la exploración de modelos de inteligencia artificial aplicados en la cuantificación visual en contextos industriales y ambientales. Esta investigación aportara a la viabilidad de poder emplear redes neuronales convolucionales para detectar concentraciones a través de imágenes considerando su iluminación.

La mayoría de los estudios previos se centran en la clasificación de la calidad del agua potable mediante sensores o modelos de aprendizaje automático, pero hay muy poca información que aborda sobre la cuantificación de colorantes específicos como sustituto o complemento a técnicas de espectrofotometría, así mismo son muy pocos los trabajos que se evalúan de una manera sistemática hacia el impacto de las condiciones de iluminación lo que representa un vacío metodológico que esta investigación busca.

El trabajo también integra un modelo de aprendizaje automático previamente entrenado con imágenes obtenidas bajo condiciones controladas de iluminación, calidad, formato de imagen, etc, junto a un sistema que se puede regular, tanto en la iluminación, la toma de las muestras con una cámara fotográfica de alta calidad, el ingreso y el retiro de la muestra, esta combinación permite la robustez del modelo frente a variaciones operativas que lleguen a suceder, ya que aporta un enfoque integral que va más allá de simulaciones computacionales.

Por otra parte, la implementación de sistemas basados en inteligencia artificial representa una reducción potencial de costos de adquisición, operación y mantenimiento frente a otros

métodos tradicionales. Esto también puede ser una mayor adaptación tecnológica por parte de empresas con recursos limitados por que puede fortalecer su competitividad y capacidad de cumplimiento normativo.

Por último, la investigación es factible ya que debido a la disponibilidad de herramientas de software gratuitos y de código abierto, plataformas que trabajan en la nube, dispositivos para la toma de imágenes y recursos computacionales accesibles. El desarrollo de un conjunto de datos, el entrenamiento de modelos y la validación experimental se hace mediante un marco temporal, técnico y patentado, respalda completamente el estudio.

5. OBJETIVOS

5.1 Objetivo general

Diseñar y evaluar un modelo de Inteligencia artificial por reconocimiento de imágenes aplicada en la predicción de Color en soluciones acuosas de azul índigo.

5.2 Objetivos específicos

- Diseñar y construir un dispositivo para la captura de imágenes de las muestras líquidas.
- Establecer una curva de calibración usando un espectrofotómetro de luz ultravioleta visible como medición de referencia en unidades mg/L de soluciones acuosas de un estándar del colorante azul índigo.
- Generar y obtener una base de datos para relacionar una solución de concentración conocida en unidades de mg/L del colorante azul índigo e imagen.
- Diseñar y entrenar un modelo de inteligencia para la predicción de las concentraciones de estándar azul índigo en mg/L.
- Diseño y desarrollo un sistema web de análisis de imagen de color.
- Validar el método de cuantificación con soluciones estándares.

6. HIPÓTESIS

La presente investigación plantea la hipótesis de que un modelo de inteligencia artificial basado en reconocimiento de imágenes es capaz de predecir las concentraciones de azul índigo en soluciones acuosas con un margen de error mínimo comparado con la espectrofotometría manteniendo precisión aceptable bajo condiciones de luz distintas, en la siguiente ilustración 8 se muestra la metodología aplicada.

7. METODOLOGÍA




Ilustración 8 metodología Crisp DM

Comprensión del negocio: Desarrollar una red neuronal convolucional desarrollada en Google Colab para clasificar la calidad del agua y cuantificar contaminantes de manera accesible y eficiente.

Comprensión de los datos: Utilizar conjunto de datos sobre imágenes capturadas de muestra, registro de espectrofotometría y datos de referencia de calidad del agua.

preparación de los datos: Utilizar la plataforma Roboflow para el etiquetado de datos

Modelado: Utilizar una red neuronal convolucional en un entorno de Google Colab para el análisis de imágenes, modelos supervisados.

Evaluación: Comparar el rendimiento del modelo con métodos tradicionales (Uv-Vis), además de evaluarlo usando métricas de evaluación como lo son precisión, Recall, mPA-50.

Implementación: Implementación del prototipo físico, Pruebas en laboratorio industrial y capacitación en empresas textiles.

7.1 Diseño y construcción de un dispositivo para la captura de imágenes de las muestras líquidas.

La toma de las imágenes para las muestras se diseñó y construyó un dispositivo que puede abrirse y cerrarse en cualquier momento, el objetivo es poder controlar las condiciones del entorno visual, específicamente de la iluminación ya que esta juega un papel muy importante dentro de la toma de imágenes esto con el fin de garantizar la calidad de las imágenes utilizadas en el entrenamiento y validación del modelo de inteligencia artificial.

El dispositivo se construyó de una estructura de color negro para que minimice la iluminación ambiental y reducir los reflejos internos, en su interior contiene un recipiente de vidrio que funciona para el almacenar las soluciones del colorante azul índigo, también se colocaron 2 bombas que sirven para ingresar y retirar la muestra, dentro de la caja se colocó un microcontrolador Arduino que es el que se encarga de dar las señales de activación a través de botones físicos ubicados en la parte exterior de la caja, también cuenta con una tira led dentro de la caja para controlar la intensidad de la luz, cuyo encendido y apagado se realizó de manera independiente a través de un interruptor independiente y reducir el nivel de errores que pueden llegar a ocasionar.

Este diseño del dispositivo permitió la obtención de imágenes para la construcción de una base de datos y el análisis del desempeño del modelo de inteligencia artificial.

En la ilustración 9 se puede observar la cámara, el recipiente que se está utilizando para la toma de imágenes la cual para el ingreso y el retiro de la muestra se utilizan las bombas que están dentro de la caja.




Ilustración 9 Cámara fotográfica con el recipiente de almacenamiento de muestra.

En la ilustración número 10 se muestra como es la caja y de igual forma como se muestran los botones, uno sirve para el encendido de las bombas, otro es para el paro de las bombas en dado caso que lleguen a fallar, otro botón es para el paro total si llega a haber errores o si las fallas son mayores y necesita un paro total de todo los componentes, el botón de encendido

y apagado sirve para las luces led y controlar la iluminación que se le va a dar a cada muestra, y el regulador es para las bombas sobre la fuerza que puede tener cada una de ellas.



Ilustración 10 prototipo de la caja

La ilustración número 11 se muestran las conexiones con el Arduino, al igual se visualiza las conexiones de la bomba y las mangueras que funcionan para las muestras.




Ilustración 11 implementación del Arduino

En la Ilustración 12 se puede observar el funcionamiento de las 2 bombas, como antes lo hemos mencionado una es para ingresar la muestra del colorante azul índigo y la segunda bomba es para el retiro de la muestra, también se ingresa agua para quitar residuos de la anterior muestra para evitar que las soluciones se mezclen.




Ilustración 12 ubicación y funcionamiento de las bombas

La ilustración número 13 se muestra de manera grafica como se ve ensamblado y conectado con el Arduino, la parte exterior de los botones al igual que el interior donde está el Arduino, la conexión y fuente de poder que le da a todo el circuito.




Ilustración 13 muestra de la conexión de los botones con el Arduino

7.2 Curva de calibración Pt-Co de soluciones acuosas de un estándar del colorante azul índigo.

Con el fin de poder establecer un valor para la cuantificación del color, se elaboró una curva de calibración basada en parámetros de Pt-Co/mg/L del colorante azul índigo FAGALAB CAS 482-89-3 ampliamente utilizado para la medición de color aparente en agua. Esta curva fue utilizada como base para la asignación de concentraciones reales a las muestras utilizadas en el entrenamiento y validación de la IA.

Para la determinación de la absorbancia se midió usando el espectrofotómetro UV—VIS marca Hach modelo DR6000, con una celda de cuarzo con 1 cm, realizando un barrido con la finalidad de obtener la longitud de onda del AI (300 nm) por lo que dicha longitud fue usada para realizar las curvas de calibración. Por lo que se preparó una solución madre de 400 mg/L las cuales fueron diluidas para obtener concentraciones de: 10, 20, 30, 40, 50 y 60 mg/L del estándar del colorante AI.

Para la preparación de los estándares se utilizó la fórmula de dilución, representada en la ecuación:

$$C_1V_1 = C_2V_2$$

Donde:

C_1 = Concentración de la solución madre.

V_1 = Volumen a adicionar de la solución estándar para preparar el estándar.

C_2 = Concentración deseada del estándar.

V_2 = Volumen final de aforo.

Para la construcción de la curva de calibración se prepararon soluciones acuosas del colorante azul índigo, en un rango de 10 y 60 mg/L obtenidas mediante diluciones controladas a partir de una solución madre, Cada solución fue preparada bajo condiciones específicas con el fin de poder reducir algunas variaciones que puedan afectar a la solución.

Las soluciones se prepararon mediante un espectrofotómetro UV-Vis empleando un estándar de Pt-Co y mg/L como referencia usando un espectrofotómetro HACH DR6000 y DR900, lo que permitió relacionar la absorbancia con la concentración del colorante. Las mediciones se realizaron mediante un procedimiento consistente, utilizando el mismo tipo de celda de cuarzo para todas las soluciones.

7.3 Base de datos de concentración conocida en unidades de Pt-Co e imagen.

A partir del dispositivo de captura de imágenes (cámara) y la curva de calibración establecida, se construyó una base de datos experimental compuesta por las imágenes previamente tomadas con la cámara que se compone por las soluciones de azul índigo, las cuales fueron utilizadas como conjunto de datos como un conjunto de datos para el entrenamiento que se realizó en Roboflow, se guardaron en carpetas con los nombres de las soluciones para que fueran más fáciles de clasificar, las carpetas se subieron en Roboflow y se clasificaron una por una con la etiqueta de la concentración especificada, se guardó en conjunto de datos para posteriormente descargarse en formato Yolo V5 y se validó el modelo de inteligencia artificial para que no haya errores de incompatibilidad.

