

# IMPLEMENTACIÓN DE TÉCNICAS DE SEGMENTACIÓN DE IMÁGENES PARA EL ANÁLISIS DE LA EFICIENCIA DE SOLUBILIZACIÓN EN BACTERIAS SOLUBILIZADORAS DE FOSFATO



**Pablo Jose Menjivar Manrique**

Director:

Ph.D (c). Andres Solis Pino

Codirector:

MSc. Julio Eduardo Mejía Manzano

Corporación Universitaria Comfacaucá

Facultad de ingeniería

Grupo de investigación en sistemas inteligentes

Popayán, Noviembre de 2024

# **Pablo Jose Menjivar Manrique**

## **Ingeniería mecatrónica**

Trabajo de investigación presentado como requisito parcial para optar por el  
título de Ingeniero Mecatrónico

Director:

Ph.D. Andrés Solís Pino

Codirector:

MSc. Julio Eduardo Mejía Manzano

Popayán

2024

Nota de Aceptación

---

---

---

---

Presidente del Jurado

---

Jurado

---

Jurado

Popayán, Cauca 13, 11, 2024

## DEDICATORIA

Para Patricia y JuanCa, que alimentaron mi imaginación, y ahora siempre tengo hambre de curiosidad.

**PJMM**

## **AGRADECIMIENTOS**

Creo que pocas veces se puede se puede escribir algo con tanta conciencia sabiendo que es el preámbulo a una nueva etapa en la existencia, supongo que hay muchas cosas por las que agradecer, pero aquí quiero plasmar las que creo que son las más vitales para marcar las nuevas lunas que vendrán, a mi hermana y a Juan que siempre creen en mí y me ayudan a seguir buscando mi mejor versión, agradecer a mi director que tuvo la infinita paciencia de ayudarme y guiarme a terminar este camino, y profundamente a los bellos paisajes de esta tierra que no es mía pero me recibió como a uno de sus hijos y me dejó encontrar en sus montañas las herramientas para culminar esta monografía.

## RESUMEN

El siguiente trabajo de grado explora la visión artificial como una herramienta capaz de facilitar la determinación de la eficiencia relativa de solubilización de fosfato, Uno de los métodos más empleados para el análisis de bacterias, se da a través de la observación de las muestras en el microscopio, este método requiere de una gran inversión de tiempo y esfuerzo por parte del personal del laboratorio, puede producir fatiga ocular en los observadores y ser diferente el conteo realizado entre diferentes especialistas [1]. Los métodos de segmentación aplicados en este trabajo son consistentes y presentan una ligera desviación respecto al cálculo manual de eficiencia relativa de solubilización, lo que indica que estos modelos ofrecen en potencia una precisión confiable.

## **ABSTRACT**

The following degree work explores artificial vision as a tool capable of facilitating the determination of the relative solubilization efficiency. One of the most used methods for the analysis of bacteria is through the observation of samples under the microscope. This method requires a large investment of time and effort on the part of laboratory personnel, it can cause eye fatigue in observers and the counting carried out between different specialists may be different [6]. The segmentation methods applied in this work are consistent and present a slight deviation from the manual calculation of relative solubilization efficiency, indicating that these models potentially offer reliable accuracy.

## Tabla de Contenidos

1	Introducción.....	13
1.1	Planteamiento del problema.....	13
1.2	Justificación.....	16
1.3	Objetivos .....	18
1.3.1	Objetivo general .....	18
1.3.2	Objetivos específicos .....	18
1.4	Metodología .....	19
1.4.1	FASE 1: PLANTEAMIENTO DEL PROBLEMA.....	19
1.4.2	FASE 2: CONSTRUCCIÓN DEL MODELO TEÓRICO.....	19
1.4.3	FASE 3: VALIDACIÓN DEL SISTEMA DE VISIÓN ARTIFICIAL .....	20
1.4.4	FASE 4: INTRODUCCIÓN DE LAS CONCLUSIONES EN LA TEORÍA 20	
1.4.5	FASE 5: DOCUMENTACIÓN.....	20
2	Marco teórico y conceptual.....	21
2.1	MARCO TEÓRICO.....	21
2.1.1	Conceptos relacionados con Visión artificial .....	21
2.1.2	Sistema de visión artificial .....	21
2.1.3	Visión artificial .....	21
2.1.4	Procesamiento de imágenes.....	21
2.1.5	Redes neuronales convolucionales.....	22
2.1.6	YOLO .....	22
2.1.7	Segmentación semántica .....	23
2.1.8	Conceptos relacionados con Bacterias solubilizadoras .....	23
2.1.9	Bacterias solubilizadoras .....	23
2.1.10	Halo de solubilización .....	23
2.1.11	Eficiencia relativa de solubilización .....	24
2.1.12	Conteo de bacterias .....	24
2.2	Antecedentes .....	24
3	Análisis bibliométrico .....	28
3.1	Recopilación de información .....	28
3.2	Resultados y análisis de resultados .....	29
3.2.1	Información general del dominio .....	30
3.2.2	Producción científica anual en el dominio .....	31



3.2.3	Fuentes relevantes en el dominio .....	32
3.2.4	Autores destacados en el dominio .....	34
3.2.5	Afiliación de los autores destacados .....	36
3.2.6	Países más productivos en el dominio.....	37
3.2.7	Relaciones internacionales en el dominio .....	39
3.2.8	Colaboraciones entre países - tendencias .....	41
3.2.9	Mapa temático del dominio .....	42
3.3	Conclusiones parciales .....	44
4	Construcción del sistema de visión artificial para estimación del índice de solubilización relativa .....	45
4.1	Cultivo de Bacterias R11 Y FCRK4.....	46
4.1.1	Locación .....	46
4.1.2	Inoculación de cepas R11 Y FCRK4.....	46
4.2	Etapas de desarrollo de IGLOO.....	49
4.2.1	Construcción del entorno experimental.....	49
4.2.2	Desarrollo del espacio muestral.....	50
4.3	Construcción del sistema de visión artificial - software .....	51
4.3.1	Construcción del dataset .....	54
4.3.2	Entrenamiento de IGLOO .....	56
5	Validación del sistema de visión artificial - IGLOO.....	61
5.1	Evaluación del modelo .....	61
5.2	Comparativa entre métodos.....	74
6	Conclusiones y Trabajos Futuros .....	79
6.1	Conclusiones .....	79
6.2	Trabajo futuro.....	81
7	Referencias Bibliográficas.....	82

## Lista de tablas

<b>Tabla 5.1</b> Comparativa de métricas .....	74
--	----

## Lista de figuras

<b>Figura 3.1</b> Información general sobre el análisis bibliométrico en el dominio .....	30
<b>Figura 3.2</b> Publicaciones anuales en el dominio de visión artificial aplicada en bacterias .....	32
Figura 3.3 Distribución de fuentes bibliográficas en el dominio.....	33
<b>Figura 3.4</b> Autores más destacados en el dominio del conteo de bacterias mediante visión artificial.....	35
<b>Figura 3.5</b> Distribución de publicaciones por filiaciones universitarias en el dominio de visión artificial aplicada a conteo de bacterias. ....	37
<b>Figura 3.6</b> Distribución mundial de países que publican en el dominio .....	38
<b>Figura 3.7</b> Representación de publicaciones de autores de un único país y de múltiples países.....	40
<b>Figura 3.8</b> Relaciones internacionales entre países en el dominio de visión artificial para el conteo de bacterias .....	41
<b>Figura 3.9</b> Análisis de componentes principales sobre el mapa temático del dominio para encontrar las principales interrelaciones .....	43
<b>Figura 4.1</b> Incubación y agitación de bacterias en el medio de cultivo m66 .....	47
Figura 4.2 Preparación del medio de cultivo NBRIP .....	48
Figura 4.3 <i>Preparación para la esterilización del medio</i> .....	48
<b>Figura 4.4</b> Preparación de las cajas para el vaciado del medio de cultivo. ....	49
<b>Figura 4.5</b> Siembra de bacterias.....	49
<b>Figura 4.6</b> Matriz morfológica de las posibles soluciones.....	51
<b>Figura 4.7</b> Diagrama de flujo de IGLOO para determinación del IS. ....	53
<b>Figura 4.8</b> Imagen estandarizada para el dataset .....	55
<b>Figura 4.9</b> Etiquetado de imágenes con Roboflow. ....	56
<b>Figura 4.10</b> Arquitectura CNN de YOLO. Fuente: [83]. ....	57
<b>Figura 4.11</b> Diagrama de flujo del modelo general para yolov8 de ultralytics.....	58
<b>Figura 4.12</b> Imágenes de los lotes de entrenamiento.....	59
<b>Figura 5.1</b> .Predicción para 10 épocas .....	62
<b>Figura 5.2</b> Matriz de confusión para 10 épocas.....	63
<b>Figura 5.3</b> Predicción para 50 épocas .....	66
<b>Figura 5.4</b> Matriz de confusión para 50 épocas.....	67
<b>Figura 5.5</b> Predicción con 100 épocas .....	68
<b>Figura 5.6</b> Matriz de confusión para 100 épocas.....	69
<b>Figura 5.7</b> Predicción para 200 épocas .....	70

<b>Figura 5.8</b> Matriz de Confusión para 200 épocas .....	71
<b>Figura 5.9</b> Predicción para 500 épocas .....	72
<b>Figura 5.10</b> Matriz de Confusión para 500 épocas .....	73
<b>Figura 5.11</b> Toma de medidas manuales para determinar los diámetros .....	75
Figura 5.12 Segmentación de imágenes para 200 épocas A), Segmentación de imágenes para 500 épocas B).....	76
<b>Figura 5.13</b> Mascaras binarias para 200 épocas .....	77
<b>Figura 5.14</b> Macaras binarias para 500 épocas .....	77

# Capítulo 1

## 1 Introducción

La siguiente investigación propone el uso e implementación de técnicas de segmentación semántica para el análisis de bacterias solubilizadoras de fosfato, estos microorganismos, así como algunos hongos, contribuyen al equilibrio del agroecosistema debido a que realizan la mayoría de ciclos bioquímicos. Los microorganismos solubilizadores de fosfato emplean distintos mecanismos de solubilización, entre estos está la producción de ácidos orgánicos que solubilizan los fosfatos insolubles presentes en la rizosfera. Estos fosfatos son absorbidos por la planta, mejorando así su crecimiento y su productividad, el análisis de las colonias que realizan el proceso de solubilización se detectan a través de la formación de halos o la acidificación del medio alrededor de ellas. El análisis de algunas propiedades de las bacterias se suele hacer de forma manual, esto se traduce en una inversión de tiempo considerable, su resultado final está sujeto a errores debido a fatiga visual, y a la subjetividad de la medida, considerando que el proceso puede ser realizado por diferentes especialistas. Utilizando visión artificial es posible identificar patrones, dimensiones y características claves a un nivel de precisión y consistencia que supera a los métodos convencionales, sin embargo, los instrumentos de laboratorio requeridos para realizar esta tarea suelen tener un alto costo, siendo esta una de las principales razones por las cuales los métodos convencionales siguen vigentes. La segmentación de imágenes asigna una etiqueta de clase a cada pixel empleando algoritmos de aprendizaje profundo, esta tarea hace parte de las subcategorías generales de segmentación de imágenes, ayudando a comprender y procesar la información visual. El propósito de esta investigación es implementar técnicas de segmentación semántica como una herramienta de apoyo, económicamente viable, para el análisis de bacterias solubilizadoras de fosfato, a fin de disminuir el tiempo de análisis del proceso convencional.

### 1.1 Planteamiento del problema

En la microbiología, así como en áreas afines, se encuentra como una práctica común el recuento de bacterias y de otros microorganismos, esta disciplina hace parte de diversas actividades cotidianas, los microorganismos se pueden encontrar de forma benéfica o perjudicial [2]. Las bacterias juegan un rol importante en diversos procesos naturales y artificiales, ya sea en la fermentación de alimentos, en el crecimiento de las plantas o en cultivos de bacterias in vitro. Para las plantas es vital la asimilación de fósforo, ya que este está directamente relacionado con el crecimiento de la planta. Usualmente para compensar la falta de fósforo en el suelo se utilizan fertilizantes químicos, sin embargo, esta opción resulta en la mayoría de los casos en el escurrimiento del fertilizante causando la erosión del suelo, donde se deposita en cuerpos de agua causando la eutrofización [3], esta carencia de fósforo se puede solventar de otras maneras, como lo es el uso de microorganismos solubilizadores de fosfato, algunos hongos y bacterias facilitan la disponibilidad del fósforo resultando en de gran importancia en la nutrición vegetal, ya que pueden incrementar la disponibilidad del fosfato en el suelo [4].

El fósforo (P) es un elemento esencial para el desarrollo de las plantas. Este elemento, se encuentra en la totalidad de los suelos en formas iónicas muy poco solubles para el aprovechamiento de las plantas [3]. Microorganismos como hongos y bacterias son capaces de solubilizar el fósforo que se encuentra presente de forma iónica, como habitantes de la rizosfera y del resto del suelo. Los microorganismos solubilizadores de fósforo juegan un importante papel en la variación de la disponibilidad del P del suelo para las plantas, constituyendo hasta un 40 % de la población de bacterias del suelo [5]. La presencia de estos microorganismos en el suelo incrementa el número de diferentes iones, entre estos el fósforo que al ser hidrolizado con enzimas como las fitasas, facilitan la movilidad de este en el suelo y se transforma en un compuesto soluble para la planta [6].

Uno de los métodos más empleados para el análisis de bacterias, se da a través de la observación de las muestras en el microscopio. Este método requiere de una gran inversión de tiempo y esfuerzo por parte del personal del laboratorio, puede producir fatiga ocular en los observadores y ser diferente el conteo realizado entre diferentes especialistas [1]. Al caracterizar la solubilización de fósforo de un microorganismo en medio sólido, podemos dividirlos en dos grupos, los solubilizadores tardíos (ST) y los no solubilizadores (NS), esto se determina después de un periodo de aproximadamente 15 días en los que, los solubilizadores tardíos presenta un halo de solubilización a partir del tercer día, mientras que los no solubilizadores carecen de esta característica [7], la formación del halo transparente que se presenta alrededor de las colonias ocurre en la medida que sucede la solubilización, esto establece un indicador de la actividad solubilizadora de fosfato por las bacterias [8]. El índice de solubilización está dado por la relación entre el diámetro de la colonia y el halo de solubilización, éste se denomina Eficiencia Solubilizadora de Fosfato (ESF/ERS), en

medios de cultivo sólidos se puede expresar como la suma del diámetro de la colonia (mm) más el diámetro del halo de solubilización (mm) sobre el diámetro de crecimiento de la colonia (mm) [9].

Otro método de conteo es el método de referencia para la determinación del conteo total de microorganismos y sus resultados se plantea en unidad formadora de colonias (UFC/mL) [10]. Los anteriores son enfoques que dependen del dominio en el que se empleen, debido a que unos son más eficientes que otros, como el caso del método del Número Más Probable (NPM), éste es práctico para contabilizar bacterias que son difíciles de aislar de una muestra, pero que pueden ser detectadas por la actividad de alguna característica metabólica, es precisamente por esa adaptación de métodos, que la visión artificial ha empezado a jugar un rol importante en esta área [11].

Puntualmente, el conteo de bacterias utilizando visión artificial identifica patrones, dimensiones y características claves que ofrece un nivel de precisión y consistencia que supera con los métodos convencionales, teniendo en cuenta lo anterior, y considerando como principal preocupación la optimización del proceso de determinación de la eficiencia relativa de solubilización de bacterias solubilizadoras de fosfato se plantea la siguiente pregunta de investigación: **¿Cómo optimizar la determinación de la eficiencia relativa de solubilización mediante técnicas de visión artificial en bacterias solubilizadoras de fosfato?**

## 1.2 Justificación

La visión artificial engloba distintos procesos y elementos, que permiten la deducción automática de la estructura y propiedades de un mundo tridimensional, a partir de un compendio de imágenes bidimensionales[12].Este campo representa hoy un área de gran utilidad e interés para los investigadores debido a la expansión tecnológica que ha permitido el desarrollo de nuevas técnicas de inteligencia artificial y en particular de visión [13], resultando en la mejora de la inspección de productos y optimizando la eficiencia y precisión en los procesos industriales en los que se aplica. Esto representa un avance significativo en la garantía de calidad y la eficiencia operativa en diversos sectores. En la actualidad, esta combinación de tecnología basadas en imágenes digitales se ha posicionado como una herramienta robusta en la investigación[14] [15]. En los últimos años la inteligencia artificial y sus distintas ramas han salido de los círculos académicos para posicionarse como una tecnología con la capacidad de transformar la industria [16].

Considerando elementos como la interpretación, captura, procesamiento o clasificación de imágenes, la visión artificial es un área compleja que requiere de diversas herramientas y lenguajes de programación, sin embargo su aplicabilidad está dictada en diversos campos como la agricultura, astronomía, biología, inspección y control de calidad, geología entre otros [16]. En campos como la agricultura de precisión, la visión artificial ha significado un avance en la producción de conocimiento, debido a su gran adaptabilidad en el medio y su relevancia como tecnología emergente. El proceso de implementación de tecnologías de la agricultura de precisión tiene como objetivo optimizar la gestión de los cultivos uniendo las técnicas agrícolas comunes con la tecnología para reducir los riesgos ambientales como la fuga del nitrógeno y además ayudan en el desarrollo de un producto más competitivo [17], en la agricultura de precisión existen distintas técnicas de segmentación como el uso del exceso de verde como forma de discriminación de la capa vegetal, esta técnica suministra buenos resultados en imágenes que presentan humedad en el suelo y variación en las condiciones de iluminación, así como el espacio HSI, ya que consigue una buena segmentación entre la capa vegetal y el suelo en distintos tipos de cultivo con diversas condiciones ambientales [18].

En campos más específicos como la microbiología, esta tecnología ha presentado ventajas significativa. Entre los desarrollos de herramienta puntuales, que facilitan el conteo de bacterias se encuentra OpenCV, que ofrece una variedad de opciones y algoritmos que permiten a los desarrolladores analizar y modificar imágenes de múltiples maneras, desde la identificación de objetos hasta el seguimiento del movimiento [19]. Dada su alta



relevancia, desde hace varios años su implementación se ha expandido a diferentes sectores de la industria [20] y puntualmente, en el proceso de conteo de bacterias facilita la observación detallada y precisa de las características microscópicas de los microorganismos [21]. Desde la identificación de patrones celulares hasta la monitorización en tiempo real de sus comportamientos, esta tecnología ha ampliado enormemente nuestra capacidad para estudiar y monitorizar estos microorganismos a escala microscópica [22]. Estos avances tecnológicos han impulsado un progreso significativo en la investigación bacteriana, abriendo nuevas perspectivas para comprender su comportamiento, su interacción con el medio ambiente y explorar su potencial aplicación en diversos campos, desde la medicina a la biotecnología.

