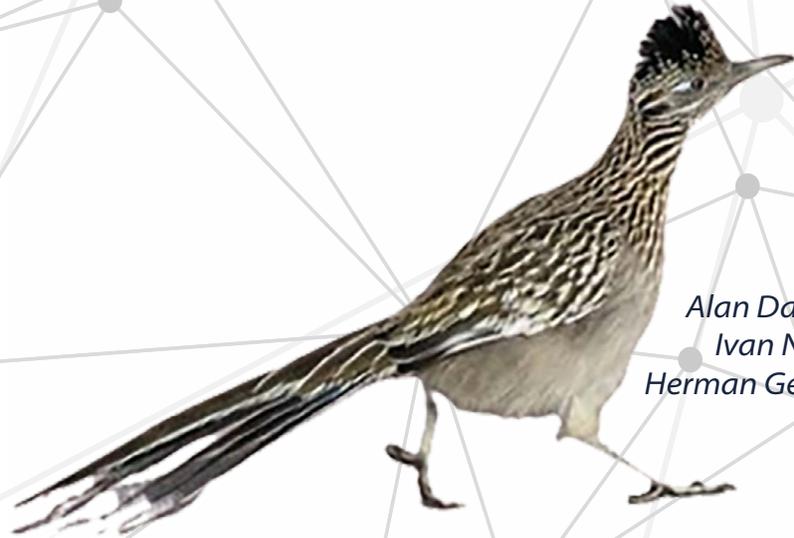


Investigaciones actuales de la computación



Coordinadores
Alan David Ramírez Noriega
Ivan Noel Alvarez Sánchez
Herman Geovany Ayala Zúñiga



Investigaciones actuales de la computación



Investigaciones actuales de la computación

Alan David Ramírez Noriega
Ivan Noel Alvarez Sánchez
Herman Geovany Ayala Zúñiga
Coordinadores



Investigaciones actuales de la computación. **Coordinadores:** Alan David Ramírez Noriega, Ivan Noel Alvarez Sánchez y Herman Geovany Ayala Zúñiga — Sinaloa, México. 2024.

148 p. 23 cm.

Primera edición

D. R. © copyright 2024. Alan David Ramírez Noriega, Ivan Noel Alvarez Sánchez y Herman Geovany Ayala Zúñiga

ISBN: **979-13-87631-27-7**

DOI: <https://doi.org/10.61728/AE24004480>



La presente obra fue dictaminada bajo el sistema de doble ciego y cuenta con el aval de los dictámenes de pares académicos en el campo de la Ciencia y Tecnología en México.

La publicación de este libro se financió con recursos del Fondo Estatal de Apoyo a la Ciencia, Tecnología e Innovación del Estado de Sinaloa (FEACTIS) de la Coordinación General para el Fomento a la Investigación Científica e Innovación del Estado de Sinaloa (CONFÍE) a través de la Convocatoria Fomento de Actividades Científicas y Tecnológicas 2024 (FACYT).

Cuerpos académicos participantes: UAIM-CA-7 Tecnología Educativa en el Aprendizaje de la Lengua Indígena Mayo Yoreme ; UAS-CA-295 Sistemas Innovadores Aplicados al Contexto Educativo; UAS-CA-303 Tecnología Educativa I+D+i UDG-CA-884 Educación y Desarrollo Tecnológico.

Edición y corrección: **Astra ediciones**

Se prohíbe la reproducción, el registro o la transmisión parcial o total de esta obra por cualquier sistema de recuperación de información, sea mecánico, fotoquímico, electrónico, por fotocopia, cualquier otro existente o por existir; sin el permiso previo, por escrito, del titular de los derechos.