Se puede observar el inicio de Roboflow y el conjunto de datos que se realizó, en este apartado se etiquetaron 348 imágenes las cuales fueron etiquetadas una por una con su respectiva solución correspondiente, también algunas características específicas como lo es el zoom que debe de tener las imágenes para que no altere la muestra, la rotación por si la imagen presenta una rotación de la solución para que también la pueda identificar, también el corte, si la solución esta recortada y aparece una parte la pueda identificar.

En la ilustración número 14 se puede observar cómo es la interfaz y el data set que se desarrolló en Roboflow, se agregaron un total de 348 imágenes, cada una fue etiquetada con su concentración correspondiente, también las especificaciones que se les dio a las muestras como lo es el zoom que puede tener las imágenes.



Ilustración 14 interfaz de Roboflow

Las imágenes fueron tomadas bajo condiciones controladas de iluminación, posición y fondo, manteniendo estos parámetros para reducir variaciones no deseadas y que la base de datos y la IA no confundan las soluciones.

Para cada concentración se obtuvo un conjunto de datos para cada una de las soluciones, para generar así una base de datos balanceada. Esta correspondencia permitió que cada una de las etiquetas tuviera un valor cuantificable, respaldado con un método analítico.

7.4 Modelo de inteligencia artificial para la predicción de las concentraciones de estándar azul índigo Color Pt-Co.

Para la predicción de las concentraciones del colorante azul índigo, se desarrolló un modelo de inteligencia artificial basado en redes neuronales convolucionales (CNN) utilizando la arquitectura de Yolo V5 la cual ha demostrado un alto desempeño en el análisis de imágenes y la extracción de características visuales complejas.

El modelo de IA fue entrenado a partir de una base de datos generada en Roboflow, realizada con imágenes digitales de soluciones acuosas con las concentraciones de 10 – 60 mg/L previamente determinadas y medidas con el espectrofotómetro hach. Cada una de las

imágenes tiene una etiqueta de la solución a la que corresponde, esto permite una relación directa entre lo que vemos y el valor numérico que tiene cada uno.

7.5 Diseño y desarrollo de una interfaz gráfica para la identificación de soluciones.

Se desarrollo una interfaz gráfica para facilitar la interacción con el usuario, esto va dirigido a la identificación y análisis de soluciones acuosas a partir de imágenes digitales. Esta interfaz une el vínculo del modelo de inteligencia artificial con lo que ve el usuario el usuario permitiendo la visualización, procesamiento y obtención de los resultados cuando se suben las imágenes o se abre la cámara del dispositivo.

La interfaz fue desarrollada como una aplicación web, permitiendo su acceso desde distintos dispositivos sin la necesidad de un software especializado. A través de esta plataforma, el usuario puede cargar imágenes de la muestra captadas o puede abrir la cámara para identificar la muestra o utilizar imágenes previamente almacenadas en la base de datos del sistema una vez ingresada la imagen para su análisis.

La integración de la interfaz gráfica con el modelo de inteligencia artificial y el dispositivo de captura de imágenes permite un sistema de monitoreo, capaz de transformar imágenes digitales en información cuantitativa.

La siguiente ilustración 15 se puede mostrar cómo es la interfaz de la página web esta se implementó en Google Colab para que al momento de que se haga el entrenamiento de las épocas y la colocación de las imágenes para que se identifique la página web a que solución corresponde cada imagen, ya sea en formato JPG o bien podamos abrir la cámara del dispositivo, de igual forma la página web solo funciona cuando se ejecuta todo y se puede visualizar en varios dispositivos cuando está en funcionamiento el Colab.



Ilustración 15 Página web implementada en Colab

8. RESULTADOS Y DISCUSIÓN

En la ilustración 16 se puede observar cómo es trabajar con Roboflow, con el cursor se selecciona toda la solución que está dentro de la celda para que posterior a eso identificarla con la solución, que en este caso es de 50 mg/L, y así sucesivamente identificar todas las soluciones para el data set.




Ilustración 16 identificación de las soluciones en Roboflow

las métricas nos indican que tan preciso fue el modelo en cada una de las soluciones, todas obtuvieron un porcentaje superior a 0.995 por ciento, lo que nos quiere decir que la red no confunde las soluciones y los parámetros que se asignaron ayudaron a que fuera de mayor precisión.

Tabla 8 Resultados del entrenamiento en Google Colab.

Clase	precisión	Recall	mAP50	mAP50-95
10mg/L	0.998	1	0.995	0.777
20 mg/L	0.995	1	0.995	0.815
30mg/L	0.997	1	0.995	0.772
40mg/L	0.999	1	0.995	0.818
50mg/L	0.997	1	0.995	0.777
60mg/L	0.997	1	0.995	0.799

La elección de la red neuronal convolucional es por su capacidad para aprender patrones especiales y cromáticos, lo que esto beneficia a la adecuación de para cuantificación, donde las variaciones de intensidad y, tonalidad y saturación están directamente relacionadas a las concentraciones hechas. El modelo no solo identifica la presencia del color, sino que también infiere sobre las características visuales aprendidas.

El proceso de entrenamiento se llevó a cabo en Google Colab, que aprovecha los recursos de la nube que maneja. El conjunto de datos fue dividido en subconjunto de entrenamiento y validación, con el objetivo de la evaluación del entrenamiento y previamente cargado en Google drive, el modelo se ajustó parámetros internos minimizando el error entre las concentraciones predichas y los valores obtenidos con el espectrofotómetro.

El modelo tiene una alternativa computacional para la cuantificación del colorante azul índigo en soluciones acuosas, orientada a sustituir o remplazar métodos tradicionales como son los espectrofotómetros UV-Vis, ofreciendo un método más accesible, automatizado y adaptable a entornos industriales

8.1 Curva de calibración Pt-Co de soluciones

En la siguiente ilustración 17, se muestra una relación lineal entre la absorbancia y la concentración de aluminio. La baja dispersión de los datos experimentales y la ausencia de curvatura significativa confirman la aplicabilidad del modelo lineal para la cuantificación de aluminio.




Ilustración 17 Curva de calibración con espectrofotómetro DR6000

La utilización de esta curva de calibración permitió asegurar que las concentraciones asociadas a cada imagen correspondieran a valores medidos mediante un método analítico confiable, garantizando la confiabilidad de las concentraciones y el entrenamiento del modelo.

En La siguiente ilustración 18 se muestran varias soluciones realizadas con el colorante azul índigo, estas fueron realizadas con la curva de calibración con el espectrofotómetro hach para poder hacer la toma de imágenes de las muestras jugando con los diferentes niveles de luz y así poder hacer el data set. La R^2 nos indica que tan bien se ajustan los datos a una línea recta, ya que esta mide la relación entre intensidad de color detectada por la IA y la concentración de platino cobalto su valor entre 1 y 0 nos indica que 0 el modelo no entiende nada y 1 el modelo es perfecto.




Ilustración 18 soluciones de 10 hasta 60 mg/L

8.3 Modelo de inteligencia medición de color

Se realizó una comparación del desempeño del modelo de clasificación entrenado durante 50 y 100 épocas, con el objetivo de analizar el impacto del número de iteraciones sobre la capacidad predictiva del sistema.

A las 50 épocas, el modelo presentó un Recall elevado 0.944 y un mAP50 de 0.967 sin embargo, la precisión global fue de 0.765, observándose confusión significativa en las clases intermedias 30 mg/L y 40 mg/L, donde la precisión fue inferior a 0.55.

Al incrementar el entrenamiento a 100 épocas, se observó una mejora sustancial en la precisión de todas las clases, alcanzando valores superiores a 0.995, manteniéndose el Recall en 1. Asimismo, el mAP50 se incrementó a 0.995, mientras que el mAP50-95 presentó valores entre 0.77 y 0.82, indicando una mejora en la consistencia de las predicciones bajo diferentes umbrales.

Estos resultados sugieren que el aumento en el número de épocas permitió una mejor comprensión del modelo reduciendo la confusión entre clases con características cromáticas similares. No obstante, no se observaron indicios claros de sobreajuste, ya que las métricas de validación se mantuvieron estables y el mAP50-95 no alcanzó valores cercanos a la perfección, lo cual indicaría memorización del conjunto de datos.

8.4 Sistema web de análisis de imagen de color

Anexo 1 C MANUAL DE USUARIO

Sistema web para la identificación de concentraciones de soluciones de azul índigo (10–60 mg/L)

1. Alcance del sistema

Tiene como objetivo principal orientar al personal de empresas y público que desee identificar soluciones acuosas de azul índigo para el uso del sistema, explicando de manera clara y accesible su alcance y limitaciones. No se requiere que el usuario cuente con conocimientos previos en programación, química analítica o aprendizaje automático para hacer uso de la aplicación.

El sistema consiste en una aplicación web que permite al usuario cargar una imagen digital de una solución de azul índigo. Una vez cargada la imagen, el sistema realiza un análisis automático del color presente en la solución y determina la concentración más probable, basándose en patrones previamente aprendidos durante la etapa de entrenamiento del modelo de inteligencia artificial.

2. Objetivo del manual de usuario

El presente manual tiene como finalidad:

- Explicar de manera detallada cómo utilizar correctamente el sistema web.
- Describir las condiciones necesarias para obtener resultados confiables.
- Orientar al usuario sobre la correcta interpretación de los resultados.
- Informar sobre las limitaciones del sistema y su alcance real.

3. Público objetivo

El sistema ha sido diseñado para público en general, lo que incluye:

- Docentes y personal académico.
- Investigadores en etapa exploratoria.
- Personas interesadas en el análisis visual de soluciones químicas.

Debido a esta diversidad de usuarios, el sistema prioriza la simplicidad, claridad visual y facilidad de uso, evitando configuraciones complejas o requerimientos técnicos avanzados.