Particularmente en la microbiología, podemos encontrar diversos proyectos que incorporan la visión artificial como una solución enfocada en la automatización y optimización de diversas tareas, como lo es en el caso de Rodríguez, que implementa un sistema embebido para el reconocimiento y conteo de esporas, a través de técnicas de visión artificial, logrando resultados favorables en el reconocimiento de estas esporas [23], así como Vargas [24] que implemente un sistema de control de calidad para la detección de contaminantes superficiales de diferentes tipos de fruta empleando visión artificial. Teniendo en cuenta lo anterior, se han identificado o múltiples estudios que relacionan la visión artificial y el conteo de microorganismos como una alternativa viable a esta metodología. Este es el caso de Peña [1], que propone un método para la detección y conteo de bacterias y levaduras en imágenes digitales, teniendo resultados con una exactitud y precisión aceptable, en ambos casos por encima de 0,95. Por otro lado Villacís [21] implementa un sistema para conteo de aerobios totales y antibiogramas de muestras bacterianas empleando visión artificial, teniendo en este estudio resultados igualmente favorables, haciendo una comparativa entre las medidas de los datos manuales y por el sistema denotan una logrando una similitud o grado de confianza del 2% y 4% en pruebas de conteo y antibiogramas respectivamente. Otro ejemplo que encontramos en la literatura es el de Alvarado [25] que planteó una caracterización del crecimiento de colonias bacterianas utilizando segmentación de imágenes con K-means, donde logró en todos los conjuntos de imágenes, observar una constante ocupación del 21.5%, que representa el fondo o la ausencia de la caja de Petri.

## **1.3 Objetivos**

### **1.3.1 Objetivo general**

Implementar un sistema de visión artificial para la determinación de la eficiencia relativa de solubilización de fosfato en enterobacterias R11 Y FCRK4 a través de técnicas de segmentación de imágenes.

### **1.3.2 Objetivos específicos**

- Caracterizar distintas técnica, métodos, herramientas y tendencias de investigación en el dominio de microorganismos solubilizadores de fosfato mediante un análisis bibliométrico
- Inocular unidades formadoras de colonias de enterobacterias R11 y FCRK4 para el análisis de la eficiencia relativa de solubilización
- Adaptar técnicas de segmentación de imágenes para el análisis de enterobacterias R11 Y FCRK4
- Validar la eficiencia de las técnicas de segmentación de imágenes en comparación con los métodos tradicionales, mediante un estudio de caso.

## 1.4 Metodología

Para alcanzar los objetivos propuestos en el proyecto denominado “implementación de técnicas de segmentación semántica para el análisis de bacterias solubilizadoras de fosfato” se utiliza una adecuación del método científico propuesto por Mario Bunge. Para la construcción del sistema de visión artificial se utiliza como principal referente el trabajo de Rajwa et al en [26] [27].

### 1.4.1 FASE 1: PLANTEAMIENTO DEL PROBLEMA

Para esta fase se utiliza la propuesta realizada por Rajwa et al [27], que propone un sistema basado en visión artificial capaz de clasificar las características morfológicas en colonias de bacterias. A continuación, se enumeran las principales actividades a desarrollar.

- Reconocimiento de los hechos: Clasificación y selección de los hechos.
- Descubrimiento del problema: Hallazgo de un vacío o faltante. Estudio de los referentes teóricos del proyecto sobre el análisis y determinación de la eficiencia relativa de solubilización de fósforo a través de técnicas de segmentación de imágenes.
- Formulación del problema: Planteamiento de una pregunta, reducción del problema a su núcleo significativo.

Producto esperado: Planteamiento del problema, pregunta problema y revisión de la literatura.

### 1.4.2 FASE 2: CONSTRUCCIÓN DEL MODELO TEÓRICO

En esta fase se emplea la metodología propuesta por Rajwa et al [27], donde se expresan las directrices principales para desarrollar un sistema de visión artificial en el dominio de los microorganismos. Las actividades de esta fase se enumeran a continuación.

- Selección de los factores pertinentes: Estudio de las diferentes técnicas de visión artificial aplicadas al dominio.

- Identificación de estrategias: Seleccionar e identificar las diferentes tecnologías que pueden ser aplicados en el dominio del problema.
- Desarrollo del sistema de visión artificial.

Producto: Reporte con la caracterización de las diferentes tecnologías empleadas para el análisis de bacterias, Desarrollo del sistema de visión artificial.

### **1.4.3 FASE 3: VALIDACIÓN DEL SISTEMA DE VISIÓN ARTIFICIAL**

En esta fase se implementan algunas directrices reportadas en la metodología general de validación [26], que guían el desarrollo de la prueba de concepto.

- Búsqueda de soportes: Deducción de consecuencias particulares que pueden haber sido verificadas en proyectos similares.
- Planteamiento de predicciones o resultados esperados al realizar el dispositivo propuesto.
- Diseño y planeación de la prueba de concepto: planteamiento de los objetivos, hipótesis y fuentes y medios para realizar la prueba de concepto.
- Ejecución de la prueba de concepto: Validar el prototipo propuesto.

Producto: Reporte técnico con las consecuencias verificables, además, de las predicciones de resultados y reporte técnico de la prueba de concepto ejecutada.

### **1.4.4 FASE 4: INTRODUCCIÓN DE LAS CONCLUSIONES EN LA TEORÍA**

- Confrontación de los resultados obtenidos con las predicciones.
- Reajustes al prototipo propuesto: Análisis de resultados y ajustes necesarios.

### **1.4.5 FASE 5: DOCUMENTACIÓN**

- Escritura de artículos.
- Redacción del documento final de la tesis.

Producto: Documento final de trabajo de fin de grado y artículo científico.

## Capítulo 2

### 2 Marco teórico y conceptual

#### 2.1 MARCO TEÓRICO

##### 2.1.1 Conceptos relacionados con Visión artificial

##### 2.1.2 Sistema de visión artificial

Un sistema de visión artificial es aquel que permite la captura, análisis y procesamiento de imágenes, con el fin de obtener información de interés para su posterior interpretación, esto a través de un complejo procesamiento de imágenes obtenidas por dispositivos ópticos. Los sistemas de visión artificial se componen de dos partes fundamentales, como lo son los sensores ópticos para la captura de imágenes y un computador que almacene las imágenes, ejecute los algoritmos de preprocesado, segmentación y reconocimiento de las mismas [28] [29].

##### 2.1.3 Visión artificial

La visión artificial, visión por computador o machine visión, es el proceso en el que un computador intenta emular la capacidad de ver una imagen, entenderla y llevar una acción en consecuencia, esto procesando la imagen y reportando “que hay en ella”, reconociendo el contenido de la imagen. La visión artificial incluye dos componentes, medición de características y clasificación de patrones con base en esas características [30] [31].

##### 2.1.4 Procesamiento de imágenes

El procesamiento digital de imágenes es uno de los pasos claves para una buena segmentación de elementos, es una disciplina que implementa bases teóricas y algorítmicas, con el fin de extraer información del mundo real a través de filtros, siendo este un elemento clave para un sistema de reconocimiento de imágenes. El

procesamiento digital de imágenes se puede distinguir en dos niveles, siendo el procesamiento de imágenes de bajo nivel, y en alto nivel, En bajo nivel tenemos la adquisición de la imagen, preprocesamiento, segmentación de la imagen, descripción y clasificación de objetos, a diferencia del procesamiento en alto nivel que consiste en la capacidad de realizar toma de decisiones respecto al contenido de la imagen [32] [33].

### **2.1.5 Redes neuronales convolucionales**

Las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés convolutional neural network) son redes neuronales artificiales que están integradas por neuronas que contienen parámetros en forma de instrucciones y sesgos que se pueden aprender. Una de las características diferencial de este tipo de redes es que realizan la deducción explícita de que las entradas son imágenes, permitiendo codificar algunas propiedades de la arquitectura. Tienen como principal ventaja que cada parte de la red es una entrada para realizar una tarea, esto le permite aprender en diferentes niveles de abstracción, se reducen el número de capas ocultas y el entrenamiento resulta ser más rápido. Este tipo de redes neuronales resultan muy potentes para el análisis de imágenes, ya que son capaces de detectar características simples como la detección de líneas, bordes, etc, y componerlas en características más complejas hasta detectar lo deseado [34].

### **2.1.6 YOLO**

La detección de objetos en tiempo real se ha convertido en un componente esencial de numerosas aplicaciones que abarcan diversos campos, como los vehículos autónomos, la robótica, la videovigilancia y la realidad aumentada. Entre los distintos algoritmos de detección de objetos, el marco YOLO (You Only Look Once) ha destacado por su notable equilibrio entre velocidad y precisión, que permite la identificación rápida y fiable de objetos en imágenes. Desde su creación, la familia YOLO ha evolucionado a través de múltiples iteraciones. Además, YOLO utiliza un resultado más sencillo basado únicamente en la regresión para predecir los resultados de la detección, a diferencia de Fast R-CNN , que utilizaba dos resultados distintos, una clasificación para las probabilidades y una regresión para las coordenadas de las cajas [35] [36].

### **2.1.7 Segmentación semántica**

La segmentación semántica asigna una etiqueta de categoría a cada píxel de una imagen. Es una tarea fundamental pero difícil en la investigación de la visión por ordenador. Dado que la segmentación semántica es capaz de proporcionar la información de categoría a nivel de píxel ayuda a los sistemas inteligentes a captar posiciones espaciales o realizar decisiones importantes. En este contexto, la segmentación semántica se distingue de otras tareas habituales de visión por ordenador. Por ejemplo, la clasificación de objetos requiere que toda la imagen esté anotada con una o más etiquetas semánticas. En cuanto a la detección de objetos, el sistema necesita saber dónde se encuentran los objetos en la escena [37] [38].

### **2.1.8 Conceptos relacionados con Bacterias solubilizadoras**

#### **2.1.9 Bacterias solubilizadoras**

Las bacterias solubilizadoras de fosfato tienen un rol importante en el suplemento de fósforo para las plantas. La capacidad de algunos microorganismos de transformar fósforo insoluble de manera que sea accesible para las plantas y/o cultivos, es una propiedad importante de la rizosfera (zona del suelo cercana a las raíces de las plantas en donde se desarrolla la vida microbiana) y el suelo. Esta característica se denomina como solubilización de fosfato y la cantidad de bacterias con este potencial se incrementa en la rizosfera [39].

Las bacterias solubilizadoras de fosfato desempeñan un rol crucial como suplemento de fósforo para las plantas. La solubilización del fosfato en el suelo se da debido a que las reacciones de precipitación se revierten, esto libera fosfato en la solución del suelo, intervenido generalmente por la acción metabólica de los microorganismos y las raíces de las plantas [40] [41].

#### **2.1.10 Halo de solubilización**

El Halo de solubilización es una característica propia de algunos microorganismos, este indica la positividad de las pruebas de solubilización de fosfato en medio de cultivo

sólido. Esta técnica ha mostrado significativos niveles de aceptación por parte de la comunidad científica ya que detecta y aísla microorganismos solubilizadores, y ha sido empleada con éxito por diversos autores. La medida de los halos de solubilización se ha empleado para estimar la capacidad de solubilización de diversas cepas bacterianas [7].

### **2.1.11 Eficiencia relativa de solubilización**

La eficiencia solubilizadora de fosfato, es un indicador que ayuda a determinar la capacidad de solubilización de un microorganismo, este indicador es adimensional y se puede estimar a través de la relación entre el diámetro del halo solubilizante y el diámetro de la colonia a estudiar. Según este indicador la capacidad de solubilización de un microorganismo se puede clasificar en tres categorías siendo, baja solubilización si el índice es menor a dos, solubilización media si el índice es mayor o igual a dos pero menor que cuatro, y solubilización elevada que se da si el índice es superior a cuatro[7] [42].

### **2.1.12 Conteo de bacterias**

El conteo de microorganismos es un elemento crítico de los estudios de ecología microbiana y microbiología, ya que aunque es relevante conocer qué actores tienen un efecto benéfico o un potencial causante de infecciones severas, lo es aún más el saber el número de microorganismos implicados, para poder establecer una relación a futuro sobre sus funciones benéficas o perjudiciales. Existen diversos métodos para realizar el conteo de bacterias, este se puede dar por métodos indirectos como la densidad óptica, o por métodos directos, en placa o por disolución, los métodos más comunes son, el recuento en placa, el sistema de petrifilm, el conteo por filtración, método del número más probable, determinación directa por microscopio y el método de turbidez [2] [43].

## **2.2 Antecedentes**

En el ejercicio de la revisión tecnológica alrededor del análisis de microorganismos solubilizadores a través de visión artificial, es importante destacar que en el dominio se ha desarrollado fuertemente un interés en el análisis y conteo de bacterias, estos



trabajos son precedentes para desarrollar algoritmos capaces de analizar características relevantes en los diversos microorganismos.

Dentro de la bibliografía encontrada las investigaciones apuntan a una mayor eficacia del proceso, menos errores y un recuento más preciso y rápido mediante técnicas de visión artificial, como en el artículo “SISTEMA EMBEBIDO PARA RECONOCIMIENTO Y CONTEO DE ESPORAS DEL HONGO DE GÉNERO TRICHODERMA MEDIANTE TÉCNICAS DE VISIÓN ARTIFICIAL”, Noboa [23] presenta un sistema embebido diseñado para detectar y contar esporas de Trichoderma utilizando técnicas de visión por ordenador. El proyecto utiliza una tarjeta Nvidia Jetson Nano con un algoritmo basado en Tiny Yolo para detectar y contar esporas. Se estableció un máximo de 150 muestras de entrenamiento, con aproximadamente 9150 esporas etiquetadas en la base de datos. Las pruebas muestran una precisión del 93% in situ y del 96% en producción, lo que puede atribuirse a la experiencia del operador en pruebas de producción. El retorno de la inversión es de 4,52 años, con la ventaja de la precisión en la clasificación final de los fungicidas. Esto se consigue utilizando una dilución de esporas más baja que reduce la dispersión en el líquido esterilizado [23].

La investigación denominada “SISTEMA DE VISIÓN ARTIFICIAL PARA EL RECONOCIMIENTO Y EL CONTEO DE UNIDADES FORMADORAS DE COLONIAS (UFC)”[44] El sistema de visión artificial utiliza imágenes de alta resolución para detectar colonias en placas de Petri. La segmentación de las imágenes se realiza mediante técnicas de transformación del color y umbralización, seguidas de operaciones morfológicas para eliminar el ruido e identificar las regiones de interés. La localización y el recuento de colonias aborda el problema de distinguir las colonias del fondo en función de la variación de la iluminación y del tamaño de las colonias. Para facilitar la identificación de las colonias, propone la creación de un mapa aproximado del fondo mediante erosión y sustracción. De este modo, se obtiene una imagen binaria en la que se distinguen claramente las colonias, simplificando así el proceso de recuento y caracterización.

El sistema de visión artificial propuesto proporciona una solución eficaz para segmentar, localizar y contar colonias en imágenes de placas de Petri. Esto simplifica el proceso de análisis microbiológico, reduce los errores y aumenta la eficiencia del laboratorio [44].

Otro caso similar, elaborado por Méndez Rubio en su investigación “Sistema automático para análisis de unidades formadoras de colonias mediante técnicas de procesamiento digital de imágenes” [45], el estudio se centró en aplicar técnicas de procesamiento digital de imágenes para analizar atributos morfológicos de las Unidades Formadoras de Colonias (UFC) en placas de Petri. Se propuso un algoritmo para segmentar eficientemente las UFC, especialmente aquellas traslapadas, lo cual es desafiante para la percepción humana. Se evaluaron dos algoritmos, siendo el segundo, basado en la metodología de segmentación binaria con ultimate erosión, más eficiente. El sistema desarrollado demostró una efectividad del 99.12%, comparado con el 99.42% de un equipo comercial. Se construyó un dispositivo para análisis automático de muestras, compatible con cualquier sistema de captura digital. Se identificaron debilidades en la calidad de las imágenes debido a la iluminación, mejorando con un anillo de LEDs. Este avance tecnológico es relevante para laboratorios y centros educativos con presupuestos limitados. Se proponen mejoras como el uso de luz ultravioleta para estimular la fluorescencia de microorganismos y la inclusión de características adicionales en el reporte de resultados [45].

Por otro lado, cabe resaltar la investigación “Morphotypic analysis and classification of bacteria and bacterial colonies using laser light-scattering, pattern recognition, and machine-learning system”[27]. Este estudio se centró en la clasificación de bacterias mediante mediciones de dispersión de luz multiángulo a partir de citometría de flujo y la detección automatizada de comunidades bacterianas mediante la técnica BARDOT. Se utilizaron diferentes bacterias para evaluar la validez de la clasificación y los resultados se resumieron en una tabla de turbidez y clasificación. Para la tarea de clasificación de especies y cepas bacterianas se propusieron y utilizaron varios clasificadores estadísticos, como las máquinas de vectores soporte (SVM), el discriminante lineal de Fisher (FLD) y el clasificador bayesiano de máxima verosimilitud (ML). Los resultados de los clasificadores se validaron de forma cruzada con 10 iteraciones. Aunque la precisión de la clasificación de las especies bacterianas probadas fue alta, el alcance de este enfoque fue limitado y sólo se pudo identificar con éxito un número limitado de especies. En comparación, BARDOT demostró ser capaz de detectar e identificar una amplia gama de patógenos bacterianos con gran precisión utilizando un formato tradicional de placa de Petri. Aunque se trata de un enfoque de "baja tecnología", los métodos de detección basados en cultivos son muy

fiables y se consideran el "patrón oro" del análisis microbiológico, al que recurren organizaciones como los CDC y el USDA para confirmar los resultados obtenidos con métodos más novedosos [27].