HECHO EN MÉXICO | MADE IN MEXICO

Contenido

Prólogo	9
<i>Gilberto Bojórquez Delgado</i>	

Capítulo 1

Desarrollo de una metodología para selección de variables de entrenamiento de una CNN para identificar el modelo dinámico de un cuadrotor	11
<i>José de Jesús Valenzuela Hernández</i>	
<i>Giovanni Mora Castro</i>	
<i>Gilberto Bojórquez Delgado</i>	

Capítulo 2

Una propuesta de alternador para vant multirotor	39
<i>José Luis Cervantes González</i>	
<i>Isaac Alfredo Ochoa Segundo</i>	
<i>Gilberto Bojórquez Delgado</i>	

Capítulo 3

Metodología de captura de imágenes en cultivos de maíz utilizando vehículos aéreos no tripulados recreativos	59
<i>Giovanni Mora Castro</i>	
<i>José de Jesús Valenzuela Hernández</i>	
<i>Gilberto Bojórquez Delgado</i>	

Capítulo 4

Selección y evaluación de modelos de inteligencia artificial para la detección de maleza en cultivos agrícolas	91
<i>Karla Vanessa Ayala Cruz</i>	
<i>José de Jesús Valenzuela Hernández</i>	
<i>Gilberto Bojórquez Delgado</i>	

Capítulo 5

Desarrollo e implementación de un clasificador espectral para la discriminación de superficies terrestres y acuáticas utilizando datos de sentinel 2 y técnicas de aprendizaje automático 119

Jesús Bojórquez Delgado

Gilberto Bojórquez Delgado

Manuel Alfredo Flores Rosales

Acerca de los autores 139

Prólogo

Investigaciones actuales de la computación reúne contribuciones que exploran cómo los avances en computación están redefiniendo el enfoque hacia problemas complejos en sectores clave. Este libro, con una perspectiva multidisciplinaria, presenta investigaciones de vanguardia donde convergen la inteligencia artificial, el aprendizaje automático y la teledetección, mostrando el impacto de estas tecnologías en áreas como la agricultura de precisión, el monitoreo ambiental y la gestión de recursos naturales.

La obra se organiza en capítulos independientes, cada uno de los cuales presenta un estudio que ilustra aplicaciones prácticas de herramientas computacionales. Desde la implementación de redes neuronales para el análisis de imágenes capturadas por drones hasta el desarrollo de algoritmos para clasificar superficies terrestres y acuáticas con datos satelitales, los temas abordados ofrecen soluciones innovadoras y efectivas en áreas donde la eficiencia y precisión son esenciales. Cada investigación, además, muestra metodologías avanzadas que aprovechan la capacidad de la computación para resolver problemas específicos de manera más ágil, precisa y sostenible.

En un contexto global donde las demandas de producción agrícola, la escasez de recursos y los efectos del cambio climático exigen soluciones efectivas, *Investigaciones actuales de la computación* resalta la capacidad de la tecnología computacional para transformar cómo gestionamos los recursos naturales y optimizamos procesos productivos. La inteligencia artificial, por ejemplo, se destaca en este libro como una herramienta invaluable para el monitoreo de cultivos y la detección de malezas, mientras que la integración de sensores y algoritmos en sistemas autónomos de drones impulsa el monitoreo en tiempo real y permite tomar decisiones basadas en datos con un alcance y precisión sin precedentes.

Para estudiantes, investigadores y profesionales en computación aplicada, esta obra representa una guía y referencia actualizada sobre cómo las tecnologías emergentes están ampliando los horizontes de la ciencia y la ingeniería. A través de cada capítulo, el lector podrá observar la evolución de estos enfoques y el potencial de la computación en aplicaciones que, hasta hace poco, eran inabordables o muy limitadas. En conjunto, *Investigaciones Actuales de la Computación* no solo enriquece el campo académico, sino que inspira nuevas investigaciones y desarrollos en una ciencia computacional cada vez más integrada y esencial para los desafíos del siglo XXI.