4. Alcance del sistema

El sistema permite identificar concentraciones de soluciones de azul índigo dentro del rango de:

- 10 mg/L
- 20 mg/L
- 30 mg/L
- 40 mg/L
- 50 mg/L
- 60 mg/L



Estas concentraciones corresponden a las clases con las que el modelo fue entrenado. El sistema puede identificar soluciones en un rango de 10 mg/L hasta los 60 mg/L que es el estándar que se proporcionó dentro de la página web, si las soluciones que se suban no corresponden, el sistema no identifica valores fuera de este rango.

5. Requisitos mínimos para el uso del sistema


- Un dispositivo (computadora) con acceso a internet.
- Intel Celeron o Ryzen Athlon
- 4 GB de Memoria RAM (Preferentemente) en adelante
- Un navegador web como por ejemplo Google, Firefox, Brave, etc. y que este actualizado.
- Python en su versión 3.10.11
- Una imagen digital en formato compatible (JPG o PNG).
- Un entorno de iluminación controlado.

Si el formato de imagen no es compatible con la página web se puede apoyar en las herramientas de Paint de cualquier dispositivo (laptop o computadora) para transformar el formato para que sea el adecuado.


Para transformar al formato adecuado vamos a abrir la herramienta de paint para posterior hacer click en archivo




Después en abrir




Para posteriormente proceder a guardarlo, dando click nuevamente en archivo



Y después en guardar como y seleccionamos JPG o PNG



Y guardamos en donde sea conveniente



6. Posibles errores

- Incompatibilidad con el formato de imagen
- Mala conexión de internet
- Soluciones que no corresponden al estándar de 10-60 mg/L
- Insuficiencia en requerimientos mínimos

7. Entorno de iluminación controlado

El entorno de iluminación es un factor fundamental para el funcionamiento del sistema. Debido a que el análisis se basa en información visual, cualquier variación significativa en la iluminación puede afectar el resultado. Se recomienda que el entorno cumpla con las siguientes condiciones:

- Iluminación uniforme y constante.
- Ausencia de sombras directas sobre la solución

- Fondo blanco
- Uso del mismo tipo de recipiente en todas las muestras (celda de cuarzo).

Estas condiciones permiten que el sistema analice correctamente el color de la solución, reduciendo errores visuales externas.

8. Descripción de la interfaz de usuario

La interfaz gráfica del sistema ha sido diseñada para ser intuitiva y fácil de comprender.



Ilustración 19 Pagina web

8.1 Área de carga de imagen

Permite al usuario seleccionar una imagen desde su dispositivo. Una vez seleccionada la imagen será enviada al sistema para su análisis.



Ilustración 20 agregar imagen

8.2 Botón “Identificar”

Este botón inicia el proceso de análisis de la imagen cargada. Al presionarlo, el sistema procesa automáticamente la imagen.




Ilustración 21 Identificar la imagen

8.3 Área de resultados

Muestra la imagen analizada junto con el resultado de la identificación de la concentración.




Ilustración 22 Muestra del resultado




Ilustración 23 Resultado

8.4 Botón “Limpiar”

Permite reiniciar la interfaz, eliminando la imagen y el resultado previo, para realizar un nuevo análisis.




Ilustración 24 botón de limpiar el resultado




Ilustración 25 botón de limpiar

9. Procedimiento detallado de uso

Paso 1: Acceso al sistema

El usuario accede al sistema mediante el navegador web, visualizando la pantalla principal.




Ilustración 26 dirección ip

Paso 2: Selección de la imagen

El usuario selecciona una imagen de la solución de azul índigo desde su dispositivo




Ilustración 27 Cragar una imagen

Paso 3: Inicio del análisis

Al presionar el botón “Identificar”, el sistema inicia el procesamiento automático de la imagen.



Ilustración 28 Resultado de la imagen identificada

Paso 4: Obtención del resultado

Una vez finalizado el análisis, el sistema muestra la concentración identificada junto con la imagen cargada.



Ilustración 29 Resultado

Paso 5 Métricas de la identificación.

En donde se encuentra el botón de limpiar aparecerán las métricas de la identificación con el nivel de confianza del modelo




Ilustración 30 Métricas de identificación

Paso 6: Apartado de instrucciones

En la parte izquierda aparecen las instrucciones de uso y también como se deben de tomar las imágenes correctamente, al igual de cómo se describen la interpretación del nivel de confianza de es menor a 50 y si es superior a 50.

Instrucciones de cómo tomar la imagen de la solución

- La imagen debe tomarse con **fondo blanco**.
- La solución debe estar contenida en una **celda de cuarzo**.
- La imagen debe capturarse con **claridad y sin ruido**.
- Para una mejor interpretación, utilizar una **cámara de buena resolución**.
- **No utilizar flash** ni ningún tipo de **luz artificial**.

Instrucciones de uso

1. Da clic en “**Coloca la imagen aquí**”.
2. Selecciona la imagen de la solución.
3. Presiona **Aceptar**.
4. Da clic en **Identificar**.
5. Usa **Limpiar** para una nueva

5. Usa **Limpiar** para una nueva concentración.

Interpretación del nivel de confianza

El nivel de confianza indica qué tan seguro está el modelo de que la identificación de la solución es correcta. Es una estimación basada en el reconocimiento de patrones aprendidos durante el entrenamiento.

- **95% – 100%**: Identificación muy confiable.
- **85% – 94%**: Identificación confiable.
- **70% – 84%**: Resultado aceptable
- **50% – 69%**: Baja confiabilidad
- **Menor a 50%**: Resultado no confiable

El nivel de confianza puede variar dependiendo de factores como iluminación, calidad de imagen, ruido, posición de la muestra y similitud con los datos utilizados en el entrenamiento. Para obtener resultados más confiables, asegúrese de seguir correctamente las instrucciones de captura de imagen.

Ilustración 31 Instrucciones de uso

Paso 7: Nuevo análisis

Para analizar otra imagen, el usuario puede limpiar la interfaz y repetir el proceso.



Ilustración 32 Botón limpiar el resultado

Consideraciones

El sistema web para la identificación de concentraciones de azul índigo representa una herramienta accesible y práctica para el análisis visual asistido por inteligencia artificial. Su diseño orientado al público en general permite que cualquier usuario pueda interactuar con el sistema de manera sencilla, siempre que se respeten las condiciones de uso establecidas.

Anexo 1 C MANUAL TÉCNICO

Sistema web para la identificación de concentraciones de soluciones de azul índigo mediante inteligencia artificial y visión por computadora

1. Introducción

El presente manual técnico documenta de manera detallada el diseño, implementación y funcionamiento interno del sistema web desarrollado para la identificación de concentraciones de soluciones de azul índigo, utilizando técnicas de inteligencia artificial y visión por computadora.

A diferencia del manual de usuario, este documento está dirigido a personal técnico, desarrolladores, investigadores y evaluadores académicos, con el objetivo de proporcionar una comprensión profunda del sistema, sus componentes, las decisiones de diseño adoptadas y sus implicaciones técnicas.

El sistema integra un modelo de aprendizaje profundo basado en YOLOv5 dentro de una aplicación web desarrollada con Flask, permitiendo la ejecución de inferencias en tiempo de ejecución sobre imágenes proporcionadas por el usuario.

2. Enfoque y alcance técnico del sistema

Desde el punto de vista técnico, el sistema se concibe como una plataforma de inferencia visual, cuyo propósito no es la medición química directa, sino la clasificación asistida por inteligencia artificial de patrones visuales asociados a concentraciones específicas de azul índigo.

El alcance técnico del sistema incluye:

- Procesamiento digital de imágenes.
- Ejecución de modelos de redes neuronales convolucionales.
- Integración de modelos de IA en aplicaciones web.
- Visualización de resultados de inferencia.

Quedan fuera del alcance técnico aspectos como análisis químico cuantitativo, calibración espectrofotométrica o validación metrológica certificada.

3. Arquitectura general del sistema

El sistema adopta una arquitectura modular de tipo cliente–servidor, organizada en capas claramente diferenciadas

3.1 Capa de presentación (Frontend)

Responsable de la interacción con el usuario final. Permite la carga de imágenes y la visualización de resultados.



Ilustración 33 Página web corriendo

3.2 Capa de aplicación (Backend)

Implementada con Flask, gestiona las solicitudes HTTP, el flujo de datos y la comunicación con el modelo de inteligencia artificial.

```
* Serving Flask app 'app'
* Debug mode: on
WARNING: This is a development server. Do not use it in a production deployment. Use a production WSGI server instead.
* Running on http://127.0.0.1:5000
Press CTRL+C to quit
* Restarting with stat
```

Ilustración 34 dirección ip desde py

3.3 Capa de inteligencia artificial

Compuesta por el modelo YOLOv5 entrenado y los módulos de preprocesamiento e inferencia.

```

# ===== MODELO =====
weights = ROOT / "model" / "best_state_dict.pt"

with open(ROOT / "yolov5" / "models" / "yolov5s.yaml", "r") as f:
    cfg = yaml.safe_load(f)

cfg["nc"] = 6
cfg["names"] = ['10 mgL', '20 mgL', '30 mgL', '40 mgL', '50 mgL', '60 mgL']

model = Model(cfg).to(device)
state_dict = torch.load(weights, map_location=device)
model.load_state_dict(state_dict)
model.eval()

names = cfg["names"]

```

Ilustración 35 Modelo del Código

3.4 Capa de almacenamiento

Gestiona el almacenamiento temporal de las imágenes cargadas por el usuario.