La investigación "Customized Computer Vision and Sensor System for Colony Recognition and Live Bacteria Counting in Agriculture"[4] se centra en el análisis de colonias bacterianas mediante un sistema inteligente que combina un ordenador personalizado y un sensor CCD con transformación Hough para microorganismos circulares. Las muestras se dividieron en dos grupos y se realizaron análisis informáticos y manuales para cada grupo, y se calculó el error absoluto, el error relativo y el porcentaje de error para cada muestra. Los resultados mostraron una alta correlación lineal entre el análisis automatizado y el análisis manual realizado por los expertos. La correlación lineal para ambos grupos de muestras fue de 0,99. Además, la interfaz de usuario desarrollada permite a los usuarios interactuar con el proceso de análisis bacteriano mediante iconos gráficos e indicadores visuales, lo que facilita su comprensión. Está previsto desarrollar otros métodos basados en el análisis cualitativo y cuantitativo de colonias bacterianas para su análisis in situ directamente en campos agrícolas. También tienen previsto integrar este método en teléfonos inteligentes Android para su procesamiento en línea [46].

## Capítulo 3

### 3 Análisis bibliométrico

Esta sección muestra en detalle cómo se realizó el análisis bibliométrico sobre las técnicas de visión artificial aplicadas al conteo de bacterias, a través de análisis descriptivos e inferenciales, teniendo en cuenta autores, fuentes, afiliaciones, países y sus interrelaciones. Este tipo de análisis es un método cuantitativo utilizado para examinar la estructura del conocimiento y el desarrollo de los campos de investigación mediante el análisis de las publicaciones relacionadas. Esta técnica proporciona una representación transparente, sistemática y estática de la investigación en su estado actual, este tipo de análisis es un método cuantitativo utilizado para examinar la estructura del conocimiento y el desarrollo de los campos de investigación mediante el análisis de las publicaciones relacionadas.

Teniendo en cuenta lo anterior, para la realización del análisis bibliométrico se emplearon como referentes la propuesta de Zhang [47] para especificar el análisis sobre el dominio de visión artificial aplicada al conteo de microorganismos solubilizadores de fosfato y el framework propuesto por Donthu [48], que propone los lineamientos para el análisis bibliométrico. También se emplearon algunas pautas de la metodología Science Mapping Workflow para obtener los datos, realizar su análisis y visualizarlos.

#### 3.1 Recopilación de información

Con el propósito de adquirir información sistemática de las bases de datos bibliográficas, se empleó una cadena de búsqueda, como se indica en la Tabla 1. Esta cadena de búsqueda se construyó a partir de los criterios PICOC [49], permite estructurar conceptos de manera lógica y metódica, asegurando de esta manera una cobertura completa de todos los temas de interés. Para este estudio se trataron los

## Resultados y análisis de resultados

datos de bases científicas como Scopus y Web of Science, siendo estas reconocidas a nivel mundial en ingeniería y fiables para la búsqueda de revisiones bibliográficas [49]. La cadena de búsqueda consta de dos partes claramente definidas para evadir el ruido de otros dominios. La primera parte consta de los conceptos relacionados con visión artificial, La segunda tiene como campo el conteo de bacterias y microorganismos.

TITLE-ABS-KEY ((“Machine vision” OR “computer vision” OR “Image processing” OR “digital image processing” OR “OpenCV”) AND ( “Bacterial Count” OR “Microbial count” OR “Total bacteria count” OR “Bacterial Numbers” OR “Microbiological count” OR “Bacterial Counting” OR “Microbial counting” OR “Total bacteria counting” OR “Microbiological counting” OR “Colony Forming Units”))
--

**Tabla 1.** Cadena de búsqueda, creación propia

Para este estudio la estrategia de búsqueda empleada se centró en los títulos, resúmenes y palabras clave de artículos de revistas y conferencias revisados por pares en inglés, con la finalidad de garantizar la calidad y el carácter académico de la literatura encontrada. Se tuvo en cuenta un rango de tiempo específico que dató entre 1982 y 2023, para este rango se encontró un total de 235 artículos. Con respecto a los estudios duplicados, se eliminaron, dejando un solo resultado en la base de datos. Para los estudios secundarios, se consideraron para la extracción de información. Finalmente, los artículos se exportaron a Bibliometrix y VOSviewer para su análisis y determinación del estado actual del dominio de estudio.

### **3.2 Resultados y análisis de resultados**

En esta sección se presentan los resultados más relevantes del análisis bibliométrico, se hace hincapié en los autores, artículos, revistas, producción por países y afiliaciones, así como la búsqueda de interrelaciones del área de investigación, con la finalidad de describir cómo las nuevas tecnologías relacionadas con visión artificial están siendo empleadas en el campo de la microbiología y específicamente, en cómo éstas son aplicadas a los organismos solubilizadores de fosfato.

### 3.2.1 Información general del dominio

El análisis bibliométrico general aporta información relevante sobre la producción científica en el dominio de técnicas de visión artificial aplicadas al conteo y análisis de bacterias (Figura 3.1). Con los datos proporcionados se desprende que el periodo abarca de 1982 a 2023 y que se han utilizado 158 fuentes (revistas y ponencias de congresos) para recopilar los 235 documentos analizados.

El promedio de edad de los documentos es de 11.6 años, lo que sugiere que la investigación en este campo se ha dado de forma paulatina, se observa una tasa de crecimiento anual de 5.51% en el número de documentos publicados, esto soportado con el promedio de edad de los documentos indica un bajo interés en el tema o una falta de motivante tecnológico que impulse los procesos investigativos en el dominio. En comparación con otros dominios que presentan mayores índices de interés, con un 17.02% [51], inteligencia artificial en el cuidado de la salud, con un 20.81% [52] La bioeconomía agrícola basada en el conocimiento. En conjunto, estos resultados indican la baja popularidad actual de la aplicación de técnicas de visión artificial aplicadas en bacterias y la preocupación de la comunidad investigadora por el crecimiento del tema.



**Figura 3.1** Información general sobre el análisis bibliométrico en el dominio

La información general del dominio revela que el número promedio de citas por documento en este campo es de 31,7, esto indica que los artículos tienen una relevancia significativa para la comunidad científica y la investigación futura. Además, se han utilizado 7565 referencias en todos los documentos analizados.

## Resultados y análisis de resultados


De estos autores solo 8 autores han producido documentos de autor único, esto podría ser un indicativo que el dominio se trabaja de forma conjunta, el corpus científico indica que el trabajo comunitario aporta más a los distintos desarrollos del área de conocimiento [53]. Soportando lo anterior, se observa que el promedio de coautores por documento es de 5.36, lo que indica una amplia colaboración entre los científicos. En esta línea se muestra que el 14.89% de las colaboraciones entre autores son internacionales, lo que habla del establecimiento de redes de un mismo país y que quizás se están estableciendo pocas colaboraciones mundiales para avanzar en el conocimiento del campo.

El análisis inferencial de los resultados indica que la investigación y el desarrollo de algoritmos basados en visión por máquina aplicados al conteo de bacterias, avanzan paulatinamente, y que su popularidad se ha mantenido constante al pasar de los años. El número de citas y referencias utilizadas demarcan esta situación considerando que el dominio tuvo un primer instante en 1982, sin embargo, la relevancia del tema está directamente ligado con los distintos avances tecnológicos que permiten obtener y procesar imágenes de manera más eficientes , esto sugiere que la relevancia del dominio permanece activa a pesar de los declives que pueda tener en materia de publicaciones de artículos.

### **3.2.2 Producción científica anual en el dominio**

Planteado lo anterior, la producción científica anual (Figura 3.2) relacionada con la aplicación de sistemas de visión artificial en conteo de bacterias, presenta un crecimiento paulatino a través de los años, con un aumento significativo en la producción de artículos en 2001 respecto a sus años anteriores, este aumento podría deberse a la creación de librerías como OpenCV que tuvo su nacimiento en 1999 como una iniciativa del grupo de investigación de Intel para aplicaciones con uso intensivo de la CPU, publicando su primera versión Alpha en el año 2000 y su versión oficial 1.0 en 2006 [54].

## Análisis bibliométrico



**Figura 3.2** Publicaciones anuales en el dominio de visión artificial aplicada en bacterias

Desde 1982 hasta 1991, el número de artículos publicados cada año no superó la media de tres artículos, a partir de 1998 se presenta un ligero aumento en la producción de artículos lo que demuestra un bajo crecimiento del interés en la aplicación de esta tecnología en el campo de la microbiología y más específicamente en el conteo de bacterias a través de visión por máquina. Se aprecia que en el año 2001, 2006, 2009 y 2010 se mantuvo la publicación de artículos en 10 artículos por año, teniendo varios descensos entre estos años evidenciado en la cantidad de publicaciones anuales, siendo en el 2002 el más significativo para el dominio. A partir del 2014 se presentó una mayor estabilidad e interés en la publicación de artículos superando los 5 artículos anuales, para el 2019 la producción de artículos alcanza su máximo índice superándolas 15 publicaciones, y presentando un decrecimiento en la producción de los mismos en los años póstumos.


### **3.2.3 Fuentes relevantes en el dominio**

Reconocer las fuentes clave en un dominio específico, como las revistas académicas, es crucial para comprender mejor el panorama científico. Las revistas cumplen distintos roles: generan, difunden y comparten conocimientos académicos, también organizan las investigaciones y el trabajo académico, lo que facilita la distribución de



## Resultados y análisis de resultados

fondos destinados a la educación y la investigación, sirven como herramientas para fundamentar decisiones relativas a nombramientos y ascensos, identifican el estatus relativo de individuos, departamentos e instituciones [55]. Para este análisis bibliométrico, la Figura 3.3, resalta las principales fuentes donde se publican artículos del área.



**Figura 3.3** Distribución de fuentes bibliográficas en el dominio

El análisis bibliométrico evidencia que la revista *Journal of Microbiological Methods* es la más prolífica en la publicación de artículos relacionados con microbiología y tecnologías emergentes dentro del área, con un total de 18 artículos relacionadas con el conteo de bacterias a través de visión artificial. *Applied and Environmental Microbiology* ocupa el segundo lugar con 14 artículos, seguida por *PLOS ONE* con 11 publicaciones. Las demás revistas publicaron entre 4 y 5 artículos, indicando que tienen una presencia menos destacada en este campo. Estos resultados sugieren que las revistas mencionadas son puntos de referencia clave para la investigación en microbiología. El índice H es un indicador bibliométrico que mide la actividad investigadora y el impacto de su difusión [56]. Según este indicador la revista que ha


## Análisis bibliométrico

tenido un mayor impacto es *Plos ONE* con índice H de 435 perteneciente a Estados Unidos, seguida por *Applied and Environmental Microbiology* con un índice h de 367 también perteneciente a Estados Unidos, *Scientific Reports* revista del Reino Unido presenta un índice h de 315, no es de extrañar que se encuentren en el top tres de este análisis bibliométrico ya que en las siguientes secciones veremos que estados unidos es líder en este campo de interés. Ahora bien, las revistas que tienen un mayor recorrido (publicación más antigua) y por ende podrían considerarse como referentes para el área de estudio son, *Journal of clinical periodontology* con una vigencia desde 1974, *Applied and Enviromental Microbiology* que publica desde 1974, *FEMS Micriobiology Letters* desde 1977 y por ultimo *Journal of Microbiological Methods* desde 1983. La mayoría de revistas que se encuentran en el top 10 de publicaciones están posicionadas en los percentiles más altos, esto según la *scimago journal & country rank* lo que evidencia que se está haciendo investigación en el dominio en revistas de alto impacto.

### **3.2.4 Autores destacados en el dominio**

Para esta sección se presentan los autores más relevantes en el campo de la visión artificial aplicada al conteo de bacterias. Identificar a estos autores aporta diversos beneficios: se reconocen expertos en el área, la actualización es constante, se adquieren publicaciones de alta calidad y el conocimiento de las últimas investigaciones y avances en el área de interés. El análisis de los autores destacados está frecuentemente asociado a otras panorámicas que se pueden subdividir en listas de producciones de autores, bibliografías nacionales o temáticas. A menudo se centran en una serie de temas amplios o más especializados en los modelos de publicación [57].

## Resultados y análisis de resultados



**Figura 3.4** Autores más destacados en el dominio del conteo de bacterias mediante visión artificial

En la Figura 3.4 se presentan los autores con mayor cantidad de publicaciones en el campo de la microbiología, particularmente en el área de visión artificial enfocada al conteo de bacterias, BLIZNUKS D, KIM H, LIEPINS J y LIHACHEV A, quienes han publicado 4 artículos cada uno en este ámbito. También se observa que varios otros autores tienen una cantidad similar de publicaciones, como ANDREINI P, BAE E, BIANCHINI M, BONECHI S, DAIMS H y MECOCCI A, con 3 artículos cada uno. El que solo unos pocos autores tengan la mayor cantidad de publicaciones, puede indicar que el área de estudio está dominada por un grupo selecto de expertos, esto puede indicar que se trata de un campo de especialización relativamente concentrado, en lugar de una amplia colaboración entre muchos investigadores lo que indicaría un campo de estudio más abierto, es importante destacar que BLINZNUKS D está asociado a la *University of Florida*, indicando el dominio que tiene estados unidos sobre área de estudio, KIM H pertenece a la *University of St Andrew* en Reino Unido, como se pudo apreciar en la sección anterior estados unidos y reino unido son líderes en el dominio estas afirmaciones serán exploradas y fundadas más adelante en el documento. El número total de publicaciones por sí solo puede utilizarse para derivar la productividad del investigador y su institución, pero no proporciona una indicación de la calidad y la

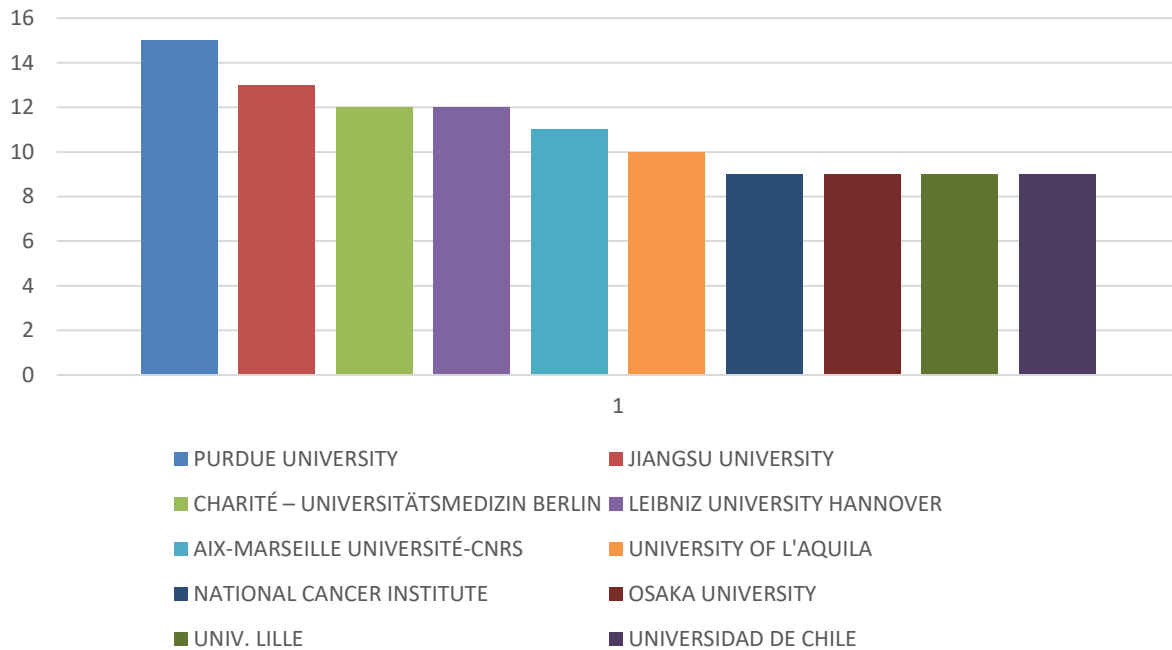
## Análisis bibliométrico

importancia de una publicación de investigación, ni indica el impacto que tiene la investigación o el investigador [58] .

### **3.2.5 Afiliación de los autores destacados**

Respecto a las afiliaciones de los autores, se presenta una tendencia homogénea entre Estados Unidos, Alemania, y Francia, ya que en los datos recopilados para la bibliometría entre las 10 principales afiliaciones mínimo dos universidades pertenecen a estos países, por lo que el dominio no está focalizado en una sola comunidad, en la figura 3.5 se puede observar la cantidad de publicaciones de cada universidad, en este sentido la *Purdue University* en estados unidos, lidera la lista con 15 artículos publicados, la universidad china de Jiangsu en segundo lugar cuenta con 13 artículos publicados, se podría decir que Alemania y estados unidos se encuentran liderando la lista ya que Alemania cuenta con 24 artículos publicados por las universidades de Charité y la universidad de Leibniz en Hannover que ocupan el tercer y cuarto puesto en la lista, sin embargo la universidad mejor valorada según el QS World University Rankings es la *Purdue University* que para el 2023 se encontraba en el puesto 129 y para las proyecciones de 2025 se estima que ocupe el puesto 89 [59].

## Resultados y análisis de resultados

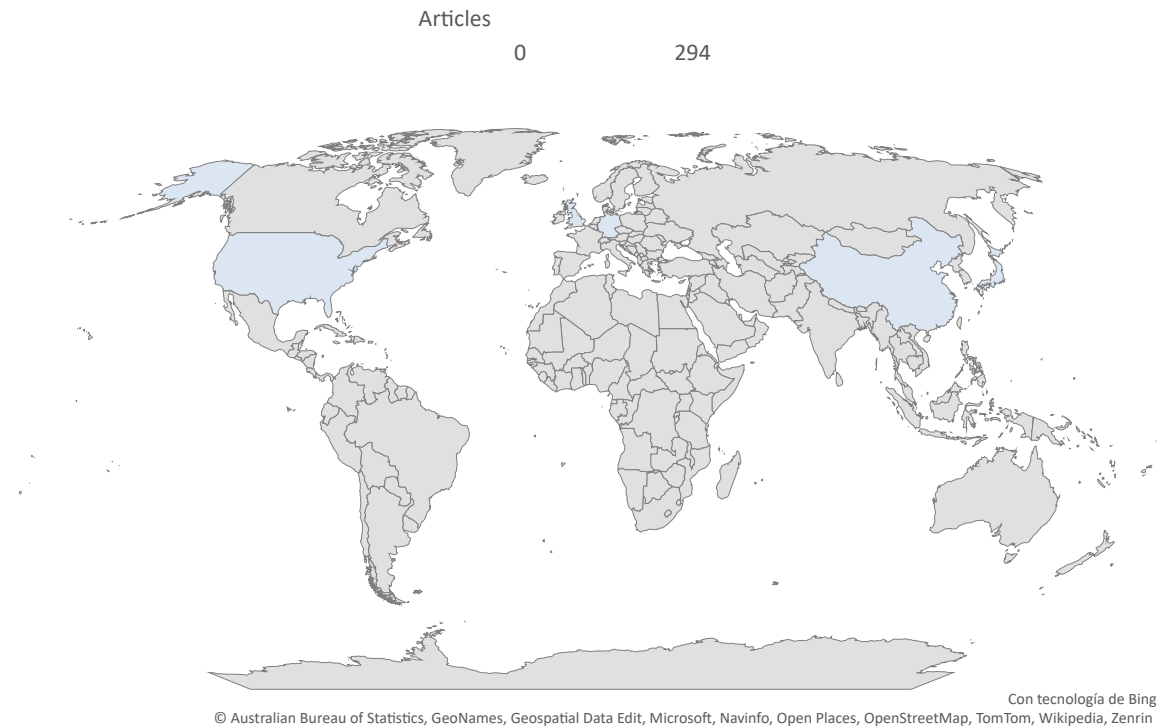


**Figura 3.5** Distribución de publicaciones por filiaciones universitarias en el dominio de visión artificial aplicada a conteo de bacterias.