Dr. Gilberto Bojórquez Delgado

<https://doi.org/10.61728/AE24004497>



Capítulo 1

Desarrollo de una metodología para selección de variables de entrenamiento de una CNN para identificar el modelo dinámico de un cuadrotor

*José de Jesús Valenzuela Hernández¹
Giovanni Mora Castro²
Gilberto Bojórquez Delgado³*

<https://doi.org/10.61728/AE24004503>



¹ Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: josevalenzuela_93@outlook.com

² Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: gmora0601@gmail.com

³ Tecnológico Nacional de México – ITS Guasave, Sinaloa, México.
Email: itsg.bojorquez@gmail.com

Resumen

El presente artículo, explora el uso de redes neuronales convolucionales (CNN) para modelar la dinámica no lineal de cuadricópteros utilizando datos de vuelo registrados en la “caja negra”. Este enfoque es crucial debido a la complejidad y la naturaleza no lineal de los cuadricópteros, que demandan métodos avanzados de modelización. La investigación se centra en seleccionar las variables más significativas para el entrenamiento de la CNN, con el objetivo de mejorar la adaptabilidad y eficiencia de los drones en entornos dinámicos y no estructurados.

El artículo inicia con una revisión de trabajos relacionados y el marco teórico, destacando la importancia y los desafíos del modelado preciso de cuadricópteros. Posteriormente, se describe la metodología para extraer y analizar datos de la caja negra, incluyendo parámetros como la aceleración, la orientación y los comandos de la radioemisora. Se construye una matriz de correlación para identificar las relaciones entre estas variables y se presentan los resultados del análisis, destacando la alta correlación entre los motores y los sensores IMU (acelerómetro y giroscopio).

Finalmente, se discuten las implicaciones de las correlaciones observadas y se concluye que las variables seleccionadas serán utilizadas para entrenar la CNN. Se menciona la intención de realizar investigaciones futuras para comparar otras técnicas de selección de variables y mejorar el modelo propuesto, con el objetivo de desarrollar sistemas de control más sofisticados y adaptativos para cuadricópteros.

Introducción

La robótica aérea, y en particular los vehículos aéreos no tripulados (UAVs) o drones, han experimentado un crecimiento significativo en su aplicación, impactando diversos sectores de la economía global. El espectro de uso de estos dispositivos abarca desde el monitoreo y la

inspección hasta la recolección de datos, la fotografía, la recreación y la logística, transformando prácticas en múltiples sectores y presentando una revolución en la gestión del espacio aéreo de baja altitud (Merkert y Bushell, 2020). Este avance ha llevado al desarrollo de soluciones innovadoras, como los sistemas de entrega con drones (Li et al., 2023), que emergen como alternativas para minimizar costos y tiempos de envío, mejorando así la eficiencia operacional y la rentabilidad en sectores como la agricultura (Rejeb et al., 2022).

El presente artículo, se centra en los cuadricópteros, un subconjunto específico de UAVs, se caracterizan por su configuración de cuatro rotores que les permite una maniobrabilidad y estabilidad únicas, haciendo posible realizar vuelos estacionarios, desplazamientos en todas las direcciones, y giros en el aire con precisión (Cooper et al., 2014). Esta configuración les otorga ventajas significativas para aplicaciones que requieren precisión en el vuelo y la captura de imágenes o datos, convirtiéndolos en herramientas ideales para la inspección de infraestructuras, la vigilancia, o la investigación agrícola. La complejidad en la modelización y control de estas aeronaves surge de su dinámica no lineal, lo que demanda enfoques avanzados para su estudio y aplicación práctica.

Otro concepto destacable en este artículo son las redes neuronales, las cuales representan una categoría de algoritmos de aprendizaje profundo que emulan la forma en que el cerebro humano opera, permitiendo a las máquinas aprender de los datos de manera similar a como lo hacen los humanos (Martínez et al., 1995; Narendra y Parthasarathy, 1990). Estos sistemas son capaces de identificar patrones complejos y realizar predicciones o clasificaciones basadas en grandes cantidades de datos. Su aplicación en la robótica y, específicamente, en la modelización de drones, ha abierto nuevas posibilidades para el análisis y control de estas aeronaves, superando muchas de las limitaciones de los métodos de modelización tradicionales (Duran et al., 2023; Lee et al., 2021; Ma et al., 2023; Zhou et al., 2023).