Esta separación favorece la mantenibilidad, escalabilidad y comprensión del sistema.

```
# ===== INFERENCIA =====
def detect_image(img_path):
    img0 = cv2.imread(str(img_path))

    img = letterbox(img0, 640, stride=32, auto=True)[0]
    img = img.transpose((2, 0, 1))[:,::-1]
    img = np.ascontiguousarray(img)

    img = torch.from_numpy(img).to(device)
    img = img.float() / 255.0
    if img.ndimension() == 3:
        img = img.unsqueeze(0)

    with torch.no_grad():
        pred = model(img)

    pred = non_max_suppression(pred, 0.4, 0.45)

    if pred[0] is not None and len(pred[0]):
        det = pred[0][0]
        cls = int(det[5])
        confidence = float(det[4])

        return names[cls], confidence

    return "No detectado", None
```

Ilustración 36 Inferencia del Código

4. Tecnologías, librerías y dependencias

El desarrollo del sistema se apoya en un conjunto de tecnologías ampliamente utilizadas en la industria y la academia:

- Python: lenguaje principal por su flexibilidad y ecosistema científico.
- Flask: framework web ligero que facilita la integración con modelos de IA.
- PyTorch: framework de aprendizaje profundo utilizado para cargar y ejecutar el modelo entrenado.

- YOLOv5: arquitectura de detección basada en redes convolucionales profundas.
- OpenCV: utilizada para la lectura y manipulación de imágenes.
- NumPy: manejo eficiente de arreglos numéricos.
- YAML: configuración estructurada del modelo.
- HTML5 y CSS3: desarrollo de la interfaz gráfica.

5. Organización del proyecto

La estructura del proyecto se diseñó para separar responsabilidades y facilitar su mantenimiento:

- app.py: punto de entrada de la aplicación y núcleo del backend.
- model/: contiene los pesos del modelo entrenado.
- yolov5/: incluye la arquitectura del modelo y utilidades auxiliares.
- templates/: archivos HTML renderizados por Flask.
- static/: almacenamiento temporal de imágenes cargadas.

Nombre	Estado	Fecha de modificación	Tipo	Tamaño
model	✓	15/01/2026 09:15 p. m.	Carpeta de archivos	
static	✓	18/01/2026 09:53 p. m.	Carpeta de archivos	
templates	✓	15/01/2026 09:02 p. m.	Carpeta de archivos	
yolov5	↻	15/01/2026 07:54 p. m.	Carpeta de archivos	
app.py	✓	15/01/2026 10:03 p. m.	Python File	3 KB

Ilustración 37 Estructura del Código

6. Modelo de inteligencia artificial

6.1 Selección de la arquitectura

Se seleccionó YOLOv5 debido a su equilibrio entre velocidad y precisión, así como a su capacidad para aprender representaciones espaciales y cromáticas complejas.

Aunque YOLOv5 está diseñado para detección de objetos, su arquitectura convolucional lo hace adecuado para clasificación visual basada en patrones de color, al adaptarse el conjunto de clases.

6.2 Configuración del modelo

El modelo fue configurado para trabajar con:

Número de clases (nc): 6

Etiquetas:

- 10 mg/L
- 20 mg/L
- 30 mg/L
- 40 mg/L
- 50 mg/L
- 60 mg/L

```
data_yaml = """
train: /content/drive/MyDrive/AzulIndigo
val: /content/drive/MyDrive/AzulIndigo

nc: 6
names: ['10 mgL', '20 mgL', '30 mgL', '40 mgL', '50 mgL', '60 mgL']
"""

with open('/content/colorantes.yaml', 'w') as f:
    f.write(data_yaml)
```

Ilustración 38 Entrenamiento en Colab

Estas clases representan concentraciones discretas previamente definidas durante la etapa de entrenamiento.

7. Carga y preparación del modelo

Durante la inicialización del sistema:

- Se carga el archivo de configuración YAML.
- Se ajusta dinámicamente el número de clases.
- Se inicializa la arquitectura del modelo.
- Se cargan los pesos entrenados desde el archivo .pt.
- El modelo se coloca en modo evaluación.

Tabla 9 Resultado de entrenamiento en Google Colab

Clase	precisión	Recall	mAP50	mAP50-95
10mg/L	0.998	1	0.995	0.777
20 mg/L	0.995	1	0.995	0.815
30mg/L	0.997	1	0.995	0.772
40mg/L	0.999	1	0.995	0.818
50mg/L	0.997	1	0.995	0.777
60mg/L	0.997	1	0.995	0.799


El uso de CPU como dispositivo de ejecución garantiza portabilidad y compatibilidad en entornos sin aceleración por hardware.

8. Flujo detallado de inferencia

El flujo de inferencia constituye el núcleo funcional del sistema y se ejecuta cada vez que el usuario carga una imagen.

8.1 Lectura de la imagen

- La imagen es leída desde el sistema de archivos utilizando OpenCV.
- ¡git clone solo es para descargar YoloV5 desde github
- %cd para cambiar el directorio de trabajo a la carpeta yolov5
- ¡pip para iinstalar todas las bibliotecas necesarias que YOLOv5 necesita para funcionar (como PyTorch, OpenCV, etc.)




```
!git clone https://github.com/ultralytics/yolov5.git
%cd yolov5
!pip install -r requirements.txt
```

Ilustración 39 Repositorios de descarga para Yolo V5

8.2 Preprocesamiento

Incluye:

- Redimensionamiento con `img 640` para redimensionadas a 640x640 píxeles.
- `!python train.py` es para ejecutar el script de entrenamiento de YOLOv5.
- `batch 16` para entrenar con un batch size de 16 (16 imágenes por paso).
- `epochs 50` para entrenar durante 100 épocas o ciclos completos sobre los datos.



```
!python train.py --img 640 --batch 16 --epochs 100 --data /content/colorantes.yaml --weights yolov5s.pt --cache
```

Ilustración 40 Código para el entrenamiento

8.3 Inferencia

El tensor resultante se pasa al modelo para obtener predicciones crudas.

8.4 Posprocesamiento

Se aplica Non-Max Suppression para eliminar detecciones redundantes y seleccionar la clase más relevante.

8.5 Interpretación

Se extrae el índice de la clase detectada y se mapea a la etiqueta correspondiente.

9. Justificación del preprocesamiento de imágenes

El preprocesamiento garantiza que las imágenes de entrada sean consistentes con las utilizadas durante el entrenamiento del modelo.

El uso de normalización y redimensionamiento:

- Reduce la variabilidad visual.
- Mejora la estabilidad de las predicciones.
- Disminuye el impacto de diferencias de resolución.
- Este paso es crítico para mantener la coherencia del sistema.

10. Backend: diseño y lógica de Flask

El backend está construido sobre Flask debido a su simplicidad y flexibilidad.

```
# ===== FLASK =====  
app = Flask(__name__)
```

Ilustración 41 Flask

10.1 Rutas

La ruta principal (/) gestiona:

Solicitudes GET para mostrar la interfaz.

Solicitudes POST para recibir imágenes y ejecutar inferencias.

```

# ===== RUTA =====
@app.route("/", methods=["GET", "POST"])
def index():
    result = None
    image_path = None
    confidence = None

    if request.method == "POST":
        file = request.files["image"]
        image_path = file.filename
        save_path = ROOT / "static" / image_path
        file.save(save_path)

        result, confidence = detect_image(save_path)

    return render_template(
        "index.html",
        result=result,
        image_path=image_path,
        confidence=confidence
    )

```

Ilustración 42 Ruta

10.2 Control de flujo

El backend coordina:

- Recepción de archivos.
- Almacenamiento temporal.
- Llamada al módulo de inferencia.
- Envío del resultado al frontend.

11. Manejo de archivos y almacenamiento

Las imágenes cargadas se almacenan temporalmente en el directorio static/.

Este enfoque:

- Permite mostrar la imagen analizada.
- Evita el uso de bases de datos.
- Reduce complejidad del sistema.

No se implementa persistencia a largo plazo por razones de simplicidad y privacidad.

12. Frontend y su integración con el backend

El frontend actúa como una capa de presentación pasiva:

- No ejecuta lógica de inferencia.
- Envía solicitudes al backend.
- Presenta resultados al usuario.

Esta separación evita duplicación de lógica y facilita el mantenimiento.

13. Consideraciones de rendimiento

El sistema está optimizado para:

- Procesar una imagen por solicitud.
- Ejecutarse en CPU con tiempos aceptables.
- Minimizar consumo de memoria.
- Para escenarios de mayor carga, se recomienda:
- Colas de procesamiento.

14. Seguridad y robustez del sistema

El sistema incluye mecanismos básicos de control:

- Validación de archivos cargados.
- Manejo de errores en inferencia.
- Respuestas controladas ante fallos.

No se implementan mecanismos avanzados de seguridad debido al carácter académico del sistema.

15. Limitaciones técnicas

Entre las principales limitaciones técnicas se encuentran:

- Dependencia estricta del entorno de iluminación.
- Clasificación discreta sin valores intermedios.
- Escalabilidad limitada en entornos multiusuario.
- Sensibilidad a variaciones visuales no entrenadas.

Estas limitaciones son consecuencia directa de las decisiones de diseño adoptadas.

16. Mantenimiento del sistema

El sistema puede mantenerse y actualizarse mediante:

- Reentrenamiento del modelo con nuevos datos.
- Ajuste de clases y etiquetas.
- Actualización de dependencias.

17. Escalabilidad y trabajo futuro

Como líneas de evolución técnica se consideran:

- Migración a GPU.
- Incorporación de base de datos.
- Implementación de autenticación.
- Integración con sensores o sistemas externos.
- Mejora del modelo mediante técnicas de calibración cromática.

18. Conclusión

El sistema documentado en este manual técnico representa una solución integrada que combina inteligencia artificial, visión por computadora y desarrollo web para la identificación visual de concentraciones de azul índigo.

Su diseño modular, decisiones y flujo de procesamiento lo convierten en una plataforma sólida para fines académicos, experimentales y de investigación aplicada.