### 3.2.6 Países más productivos en el dominio

Es relevante conocer cuáles son los países más productivos con respecto a la implementación de visión artificial para el campo de la microbiología y más específicamente para el conteo de bacterias, del análisis bibliométrico podemos extraer una medida cuantitativa que indica el valor de la investigación de un individuo para su institución. Como índice medible del impacto de la investigación, puede emplearse como una forma de evaluar la concesión de fondos de investigación, el rango académico y titularidad, la determinación de salarios y la proyección de objetivos anuales de investigación, conocer la productividad en materia científica de los países permite observar el rendimiento de la inversión a los organismos de financiación, así como a las instituciones anfitrionas, la industria el público en general, esta métrica permite identificar a los científicos clave en la formación de opinión en un ámbito de investigación concreto, también plantea datos relevantes para políticas en los diversos organismos gubernamentales y las industrias pertinentes [58].

## Análisis bibliométrico



**Figura 3.6** Distribución mundial de países que publican en el dominio

La Figura 3.6 muestra la frecuencia de los artículos científicos relacionados con la implementación de técnicas de visión artificial para el conteo de bacterias, publicados por investigadores de diferentes países. Según los datos recabados, Estados Unidos es el primer país productor en este dominio, con 294 artículos publicados, seguido por el Reino Unido con 125 artículos, Alemania se encuentra en tercer lugar con 106 artículos, Japón y China comparten el cuarto lugar con 79 artículos publicados, los datos sugieren que Estados Unidos es el principal actor en este campo de investigación, contando con una frecuencia de publicación significativamente superior a los otros países, otros autores también plantean la dominancia de estados unidos frente a temáticas similares como lo es el uso de microorganismos solubilizadores de fósforo como alternativa biotecnológica, donde estados unidos cuenta con el 52.6% del total de publicaciones [60].


Se ha presentado un creciente interés por la detección de microorganismo mediante métodos alternativos a los empleados en el microscopio, particularmente varios de estos estudios están enfocados al sector alimenticio y al sector de la salud, los autores

## Resultados y análisis de resultados

plantean que los microorganismos que deben analizarse suelen ser de grandes órdenes de magnitud, y al tener una gran cantidad de datos se dificulta abordar el análisis con los métodos tradicionales de microscopios. Por eso se plantean estas tecnologías como alternativas para el análisis de estas muestras [61]. particularmente Estados Unidos presenta un gran dominio en el área de machine learning, en otros análisis bibliométricos alrededor del área, liderando la influencia académica mundial en el campo del aprendizaje automático y la AMR, con 254 publicaciones y 5.466 citas, lo que supone más del 37% del corpus total y China [62]. La vista del mundo está sobre los biofertilizantes desde hace un par de décadas esto como una alternativa para los fertilizantes químicos, en este sentido China y Estados Unidos lideran el campo de investigación alrededor de los biofertilizantes [63], esta área es relevante para el análisis por medio de visión artificial debido a que los microorganismos solubilizadores de fosfatos juegan un rol crucial como biofertilizantes, y el estudio manual de estos puede llevar a fatiga visual y errores de conteo [61], sin embargo, Xian-yuan plantea que en el dominio de microorganismos solubilizadores de fósforo el país que cuenta con mayor número de publicaciones es India con un total de 673, seguido de China con 585 siendo Estados Unidos el cuarto país con mayor número de producción de artículos con 141 [64].

### **3.2.7 Relaciones internacionales en el dominio**

El análisis bibliométrico permite evaluar la colaboración internacional cuantificando los artículos publicados por autores de correspondencia pertenecientes a un mismo país y los artículos con autores de correspondencia de distintos países, de esta forma, las publicaciones de un solo país (SCP), pertenecen a autores que proceden del mismo país, y las publicaciones de múltiples países (MCP), son aquellas en las que los autores proceden de múltiples países, se utiliza la coautoría porque es una forma suficientemente objetiva y directa de medir la cooperación científica. Además, las publicaciones de varios países (MCP) son beneficiosas en general, debido a que se considera que realizar investigación colaborativa aporta perspectivas desde distintos contextos geográficos desembocando en propuestas más relevantes para el entorno [65].



**Figura 3.7** Representación de publicaciones de autores de un único país y de múltiples países

El análisis presenta que Estados Unidos posee el mayor número de publicaciones, seguido de Alemania, Reino Unido y China. Para este caso se puede asumir que la investigación se focaliza en un grupo selecto de países, debido a que gran parte de las publicaciones se tratan de publicaciones de autores de un solo país. Esto se puede apreciar en la Figura 3.7, donde se evidencia que Estados Unidos se posiciona en la cabecera con 40 artículos de autores propios de este país, seguido de Alemania con 13 artículos, Reino Unido y China comparten la cantidad de 12 artículos, al analizar la representación total de la producción por país, se evidencia que estas cifras son bajas respecto a esta producción, teniendo para China y Reino Unido 5% de su producción total, esto podría indicar una baja inversión en el campo de estudio.

Por otra parte, la cantidad de publicaciones en colaboración entre autores de diferentes países es relativamente baja en comparación con las publicaciones individuales, aunque Estados Unidos, Alemania y Reino Unido lideran la lista de países con más publicaciones de autores de un único país, países como Brasil y Corea, equiparan el número de publicaciones en colaboración entre autores de diferentes países, mientras




## Resultados y análisis de resultados

que países como Chile, Argentina y Bélgica presenta la misma cantidad de publicaciones tipo SCP como MCP, el porcentaje de producción de artículos en colaboración entre autores de diferentes países tiende a aumentar cuando estos presentan fuertes economías, esto se puede deber a una mayor inversión en investigación científica y a una colaboración más intensa en los países desarrollados [66], sin embargo la investigación global en visión artificial aplicada al conteo de bacterias sigue siendo poco frecuente, una mayor comunicación internacional podría producir hallazgos de investigación más significativos

### **3.2.8 Colaboraciones entre países - tendencias**

En la Figura 3.8, se puede apreciar la información relacionada con la extensión y evolución de las colaboraciones internacionales en el campo de la visión artificial conteo de bacterias, de la figura 8 se destacan en azul los países con alta productividad en esta área, las líneas rojas representan las redes de colaboración interregional.



**Figura 3.8** Relaciones internacionales entre países en el dominio de visión artificial para el conteo de bacterias

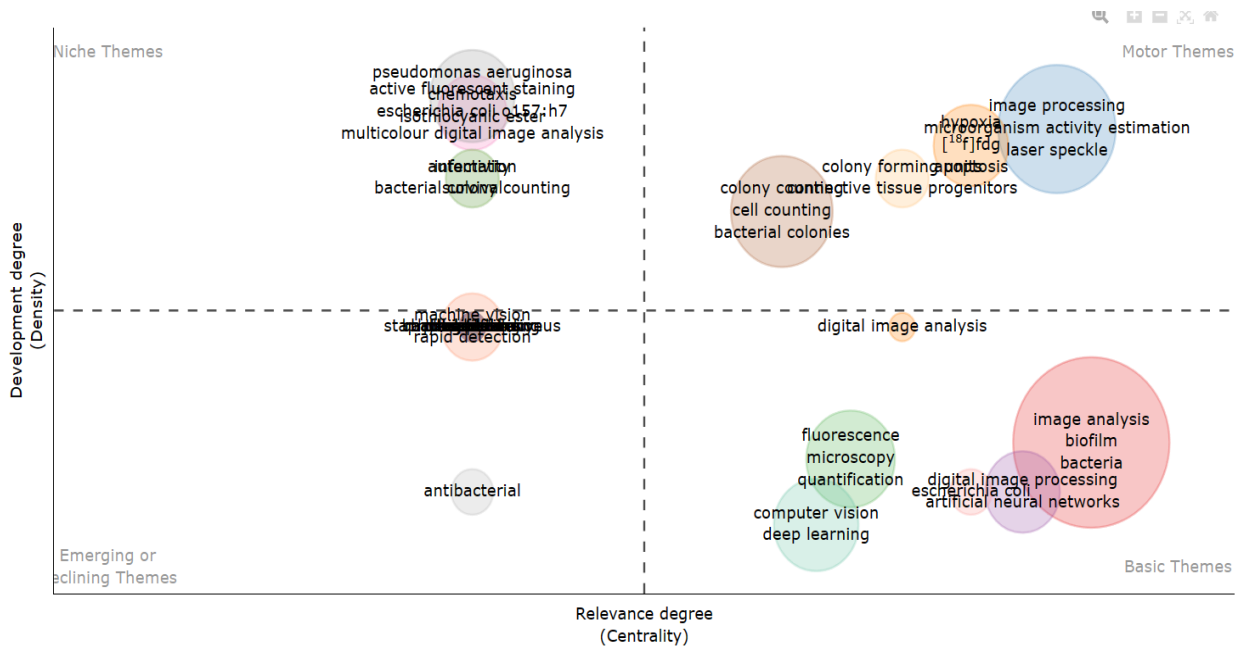
## Análisis bibliométrico

Para empezar, se puede indicar que Estados Unidos es el país con mayor número de colaboraciones con otros países, con un total de 21 colaboraciones, esto sustentado con lo visto en la sección anterior se puede corroborar el liderazgo que presenta Estados Unidos en relación a la producción de artículos colaborativos, seguido por Reino Unido con 11 colaboraciones y luego Alemania con 10 colaboraciones. Esto señala que Estados Unidos colabora activamente con otros países en este campo, y se puede sustentar con los datos de secciones anteriores. Además, cabe destacar que los países líderes en colaboración son todos del primer mundo, lo que sustentado por otros autores cuentan con una mayor inversión a educación e investigación [66]. El involucrar a países en desarrollo podría hacer que las investigaciones sean más inclusivas y reflejen mejor la realidad global.

### **3.2.9 Mapa temático del dominio**

Un mapa temático representa gráficamente un campo de investigación donde se muestran los principales tópicos y temas basados en el análisis de coocurrencias; En este se pueden clasificar los temas en cuatro categorías: motor, nicho, emergente o en declive y temas básicos, el objetivo de realizar un mapa temático del dominio, se basa en conocer la situación actual de campo y lo que depara su sostenibilidad futura. Este tipo de análisis proporciona conocimientos a los investigadores y partes interesadas sobre las posibilidades de desarrollo futuro de la investigación de áreas temáticas dentro de un campo [67]. En la Figura 3.9 se muestran los términos clave empleados por los autores para este dominio, evaluados según su centralidad y densidad dentro de la red de clusters. La centralidad refleja la relevancia de un tema para la estructura de un área de investigación, por otro lado, la densidad indica cuán desarrollado se encuentra dicho tema [67].

## Resultados y análisis de resultados



**Figura 3.9** Análisis de componentes principales sobre el mapa temático del dominio para encontrar las principales interrelaciones

En el cuadrante superior derecho encontramos los temas impulsores o motor, el cuadrante inferior derecho los temas básicos, el cuadrante superior izquierdo se encuentran los temas muy especializados o de nicho, y en cuadrante inferior izquierdo los temas emergentes o en declive, de la figura 9 se desprende que un tema como el “*digital image analysis*”, en el cuadrante inferior derecho pero cerca del cuadrante superior derecho, está en desarrollo y potencialmente es capaz de estructurar el campo de la investigación, podría decirse que este tema puede llegar a ser el tema principal en este campo. Temas como “Computer visión” e “Image analysis”, que aparecen en el cuadrante inferior derecho, Son los básicos y muy valiosos para el desarrollo del campo. Los temas del cuadrante izquierdo superior como “*Multicolour digital image analysis*”, “*pseudomonas aeruginosa*”, “*active fluorescent staining*”, por mencionar algunos, son temas potenciales que necesitan estar más conectados con temas como “*digital image analysis*”. En este sentido capta la atención que *active fluorescent staining* sea utilizado para el conteo de bacterias, debido a la naturaleza de la técnica se podría suponer que brinda mayores datos respecto a las estructuras moleculares de las bacterias y por ende mayor cantidad de datos a estudiar en *digital image análisis*.

## Análisis bibliométrico

Los temas relacionados al cuadrante inferior izquierdo como, “*machine vision*”, “*antibacterial*”, son emergentes, pero en el caso de “*machine vision*”, este se encuentra ligeramente transversal a el cuadrante superior izquierdo lo que indica que alguno de sus componentes son muy especializados y necesarios para desarrollar el campo de “*Multicolour digital image analysis*”, temas como *machine visión donde* emplea técnicas de inteligencia artificial son coherentes con el cuadrante de temas emergentes debido a la irrupción de diferentes técnicas de inteligencia artificial y herramientas, como YOLO, SAM2, DETECTRON que facilitan el conteo de bacterias en el dominio de *machine vision*. El análisis temático sugiere que son necesarios más esfuerzos para desarrollar temas como “*pseudomonas aeruginosa*”, y sus componentes asociados como “*Multicolour digital image analysis*”, “*active fluorescent staining*”, para establecer más vínculos con “*digital image analysis*”, ya que este tema potencialmente es capaz de estructurar el campo de la investigación, podría decirse que este tema puede llegar a ser el tema principal en este campo.

### **3.3 Conclusiones parciales**

Estados Unidos lidera tanto en la producción de artículos científicos como en colaboraciones internacionales, con 21 colaboraciones, seguido por Reino Unido y Alemania. En términos de publicaciones individuales, Estados Unidos también ocupa el primer lugar con 40 artículos, mientras que Alemania, Reino Unido y China cuentan con entre 12 y 13 artículos. Sin embargo, la mayoría de estas publicaciones provienen de autores de un solo país, lo que indica una concentración de la investigación en países desarrollados. La colaboración internacional es baja, aunque países como Brasil y Corea logran un equilibrio entre publicaciones individuales y colaborativas. Países como Chile, Argentina y Bélgica mantienen una producción constante tanto en publicaciones individuales como en colaboración, pero siguen siendo pocos. La baja inversión en ciertos países y la limitada colaboración internacional sugieren que el campo, especialmente en temas como la visión artificial aplicada al conteo de bacterias, podría beneficiarse de más esfuerzos colaborativos, lo que permitiría avances científicos más significativos y globalmente representativos.

## Capítulo 4

### 4 Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

En este capítulo se aborda de manera detallada el proceso de construcción IGLOO (por sus siglas en inglés, Image seGmentation anaLysis Of sOlubilization), un sistema diseñado para el análisis de la eficiencia relativa de solubilización de fosforo. En el presente, se inicia describiendo el proceso de inoculación de las comunidades bacterianas, este proceso consiste en la introducción de microorganismos en un entorno donde puedan crecer y reproducirse, para este caso un medio de cultivo sólido, un paso fundamental para asegurar la relevancia y precisión de los datos que se obtendrán. Posteriormente, se detallará el entorno experimental en el que se llevarán a cabo las tomas de imágenes, incluyendo las condiciones específicas bajo las cuales se realizarán las fotografías, así como los elementos y materiales que se utilizarán durante el proceso.

A continuación, se abordará la construcción de IGLOO, comenzando por el etiquetado de las imágenes, donde se explicarán las razones detrás de este método y las herramientas que se emplearán para llevarlo a cabo. Se definirá el tipo de convoluciones que se realizarán, justificando la elección de este enfoque basado en inteligencia artificial y su pertinencia para el análisis de los datos. Además, se incluirán diagramas de flujo que ilustrarán la construcción del modelo y los diversos procesos involucrados en su desarrollo.

Finalmente, se explicará el proceso de entrenamiento del modelo, seguido de las estrategias de optimización que se emplearán, incluyendo la aplicación de filtros, que serán esenciales para mejorar el rendimiento y la precisión del sistema. A través de esta construcción meticulosa y bien documentada, se buscará establecer un marco robusto para el análisis de comunidades bacterianas, contribuyendo así al avance en el campo de la microbiología y la visión artificial.

## **4.1 Cultivo de Bacterias R11 Y FCRK4.**

La principal población de estudio fueron bacterias endofíticas solubilizadoras de fosfato, que previamente fueron caracterizadas por su potencial como biofertilizante debido a que gran parte de las reservas de fosforo se encuentran en el suelo, no todo el fosforo se encuentra de forma asimilable para las plantas, es por esta razón que la población de estudio juega un papel fundamental para la agricultura sostenible al presentarse como una alternativa a los fertilizantes químicos [68]. Particularmente se trabajó con dos cepas bacterianas R11 y FCRK4, estos microorganismos son conocidos como microorganismos promotores de crecimiento vegetal o PGPR, microorganismos, debido a que muestran alta eficiencia a la hora de proveer los nutrientes necesarios para las plantas en formas realmente disponibles y asimilables debido a una serie de transformaciones químicas [69], se emplearon con la finalidad de determinar el índice de eficiencia relativa solubilización, y contrastar los métodos tradicionales con las alternativas propuestas en este trabajo.

### **4.1.1 Locación**


La población de estudio se extrajo de la Hacienda Los Naranjos ubicada en el municipio de Cajibío (Cauca-Colombia) nativas de la variedad de café bourbon cultivada en suelos andisoles de la meseta de Popayán. Las muestras de raíz de café variedad bourbon se tomaron del lote # 19, ubicado a una altura de 1870 m s. n. m, con coordenadas 2°35'11.6" Norte y 76°33'11.2" Oeste [68], ubicada en las cercanías del volcán Puracé sobre suelos volcánicos, a una distancia de 28 km de la ciudad de Popayán, cuenta con características de topografía plana [70], presenta una temperatura ambiente de 12 a 18 °C [71]. El departamento del Cauca se identifica por su actividad social y económica centrada en el sector agropecuario, siendo el cultivo de café una de las principales actividades de la región. Sus suelos son mayoritariamente ácidos, lo que reduce la disponibilidad de fósforo (P) [68].