De forma general, se analiza el problema de la necesidad de modelos matemáticos más exactos para distintos sistemas, destaca los desafíos propios de los métodos tradicionales de modelado y la promesa que representan las técnicas basadas en aprendizaje profundo. Los enfoques convencionales, que se apoyan en principios de dinámica bien establecidos,

enfrentan limitaciones significativas debido a las complejidades intrínsecas de los sistemas y las restricciones de las técnicas mismas. Por ejemplo, la parametrización de ángulos de Euler, aunque ampliamente adoptada, es susceptible a singularidades que pueden resultar en errores significativos en la simulación y control (Abdulkareem et al., 2022; Jazar, 2022). Por otro lado, la parametrización de cuaterniones, aunque evita estas singularidades, introduce una complejidad algorítmica que puede representar un obstáculo considerable en aplicaciones prácticas (Kremer et al., 2022). Además, la discrepancia entre el número de grados de libertad y las entradas de control, junto con la necesidad de incorporar efectos giroscópicos y de arrastre, aumenta la complejidad del modelado y la simulación, subrayando la necesidad de enfoques más innovadores para lograr modelos representativos y eficientes (Martini et al., 2022; Mizouri et al., 2020).

Gracias a la evolución tecnológica y métodos avanzados de modelización, se han desarrollado múltiples técnicas de estructura de modelos para crear representaciones precisas y fiables de sistemas complejos. La integración del aprendizaje profundo en el diseño y control de sistemas se explora como un método para capturar relaciones complejas y no lineales en los datos, ofreciendo un nuevo nivel de sofisticación en la modelización (Kremer et al., 2022).

Algunos autores, discuten la incorporación progresiva de métodos computacionales, especialmente el aprendizaje automático, el cual ha ampliado los horizontes del análisis y diseño de sistemas complejos. La fusión de conocimientos procedentes de la física tradicional y enfoques computacionales modernos ha dado lugar a modelos más adaptables y capaces de manejar la complejidad relacionada a los sistemas dinámicos (Esfandiari et al., 2023; Huang et al., 2020; Khaki et al., 2020; Springer et al., 2021).

Mientras que otros autores (Li et al., 2019; Wenhui et al., 2018; Zhi-lenkova et al., 2021) analizan la importancia de la precisión en los modelos, concluyendo que un modelo solo es útil si es suficientemente preciso para capturar el comportamiento real del sistema, un principio que subyace en el desarrollo de modelos basados en aprendizaje automático. Este criterio es fundamental para la evaluación y aplicación práctica de dichos modelos.

Existen trabajos que son clave en el campo (López Pacheco y Yu, 2022; Rajendra y Brahmajirao, 2020), los cuales muestran cómo las

redes neuronales convolucionales pueden ser entrenadas para descubrir patrones y comportamientos en datos altamente no lineales y complejos, subrayando el potencial transformador del aprendizaje profundo en el modelado de sistemas dinámicos.

De forma específica la problemática se centra en la complejidad de integrar efectivamente métodos basados en aprendizaje profundo para el modelado preciso de las dinámicas no lineales en cuadricópteros, una subcategoría de drones. A pesar de los avances tecnológicos en drones y técnicas de aprendizaje automático, aún persiste el desafío de desarrollar modelos que sean simultáneamente precisos y computacionalmente eficientes. Esta dificultad radica en la naturaleza dinámica y compleja de los cuadricópteros, junto con los factores ambientales y operativos variables, los cuales complican la tarea de predecir su comportamiento y controlarlos en tiempo real con alta fidelidad. La brecha existente limita la autonomía y la capacidad de los drones para ejecutar tareas complejas en entornos impredecibles o desconocidos, lo que subraya la urgencia de explorar nuevas metodologías que puedan abordar estas dinámicas no lineales de manera más eficaz (como se ha discutido anteriormente).