8.5 Validación del método de cuantificación

Tabla 10 Validación de mediciones en pruebas de reproducibilidad y repetibilidad usando soluciones acuosas

# de prueba	Analista 1		Analista 2	
	Valor esperado (mg/L)	Valor obtenido (mg/L)	Valor esperado (mg/L)	Valor obtenido (mg/L)
1	20	20	20	20
2	20	20	20	20
3	20	10	20	20
4	30	0	30	30
5	30	0	30	0
6	30	40	30	30
7	50	0	50	0
8	50	0	50	0
9	50	0	50	0
10	50	30	50	0

Para asegurar la seguridad y robustez en la predicción de color en soluciones acuosas de azul índigo, se estructuro siguiendo el estándar industrial CRISP-DM. Este proceso sistemático permite validar el modelo de inteligencia artificial desarrollado y cuantificar su desempeño frente a métodos analíticos.

1. Definición del objetivo y comprensión del negocio: El desarrollo de una alternativa accesible y eficiente para cuantificar colorante azul índigo. Para ello se definió el objetivo de implementar una red neuronal convolucional desarrollada en un entorno colab capaz de predecir el color y estimar la concentración del azul índigo
2. Adquisición y comprensión de datos para el estándar: El método necesita datos de referencia reales, se utilizó una base de datos utilizando un espectrofotómetro como referencia para la toma de imágenes.
3. Preparación y estandarización: Antes de la validación de datos, se sometieron a un proceso de estandarización y etiquetado utilizando la plataforma Roboflow. Esta fase asegura que las imágenes utilizadas para entrenar y evaluar el modelo cumplan con criterios de calidad uniformes.
4. Modelo y análisis de imágenes: Se implementaron modelos supervisados en Google Colab para el análisis específico de las imágenes, optimizando la capacidad del modelo para correlacionar características de la imagen con concentraciones del color.

5. Evaluación del desempeño y validación: Se observó el rendimiento del modelo desarrollado mediante una comparación con los métodos tradicionales de espectrofotometría, esta validación se realizó utilizando métricas estándar de la evaluación del modelo como lo es precisión, Recall, mAP50 y mAP50-95.
6. Implementación y validación: Se implementó el prototipo en un entorno donde se realizaron pruebas en una empresa textil, permitiendo validar la aplicabilidad y rendimiento del modelo en condiciones reales de aguas teñidas con el colorante azul índigo.

Analista 1: Los resultados tienen alta variabilidad y errores extremos en la identificación de las soluciones. En la solución de 20 mg/L se obtuvieron valores cercanos al valor esperado en la mayoría de las pruebas realizadas, sin embargo, en la solución de 30 mg/L no se obtuvieron los mismos resultados lo que indica que tiene una falla en la detección de la concentración.

Para la solución de 50 mg/L la red no logró identificar la solución en la mayoría de la prueba, que esta registra valores de 0 mg/L y en la última prueba se obtuvo una respuesta de 30 mg/L. Estos resultados sugieren que el modelo presenta dificultades para la detección correcta de las demás concentraciones por que los factores como son la iluminación, la celda de cuarzo, fondo blanco y una cámara de buena resolución hacen que confunda las tonalidades del azul índigo y errores en la estimación que se desea.

Analista 2: Los resultados obtenidos por el analista 2 muestran una mayor consistencia en comparación con el analista 1, aunque todavía se observan errores en la identificación de las soluciones, lo que es en la concentración de la solución de 20 mg/L el sistema logró identificar correctamente la mayoría de las pruebas.

No obstante, en las soluciones de 30 mg/L y 50 mg/L hubo errores muy notorios, la red no logró identificarlos de forma satisfactoria, esto nos indica que las especificaciones para tomar imagen no fueron las adecuadas y la interferencia fue muy notoria.

8.5 Productos académicos



CONCIENCIA TECNOLÓGICA No. 69, Julio-Diciembre 2025: 94-98

Cuantificación de color usando reconocimiento con inteligencia artificial

Color quantification using artificial intelligence recognition

Investigación

Ricardo Alejandro Sánchez-González¹, María Guadalupe Pineda-Arizmendi¹, Iván Lenin Cruz-Jaramillo¹,
Luis Antonio Castillo-Suárez¹

¹Tecnológico Nacional de México/Tecnológico de Estudios Superiores de Tianguistenco, División de Ingeniería en
Sistemas Computacionales, División de Ingeniería Industrial, Posgrado, Maestría en Ingeniería
Carretera Tenango, Santiago-La Marquesa 22, Santiago Tilapa, Estado de México, México, 52650

Autor de contacto: maria_pa@test.edu.mx

Resumen

La industria textil representa un sector económico muy importante. Sin embargo, el agua residual que genera se caracteriza por el elevado contenido de color. Las normativas para la descarga de estas aguas generalmente regulan los niveles este parámetro. Los métodos convencionales de medición por espectroscopia ultravioleta suelen ser caros, requieren de personal altamente entrenado y los costos de mantenimiento suelen ser elevados.

La aplicación de inteligencia artificial (IA), ha permitido optimizar recursos y desarrollar tecnologías altamente eficientes. Estos algoritmos han permitido automatizar tareas y el rápido desarrollo está haciendo que el aprendizaje automático cobre más importancia en su campo de investigación. El objetivo del presente estudio fue entrenar un modelo de IA capaz de identificar automáticamente concentraciones de color azul índigo (AI) en soluciones acuosas.

Para la recolección de datos se utilizó un dataset de imágenes de diferentes tonalidades y concentraciones de un estándar de AI. El modelado y entrenamiento de una red neuronal convolucional (CNN) fue realizada en Google Colab. El modelo alcanzó una precisión del 70% en la identificación correcta de la concentración del colorante en su etapa beta. Mostró adaptabilidad a diferentes intensidades de color y condiciones de iluminación. La IA demostró ser una herramienta

for the discharge of this water generally regulate color levels. Conventional UV spectroscopy measurement methods are often expensive, require highly trained personnel, and maintenance costs are often high.

The development and application of artificial intelligence (AI) has made it possible to optimize resources and develop highly efficient technologies. These algorithms have made it possible to automate tasks and the rapid development is making machine learning more important in its field of research. The objective of the present research was to develop an AI model capable of automatically identifying indigo blue concentrations in aqueous solutions.

Data collection used a dataset of images of different shades and concentrations of an indigo blue standard. Modeling and training of a convolutional neural network (CNN) was performed in Google Colab. The model achieved 70% accuracy in correctly identifying the concentration of indigo blue in its beta stage. It showed adaptability to different color intensities and lighting conditions. AI proved to be an effective tool to automate the identification of different concentrations of indigo blue dye, which could improve efficiency in quality control and environmental monitoring.

Keywords: 3D printing, water treatment, dyes, textile industry, Google Colab.

Introducción



TECNOLÓGICO DE ESTUDIOS SU PERIORES DE TIANGUISTENCO
OTORGA LA


CONSTANCIA

A

RICARDO ALEJANDRO SÁNCHEZ GONZÁLEZ

POR SU DESTACADA PARTICIPACIÓN COMO PONENTE CON EL TEMA "CUANTIFICACIÓN DE COLOR CON INTELIGENCIA ARTIFICIAL", EN EL MARCO DEL 1ER CONGRESO NACIONAL DE INGENIERÍAS SOSTENIBLES: INNOVANDO EL FUTURO, QUE SE LLEVÓ A CABO LOS DÍAS 25 Y 26 DE NOVIEMBRE DE 2025.




Mtra. Mónica González Bautista
Directora General del TEST


Mtra. Sarai Avila Gutiérrez
Directora Académica

Tianguistenco, Estado de México a 19 de marzo de 2026



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO

EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TIJUANA
OTORGA LA PRESENTE

CONSTANCIA

A

**Ricardo Alejandro Sánchez-González, María
Guadalupe Pineda-Arizmendi, Iván Lenin Cruz-
Jaramillo, Luis Antonio Castillo-Suárez**

Tecnológico de Estudios Superiores de Tianguistenco

Por su valiosa participación con la ponencia
**Cuantificación de color usando reconocimiento con inteligencia
artificial,**
dentro del Primer Congreso Internacional en Agua Limpia y Saneamiento
del TecNM, llevado a cabo los días 25 y 26 de septiembre del 2025.

JOSÉ GUILLERMO CARDENAS LÓPEZ
DIRECTOR

Tijuana, Baja California a 25 de septiembre del 2025.



Educación
Secretaría de Educación Pública



INSTITUTO TECNOLÓGICO DE TIJUANA

DIRECCIÓN



"2025. Bicentenario de la vida municipal en el Estado de México".

Tecnológico de Estudios Superiores de Tlanguistenco

Tlanguistenco, Estado de México; a 21 de noviembre de 2025

Asunto: Carta de Aceptación

ESTIMADOS INVESTIGADORES: Luis Antonio Castillo Suárez, María Guadalupe Pineda Arizmendi y Ricardo Alejandro Sánchez González

PRESENTES

Agradecemos mucho su participación e interés para participar en el **1er Congreso Nacional en Ingeniería Sustentable, Innovando el Futuro**, hacemos de su conocimiento que después de haber sido revisado rigurosamente por el comité científico su trabajo titulado:

Cuantificación de color con Inteligencia Artificial

Ha sido **APROBADO** para presentarse de manera **VIRTUAL** como **PONENTE** el día 25 al 26 de noviembre de 2025.

Sin más por el momento, agradecemos su participación.