### **4.1.2 Inoculación de cepas R11 Y FCRK4**

Para el proceso de inoculación, las cepas bacterianas ubicadas en el laboratorio de biología de la Corporación Universitaria Comfacauca - Unicomfacauca fueron conservadas en glicerol al 20% y -20 °C y revividas en el medio de cultivo líquido M66;

## Cultivo de Bacterias R11 Y FCRK4.

la preparación del medio de cultivo consistió en diluir 15 gramos del medio en 1L de agua destilada, luego se vertieron 500 ml del medio de cultivo en 2 matraces Erlenmeyer, los frascos se cerraron parcialmente con papel aluminio y algodón para llevarlos al autoclave para esterilizar el medio. Una vez esterilizado, el medio de cultivo debe dejarse enfriar a temperatura ambiente y una alícuota del medio de glicerol; los cultivos inoculados deben ser llevados a agitación e incubados a 28 ° C durante 24 horas.



**Figura 4.1** Incubación y agitación de bacterias en el medio de cultivo m66

Una vez crecieron las cepas en medio de cultivo M66 se deben inocular en el medio de cultivo NBRIP por sus siglas en ingles (National Botanical Research Institute's phosphate growth medium) desarrollado para la visualización de la solubilización de fosfato [72] para poder estimar la capacidad de solubilización, para la preparación de medio de cultivo NBRIP se utilizaron: Extracto de levadura 15g, glucosa 10 g,  $\text{Ca}_3(\text{PO}_4)_2$  5 g,  $\text{MgCl}_2 \cdot 6\text{H}_2\text{O}$  5 g,  $\text{MgSO}_4 \cdot 7\text{H}_2\text{O}$  0.25 g, KCl 0.2 g,  $(\text{NH}_4)_2\text{SO}_4$  0.1g.

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa




Figura 4.2 Preparación del medio de cultivo NBRIP

Los medios de cultivos se sellaron con papel aluminio para disponerlos en la autoclave para su esterilización, esto con el fin evitar contaminaciones o falsos positivos.



Figura 4.3 Preparación para la esterilización del medio



## Etapa de desarrollo de IGLOO

Se deja enfriar hasta que la mano pueda soportar el calor e inmediatamente se transfiere a las cajas de Petri debido a que de enfriarse en su totalidad el medio de cultivo se solidifica.



**Figura 4.4** Preparación de las cajas para el vaciado del medio de cultivo.



**Figura 4.5** Siembra de bacterias

El volumen por caja debe ser 25ml, posterior a esto se tomó una alícuota del medio de cultivo y se sembró en la caja de Petri para después incubarlas a 28 ° C con el fin de verificar la capacidad de solubilización del fosforo.

## **4.2 Etapa de desarrollo de IGLOO**

### **4.2.1 Construcción del entorno experimental**

Una parte crucial del desarrollo de IGLOO fue la construcción de un conjunto de datos adecuado para el entrenamiento con el fin de obtener imágenes de calidad. Se utilizó

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

y diseñó una caja negra para obtener estas imágenes y construir un conjunto de datos adecuado para el entrenamiento; esta caja cumple la función de proporcionar fotos consistentes de las bacterias; su función principal es evitar la influencia de la luz ambiental y los reflejos que ésta puede producir, asegurando así una iluminación controlada y uniforme. Esto mejora la calidad y la precisión de las imágenes[73].

La electrónica que forma parte de la caja negra es sencilla ya que solo cuenta con una serie de LEDs y un SWITCH y pilas AA para su alimentación; es indispensable tener en cuenta que los LEDs no deben estar tan cerca de la lámina de acrílico que sostiene la caja Petri. La iluminación en la caja negra es parte fundamental en una excelente estandarización de las imágenes [74], la iluminación debe ser controlada, de esta manera se obtienen imágenes homogéneas y adecuadas para la construcción del conjunto de datos.

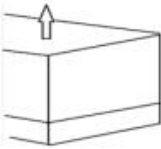

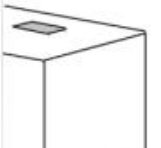
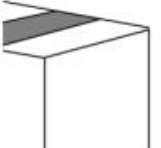





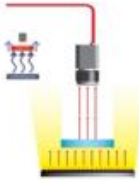
### **4.2.2 Desarrollo del espacio muestral**

Para el desarrollo de la caja negra se plantearon diversas soluciones siguiendo el esquema de matriz morfológica, morfología en su definición general es “el estudio de la forma o patrón”, el cómo los objetos se “conforman” para la creación de un conjunto, este método sirve para identificar e investigar un conjunto de posibles soluciones para un problema complejo [75]. Finger plantea el análisis morfológico desde los siguientes supuestos [76], que cualquier problema complejo de ingeniería puede dividirse en un número finito de subproblemas, cada subproblema puede considerarse por separado y sus relaciones con otros subproblemas suspenderse temporalmente, todos los subproblemas y sus soluciones pueden presentarse en una tabla morfológica, una solución global a cualquier problema complejo de ingeniería puede encontrarse como una combinación de soluciones a subproblemas individuales, una solución global puede encontrarse de forma insesgada mediante una generación aleatoria de combinaciones de soluciones a subproblemas a partir de la tabla morfológica.

### **Matriz Morfológica**

Esta matriz puede ser empleada en cualquiera de sus combinaciones para dar respuesta a la problemática planteada, sin embargo, se sigue la implementación de la primera columna de soluciones.

## Construcción del sistema de visión artificial - software

		Alternativa 1	Alternativa 2	Alternativa 3
1	Posicionamiento Caja			
2	Posicionamiento Camara			
3	Tipo de Camara			
4	Procesador			
5	Tipo de Iluminación			

**Figura 4.6** Matriz morfológica de las posibles soluciones

Teniendo en cuenta el desarrollo de la matriz morfológica y considerando las distintas soluciones, para el desarrollo de IGLOO se considero la alternativa 1 como la más viable, ya que cumple con los requisitos del proyecto a nivel presupuestal y se acomodó a los plazos de desarrollo, se procede a desglosar en detalle la construcción del sistema.

### **4.3 Construcción del sistema de visión artificial - software**

En la siguiente sección se abordarán todos los conceptos de software relevantes para la construcción del sistema de visión artificial, esta sección es el corazón del trabajo,

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

es por eso que se describirán los procesos y herramientas utilizadas para el desarrollo del sistema de visión artificial. En la Figura 4.7 se puede apreciar el diagrama de flujo que indica el funcionamiento del sistema de visión artificial para determinar la eficiencia relativa de solubilización, el código fue desarrollado en Google Colaboratory, esto debido a que ofrece recursos de computación en la nube como GPU que permiten un mejor desarrollo sin necesidad de hardware de alto costo [77].

El procesamiento de imágenes se realizó a través de la librería de código abierto ultralytics You only look once (YOLO) en su versión 8, con el fin de utilizar las funciones para la segmentación, por ejemplo, YOLOv8 fue liberada en enero de 2023 siguiendo su esquema de liberación de diferentes versiones. YOLOv8 ofrece cinco versiones escaladas: YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large), y YOLOv8x (extra-large), que soportan múltiples tareas de visión, como detección de objetos, segmentación, estimación de pose, seguimiento y clasificación [78].

## Construcción del sistema de visión artificial - software

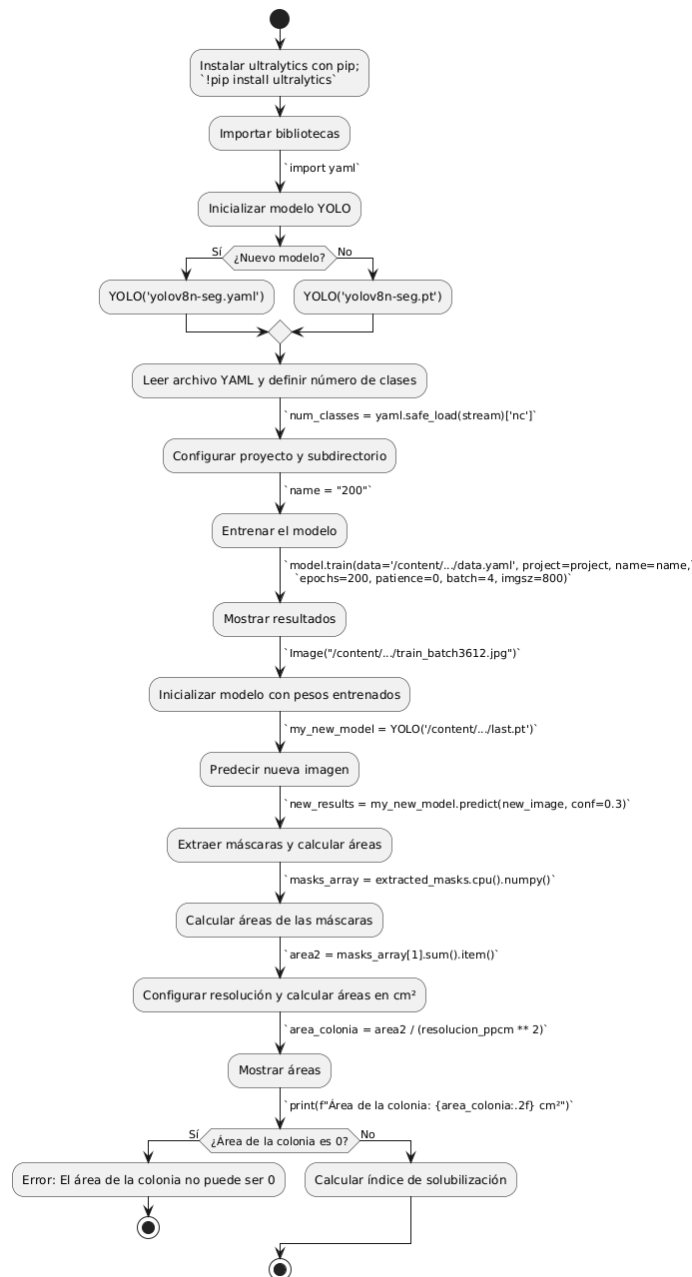


Figura 4.7 Diagrama de flujo de IGLOO para determinación del IS.

En primer lugar, se instala el paquete Ultralytics con pip, se importan las librerías necesarias para el trazado de imágenes, se importa YOLO desde ultralytics, se instancia el modelo con un fichero de configuración YAML o pesos preentrenados (yolov8n-seg.yaml o .pt). El proceso continúa cargando la configuración de datos del fichero YAML, en este se definen el número de clases a segmentar, en este caso se cuenta únicamente con dos clases, la clase “BAC” que hace referencia a las unidades


## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

formadoras de colonia, y la clase “AS” que hace referencia a las áreas de solubilización, estos datos se importan a su vez de la herramienta roboflow que facilita el proceso de segmentación al brindar un acceso directo donde se alojan las carpetas de entrenamiento y validación [79], se definen el número de clases basados en el archivo YAML y se define el directorio donde se depositarán los resultados, posterior a esto se configuran los parámetros teniendo así 200 épocas, un tamaño de lote de 4 y un tamaño de imagen de 800 píxeles. El proceso de parada anticipada se desactivó para evitar la finalización prematura del entrenamiento y garantizar que se completan todas las épocas.

Al final del entrenamiento, los pesos y los resultados se almacenan y el modelo se carga sobre la base de los pesos almacenados para la predicción de nuevas imágenes. Las predicciones se realizan utilizando un umbral de confianza del 30% y se muestran los resultados. Se extraen las máscaras de segmentación, se convierten en matrices Numpy para facilitar el procesamiento, se muestran una a una y se calcula el área de las regiones segmentadas en píxeles, lo que permite un análisis cuantitativo de las regiones segmentadas.

### **4.3.1 Construcción del dataset**

Uno de los puntos cruciales para desarrollar la segmentación de imágenes es tener un dataset apropiado para el entrenamiento, en este estudio el conjunto de datos empleado para el entrenamiento del modelo se creó a partir de la inoculación de las bacterias presentada en la sección anterior, esto debido a la baja disponibilidad de imágenes referentes al tema, las fotos fueron condicionadas a un tamaño de 1746x1746 con una resolución horizontal y vertical de 72ppp.



**Figura 4.8** Imagen estandarizada para el dataset

En esta línea, una vez estandarizadas las imágenes se utilizó el enfoque de entrenamiento test and train [80], que consiste en dividir el conjunto de datos, un porcentaje para entrenar el modelo y otro para validar su eficiencia. En este sentido, el total de imágenes se dividió en un 75% para entrenar y un 25% para probar, tal y como se ha propuesto en otras investigaciones [81], siguiendo el modelo COCO para datasets, el conjunto de datos Microsoft Common Objects in COntext (MS COCO) contiene 91 categorías de objetos comunes, 82 de las cuales tienen más de 5.000 instancias etiquetadas. En comparación con otros conjuntos de datos, COCO tiene menos categorías, pero más instancias por categoría. Esto puede ayudar a aprender modelos detallados de objetos capaces de una localización 2D precisa. El conjunto de datos también es significativamente mayor en número de instancias por categoría que los conjuntos de datos PASCAL VOC y SUN [82] [83].

Al preparar el dataset de imágenes, un paso necesario para el proceso de aprendizaje con algoritmos YOLO es el etiquetado de información. En este proceso manualmente se indican las coordenadas de los objetos que se desean detectar, delimitar de manera

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

óptima los objetos permite garantizar la calidad y efectividad del entrenamiento. Existen varias herramientas que facilitan este proceso, permitiendo dibujar cajas alrededor de los objetos de interés y guardar las anotaciones en formato YOLO. Algunas de ellas son: LabelImg, RectLabel, Labelbox, VoTT y Roboflow, que es una de las más utilizadas [84].




Figura 4.9 Etiquetado de imágenes con Roboflow.

### 4.3.2 Entrenamiento de IGLOO

Las redes neuronales convolucionales (CNN) constituyen arquitecturas diseñadas para procesar datos con una estructura de tipo matricial. Su función principal es extraer características mediante convoluciones, que aplican filtros a pequeñas secciones de la imagen, lo que les permite captar detalles locales como bordes y texturas. En YOLOv8, las CNN (Figura 4.10) extraen características de las imágenes de entrada, pasando por varias capas convolucionales y de agrupamiento que reducen gradualmente la resolución pero aumentan la profundidad de las características detectadas [85]. Estas características son clave para detectar y segmentar objetos con precisión en tiempo real




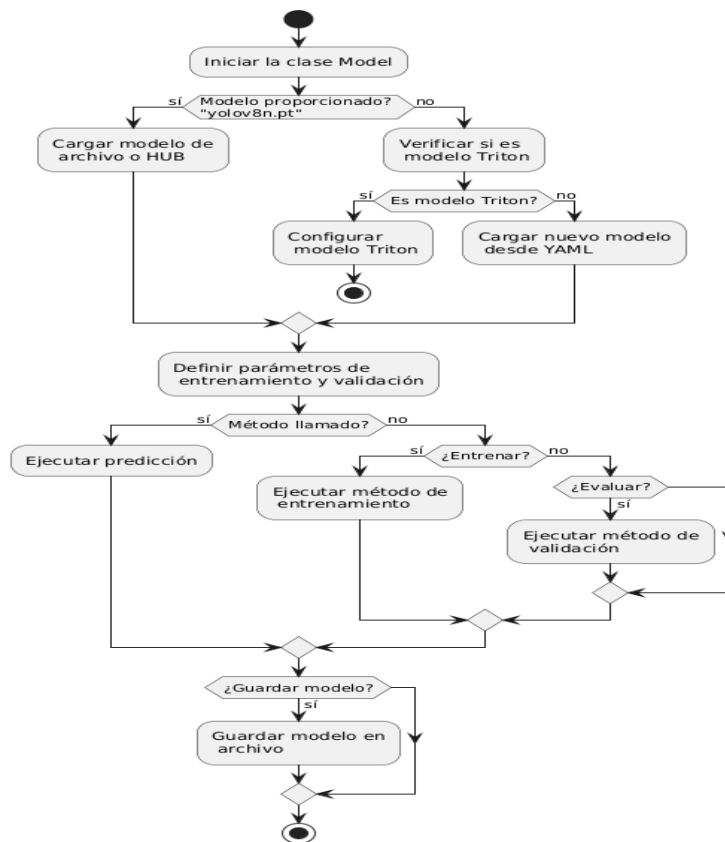


Figura 4.10 Arquitectura CNN de YOLO. Fuente: [85].

#### 4.3.2.1 Funcionamiento del modelo en YOLOv8


El diagrama de flujo de la clase Model en YOLOv8 (Figura 4.11) ilustra el proceso de inicialización y ejecución de un modelo de detección de objetos. Este proceso comienza con la creación de una instancia de la clase Model, que gestiona la configuración y carga del modelo preentrenado, como yolov8n.pt. Si no se especifica un modelo preentrenado, se verifica si el modelo es de tipo Triton, en cuyo caso se configura adecuadamente; de lo contrario, se carga un nuevo modelo a partir de un archivo de configuración YAML. Una vez cargado el modelo, se establecen los parámetros necesarios para el entrenamiento y la validación. Dependiendo del método invocado, el modelo puede realizar predicciones, ser entrenado o evaluado. Por último, existe la opción de guardar el modelo entrenado o actualizado en un archivo para su uso posterior.

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa



**Figura 4.11** Diagrama de flujo del modelo general para yolov8 de ultralytics  
**Fuente:** Elaboración propia

Durante la configuración de parámetros, se definen aspectos fundamentales para controlar el entrenamiento del modelo: **epochs**, **batch size** e **image size**. Las *epochs*, fijadas en 200. El número de épocas es un hiperparámetro que define el número de veces que el algoritmo de aprendizaje trabajará a través de todo el conjunto de datos de entrenamiento. Cada época hacer referencia a que cada muestra en el conjunto de datos de entrenamiento ha tenido la oportunidad de actualizar los parámetros internos del modelo, una época que tiene un lote (batch) se denomina algoritmo de aprendizaje de descenso de gradiente por lotes, se puede pensar en un bucle for sobre el número de épocas donde cada bucle porcede sobre el conjunto de datos de entrenamiento [86]. Dentro de este bucle *for* hay otro bucle *for* anidado que itera sobre cada lote de muestras, donde un lote tiene el número de muestras especificado como “tamaño de lote”. El número de épocas es tradicionalmente grande, a menudo cientos o miles, permitiendo que el algoritmo de aprendizaje se ejecute hasta que el error del modelo se haya minimizado lo suficiente.