Debido a esta problemática, el objetivo del trabajo de investigación plantea una metodología basada en aprendizaje profundo, que busca una solución al modelado de la dinámica no lineal del cuadrotor mediante una red neuronal convolucional (CNN) que utiliza datos de la caja negra del cuadricóptero, la cual se centra en mejorar la adaptabilidad y eficiencia de estos drones en entornos dinámicos y no estructurados. Este trabajo se orienta hacia la identificación de variables significativas que afectan la operación del dron, la optimización de los datos para el entrenamiento de modelos de aprendizaje profundo y el diseño de un modelo predictivo preciso. Se plantean pruebas rigurosas para validar la eficacia del modelo en diferentes escenarios de operación, interpretando los resultados para su aplicabilidad en el control autónomo de drones.

Este enfoque busca contribuir significativamente al campo del control de vehículos aéreos no tripulados, ofreciendo un modelo capaz de manejar complejidades reales y proporcionar un rendimiento mejorado en aplicaciones prácticas. La integración del aprendizaje profundo y específicamente las CNN en la robótica aérea representa un cambio de paradigma en cómo

los drones son diseñados, programados y desplegados, mejorando no solo la eficiencia y precisión, sino también abriendo puertas a nuevas posibilidades de interacción y servicio en una variedad de sectores.

Este artículo se centra en la fase inicial, exclusivamente en extraer y comprender las variables ocultas dentro de la “caja negra” que juegan un papel crucial en el modelado matemático de la dinámica de un cuadrotor. Este enfoque es esencial, ya que proporciona una base sólida para la identificación precisa de los factores que impactan significativamente el comportamiento de vuelo y la estabilidad del cuadrotor, facilitando así la creación de modelos más precisos y fiables.

El artículo está estructurado de la siguiente manera: tras esta introducción, se presenta una revisión de trabajos relacionados, destacando avances previos y áreas de oportunidad. A continuación, se detalla el marco teórico que sustenta la investigación, seguido de una descripción de la metodología propuesta, incluyendo diseño experimental, implementación de modelos y análisis de resultados. Finalmente, se discuten las conclusiones del estudio, su impacto potencial en el campo de los drones multirotor, y se dan recomendaciones para investigaciones futuras.

Trabajos relacionados

El modelado matemático de cuadricópteros es fundamental para el desarrollo de sistemas UAV. Tradicionalmente, se han utilizado principios dinámicos para formular ecuaciones que describen el movimiento y la estabilidad de estos robots aéreos. Sin embargo, surgen desafíos debido a las características inherentes de los UAV y las limitaciones de técnicas como la parametrización del ángulo de Euler, que puede conducir a singularidades (Ayyad et al., 2020).

Por otro lado, investigaciones recientes han explorado varias técnicas de control para cuadricópteros, incluido el control de modo deslizante, el control de retroceso y la linealización de retroalimentación (Eltayeb et al., 2022; Nguyen et al., 2021). Estos estudios se han centrado en mejorar el control de actitud y altitud de los cuadricópteros para mejorar su rendimiento y robustez en diferentes escenarios operativos. Además, se han propuesto avances en los métodos de detección de fallas basados

en señales de vibración de la estructura de aeronaves para identificar de manera efectiva fallas en las palas de los cuadrotores, lo que muestra un rendimiento mejorado en comparación con los modelos tradicionales (Zhang et al., 2021).

Además, se ha investigado el uso de redes neuronales para el control adaptativo y el seguimiento de trayectorias en cuadricópteros, lo que demuestra el potencial para mejorar la estabilidad y la maniobrabilidad (Ccarí y Yanyachi, 2023; Gotov et al., 2022). Otros estudios también han destacado la importancia del modelado no lineal que considera las interacciones aerodinámicas para comprender mejor el impacto de los factores externos en la dinámica del cuadricóptero (Ye et al., 2021). Asimismo, la aplicación de control predictivo de modelos y controladores óptimos ha mostrado resultados prometedores en el seguimiento de trayectorias y el rechazo de perturbaciones, lo que contribuye a mejorar el rendimiento en entornos desafiantes (González-Hernández et al., 2022; Zhenhuan et al., 2021).