Atentamente

"Tecnología, Estudio, Superación y Trabajo Para Tu Futuro"

M.A.P. Erick René Hernández Muñoz
Subdirector de Apoyo y Desarrollo Académico

C.c.p. Archivo.
LGP





Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA LA PRESENTE

CONSTANCIA

A

RICARDO ALEJANDRO SÁNCHEZ GONZÁLEZ

POR SU DESTACADA PARTICIPACIÓN PRESENTANDO EL PROYECTO
COLORSENSE, DE LA **CATEGORÍA INDUSTRIA ELÉCTRICA Y ELECTRÓNICA**
EN EL CERTAMEN DE PROYECTOS (NIVEL LICENCIATURA), DE LA
CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, EMPRENDIMIENTO E INNOVACIÓN,
INNOVATECNM 2025
ETAPA REGIONAL, REGIÓN 4

CELEBRADO DEL 23 AL 26 DE SEPTIEMBRE
TOLUCA DE LERDO, ESTADO DE MÉXICO A 26 DE SEPTIEMBRE DE 2025


MARCO ANTONIO
TRUJILLO MARTÍNEZ

**DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO**

DANIEL
VILLANUEVA VÁSQUEZ
**DIRECTOR DEL
IT DE TOLUCA**





GOBIERNO DEL
ESTADO DE
MÉXICO



TECNOLÓGICO
NACIONAL DE MÉXICO



TECNOLÓGICO DE ESTUDIOS SUPERIORES DE TIANGUISTENCO
OTORGA EL

RECONOCIMIENTO

A:

RICARDO ALEJANDRO SÁNCHEZ GONZÁLEZ

POR SU VALIOSA PARTICIPACIÓN EN LA "FERIA DE CIENCIAS" CON UNA EXPOSICIÓN
EN ESTAND, DEL PROYECTO DE DIFUSIÓN CIENTÍFICA, EN EL MARCO DE LA "SEMANA
DE LA CIENCIA Y TECNOLOGÍA 2025", QUE SE LLEVÓ A CABO EL 27 Y 28 DE
OCTUBRE DE 2025.



Mtra. Mónica González Baumbach
Directora General del TESI Tón General



Mtra. Sarai Avila Gutiérrez
Directora Académica

Tianguiستنكو, Estado de México a 29 de octubre de 2025



GOBIERNO DEL
ESTADO DE
MÉXICO




EL TECNOLÓGICO DE ESTUDIOS SUPERIORES DE TIANGUISTENCO OTORGA EL PRESENTE:


RECONOCIMIENTO

A:

RICARDO ALEJANDRO SÁNCHEZ
GONZÁLEZ

POR HABER PARTICIPADO COMO EXPOSITOR DE SU PROYECTO
EN LA ETAPA LOCAL DEL INNOVATECNM 2025


Mtra. Mónica González Bauuista
Directora General TEST


Lic. Emmanuel Garduño Medina
Director de Planeación y Vinculación

Tianguiستenco, Estado de México, a 28 de mayo de 2025.



Economía
Secretaría de Economía



IMPI
INSTITUTO MEXICANO
DE LA PROPIEDAD
INDUSTRIAL



(1) Tema de la búsqueda de información tecnológica

**Tema de
la búsqueda:**

**Es un dispositivo para la
determinación del color en
muestras líquidas, mediante visión
artificial y procesamiento**

El presente reporte se elabora a partir de los resultados de la búsqueda de información tecnológica encontrados en bases de datos de patentes internacionales a las que tiene acceso el Instituto, las cuales puedes consultar a detalle en la “hoja de resultados”.

La información que se incluye se obtiene de las bases de datos de patentes tal y como fueron capturadas por las oficinas de propiedad intelectual de los diferentes países que aportan los datos consultados.

En los resultados de la búsqueda se encuentran incluidas las solicitudes de patente, modelo de utilidad o diseños industriales que a la fecha de elaboración del presente reporte se encontraban publicadas en los diferentes portales de patentes consultados.



2025
Año de
La Mujer
Indígena

Periférico Sur 3106, Jardines del Pedregal, C.P. 01900, Alcaldía Álvaro Obregón, Ciudad de México.

Teléfono: 55 5624 0400 Ext.10048 www.gob.mx/impi



IT/S/2025/000867
DIRECCIÓN DIVISIONAL DE PROMOCIÓN Y
SERVICIOS DE INFORMACIÓN TECNOLÓGICA
REPORTE DE BÚSQUEDA DEL ESTADO DE LA TÉCNICA
Folio de Salida: IT/S/2025/000867
Folio de Solicitud: IT/B/2025/000845
Folio del Expediente: IT/E/2025/006620
CDMX
" "

27 de noviembre de 2025

LUIS ANTONIO CASTILLO SUAREZ

Presente

En este documento encontrará la información recuperada de las distintas bases de datos en las que se realizó la búsqueda de información solicitada, la estrategia se ejecutó conforme a la información proporcionada en su solicitud y está conformada por palabras claves y/o clasificación que permitieron hacer la recuperación de los documentos cercanos a la investigación, asimismo se mencionan el número de documentos obtenidos de las bases consultadas. Estos se podrán visualizar en los archivos adjuntos que se proporcionan.

Cada archivo contendrá los datos bibliográficos y técnicos de cada uno de los documentos que se relacionan con la información proporcionada.

Se adiciona a esta hoja de resultados, información relevante acerca de los tipos de servicio que pudiera concordar con sus necesidades.

Con relación a su solicitud de búsqueda con fecha de presentación 07 de noviembre de 2025, correspondiente a:

es un dispositivo para la determinación del color en muestras líquidas, mediante visión artificial y procesamiento digital de imágenes asistida con inteligencia artificial, integra una celda de muestra, bombas

A continuación se presentan los siguientes resultados:

BASE DE DATOS	ESTRATEGIA DE BÚSQUEDA	DOCUMENTOS ENCONTRADOS
IMPI (SIGA)	visi_n and (artificial or computarizada) and agua and G01N*	5
DERWENT INNOVATION	(water) AND CTB=((artificial or computer or machine) and vision and color) AND AIC=(G06V* or G01N* or G01J*);	125
DERWENT INNOVATION	(artificial and vision) AND ALL=(water and quality) AND (TF>=(1898) AND TF<=(2025));	2
TOTAL DE DOCUMENTOS ENCONTRADOS		132

9. CONCLUSIONES

Los algoritmos de inteligencia artificial aplicados a la clasificación de agua representan una herramienta prometedora para mejorar la precisión y rapidez frente a los métodos tradicionales. Se destaca que estos modelos permiten identificar con mayor exactitud si el agua es potable, residual o subterránea, lo cual facilita la gestión de recursos hídricos y el monitoreo ambiental. Sin embargo, también se señalan limitaciones importantes, como la falta de bases de datos estandarizadas, el acceso desigual a información en distintos contextos y la necesidad de validar los modelos en escenarios reales más allá de entornos controlados. El impacto de estas técnicas se reconoce como clave para la sostenibilidad ambiental y la protección de la salud pública, ya que contribuyen a optimizar procesos de tratamiento y a la toma de decisiones en políticas de gestión del agua. Finalmente, se recomienda avanzar en la integración de datos confiables y estandarizados, en la optimización de algoritmos para distintos contextos y en su implementación práctica a gran escala, de modo que la combinación de inteligencia artificial y métodos tradicionales garantice un manejo más eficiente y seguro de los recursos hídricos.

10. RECOMENDACIONES

10.1 Trabajo futuro y /o recomendaciones

A partir de los resultados obtenidos durante el desarrollo del proyecto de cuantificación de color mediante reconocimiento artificial, se identifican diversas oportunidades de mejora y líneas de trabajo futuro.

10.2 Ampliación y diversificación de la base de datos

Se recomienda ampliar la base de datos de imágenes utilizadas para el entrenamiento del modelo, incorporando un mayor número de muestras y una mayor diversidad de concentraciones de color. Asimismo, resulta conveniente incluir variaciones controladas en condiciones de iluminación, tipo de recipiente y fondo, con el fin de mejorar la capacidad de generalización del modelo ante escenarios reales de uso.

La inclusión de un conjunto de datos más amplio permitiría reducir el sobreajuste y mejorar el desempeño del modelo cuando se enfrente a imágenes no vistas durante el entrenamiento.

10.3 Mejora del proceso de calibración y validación

Como trabajo futuro, se propone fortalecer el proceso de validación del sistema mediante una comparación cuantitativa más detallada entre los valores estimados por el modelo de reconocimiento artificial y los valores obtenidos mediante espectrofotometría. Esto podría realizarse mediante el cálculo de métricas de error, análisis de correlación y estudios de repetibilidad, lo que permitiría evaluar de forma más precisa la confiabilidad del sistema.

Asimismo, se recomienda explorar el uso de múltiples curvas de calibración asociadas a diferentes rangos de concentración, con el fin de mejorar la precisión del sistema en distintos intervalos de color.

10.4 Optimización y exploración de nuevos modelos de inteligencia artificial

Se sugiere evaluar otras arquitecturas de aprendizaje profundo orientadas al análisis de color, tales como modelos de regresión basados en redes neuronales convolucionales o enfoques híbridos que combinen detección de objetos con análisis estadístico del color. La comparación entre distintos modelos permitiría identificar la arquitectura más adecuada para la cuantificación de color en soluciones acuosas.

Adicionalmente, se recomienda optimizar los parámetros del modelo entrenado y analizar el impacto de técnicas de aumento de datos sobre el desempeño del sistema.

10.5 Integración de análisis cromático más avanzado

Como línea de mejora, se propone integrar métodos de análisis cromático en espacios de color alternativos, como HSV o CIELAB, los cuales pueden ofrecer una representación más robusta de la información visual frente a cambios de iluminación. Esta integración podría complementar el reconocimiento basado en aprendizaje profundo y contribuir a una estimación más precisa del color.

10.6 Evolución de la aplicación web

Se recomienda ampliar las funcionalidades de la aplicación web desarrollada, incorporando opciones como el almacenamiento histórico de resultados, la exportación de datos y la visualización gráfica de las concentraciones estimadas. Asimismo, podría considerarse la adaptación del sistema a dispositivos móviles, lo que incrementaría su accesibilidad y potencial de aplicación en campo.