**Figura 4.12** Imágenes de los lotes de entrenamiento.  
**Fuente:** Elaboración propia

Es común crear gráficos de líneas que muestren las épocas a lo largo del eje x como tiempo y el error o habilidad del modelo en el eje y. Estos gráficos son a veces llamados curvas de aprendizaje [87]. Estos gráficos pueden ayudar a diagnosticar si el modelo ha aprendido demasiado, poco o si se ajusta adecuadamente al conjunto de datos de entrenamiento. Un número elevado de epochs favorece el aprendizaje profundo del modelo, pero también incrementa el riesgo de **sobreajuste** (overfitting) [88], donde el modelo se adapta tanto a los datos de entrenamiento que pierde capacidad de

## Construcción del sistema de visión artificial para estimación del índice de solubilización relativa

generalización para nuevos ejemplos. El **batch size**, configurado en 4, indica que en cada paso del entrenamiento se procesarán cuatro imágenes simultáneamente. Esto permite actualizar los gradientes de manera más eficiente y gestionar mejor el uso de memoria, aunque un batch size demasiado pequeño podría hacer que las actualizaciones sean menos estables y uno demasiado grande podría sobrecargar la GPU, especialmente en entornos como Google Colab. Finalmente, el **image size** de 800x800 píxeles asegura que las imágenes tengan una resolución suficiente para capturar los detalles relevantes, sin ser tan grandes como para ralentizar el entrenamiento o exceder la capacidad de procesamiento. Estos parámetros trabajan en conjunto para equilibrar precisión, eficiencia y uso de recursos, afectando directamente el rendimiento del modelo y los tiempos de entrenamiento.

## Capítulo 5

### 5 Validación del sistema de visión artificial - IGLOO

En este capítulo se abordará el proceso de validación del sistema de visión artificial desarrollado para el análisis de bacterias solubilizadoras de fosfato. El proceso de validación garantiza la funcionalidad del modelo; se presenta en dos etapas, la primera valida la detección de las bacterias y su halo de solubilización; en este proceso, el modelo recibe nuevas imágenes y se evalúa la precisión con la que detecta los objetos de interés, la segunda consiste en contrastar los resultados obtenidos por el modelo y contrastarlos con técnicas tradicionales para adquirir la eficiencia relativa de solubilización.


#### 5.1 Evaluación del modelo

Para la evaluación del modelo se emplearon distintos entrenamientos variando las épocas de los mismos, esto con el fin de determinar el número necesario de épocas para la predicción de los parámetros deseados, teniendo en cuenta que se emplearon 75% de las imágenes para entrenamiento y 25% para validación. Según lo plantean otros investigadores [89], definir bien las imágenes que hacen parte de estos conjuntos requiere que las muestras de cada uno de ellos sean distintas, este proceso es crucial ya que uno de los objetivos en el entrenamiento es evitar el sobre entrenamiento (Overfitting) y el sub entrenamiento (Underfitting), estos errores son comunes en el entrenamiento del modelo. Pueden producirse porque el modelo ha aprendido tan bien los datos de entrenamiento que ya no es capaz de tomar en general los conocimientos y aplicarlos a los datos de prueba (overfitting), o bien el modelo aún no es capaz de aprender los datos de entrenamiento y es incapaz de clasificar los datos de entrenamiento o los datos utilizados para probarlo (underfitting) [90].

En la evaluación de los resultados obtenidos, se contrastaron los resultados de una sola imagen para distintas épocas de forma experimental, esto con el fin de determinar el número de épocas necesarias para entrenar el modelo; este se entrenó con 10, 50,


100, 200 épocas, a partir de este entrenamiento se evaluó el porcentaje de precisión en las predicciones, y la matriz de confusión asociada a uno de esos entrenamientos, esta nos da una comprensión más intuitiva del rendimiento del modelo, proporciona información detallada de las clasificaciones realizadas correctamente y describe el desempeño del modelo sobre un conjunto de datos de prueba para los que se tienen los valores verdaderos [91].

Los resultados obtenidos sobre las imágenes de prueba para 10 épocas son bajos y poco precisos, en la Figura 5.1 se muestra una imagen de prueba y las predicciones que realiza IGLOO sobre la misma, se puede apreciar que no cumple con el objetivo de detectar el halo de solubilización, siendo este un elemento vital para determinar el índice de solubilización, en cuanto a la identificación de las unidades formadoras de colonia, cumple parcialmente esta identificación aunque el modelo considera la presencia de tres bacterias con una precisión significativamente baja para cada una de ellas.



**Figura 5.1** .Predicción para 10 épocas  
**Fuente:** Elaboración propia

La matriz de confusión es un método del cual podemos extraer métricas como la precisión, el recall y la puntuación  $F\beta$  para cada clase y la media micro, macro y ponderada de todas las clases, estas se utilizan para medir el rendimiento general de un clasificador [92], para el análisis de estas matrices se siguieron las metodologías empleadas por otros investigadores [93], en la Figura 5.2 se muestra la matriz de confusión asociada a el entrenamiento con 10 épocas.



**Figura 5.2** Matriz de confusión para 10 épocas.  
**Fuente:** Elaboración propia.

El modelo entrenado con 10 épocas tiene una cantidad notable de errores, para la clase de ‘AS’ evaluó 9 elementos como verdaderos positivos (VP) (estos elementos son los que se reconocen como clasificados correctamente), presentó 8 elementos como falsos positivos (FP), 7 elementos como falsos negativos (FN), y 35 elementos como verdaderos negativos (VN) (estos indican cuantos se excluyeron de la categoría ‘AS’ debido a que no se debían predecir como ‘AS’), para ambos falsos el modelo presenta fallos al predecir el área de solubilización debido al ruido del fondo. Para profundizar un poco más en estos datos se emplearon las siguientes formulas [94] con

el fin de conocer la exactitud, la precisión, el *recall* y el *F1 Score*, estas métricas son claves para evaluar el desempeño de los modelos, en ese sentido, para calcular la exactitud usamos la siguiente ecuación,

$$Exat = \frac{VP + VN}{VP + VN + FP + FN}$$

**Ecuación 1** : Formula para medir exactitud [95]

Al realizar la operación el valor de la exactitud es aproximadamente 0.74 este indica el porcentaje de predicciones correctas para la clase 'AS', para el calculo de la precisión y el recall emplearemos las siguientes ecuaciones:

$$Prec = \frac{VP}{VP + FP}$$

**Ecuación 2** : Formula para medir precisión [95]

$$recall = \frac{VP}{VP + FN}$$

**Ecuación 3** : Formula para medir recall [95]

la métrica de precisión se utiliza para asegurarnos del porcentaje de valores que fueron clasificado como positivos son realmente positivos, esta métrica va de la mano del recall ya que se mide los falsos positivos los cuales son positivos reales que se clasificaron erróneamente como negativos [95] , realizando despejes pertinentes, tenemos que la precisión para este modelo es de 0.52 teniendo una precisión baja al clasificar la clase 'AS', el recall es de 0.56 por lo cual asigna pocas imágenes a la clase 'AS' lo que deja bastante información de lado, que ambas métricas se encuentren rondando el 50% indica que el modelo posee dificultades para acertar y detectar correctamente la clase 'AS', al juntar estas métricas podemos calcular el *F1 Score* o promedio armónico de estos dos parámetros,

$$F1 Sc = 2 * \frac{prec * recall}{prec + recall}$$

**Ecuación 4** : Formula para medir recall [95]


El *F1 score* al combinar precisión y recall, brinda información relacionada con el equilibrio que existen entre ambas métricas, dando a entender mejor las fortalezas y



debilidades del modelo mas allá de una simple tasa de aciertos, para esta matriz de confusión se tiene un F1 score aproximado de 0.54 y confirma que el modelo no logra equilibrar de manera efectiva la precisión y el recall.


El mismo proceso se aplica para las demás clases de nuestro modelo, siguiendo con la clase 'BAC', el modelo muestra un desempeño razonable pero con áreas claras de mejora, la precisión de 0.766 indica que cerca del 24% de las predicciones de 'BAC' fueron incorrectas, lo que revela un problema con falsos positivos, el recall de 0.82 es positivo, ya que la mayoría de las instancias reales fueron identificadas, aunque algunas aún se pierden, la accuracy de 0.796 sugiere que el modelo tiene un rendimiento general decente, acertando en casi 8 de cada 10 casos, el F1-score es de 0.8 y refleja un balance aceptable entre precisión y recall, pero reducir los errores seguiría siendo necesario para mejorar la consistencia del modelo.

Pasando a los resultados obtenidos con 50 épocas, la principal diferencia respecto a los resultados obtenidos en el pasado entrenamiento como se puede apreciar en la Figura 5.3, en este entrenamiento se puede apreciar la presencia del halo de solubilización, la predicción se realizó con un 55% de confianza, esta baja probabilidad sugiere que el modelo aun no tiene mucha certeza en la clasificación de esta región, el cambio mas importante es que ahora el modelo toma como un solo elemento las unidades formadoras de colonias con un 76% de confianza, ligeramente bajo respecto al anterior modelo pero significativamente más relevante ya que asigna correctamente estas unidades a la clase 'BAC'.



**Figura 5.3** Predicción para 50 épocas

En cuanto a la matriz de confusión para las 50 épocas como se puede visualizar en la Figura 5.4, para la clase 'AS' se presentan 14 verdaderos positivos, 6 Falsos positivos, 2 Falsos Negativos y 31 Verdaderos Negativos, esto en comparación con la Figura 23, podemos apreciar una reducción en la cantidad de falsos que se consolidaron en la matriz lo cual indica que se tendrán mejores métricas de precisión y de recall.




**Figura 5.4** Matriz de confusión para 50 épocas

Haciendo uso de las ecuaciones planteadas anteriormente, se calcula una exactitud para la clase ‘AS’ de 0,85, esto indica que el modelo es globalmente fiable aunque aun existe un margen de mejora en la precisión, en cuanto al recall su valor fue de 0.87, para el modelo empieza a ser un poco alto y sugiere que logra identificar la mayoría de las instancias reales de la clase ‘AS’, con la métrica de precisión con un 0.7, podemos observar que pese a que está moderadamente equilibrado, el proceso aun genera falsos positivos con cierta frecuencia, el F1 score de 0.78 refleja un desempeño razonable, este podría mejorarse reduciendo los Falsos positivos.


Para la clase ‘BAC’ la precisión es sólida con un 0.85, este valor sugiere que comete pocos falsos positivos, con un recall de 0.82 el modelo muestra que la mayoría de instancias reales son detectadas aunque aun pasa por alto algunos falsos negativos, en cuestión de la exactitud para esta clase presenta una exactitud de 0.83 y un F1 score de 0.83, esto confirma que el modelo tiene un desempeño consistente y equilibrado para la clase ‘BAC’.

Siguiendo con los resultados del entrenamiento para el modelo de 100 épocas, encontramos nuevamente algunos fallos relacionados con la cantidad de predicciones, esta vez a diferencia del modelo de 10 épocas, realiza una doble predicción sobre la clase 'AS' considerando parte del fondo como objeto a clasificar con esta etiqueta, en cuestión de la predicción de la clase 'BAC' se puede apreciar en la Figura 5.5, que su porcentaje de confianza bajó considerablemente.



**Figura 5.5** Predicción con 100 épocas

Para la matriz de confusión asociada a este entrenamiento tenemos que para la clase 'AS' como se ve en la Figura 5.6, tiene 15 verdaderos positivos, 3 Falsos positivos, 1 Falsos Negativos y 31 Verdaderos Negativos, del mismo modo podemos determinar que para la clase 'BAC' tiene 23 verdaderos positivos, 3 Falsos positivos, 5 Falsos Negativos y 19 Verdaderos Negativos,




**Figura 5.6** Matriz de confusión para 100 épocas

En las 100 épocas de entrenamiento el modelo demuestra un rendimiento consistente y equilibrado para ambas clases, teniendo una exactitud para la clase ‘AS’ de 92% y del 84% para la clase ‘BAC’, demostrando un avance con respecto al entrenamiento pasado, ambas clases el F1 score supera o iguala el 85% confirmando que el modelo ha mejorado en el aprendizaje de estas dos clases.

A pesar de los buenos resultados, se observa que el rendimiento podría mejorar para ambas clases y en particular para ‘BAC’, sin sacrificar la precisión, en términos generales el modelo está en un estado sólido, se identifica que al incrementar el numero de épocas los modelos llegan a ser ligeramente superiores entre sí.


A las 200 épocas el modelo presenta una mayor confianza al clasificar y predecir los elementos deseados en las imágenes, en comparativa con los resultados presentados por el modelo en 100 épocas, se puede apreciar que hace una mejor segmentación de la clase ‘BAC’ teniendo un 86% de confianza al realizar la predicción, estos resultados demuestra la hipótesis previa de que a mayor numero de épocas mejor resulta ser la

confianza desempeñada por el modelo, es importante resaltar que para estas 200 épocas el modelo identifica solo un elemento de cada clase-



**Figura 5.7** Predicción para 200 épocas


EN la matriz de confusión asociada a este entrenamiento tenemos que para la clase 'AS' como se ve en la Figura 5.8, tiene 15 verdaderos positivos, 3 Falsos positivos, 1 Falsos Negativos y 29 Verdaderos Negativos, del mismo modo podemos determinar que para la clase 'BAC' tiene 25 verdaderos positivos, 1 Falsos positivos, 3 Falsos Negativos y 19 Verdaderos Negativos,



**Figura 5.8** Matriz de Confusión para 200 épocas

Al compara los resultados obtenidos para las 200 épocas con los resultados del entrenamiento para 100 épocas, se puede observar que el desempeño del modelo se estabiliza para la clase 'AS', también se nota un mejoramiento en la clase 'BAC', en la clase 'AS' ambas configuraciones presentan métricas casi idénticas en precisión de 83%, recall 93% y F1-Score 87%, con una ligera disminución de la exactitud para las 200 épocas presentando un resultado de 91% contra el 92% del entrenamiento pasado, por otro lado la clase 'BAC' muestra una clara mejora tras las 200 épocas, aumentando su precisión a un 96% contra el 88% del entrenamiento para 100 épocas, el recall también aumentó a un 89% en comparación con el 82% del entrenamiento pasado, esto puede indicar una mayor capacidad para identificar instancias reales presentando una reducción de los falsos positivos de 3 a 1 y los falsos negativos de 5 a 3, en cuanto al F1-Score para las 200 épocas aumenta a un 90%, estableciendo un mejor equilibrio entre precisión y sensibilidad, es evidente que al extender el entrenamiento se pueden conseguir mejores rendimientos en casos complejos como la detección de estas unidades formadoras de colonia, sin embargo, un factor crucial en la optimización de estos parámetros es el dataset, ya que al expandirlo y mejorarlo se pueden llegar a tener mejores resultados sobre estas métricas.

El último modelo a entrenar fue el de 500 épocas, que presentó la mejor tasa de confianza al predecir las clases 'BAC' Y 'AS'. Se vuelve evidente que a mayor numero de épocas el resultado, aun teniendo un dataset limitado, llega a mejorar significativamente, sin embargo, se debe considerar el *overfitting* en estos casos, para ejemplos prácticos de este trabajo de grado se emplearán los modelos de 200 y 500 épocas, con el fin de contrastar los resultados obtenidos al calcular el Índice de solubilización, es por esto que el tener como límite superior el modelo de 500 épocas es realmente útil a la hora de realizar este tipo de comparativas.




**Figura 5.9** Predicción para 500 épocas

En la Figura 5.10 se consolida la matriz de confusión correspondiente al entrenamiento de 500 épocas. Los elementos que más llaman la atención de ésta matriz respecto a las anteriores, es que para la clase 'BAC' ya no se presentan falsos positivos, esto indica que el modelo presenta una precisión del 100%. En esta clase también se tienen 23 verdaderos positivos, 5 falsos negativos y 18 verdaderos negativos, para la clase



'AS' se tiene 15 verdaderos positivos, 2 falsos positivos, 1 falso negativo y 28 verdaderos negativos.



**Figura 5.10** Matriz de Confusión para 500 épocas

Teniendo en cuenta los datos presentados anteriormente, se calculan las respectivas métricas que funcionarían para dar un punto de comparación con los anteriores modelos, es por eso que, comparando el entrenamiento de 200 épocas con el actual entrenamiento, se observan mejoras en la precisión y el *recall*, también se identifican algunas limitaciones persistentes en la clase 'AS', la exactitud pasó de un 91% a un 93% manteniendo un *F1-Score* constante del 0.87, para esta clase la precisión se mantuvo en 0.83, lo que sugiere que los falsos positivos no se redujeron significativamente a pesar del entrenamiento adicional, para la clase 'BAC' el *recall* se mantuvo en niveles similares de 0.89 en 200 épocas y 0.82 en 500, indicando que los falsos negativos siguen siendo un desafío, después de realizar estos entrenamientos podemos concluir que es viable refinar los porcentajes de precisión a través de mayores niveles de entrenamiento, sin embargo, para conseguir mejores porcentajes en *recall* es preciso emplear otras estrategias más allá de aumentar las épocas, como balanceo del *dataset* o ajustes en el umbral de decisión para mejorar las detecciones,

sin embargo el comportamiento de los modelos cumple satisfactoriamente los objetivos planteados para la determinación del índice de solubilización.


**Tabla 5.1** Comparativa de métricas

<b>Métrica</b>	<b>Clase</b>	<b>10 Épocas</b>	<b>50 Épocas</b>	<b>100 Épocas</b>	<b>200 Épocas</b>	<b>500 Épocas</b>
F1 Score	AS	0.75	0.78	0.87	0.87	0.87
F1 Score	BAC	0.72	0.83	0.85	0.90	0.90
Precisión	AS	0.70	0.70	0.83	0.83	0.83
Precisión	BAC	0.74	0.85	0.88	0.96	1.00
Exactitud	AS	0.78	0.85	0.92	0.91	0.93
Exactitud	BAC	0.76	0.83	0.84	0.91	0.89
Recall	AS	0.80	0.87	0.93	0.93	0.93
Recall	BAC	0.71	0.82	0.82	0.89	0.82

## 5.2 Comparativa entre métodos

La eficiencia relativa de solubilización es un parámetro de varios organismos solubilizadores de fosfato, este se determina rutinariamente mediante el análisis cualitativo de la medición del tamaño de la zona de halo alrededor de la colonia en la placa. Muchos investigadores siguen utilizando este método cualitativo (ensayo en placa) para evaluar la capacidad de solubilización de P de los organismos solubilizadores mediante la observación de un halo claro alrededor de la colonia. Sin embargo, la fiabilidad de este método cualitativo (técnica basada en el halo) aún no se ha establecido bien y debe determinarse [96]. La prueba de la eficacia relativa de las cepas aisladas se lleva a cabo seleccionando los microorganismos que son capaces de producir un halo/zona clara en una placa debido a la producción de ácidos orgánicos en el medio circundante [97].