Si bien, se han logrado avances en las estrategias de control y técnicas de modelado, todavía hay áreas que requieren mayor exploración. Por ejemplo, la comparación de diferentes algoritmos de control como PID y redes neuronales para el control de actitud y la investigación de factores que influyen en la precisión de los levantamientos utilizando cuadricópteros en industrias específicas como la minería (Ali y Jaber, 2022; Gusev et al., 2022). Además, la investigación sobre la identificación de sistemas en tiempo real mediante el aprendizaje profundo y la implementación práctica de esquemas de control de rechazo de perturbaciones puede proporcionar información valiosa para mejorar la eficiencia y confiabilidad generales de los sistemas de cuadricópteros (Abdelmaksoud et al., 2021).

Marco teórico

En esta sección se abordan los conceptos clave y las teorías fundamentales que constituyen la base para el desarrollo de una metodología basada en aprendizaje profundo para la caracterización de dinámicas no lineales en cuadricópteros, centrándose en la elección de las variables de entrenamiento. Se inicia con una revisión de los principios básicos

de los cuadricópteros, su importancia en aplicaciones actuales y los retos asociados a su modelado preciso. A continuación, se profundiza en la exploración de metodologías para la selección de variables críticas, fundamentales para el entrenamiento efectivo de modelos de aprendizaje profundo, subrayando cómo una elección adecuada de estas variables puede influir significativamente en el rendimiento y la eficacia del modelado. Por último, se describen las características y datos de la caja negra.

Fundamentos del modelado de cuadricópteros

Un cuadricóptero, también conocido como helicóptero cuatrirrotor o cuadrotor, es un tipo de vehículo aéreo no tripulado (UAV) que opera con cuatro rotores distribuidos equitativamente alrededor de su estructura (Ho et al., 2017).

La modelación precisa de cuadricópteros es crucial para su rendimiento óptimo. La identificación del sistema para cuadricópteros implica procesos de ingeniería complejos, a menudo dependiendo del conocimiento parcial del modelo para capturar la dinámica con precisión. La modelación matemática de cuadricópteros presenta desafíos debido a su naturaleza compleja y altamente no lineal, con variables de estado que están fuertemente acopladas y son subactuadas (Rashdi et al., 2019). Esta complejidad subraya la importancia de una modelación precisa para desarrollar estrategias de control efectivas.

Modelar cuadricópteros presenta desafíos inherentes debido a su dinámica compleja, que es altamente no lineal y subactuada, lo que hace difícil lograr estabilidad y control (Esmail et al., 2022; Heidari y Saska, 2021; Shauqee et al., 2021). La no linealidad de los sistemas de cuadricópteros plantea obstáculos significativos para capturar su comportamiento de manera precisa, especialmente al considerar efectos aerodinámicos y perturbaciones externas.

Selección de variables en modelos de aprendizaje profundo

La selección de variables es un aspecto crucial en los modelos de aprendizaje profundo, impactando su rendimiento, interpretabilidad y eficiencia computacional. Seleccionar características relevantes influye significativamente en los resultados de los algoritmos de aprendizaje profundo. (Ahn et al., 2021) enfatizan la importancia de la selección de características clave en explicar cómo los modelos de aprendizaje profundo clasifican los datos, subrayando la necesidad de entender las variables que más contribuyen al proceso de toma de decisiones.

Además, (Zhan, 2022) destaca que el aprendizaje profundo puede manejar efectivamente configuraciones de alta dimensión para tareas como la selección de variables. Sin embargo, una comprensión integral de las propiedades estadísticas involucradas en este proceso es un área de investigación en curso, indicando la complejidad de la selección de variables dentro de los marcos de aprendizaje profundo y la necesidad de una mayor investigación sobre sus implicaciones estadísticas.