11. FUENTES BIBLIOGRÁFICAS

- Ahmed, S., & Raihan, M. (2014). Estado de salud de las trabajadoras del sector textil de Bangladesh. *Faculty Econom Administr Sci*, 43-58.
- Alonso, A., & Jara, E. (2016). Visión por computadora: identificación, clasificación y seguimiento de objetos. *FPUNE Scientific*, 11(1), 48–55.
- Bermeo Matute, N., & Salazar Vallejo, F. (2013). Optimización de la planta de tratamiento de aguas residuales Industriales de una empresa Textil. Bachelor's thesis.
- Bharat, P., & Pramanik, A. (2019). Deep learning techniques—R-CNN to mask R-CNN: a survey. *Computational Intelligence in Pattern Recognition: Proceedings of CIPR*, 657-668. doi:10.1007/978-981-13-9042-5_56
- Boden, M. (2017). Inteligencia artificial. Turner.
- Borja Hernández, F., & Cruz Escobar, D. (2024). Diseño e implementación de un sistema de bienvenida con reconocimiento facial en un conjunto habitacional. Bachelor's thesis.
- Calixto, Nelson, J., & Carrillo-Soto, G. (2022). Fundamentos de la contaminación de aguas subterráneas. Bogotá, Colombia.: Ecoe Ediciones S.A.S.,. doi:ISBN: 978-958-503-241-5
- Campos Ruiz, C. (2017). Colorantes usados en textiles artesanales e industriales. Análisis mediante Espectroscopia Raman de anilinas sintéticas.
- Canchanya Balvim, V. (2021). Decoloración de aguas residuales contaminados con verde de malaquita por foto Fenton.
- Cano, R. T. (2020). La ganadería y su incidencia en la contaminación de fuentes de agua de la parroquia sexto duran ballén. Jipijapa- Manabí- Ecuador: Jipijapa.UNESUM.
- Cárdenas Díaz, L., & Tirado Ballestas, R. (2004). Visión por computador. Barranquilla, Colombia.: Ediciones Uninorte. doi:ISBN: 958-8133-93-X

- Carlos, P., & Liduvina, S. (2018). Metales pesados: fuentes y su toxicidad sobre la salud humana. *Revista de Ciencias*, 23(2), 31-41. doi:10.2701/rc.v23i2.417
- Casado Beinat, N. (2022). Redes neuronales convolucionales y aplicaciones.
- Casas, A., Tapias, J., Bustamante, I., Iglesias, J., Miguel, Á., Lillo, J., & Mas, J. (2011). Guía metodológica para el uso de aguas regeneradas en riego y recarga de acuíferos. Madrid, España.: Comunidad de Madrid / Universidad de Alcalá (UAH). doi:ISBN: 978-84-615-3850-8
- Castillo-Suárez, L., Sierra-Sánchez, A., & Linares, H. (2023). A critical review of textile industry wastewater: Green technologies for indigo dye removal. *International Journal of Environmental Science and Technology*, 20, 10553-10590. doi:10.1007/s13762-023-04803-3
- Castro Astudillo, J. (2023). Experimentación de tinturado natural sobre denim. Bachelor's thesis, Universidad del Azuay.
- CONAPESCA. (2015). Atiende CONAPESCA mortalidad de peces en Almoloya del Río. *Agricultura|edomex*.
- Economista, Alma Córdova / El. (26 de febrero de 2014). *eleconomista.com.mx*. Obtenido de EL ECONOMISTA: <https://www.eleconomista.com.mx/estados/Kaltex-ve-mayor-produccion-de-mezclilla-este-ano-20140225-0091.html>
- Esther, F., Tibor, c., & Gyula, O. (2004). Removal of synthetic dyes from wastewaters: a review. *Environment International*, 30(7), 953-971. doi:10.1016/j.envint.2004.02.001
- ferrovial. (2024). Obtenido de *ferrovial.com*: <https://www.ferrovial.com/es/recursos/aguas-residuales/>
- Figueroa, C., Silvas, L., & Hidalgo, S. (2025). Revisión de los procesos de clasificación de agua mediante modelos de aprendizaje máquina. *South Florida Journal of Development*, 6(1), e5136-e5136. doi:10.46932/sfjdv6n1-015
- Francesco, , M. (2019). Jeans sustentables: La industria jeanera se reinventa para mantener vigente el clásico pantalón. Proyecto de investigación, Universidad del Este, Facultad de Diseño y Comunicación.
- Francisco, R., Moreira, S., & Albuquerque. (2023). Toxic effects of synthetic and natural indigo dyes on *Danio rerio* reproduction. *Studies in Environmental and Animal Sciences*, 4(1), 128-145. doi:10.54020/seasv4n1-011
- Franco, E., Ramos, R., Ovando-Javier, A., & Monte. (2023). Sensores de calidad de agua para el control de la contaminación físicoquímica en los acuíferos de Latinoamérica. *Ciencia, Ambiente y Clima*, 6(1), 45–62. doi:10.22206/cac.2023.v6i1.2825

- Fuga, A. (2006). *Tecniche e materiali delle arti*. Los Ángeles, Estados Unidos: Getty Publications. doi:ISBN: 978-0-89236-756-6
- Galán Cortina, V. (2016). Aplicación de la metodología CRISP-DM a un proyecto de minería de datos en el entorno universitario.
- Gereffi, G. (2005). Crecimiento orientado a la exportación y modernización industrial: lecciones del caso mexicano de la confección: un estudio de caso sobre el análisis de las cadenas globales de valor. *Comercio Exterior*, 55(1), 54–69.
- Gomez, H., Vargas, R., & CHECA, N. (2020). Desarrollo de una solución comercial tecnológica basada en software y hardware libres. Doctoral dissertation, 50.
- Guanajuato, U. d. (20 de julio de 2011). Degradan en la UG contaminantes de las aguas textiles. Obtenido de ugto.mx: <https://www.ugto.mx/noticias/quehacer-institucional/638-degradan-en-la-ug-contaminantes-de-las-aguas-textiles>
- Günther Wyszecski, W., & S., S. (2020). *Color Science: Concepts and Methods, Quantitative Data and Formulae*. John Wiley & Sons. doi:10.1002/9781118150856
- Guzmán Gamboa, N. (2022). Revisión del estado de avance de las aplicaciones de la nanotecnología para la reducción de contaminantes presentes en los vertimientos de la industria textil.
- Hernández Cortez, C., & Aguilera Arreola, M. (2011). Situación de las enfermedades gastrointestinales en México. *Enfermedades Infecciosas y Microbiología*, 31(4), 137–151.
- Herrador, R. (2009). *Guía de usuario de Arduino*.
- Ibarra, L., Castillo, P., & Montelongo. (2021). Sistema de clasificación de agua jabonosa empleando Redes Neuronales. *Revista ELECTRO*, 43, 44-49.
- James Holler, F., & Stanley R., C. (2015). *Química Analítica*. México, D.F.: CENGAGE Learning. doi:ISBN-13: 978-607-519-376-2.
- Jiménez, F. (25 de Diciembre de 2023). 'Leobardo California', el taller familiar de Almoloya que lleva 35 años produciendo jeans. (B. Jasso., Entrevistador) Almoloya de Juárez, Estado de México.
- Kaltex. (s.f.). Kaltex.com.mx. Obtenido de Kaltex: <http://www.kaltex.com.mx/espanol/index.html>
- Kant, R. (2011). Textile dyeing industry an environmental hazard. *Scientific Research Publishing*, 3(1), 22–26. doi:10.4236/ns.2011.31004
- Kant, R. (2012). Textile dyeing industry an environmental hazard. *Natural science*, 22-26. Obtenido de <https://doi.org/10.4236/ns.2012.41004>

- Larson, E. (2022). *The Myth of Artificial Intelligence: Why Computers Can't Think the Way We Do*. Shackleton books. doi:ISBN: 978-84-1361-124-2.
- Liu, J., & Diamond, J. (2006). El medio ambiente de China en un mundo globalizado. Cómo se interrelacionan China y el resto del mundo. *Ars Medica*, 5(2), 228-255. doi:10.1038/4351179a
- Maldonado Rogel , A., & Molina Ayala, R. (2011). Estudio para la reducción de colorantes de las aguas residuales de la industria textil a través de procesos electroquímicos. Tesis de grado, Universidad Politécnica Salesiana, Facultad de Ciencias Agropecuarias y Ambientales.
- Marcó , L., Azario , R., Metzler, C., & Garcia, M. (2004). La turbidez como indicador básico de calidad de aguas potabilizadas a partir de fuentes superficiales. Propuestas a propósito del estudio del sistema de potabilización y distribución en la ciudad de Concepción del Uruguay. *Higiene y Sanidad Ambiental*, 4, 72–82.
- Marín Balseca, A. (2024). Tratamiento de imágenes para la detección de objetos y personas con inteligencia artificial en el laboratorio de fabricación digital.
- Martínez Llamas, J. (2018). Reconocimiento de imágenes mediante redes neuronales convolucionales.
- McCulligh, C. (2013). La no regulación ambiental: contaminación industrial del río Santiago en Jalisco. *Observatorio del desarrollo.*, 5(2), 45–50.
- Mena Bolaños, D. (2019). Evaluación de la respuesta fisiológica de la microalga *Chlorella* sp. a la presencia de metal cromo (VI) en aguas sintéticas. Ecuador.
- Montes-Ortiz, L., & L., B.-M. (2024). Chimaliapan: resiliencia de una naturocultura lacustre. *Revista de Antropología y Sociología*, 26(1), 143–169. doi:10.17151/ras.2024.26.1.7
- Morales, G., Gutiérrez, M., & Andrade,. (2010). *Muestreo y Calidad del Agua*. Fondo Editorial Fundación Koinonía.
- Moreira Ramos, D. (2021). Aplicación de un modelo de reconocimiento de objetos utilizando yolo. Bachelor's thesis, La Libertad: Universidad Estatal Península de Santa Elena.
- Moreno-Villalba, L., & Ávila-Camacho, F. (2021). Diseño de un espectrofotómetro UV-VIS de bajo costo para la industria bioquímica: una revisión. researchGate.
- Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press. Obtenido de <http://neuralnetworksanddeeplearning.com/>
- Oliver, N. (2021). *Inteligencia artificial, naturalmente: un manual de convivencia entre humanos y máquinas para que la tecnología nos beneficie a todos*.
- Ortiz Páez, S. (2021). Estudio de la aplicación de los procesos fotocatalíticos para la remoción de metales pesados presentes en aguas residuales industriales.