El método empleado por distintos investigadores consisten en tomar una medida manual del tamaño de las unidades formadoras de colonia y el tamaño total incluyendo el halo de solubilización, al restar el diámetro de la colonia del diámetro total se encuentra el tamaño del halo [98]. En la Figura 5.11, se muestra una aproximación a las medidas manuales para determinar el diámetro de la colonia y el diámetro del halo.



**Figura 5.11** Toma de medidas manuales para determinar los diámetros

El diámetro de la colonia obtenido con los métodos manuales fue de 1.6 cm, el diámetro del halo de solubilización fue de 2.8 cm. Para esta investigación se contó con la participación de un experto para determinar estos parámetros y de esa forma realizar una mejor comparativa entre el método manual y los resultados presentados por IGLOO.

La misma imagen se sometió a los entrenamientos de 200 épocas y 500 épocas, como se pudo apreciar en la sección anterior, estos entrenamientos fueron los que presentaron mayor nivel de confianza al realizar la predicción, es por eso que se sometieron para evaluar la determinación de la eficiencia de solubilización relativa.

Para los modelos entrenados se obtuvieron resultados favorables para la predicción de las unidades formadoras de colonia (BAC) y el Halo de solubilización (AS). Teniendo una confianza de 97% y 93% para el modelo de 200 épocas (Figura 5.12A), y una confianza del 92% y 97% (Figura 5.12B) para el modelo de 500 épocas, indica un buen rendimiento respecto a los anteriores entrenamientos, lo que implica que las

máscaras binarias tendrán mucha más información para determinar la eficiencia de solubilización.






Figura 5.12 Segmentación de imágenes para 200 épocas A), Segmentación de imágenes para 500 épocas B)

Una vez realizada la predicción de los elementos de interés, se procede a extraer las máscaras binarias de los elementos segmentados, a partir de estas máscaras se puede determinar factores como el área de los elementos, y en este caso el diámetro de la colonia y el halo de solubilización, elementos importantes para la determinación de la eficiencia relativa de solubilización, los resultados de estas máscaras se almacenan en arreglos ordenados de matrices que permiten el tratamiento algebraico de los datos, es importante conocer que estos datos son los píxeles que se extraen de las máscaras binarias, por lo que en una primera instancia se realiza una conversión de píxeles a cm, teniendo en cuenta el diámetro de la caja de Petri con este dato, se sabe que en la imagen se cuenta con un ancho de 1746 píxeles que corresponde con el diámetro de la caja de Petri que es de 11 cm, con estos datos se realiza el factor de conversión para tratar de píxeles a cm que para este caso es de 158 píxeles por cada 1 cm, esto se plantea debido a que la eficiencia relativa de solubilización se calcula con en estas unidades, sin embargo, el resultado de esa ecuación es adimensional, por lo que, también se planteó el cálculo de este índice a partir de los píxeles extraídos de las máscaras, las figuras 5.13 y 5.14 se muestran las máscaras extraídas para ambos modelos



**Figura 5.13** Máscaras binarias para 200 épocas



**Figura 5.14** Máscaras binarias para 500 épocas

Para el modelo de 200 épocas se extrajo un tamaño de píxeles de 13329 para la colonia segmentada y 25571 para el halo de solubilización, en cuanto al modelo de 500 épocas se obtuvo un tamaño de 13331 para la colonia y 25409 para el halo de solubilización.

En la última etapa del desarrollo de IGLOO se calcula finalmente la eficiencia de solubilización, este dato se contrasta con la eficiencia obtenida de forma manual, para determinar esta métrica se emplea la ecuación 5.

$$Ef = \frac{A + B}{A}$$

**Ecuación 5.** Ecuación para determinar la eficiencia relativa de solubilización [99]

Donde A es el diámetro de la colonia y B es el diámetro del halo de solubilización [99], teniendo esto en cuenta, el resultado obtenido de forma manual fue de 2.75, para ambas segmentaciones se obtuvieron resultados muy cercanos al obtenido de forma manual, para el modelo de 200 épocas se determinó una eficiencia relativa de 2.92 utilizando la conversión de píxeles a cm, sin embargo usando únicamente los píxeles como dato para determinar este índice, se consiguió el mismo resultado, para el modelo de 500 épocas el resultado de la eficiencia relativa de solubilización fue de 2.91 en ambos casos.

Los métodos de segmentación aplicados son consistentes y presentan una ligera desviación respecto al cálculo manual de eficiencia relativa de solubilización, lo que indica que estos modelos ofrecen en potencia una precisión confiable. La cercanía de los resultados en ambos enfoques (conversión de píxeles a centímetros y en píxeles directos) indica que la técnica automatizada podría replicar eficazmente el cálculo manual.

## **Capítulo 6**

# 6 Conclusiones y Trabajos Futuros

## 6.1 Conclusiones

El análisis bibliométrico resalta una relación directa entre los avances en el recuento y análisis de bacterias y los desarrollos tecnológicos que sustentan estas actividades; a pesar del creciente interés por estos temas, el crecimiento en el uso de tecnologías avanzadas para el análisis de microorganismos ha sido gradual y lento, esta tendencia de crecimiento pausado puede deberse en gran medida a factores como la falta de recursos en ciertas regiones, los altos costos de implementación de tecnología de última generación y la disponibilidad limitada de infraestructuras de investigación adecuadas. A nivel mundial, pocos países han priorizado inversiones fuertes en biotecnología y microbiología, lo que limita la expansión del uso de estas tecnologías en laboratorios. Estados Unidos, sin embargo, lidera notablemente este campo, impulsado por políticas de apoyo a la investigación científica y por un ecosistema de innovación que integra a universidades, empresas biotecnológicas y laboratorios de primer nivel. Este predominio de un solo país también resalta la desigualdad en el acceso a las tecnologías avanzadas, lo que genera una brecha considerable en la calidad de la investigación microbiológica entre las naciones que disponen de estos recursos y aquellas que en sus prioridades de inversión no se encuentra la microbiología, esto está también relacionado con las políticas internas de los distintos países y las circunstancias sociales en las que se desarrolla la investigación.

La exploración de este dominio se refleja también en la escasez de información que existe relacionada a los dataset de bacterias o/u organismos solubilizares de fosforo, esto guía a la necesidad de establecer procedimientos fundamentales para crear bases de datos precisas y representativas. Para esta investigación uno de estos pasos críticos ha sido la inoculación de bacterias, una etapa esencial en la conformación de un dataset adecuado para el estudio, este proceso contó con la selección de bacterias específicas del entorno donde se realiza la investigación, lo cual permite que los datos recolectados sean relevantes y adaptados a las condiciones locales, esto refleja comportamientos biológicos y ambientales propios de la zona de estudio. Este enfoque

se vuelve particularmente relevante cuando se intenta establecer correlaciones o patrones específicos, ya que el empleo de organismos que han evolucionado en el ambiente local aumenta la validez de las observaciones, permitiendo a la investigación tener una visión a futuro de los alcances que pueden tener tanto IGLOO como los organismos solubilizadores de fosforo empleados para validar a IGLOO.

La implementación de técnicas de segmentación de imágenes en el estudio de bacterias permitió identificar aspectos importantes para su efectividad. Elementos como el tamaño y el etiquetado del conjunto de datos fueron variables que jugaron un papel relevante en el desarrollo de IGLOO, fueron determinantes en el éxito de la aplicación de técnicas de visión por computador, en primera instancia el tamaño del conjunto de datos influye en la capacidad de generalización del modelo, ya que un conjunto de datos grande y diverso permite que el modelo aprenda patrones robustos y pueda aplicar sus predicciones a nuevas imágenes con precisión. En este sentido, se debe mencionar que el etiquetado adecuado de cada imagen dentro del conjunto de datos es importante para el entrenamiento del modelo, esto asegura que el algoritmo aprenda a diferenciar correctamente entre las distintas clases de objetos. En la implementación de IGLOO jugó un papel importante el proceso de perfeccionamiento del algoritmo post dataset, debido a las limitaciones de tiempo y recursos con los que se desarrolló. Dar mayor profundidad al entrenamiento a través de las épocas dio un punto fundamental para el desarrollo del sistema, logrando resultados favorables tanto para la predicción de clases como para determinar la eficiencia relativa de solubilización.

Los métodos manuales para el análisis de microorganismos, aunque valiosos, presentan limitaciones importantes al depender de la interpretación subjetiva de los investigadores, esto es especialmente crítico en métodos que buscan aproximarse a fenómenos complejos, como la solubilización de fosfato en bacterias, los métodos tradicionales pueden llevar a variabilidad en los resultados, ya que dependen de la percepción y experiencia del investigador al evaluar el fenómeno. En este contexto, la incorporación de IGLOO para determinar el índice de solubilización de fosfato establece una oportunidad de estandarización que podría mejorar la objetividad de los estudios. Al emplear herramientas automatizadas se eliminan elementos de subjetividad y se obtiene un método replicable que facilita la comparación de resultados entre distintos laboratorios e investigadores. Esto es de gran relevancia en



estudios de microbiología agrícola, donde se requiere precisión para evaluar el impacto de estos microorganismos en la salud del suelo y en el crecimiento vegetal, la estandarización también permite que los resultados sean comparables y más confiables, promoviendo un avance más rápido en la investigación, como última instancia, el uso de IGLOO en la evaluación de la solubilización de fosfato podría contribuir a una mayor comprensión de la función de estas bacterias en el ecosistema, impulsando aplicaciones prácticas en el campo de la biotecnología agraria y la mejora de suelos.

## **6.2 Trabajo futuro**

Entre los resultados encontrados en el desarrollo de IGLOO, se establece como trabajo futuro el diseño experimental para lograr la estandarización de este método frente a los métodos manuales; disponer de un estudio estadístico para determinar la capacidad de IGLOO para promocionarse como herramienta alternativa de mayor validez en cuanto a fiabilidad como herramienta, otro aspecto relevante a la hora de analizar bacterias solubilizadoras de fósforo. Este trabajo implicaría adaptar los resultados obtenidos por IGLOO y ampliar el conjunto de datos de entrenamiento para poder determinar el mismo índice para diferentes microorganismos, teniendo en cuenta que IGLOO tendría que estar embebido en un controlador para su uso directo en el laboratorio.

## 7 Referencias Bibliográficas

- [1] J. Peña Martín, Y. Alvarado Capó, R. Orozco Morales, T. Pichardo, and A. Abreu López, "Conteo de bacterias y levaduras en imágenes digitales," *MediSur*, vol. 20, no. 2, pp. 243–256, 2022.
- [2] E. P. Sánchez, D. Núñez, R. O. Cruz, M. A. Torres, and E. V. Herrera, "Simulación y conteo de unidades formadoras de colonias," *ReCIBE Rev. Electrónica Comput. Informática Bioméd. Electrónica*, vol. 6, no. 1, pp. 97–111, 2017.
- [3] B. Berlanga and A. Isabel, "Aislamiento y evaluación de microorganismos solubilizadores de fósforo de suelos áridos en el noreste Mexicano," May 2018, Accessed: Mar. 04, 2024. [Online]. Available: <https://repositorio.uaaan.mx/xmlui/handle/123456789/45231>
- [4] "Solubilización in vitro de fosfatos por una cepa de *Paecilomyces lilacinus* (Thom) Samson." Accessed: Mar. 04, 2024. [Online]. Available: [https://www.scielo.org.mx/scielo.php?pid=S1405-31952011000800003&script=sci\\_arttext](https://www.scielo.org.mx/scielo.php?pid=S1405-31952011000800003&script=sci_arttext)
- [5] M. T. Fernández and H. Rodríguez, "Aplicaciones biológicas de las fitasas: papel en los fertilizantes microbianos," *ICIDCA Sobre Los Deriv. Caña Azúcar*, vol. XL, no. 2, pp. 27–34, 2006.
- [6] L. C. Corrales Ramírez, Z. Y. Arévalo Galvez, and V. E. Moreno Burbano, "Solubilización de fosfatos: una función microbiana importante en el desarrollo vegetal," *Nova*, vol. 12, no. 21, pp. 68–79, Jan. 2014.
- [7] F. R. Berraquero, A. M. Baya, and A. R. Cormenzana, "Establecimiento de índices para el estudio de la solubilización de fosfatos por bacterias del suelo," *Ars Pharm. Internet*, vol. 17, no. 4, Art. no. 4, Sep. 1976.
- [8] L. C. Corrales Ramírez, L. C. Sánchez Leal, Z. Y. Arévalo Galvez, and V. E. Moreno Burbano, "Bacillus: género bacteriano que demuestra ser un importante solubilizador de fosfato," *Nova*, vol. 12, no. 22, pp. 165–178, Jul. 2014.
- [9] C. A. C. R, M. S. de P, and J. C. M. F, "Identificación de bacterias solubilizadoras de fosfatos en un Andisol de la región cafetera colombiana," *Rev. Colomb. Biotecnol.*, vol. XIX, no. 1, pp. 21–28, 2017.
- [10] N. da Silva, *Manual de métodos de análisis microbiológica de alimentos*. Varela, 2007.
- [11] A. Corral-Lugo, Y. E. Morales-García, L. A. Pazos-Rojas, A. Ramírez-Valverde, R. D. Martínez-Contreras, and J. Muñoz-Rojas, "Cuantificación de bacterias cultivables mediante el método de" Goteo en Placa por Sellado (o estampado) Masivo", " *Rev. Colomb. Biotecnol.*, vol. 14, no. 2, pp. 147–156, 2012.
- [12] A. González Marcos *et al.*, *Técnicas y Algoritmos Básicos de Visión Artificial*. Universidad de La Rioja, 2006. Accessed: Mar. 11, 2024. [Online]. Available: <https://investigacion.unirioja.es/documentos/5c13b22ac8914b6ed3778a6a>
- [13] C. Russo *et al.*, *Visión artificial aplicada en Agricultura de Precisión*. Red de Universidades Nacionales con Carreras de Informática, 2018. Accessed: Mar. 11, 2024. [Online]. Available: <http://repositorio.unnoba.edu.ar/xmlui/handle/23601/662>

- [14] H. V. Sánchez, R. C. G. Gómez, O. E. C. Reyes, and G. M. Pérez, “Contador de bacterias de fermentación basados en métodos numéricos.”
- [15] A. Nogué and J. Antiga, “Aplicación práctica de la visión artificial en el control de procesos industriales,” *Gob. Esp. Minist. Educ.*, 2012.
- [16] R. Atencio and E. Cruz, “Situación actual de la aplicación y potenciales usos de la visión artificial en la entomología agrícola en Panamá,” *ID Tecnológico*, vol. 18, no. 2, Art. no. 2, Jul. 2022, doi: 10.33412/idt.v18.2.3741.
- [17] M. D. D. Cristina and Q. A. A. Alexander, “Tema: ‘Visión Artificial para la detección de enfermedades en el cultivo de papa,’” 2022.
- [18] J. F. Sotomayor, A. P. Gómez, and A. F. Cela, “Sistema de Visión Artificial para el Análisis de Imágenes de Cultivo basado en Texturas Orientadas,” *Rev. Politécnica*, vol. 33, no. 1, Art. no. 1, Feb. 2014, Accessed: Mar. 11, 2024. [Online]. Available: [https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista\\_politecnica2/article/view/104](https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/104)
- [19] E. M. i García, “Visión artificial,” *Fund. Para Univ. Oberta Catalunya*, 2012.
- [20] I. García and V. Caranqui, “La visión artificial y los campos de aplicación,” *Tierra Infín.*, vol. 1, no. 1, pp. 98–108, 2015.
- [21] J. A. Villacís Alejandro, “Implementación de un sistema para conteo de aerobios totales y antibiogramas de muestras bacterianas empleando visión artificial para la Facultad de Ciencias.” 2020.
- [22] J. E. Soto Sogamoso, J. E. Pinto Lopera, and E. E. Millán Rojas, “Micorrizas arbusculares y las técnicas de visión artificial para su identificación,” *TecnoLógicas*, vol. 25, no. 54, 2022.
- [23] E. M. Noboa Delgado, “Sistema embebido para reconocimiento y conteo de esporas del hongo de género trichoderma mediante técnicas de visión artificial,” bachelorThesis, 2022. Accessed: Mar. 11, 2024. [Online]. Available: <http://repositorio.utn.edu.ec/handle/123456789/12904>
- [24] “ESPEL-MEC-0161-P.”
- [25] D. A. Alvarado-Ruiz, K. Ordaz-Hernández, G. L. Lara-Cadena, V. María de Lourdes, M. Castelán, and others, “Caracterización del crecimiento de colonias bacterianas utilizando segmentación de imágenes con K-means,” *Pädi Bol. Científico Cienc. Básicas E Ing. ICBI*, vol. 11, no. Especial2, pp. 1–6, 2023.
- [26] M. Bunge, *Philosophy of Science: Volume 1, From Problem to Theory*. New York: Routledge, 2017. doi: 10.4324/9781315126371.
- [27] B. Rajwa *et al.*, “Morphotypic analysis and classification of bacteria and bacterial colonies using laser light-scattering, pattern recognition, and machine-learning system,” in *Optics and Photonics in Global Homeland Security V and Biometric Technology for Human Identification VI*, SPIE, May 2009, pp. 204–210. doi: 10.1117/12.818589.
- [28] “teai-92.pdf.” Accessed: Mar. 19, 2024. [Online]. Available: [http://www.cse.yorku.ca/~tsotsos/Homepage%20of%20John%20K\\_files/teai-92.PDF](http://www.cse.yorku.ca/~tsotsos/Homepage%20of%20John%20K_files/teai-92.PDF)
- [29] A. F. L. Quintana, D. A. M. Herrera, and L. E. M. Salazar, “Sistema de visión artificial para conteo de objetos en movimiento”.