Los autores (Ullah Khan y Kumar, 2018) argumentan que la falta de procesos bien definidos de selección de variables en técnicas tradicionales de aprendizaje automático ha llevado a los investigadores a recurrir a redes neuronales profundas para obtener resultados de pronóstico más precisos. Esto sugiere que los modelos de aprendizaje profundo ofrecen ventajas al abordar desafíos de selección de variables que pueden existir en otros métodos de aprendizaje automático.

En el campo de la modelización de sistemas físicos, como los cuadrotros, la selección de variables es crucial para desarrollar modelos precisos y eficientes. Se han explorado diversas técnicas estadísticas y de aprendizaje automático para la selección de variables. Los métodos de aprendizaje automático ofrecen ventajas como enfoques multivariados robustos que consideran múltiples características simultáneamente sin necesidad de una selección de variables explícita (Ma et al., 2018). Estas técnicas han sido reconocidas por su efectividad en la selección de variables, especialmente en escenarios donde se necesitan modelar relaciones no lineales y heterocedásticas (Froud et al., 2021).

En el ámbito del modelado matemático de cuadrotros mediante el uso de redes neuronales, la revisión sistemática de la literatura no reveló investigaciones destacadas que abordaran específicamente la selección de variables de entrenamiento. Los estudios identificados se enfocaron primordialmente en algoritmos de control para cuadrotros utilizando redes neuronales, utilizando modelos matemáticos tradicionales. Esta observación subraya una potencial área de oportunidad para explorar cómo la selección de variables de entrenamiento puede influir en el rendimiento de los modelos de cuadrotros desarrollados con técnicas de aprendizaje profundo, señalando un camino prometedor para futuras investigaciones en este campo.

Dada la situación se plantean los métodos usados para la selección (generalmente) de variables de entrenamiento en la siguiente tabla (Tabla 1).

Tabla 1

Métodos de selección de variables de entrenamiento.

Método	Características	Aplicaciones
Correlación	Mide la relación lineal entre dos variables.	Preselección de variables para modelos predictivos.
Chi-cuadrado	Evalúa la independencia entre variables categóricas.	Clasificación y selección de características para variables categóricas.
ANOVA	Compara las medias entre grupos; basado en la varianza.	Comparar grupos y seleccionar variables con efectos significativos.
Mutual Information	Mide la cantidad de información compartida entre variables; captura relaciones lineales y no lineales.	Selección de características en clasificación y regresión.
Recursive Feature Elimination (RFE)	Utiliza un modelo externo que asigna pesos a las características (e.g., coeficientes de un modelo lineal) para eliminar sucesivamente variables hasta alcanzar el número deseado de características.	Es ampliamente utilizado en la clasificación y regresión donde la interpretación de los modelos es crucial, como en la biomedicina para la selección de biomarcadores.

Método	Características	Aplicaciones
Sequential Feature Selection (SFS)	Incluye tanto la selección secuencial hacia adelante como la eliminación secuencial hacia atrás. Comienza con un conjunto vacío de características y añade (o elimina) una característica en cada paso basándose en el criterio de desempeño hasta que se alcanza el número deseado de características.	Se utiliza en contextos donde el número de características es muy grande comparado con el número de muestras, como en la genética y el procesamiento de imágenes.
Genetic Algorithms (GA)	Simula el proceso de evolución natural para seleccionar las mejores características basándose en una función de aptitud, utilizando operadores genéticos como la mutación y la cruz.	Aplicado en problemas complejos de clasificación y regresión donde las relaciones entre las variables no son lineales o son desconocidas, como en la optimización de redes neuronales.
LASSO (Least Absolute Shrinkage and Selection Operator)	Añade una penalización L1 al modelo, lo que puede reducir algunos coeficientes de las variables a cero, eliminando así esas variables del modelo.	Se usa en regresión donde el número de predictores es muy superior al número de observaciones, como en genómica y otras aplicaciones biomédicas.
Ridge Regression	Incorpora una penalización L2, que reduce el tamaño de los coeficientes, pero no los lleva a cero. Es útil cuando hay variables correlacionadas.	A menudo se aplica en situaciones donde se necesita estabilidad en la estimación de los parámetros, como en finanzas y economía.
Elastic Net	Combina las penalizaciones L1 y L2, permitiendo tanto la selección de variables como el manejo de variables correlacionadas.	Útil en modelos donde hay muchas variables correlacionadas, como en la selección de características en grandes bases de datos genéticos.