- Peralta, F. (2014). Proceso de conceptualización del entendimiento del negocio para proyectos de explotación de información. *RELAIS*, 2(5), 273-306. doi:10.18294/relais.2014.273-306
- Porkodi, M., Brahmane, M., Pathan, M., & Poojary, N. (2024). Toxicity, teratogenicity and genotoxicity studies in zebrafish embryos. *Mutation Research - Toxicología Genética y Mutagénesis Ambiental*. doi:10.1016/j.mrgentox.2023.503718
- Ramírez Quiroga, C. (2022). Desarrollo de un sistema clasificador de contaminantes en una muestra de agua utilizando inteligencia artificial. Master's thesis.
- Roboflow, I. (2023). Roboflow: Give your software the power to see objects in images and video.
- Rodríguez, C., Cedillo, D., & G. G, R. (2019). Contaminación por aguas residuales en la laguna de Chignahuapan, Estado de México: análisis de causas y efectos.
- Román, J. (2016). Talleres de mezclilla y transformaciones sociambientales en un municipio rural. El caso de Tepetitla de Lardizábal, Tlaxcala, México. *Sociedad y Ambiente*, 1(11), 130–156. doi:10.24310/socyamb.v1i11.13961
- Romero Carrillo, F. J. (2025). Estudio de librerías de detección de posturas sobre dispositivos móviles.
- Romo, M. (2001). Análisis de agua determinación de color platino cobalto en aguas naturales, residuales y residuales tratadas-método de prueba. Obtenido de SECRETARIA ECONOMICA DE MEXICO . Obtenido de <http://legismex.mty.itesm.mx/normas/aa/aa045-01>.
- Rosero Romero, M. (2024). Contribución a las emisiones de gases de efecto invernadero generados por el tratamiento térmico (incineración) de desechos peligrosos contaminados con hidrocarburos en el Ecuador. Quito, EC: Universidad Andina Simón Bolívar, Sede Ecuador.
- Soto, D., & Gonzalez_Gutierrez, L. (2025). Construcción y operación de un proceso bioelectroquímico prototipo para el tratamiento de agua residual textil.
- Villar, J., Garcia, J., & Hiyo, S. (2020). Diseño y construcción de un sistema automatizado de control de bombas de agua en un cultivo hidropónico en el entorno Arduino. UNSCH–Ayacucho.
- Worood A., E.-M., Najma, L., c Ahmed H., I., a Rana R., H., a Paulina, M., d Ryszard T., S., . . . Mohamed H., A. (2021). Digital image colorimetry based on smartphone platforms: A review. *Analytical Methods*, 5196-5213. Obtenido de <https://doi.org/10.1039/D1AY01151G>

- Zambrano-Chacón, P. (2013). Greenpeace International. 2012: Hilos tóxicos: al desnudo. Exponiendo el papel de la industria textil en la contaminación de los ríos de México. Agua y Territorio/Water and Landscape, 177-177. doi:10.17561/at.v1i2.1355
- Zhou, Z., Guo, Q., Xu, Z., Wang, L., & Cui, K. (2015). Distribution and removal of endocrine-disrupting chemicals in industrial wastewater treatment. Environmental Engineering Science, 32(2), 203-211. doi:10.1089/ees.2014.0326

12. ANEXOS

Anexo 1 A Descripción del código (app.py)

```
import sys  
  
import torch  
  
import yaml  
  
import cv2  
  
import numpy as np  
  
from flask import Flask, render_template, request  
  
from pathlib import Path
```

En este apartado se agregaron todas las paqueterías que se utilizaron, como lo es sys que sirve para manipular las rutas del sistema, torch que es cargar y ejecutar el modelo de Yolo v5, cv2 es para abrir, leer y procesar imágenes, flask es muy importante ya que es todo el framework web para crear la aplicación, y path es el manejo de rutas de archivo.

```
FILE = Path(__file__).resolve()  
  
ROOT = FILE.parent  
  
sys.path.append(str(ROOT / "yolov5"))
```

Esto solo es para leer las rutas donde está el archivo en la carpeta YOLOv5 para poder importarlas

```
from models.yolo import Model
```

```
from utils.general import non_max_suppression
```

```
from utils.augmentations import letterbox
```

Model. Define la arquitectura que tendrá yolo, non_max_suppression elimina detecciones duplicadas y letterbox redimensiona la imagen

```
app = Flask(__name__)
```

Este apartado solo es para crear la aplicación web

```
weights = ROOT / "model" / "best_state_dict.pt"
```

```
with open(ROOT / "yolov5" / "models" / "yolov5s.yaml", "r") as f:
```

```
    cfg = yaml.safe_load(f)
```

```
cfg["nc"] = 6
```

```
cfg["names"] = ['10 mgL','20 mgL','30 mgL','40 mgL','50 mgL','60 mgL']
```

```
model = Model(cfg).to(device)
```

```
state_dict = torch.load(weights, map_location=device)
```

```
model.load_state_dict(state_dict)
```

```
model.eval()
```

```
names = cfg["names"]
```

Este apartado solo se utiliza para verificar las rutas del archivo, en este caso es solo de buscar la ruta donde esta entrenado el modelo que es el .best, se ajusta los modelos clasificados que son las 6 soluciones entrenadas

```
def detect_image(img_path):  
  
    img0 = cv2.imread(str(img_path))  
  
    img = letterbox(img0, 640, stride=32, auto=True)[0]  
  
    img = img.transpose((2, 0, 1))[:,::-1]  
  
    img = np.ascontiguousarray(img)  
  
    img = torch.from_numpy(img).to(device)  
  
    img = img.float() / 255.0  
  
    if img.ndimension() == 3:  
  
        img = img.unsqueeze(0)  
  
    with torch.no_grad():  
  
        pred = model(img)  
  
    pred = non_max_suppression(pred, 0.4, 0.45)  
  
    if pred[0] is not None and len(pred[0]):  
  
        det = pred[0][0]  
  
        cls = int(det[5])  
  
        confidence = float(det[4])  
  
        return names[cls], confidence  
  
    return "No detectado", None
```

La línea de código `cv2.imread` es para cargar la imagen, el `letterbox` redimensiona por completo la imagen a 640px manteniendo las proporciones, `torch.from_numpy` esta es muy importante ya que con esta línea de código convierte la imagen a tensor para que la página web pueda leerla sin problema, `model(img)` solo para ejecutar la inferencia, `non_max_suppression` filtra las detecciones para asimilar si la solución que se carga corresponde a la que están cargadas y si hay detención devuelve la imagen con el nombre de la solución correspondiente si no solo pasa como no detectado

```
@app.route("/", methods=["GET", "POST"])
```

```
def index():
```

```
    result = None
```

```
    image_path = None
```

```
    confidence = None
```

```
    if request.method == "POST":
```

```
        file = request.files["image"]
```

```
        image_path = file.filename
```

```
        save_path = ROOT / "static" / image_path
```

```
        file.save(save_path)
```

```
        result, confidence = detect_image(save_path)
```

```
    return render_template(
```

```
        "index.html",
```

```
        result=result,
```

```
        image_path=image_path,
```

```
        confidence=confidence
```

)

Este bloque de código es para definir la ruta, el usuario puede subir una imagen, la guarda en static y pasa a detect_image, y devuelve la imagen con el resultado obtenido

Anexo 1 B Descripción del código(html)

```
<!DOCTYPE html>
```

```
<html lang="es">
```

```
<head>
```

```
<meta charset="UTF-8">
```

```
<title>Identificador de Soluciones (10–60 mg/L)</title>
```

Es el encabezado de todo el documento aquí se declara la documentación html, Lang="esp" es para español, meta charset="UTF-8"

```
<style>
```

```
body {
```

```
margin: 0;
```

```
font-family: Arial, sans-serif;
```

```
background: radial-gradient(circle at top, #1c1c1c, #000);
```

```
color: white;
```

```
}
```

Este es para todo el estilo css que va a tener la página web, por ejemplo, el fondo oscuro que va a tener, texto en blanco, título, las cajas, botones, las imágenes ajustadas, prácticamente todo lo que visualmente se puede observar o lo que puede observar el usuario final.

```

<div class="box">

    <p>Imagen de entrada</p>

    <form method="POST" enctype="multipart/form-data">

        <input type="file" name="image" required>

        <div class="buttons">

            <button class="btn-identificar" type="submit">Identificar</button>

        </div>

    </form>

</div>

```

Este es solo para la imagen que va a tener de entrada la imagen que se envía a flask, el botón que se encarga de subir las imágenes y el botón de identificar.

```

<div class="box">

    <p>Resultado</p>

    {% if image_path %}

    {% endif %}

    {% if result %}

        <div class="resultado-texto">

            {{ result }}

        </div>

    {% endif %}

</div>

```

```
{% endif %}
```

```
</div>
```

Por este lado tenemos el resultado que enviar cuando nosotros identificamos las soluciones, muestra la imagen si corresponde a alguna solución y el texto que muestra la predicción.

```
<div class="buttons">
```

```
<form method="GET">
```

```
<button class="btn-limpiar" type="submit">Limpiar</button>
```

```
</form>
```


```
</div>
```

Por último, tenemos el botón de limpiar que sirve para quitar la solución ya identificada y poder identificar una nueva.

13. ANEXO FOTOGRÁFICO

Tabla 11 evidencia fotográfica

	En este apartado se puede visualizar el trabajo que se está realizando para comprobar métodos de espectrofotometría con el modelo de inteligencia artificial.
---	--

	En este punto se está calibrando y ajustando los parámetros para comparar los métodos correspondientes.
	En este punto se está ejecutando la página web para probar si identifica las soluciones correctamente.
	Aquí se está comparando ambos métodos.
	Por último, se puede ver la pantalla de la computadora donde se estaban realizando las pruebas.