- [30] I. G. S and V. C. S, “La visión artificial y los campos de aplicación,” *Tierra Infin.*, vol. 1, no. 1, Art. no. 1, Dec. 2015, doi: 10.32645/26028131.76.
- [31] W. E. Snyder and H. Qi, *Machine Vision*. Cambridge University Press, 2004.
- [32] L. Mereles, “Preprocesamiento de imágenes digitales a través de su Transformada de Fourier”.
- [33] M. R. Rivas, “Sistema de pre-procesamiento de imagenes electrocardiograficas en telemedicina.” Accessed: Mar. 19, 2024. [Online]. Available: [http://catarina.udlap.mx/u\\_dl\\_a/tales/documentos/lis/ramos\\_r\\_m/](http://catarina.udlap.mx/u_dl_a/tales/documentos/lis/ramos_r_m/)
- [34] S. Domínguez Pavón, “Identificación del modelo de cámara mediante Redes Neuronales Convolucionales,” 2019, Accessed: Mar. 29, 2024. [Online]. Available: <https://idus.us.es/handle/11441/92171>
- [35] J. Terven and D. Cordova-Esparza, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [36] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [37] S. Hao, Y. Zhou, and Y. Guo, “A Brief Survey on Semantic Segmentation with Deep Learning,” *Neurocomputing*, vol. 406, pp. 302–321, Sep. 2020, doi: 10.1016/j.neucom.2019.11.118.
- [38] P. Wang *et al.*, “Understanding Convolution for Semantic Segmentation,” in *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Mar. 2018, pp. 1451–1460. doi: 10.1109/WACV.2018.00163.
- [39] C. Azpilicueta, “Nematodos como indicadores de la calidad del suelo: Efectos de la fertilización nitrogenada,” 2012.
- [40] C. O. Patiño-Torres and O. E. Sanclemente-Reyes, “Los microorganismos solubilizadores de fósforo (MSF): una alternativa biotecnológica para una agricultura sostenible,” *Entramado*, vol. 10, no. 2, pp. 288–297, Jul. 2014.
- [41] R. A. García, N. C. Lovaisa, and E. L. Ulla, “Aislamiento y caracterización de bacterias solubilizadoras de fosfatos del Noroeste Argentino y su efecto en la promoción de crecimiento en maíz (*Zea mays* L.),” *Rev. Agronómica Noroeste Argent.*, vol. 35, no. 1, pp. 13–28, Jun. 2015.
- [42] “Efecto del uso del suelo sobre hongos solubilizadores de fosfato y bacterias diazotróficas en el páramo de Guerrero (Cundinamarca).” Accessed: Mar. 31, 2024. [Online]. Available: [http://www.scielo.org.co/scielo.php?pid=S0120-99652005000200015&script=sci\\_arttext](http://www.scielo.org.co/scielo.php?pid=S0120-99652005000200015&script=sci_arttext)
- [43] C. G. Hernández Plata, L. K. Pantoja Avila, and S. C. Turriago Mojica, “Evaluación de la presencia de bacteriocinas en cultivos de bacterias ácido lácticas,” bachelorThesis, Universidad de la Sabana, 2012. Accessed: Mar. 31, 2024. [Online]. Available: <https://intellectum.unisabana.edu.co/handle/10818/5064>
- [44] C. Peña Cortés, “Sistema de Visión Artificial para el Reconocimiento y el Conteo de Unidades Formadoras de Colonias (UFC),” *Rev. Colomb. Tecnol. Av.*, vol. 1, pp. 9–15, Jun. 2011.

- [45] A. Méndez Rubio, "Sistema Automático para análisis de unidades formadoras de colonias mediante técnicas de procesamiento digital de imágenes," 2023.
- [46] G. M. Alves and P. E. Cruvinel, "Customized Computer Vision and Sensor System for Colony Recognition and Live Bacteria Counting in Agriculture," *Sens. Transducers*, vol. 201, no. 6, pp. 65–77, 2016.
- [47] Y. Feng *et al.*, "Phosphate solubilizing microorganisms: a sustainability strategy to improve urban ecosystems," *Front. Microbiol.*, vol. 14, Jan. 2024, doi: 10.3389/fmicb.2023.1320853.
- [48] N. Donthu, S. Kumar, D. Mukherjee, N. Pandey, and W. M. Lim, "How to conduct a bibliometric analysis: An overview and guidelines," *J. Bus. Res.*, vol. 133, pp. 285–296, Sep. 2021, doi: 10.1016/j.jbusres.2021.04.070.
- [49] A. M. Methley, S. Campbell, C. Chew-Graham, R. McNally, and S. Cheraghi-Sohi, "PICO, PICOS and SPIDER: a comparison study of specificity and sensitivity in three search tools for qualitative systematic reviews," *BMC Health Serv. Res.*, vol. 14, no. 1, pp. 1–10, 2014.
- [50] P. Mongeon and A. Paul-Hus, "The journal coverage of Web of Science and Scopus: a comparative analysis," *Scientometrics*, vol. 106, pp. 213–228, 2016.
- [51] Y. Guo, Z. Hao, S. Zhao, J. Gong, and F. Yang, "Artificial Intelligence in Health Care: Bibliometric Analysis," *J. Med. Internet Res.*, vol. 22, no. 7, p. e18228, Jul. 2020, doi: 10.2196/18228.
- [52] C.-I. Papadopoulou, E. Loizou, K. Melfou, and F. Chatzitheodoridis, "The Knowledge Based Agricultural Bioeconomy: A Bibliometric Network Analysis," *Energies*, vol. 14, no. 20, Art. no. 20, Jan. 2021, doi: 10.3390/en14206823.
- [53] "The Benefits of Engaging in Collaborative Research Relationships – Association for Psychological Science – APS." Accessed: Sep. 10, 2024. [Online]. Available: <https://www.psychologicalscience.org/observer/the-benefits-of-engaging-in-collaborative-research-relationships>
- [54] G. Bradski and A. Kaehler, *Learning OpenCV: Computer Vision with the OpenCV Library*. O'Reilly Media, Inc., 2008.
- [55] C. Michael Hall, "Publish and perish? Bibliometric analysis, journal ranking and the assessment of research quality in tourism," *Tour. Manag.*, vol. 32, no. 1, pp. 16–27, Feb. 2011, doi: 10.1016/j.tourman.2010.07.001.
- [56] M. Túnñez-López, K. Valarezo-González, and I. Marín-Gutiérrez, "Impacto de la investigación y de los investigadores en comunicación en Latinoamérica: el índice h de las revistas científicas," *Palabra Clave*, vol. 17, no. 3, pp. 895–919, Sep. 2014.
- [57] O. Ellegaard and J. A. Wallin, "The bibliometric analysis of scholarly production: How great is the impact?," *Scientometrics*, vol. 105, pp. 1809–1831, 2015.
- [58] A. Agarwal *et al.*, "Bibliometrics: tracking research impact by selecting the appropriate metrics," *Asian J. Androl.*, vol. 18, no. 2, p. 296, Apr. 2016, doi: 10.4103/1008-682X.171582.
- [59] "Purdue University," Top Universities. Accessed: Sep. 02, 2024. [Online]. Available: <https://www.topuniversities.com/universities/purdue-university>
- [60] E. V. Ramos Cabrera, Z. Y. Delgado Espinosa, and A. F. Solis Pino, "Use of Phosphorus-Solubilizing Microorganisms as a Biotechnological Alternative: A

- Review,” *Microorganisms*, vol. 12, no. 8, Art. no. 8, Aug. 2024, doi: 10.3390/microorganisms12081591.
- [61] “A state-of-the-art survey of object detection techniques in microorganism image analysis: from classical methods to deep learning approaches | Artificial Intelligence Review.” Accessed: Sep. 02, 2024. [Online]. Available: <https://link.springer.com/article/10.1007/s10462-022-10209-1>
- [62] “Frontiers | Antimicrobial resistance and machine learning: past, present, and future.” Accessed: Sep. 02, 2024. [Online]. Available: <https://www.frontiersin.org/journals/microbiology/articles/10.3389/fmicb.2023.1179312/full>
- [63] G. Zhao *et al.*, “Development of biofertilizers for sustainable agriculture over four decades (1980–2022),” *Geogr. Sustain.*, vol. 5, no. 1, pp. 19–28, Mar. 2024, doi: 10.1016/j.geosus.2023.09.006.
- [64] X. Du, D. Li, Q. Wang, H. Zhang, and Y. Yang, “Bibliometric analysis of soil phosphate solubilizing microorganisms research using VOSviewer,” *Life Res.*, vol. 7, no. 1, p. 3, 2024, doi: 10.53388/LR20240003.
- [65] M. C. Moshobane, T. T. Khoza, and S. Niassy, “The period of insect research in the tropics: a bibliometric analysis,” *Int. J. Trop. Insect Sci.*, vol. 42, no. 1, pp. 989–998, Feb. 2022, doi: 10.1007/s42690-021-00616-2.
- [66] Z. Liu, Z. Li, L. Wang, Z. Gu, and L. Ma, “Bibliometric Analysis of the Knowledge Landscape of Periodontal Disease in Pregnancy: A Noteworthy Multidisciplinary Issue,” *J. Multidiscip. Healthc.*, Dec. 2023, Accessed: Sep. 03, 2024. [Online]. Available: <https://www.tandfonline.com/doi/abs/10.2147/JMDH.S437127>
- [67] F. J. Agbo, S. S. Oyelere, J. Suhonen, and M. Tukiainen, “Scientific production and thematic breakthroughs in smart learning environments: a bibliometric analysis,” *Smart Learn. Environ.*, vol. 8, no. 1, p. 1, Jan. 2021, doi: 10.1186/s40561-020-00145-4.
- [68] E.-V. Ramos-Cabrera *et al.*, “Evaluación de bacterias endofíticas solubilizadores de fósforo en café, una alternativa sostenible,” *Biotechnol. En El Sect. Agropecu. Agroindustrial*, vol. 19, no. 2, pp. 94–107, Dec. 2021, doi: 10.18684/bsaa.v19.n2.2021.1554.
- [69] D. A. M. Benavides, M. F. M. Londoño, M. L. P. Buitrago, and N. I. C. Orjuela, “EVALUACIÓN DEL POTENCIAL DE BACTERIAS PROMOTORAS DE CRECIMIENTO VEGETAL PGPR, APLICADAS A CULTIVOS DE PAPA EN CONDICIONES DE INVERNADERO”.
- [70] Z. K. O. Fernández and B. P. M. Bonilla, “Evaluación agronómica de Coffea Arábica variedad castillo y caturra en dos sistemas de producción (sol y sombra); en la hacienda los naranjos, vereda la Venta (Cajibío-Cauca),” *Rev. Asoc. Colomb. Cienc. Biol.*, vol. 1, no. 29, Art. no. 29, Aug. 2017.
- [71] A. F. Solis, D. A. Revelo Luna, D. A. Campo Ceballos, and C. A. Gaviria López, “Correlación del contenido de clorofila foliar de la especie Coffea arabica con índices espectrales en imágenes,” *Biotechnol. En El Sect. Agropecu. Agroindustrial*, vol. 19, no. 2, pp. 51–68, Jan. 2021, doi: 10.18684/bsaa.v19.n2.2021.1536.
- [72] “efficient microbiological growth medium for screening phosphate solubilizing microorganisms | FEMS Microbiology Letters | Oxford Academic.” Accessed: Oct.

- 10, 2024. [Online]. Available: <https://academic.oup.com/femsle/article/170/1/265/454487>
- [73] "2023NicolasPadilla.pdf." Accessed: Oct. 31, 2024. [Online]. Available: <https://repository.usta.edu.co/bitstream/handle/11634/52971/2023NicolasPadilla.pdf?sequence=1&isAllowed=y>
- [74] J. D. Peñaloza Aldaz, "Clasificación y detección de defectos en la superficie de las papas utilizando procesamiento digital de imágenes y machine learning.," Apr. 2023, Accessed: Oct. 31, 2024. [Online]. Available: <http://dspace.esepoch.edu.ec/handle/123456789/20911>
- [75] R. A. Dean, L. S. Maglione, and F. O. Cappellari, "Análisis de función y matriz morfológica aplicado al diseño de un implemento agrícola," *Aporte Santiaguino*, p. ág. 11-20, Jul. 2018, doi: 10.32911/as.2018.v11.n1.451.
- [76] "A review of research in mechanical engineering design. Part II: Representations, analysis, and design for the life cycle | Research in Engineering Design." Accessed: Oct. 16, 2024. [Online]. Available: <https://link.springer.com/article/10.1007/BF01580205>
- [77] T. S. Gunawan *et al.*, "Development of video-based emotion recognition using deep learning with Google Colab," *TELKOMNIKA Telecommun. Comput. Electron. Control*, vol. 18, no. 5, Art. no. 5, Oct. 2020, doi: 10.12928/telkomnika.v18i5.16717.
- [78] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS," *Mach. Learn. Knowl. Extr.*, vol. 5, no. 4, Art. no. 4, Dec. 2023, doi: 10.3390/make5040083.
- [79] G. Jocher *et al.*, "ultralytics/yolov5: v6.0 - YOLOv5n 'Nano' models, Roboflow integration, TensorFlow export, OpenCV DNN support," *Zenodo*, Oct. 2021, doi: 10.5281/zenodo.5563715.
- [80] E. Avuçlu and A. Elen, "Evaluation of train and test performance of machine learning algorithms and Parkinson diagnosis with statistical measurements," *Med. Biol. Eng. Comput.*, vol. 58, no. 11, pp. 2775–2788, Nov. 2020, doi: 10.1007/s11517-020-02260-3.
- [81] X. Xie, J. W. K. Ho, C. Murphy, G. Kaiser, B. Xu, and T. Y. Chen, "Testing and validating machine learning classifiers by metamorphic testing," *J. Syst. Softw.*, vol. 84, no. 4, pp. 544–558, Apr. 2011, doi: 10.1016/j.jss.2010.11.920.
- [82] T.-Y. Lin *et al.*, "Microsoft COCO: Common Objects in Context," in *Computer Vision – ECCV 2014*, D. Fleet, T. Pajdla, B. Schiele, and T. Tuytelaars, Eds., Cham: Springer International Publishing, 2014, pp. 740–755. doi: 10.1007/978-3-319-10602-1\_48.
- [83] S. Shao *et al.*, "Objects365: A Large-Scale, High-Quality Dataset for Object Detection," in *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, Korea (South): IEEE, Oct. 2019, pp. 8429–8438. doi: 10.1109/ICCV.2019.00852.
- [84] E. Universitat Politècnica De València, "Universitat Politècnica de València," *Ing. Agua*, vol. 18, no. 1, p. ix, Sep. 2014, doi: 10.4995/ia.2014.3293.
- [85] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer*

- Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [86] J. Brownlee, “What is the Difference Between a Batch and an Epoch in a Neural Network?”.
- [87] W. Hastomo, A. S. B. Karno, N. Kalbuana, A. Meiriki, and Sutarno, “Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia,” *J. Phys. Conf. Ser.*, vol. 1933, no. 1, p. 012050, Jun. 2021, doi: 10.1088/1742-6596/1933/1/012050.
- [88] T. Dietterich, “Overfitting and undercomputing in machine learning,” *ACM Comput. Surv.*, vol. 27, no. 3, pp. 326–327, Sep. 1995, doi: 10.1145/212094.212114.
- [89] C. M. Oliver, D. Wagstaff, J. Bedford, S. R. Moonesinghe, and the Peri-operative Quality Improvement Project delivery team and collaborative, “Systematic development and validation of a predictive model for major postoperative complications in the Peri-operative Quality Improvement Project (PQIP) dataset,” *Anaesthesia*, vol. 79, no. 4, pp. 389–398, 2024, doi: 10.1111/anae.16248.
- [90] A. Montalvo-Fernandez and A. Barranco Gutiérrez, “Sistema Electrónico de Detección de Baches y Topes para Automóviles,” 2021. doi: 10.13140/RG.2.2.34688.15362.
- [91] A. Montalvo-Fernandez and A. Barranco Gutiérrez, “Sistema Electrónico de Detección de Baches y Topes para Automóviles,” 2021. doi: 10.13140/RG.2.2.34688.15362.
- [92] M. Heydarian, T. E. Doyle, and R. Samavi, “MLCM: Multi-Label Confusion Matrix,” *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [93] M. C. C. Montealegre, F. L. Martinez, and C. H. Arias, “Identificación de idioma y respuesta en tiempo real usando técnicas de Deep Learning con espectrogramas y reconocimiento de voz”.
- [94] W. Sun, “EVALUACIÓN DE ALGORITMOS DE MACHINE LEARNING PARA CONDUCCIÓN MACHINE LEARNING ALGORITHM EVALUATION ON ADVANCED DRIVER ASSISTANCE”.
- [95] A. Z. Hernández, G. A. G. Rosales, H. J. J. Santiago, and M. M. Lee, “Métricas de rendimiento para evaluar el aprendizaje automático en la clasificación de imágenes petroleras utilizando redes neuronales convolucionales,” *Cienc. Lat. Rev. Científica Multidiscip.*, vol. 6, no. 5, Art. no. 5, Nov. 2022, doi: 10.37811/cl\_rcm.v6i5.3420.
- [96] K. S. Baig, M. Arshad, Z. Zahir, and M. A. Cheema, “Comparative efficacy of qualitative and quantitative methods for rock phosphate solubilization with phosphate solubilizing rhizobacteria,” *Soil Environ.*, vol. 29, pp. 82–86, Jan. 2010.
- [97] S. Mehta and C. S. Nautiyal, “An Efficient Method for Qualitative Screening of Phosphate-Solubilizing Bacteria,” *Curr. Microbiol.*, vol. 43, no. 1, pp. 51–56, Jul. 2001, doi: 10.1007/s002840010259.
- [98] R. Gupta, R. Singal, A. Shankar, R. C. Kuhad, and R. K. Saxena, “A Modified Plate Assay for Screening Phosphate Solubilizing Microorganisms,” *J. Gen. Appl. Microbiol.*, vol. 40, no. 3, pp. 255–260, 1994, doi: 10.2323/jgam.40.255.



- [99] “Details for: Effect of phosphate-solubilizing *Pseudomonas putida* on the growth of maize and its survival in the rhizosphere › Koha online catalog.” Accessed: Nov. 02, 2024. [Online]. Available: [https://knowledgecenter.cimmyt.org/cgi-bin/koha/opac-detail.pl?biblionumber=25521&shelfbrowse\\_itemnumber=19186](https://knowledgecenter.cimmyt.org/cgi-bin/koha/opac-detail.pl?biblionumber=25521&shelfbrowse_itemnumber=19186)