Método	Características	Aplicaciones
Decision Trees (Árboles de decisión)	Los árboles de decisión realizan la selección de variables intrínsecamente al construir el árbol, eligiendo en cada nodo la variable que mejor divide el conjunto de datos.	Se aplican en clasificación y regresión en una amplia gama de campos, desde el marketing hasta la investigación médica.
Random Forest y Gradient Boosting Machines (GBM)	Estos métodos agregan múltiples modelos (árboles de decisión) y pueden medir la importancia de las características basándose en cuánto mejora la predicción del modelo al incluir una variable.	Aplicados en clasificación y regresión en áreas tan diversas como la detección de fraudes, diagnósticos médicos y predicción de demanda.
Análisis de Componentes Principales (PCA)	Transforma las variables originales en un nuevo conjunto de variables linealmente no correlacionadas llamadas componentes principales.	Utilizado ampliamente en exploración de datos, visualización, preprocesamiento para modelos de aprendizaje automático, y para eliminar la multicolinealidad.
Autoencoders	Redes neuronales utilizadas para aprender representaciones eficientes (codificaciones) de los datos de entrada, reduciendo la dimensionalidad mediante una arquitectura de codificador-decodificador.	Aplicado en la compresión de datos, reducción de ruido, y como paso previo para tareas de aprendizaje profundo más complejas.
Dropout	Reduce el sobreajuste en los modelos de aprendizaje profundo al “desactivar” aleatoriamente algunas neuronas durante la fase de entrenamiento.	Ampliamente utilizado en redes neuronales densamente conectadas (DNNs) y redes neuronales convolucionales (CNNs) para la clasificación de imágenes, detección de objetos, etc.

Método	Características	Aplicaciones
Attention Mechanisms	Permite que el modelo se concentre en partes específicas de los datos de entrada, asignando “pesos” o importancia a diferentes partes de la entrada.	Fundamental en modelos de procesamiento de lenguaje natural (NLP) como Transformers, para traducción automática, generación de texto, y análisis de sentimientos. También se aplica en el análisis de series temporales y en tareas de visión por computadora que requieren una comprensión contextual de las imágenes.

Fuente: Elaboración propia.

Datos de la caja negra en cuadricópteros

Los datos de la caja negra en el contexto de cuadricópteros se refieren a la información recopilada durante el vuelo por sensores integrados en el dispositivo. Estos datos pueden incluir una amplia gama de parámetros, como la velocidad, altitud, orientación (pitch, roll, yaw), aceleraciones, datos de los controles de mando, y más. La recopilación de estos datos es crucial para varios propósitos, incluyendo: análisis de desempeño, diagnóstico de fallos, desarrollo de algoritmos de control, entre otros.

En la era del aprendizaje profundo y el aprendizaje por refuerzo, estos datos son esenciales para entrenar modelos que pueden mejorar de manera autónoma el vuelo y la navegación del cuadricóptero, adaptándose a condiciones cambiantes y aprendiendo de experiencias previas.

En el desarrollo y optimización de cuadricópteros, especialmente aquellos configurados con firmware Betaflight, es esencial comprender los múltiples datos que la “caja negra” recopila durante el vuelo. Betaflight, siendo una de las soluciones de firmware más avanzadas para el control de vuelo en drones de carreras y freestyle, ofrece detalladas capacidades de registro de datos que permiten a los pilotos y desarrolladores analizar y afinar el rendimiento de sus aeronaves con precisión sin precedentes. A continuación, se presenta la tabla 2 que detalla las variables comúnmente

registradas por la caja negra de un cuadricóptero con firmware Betaflight, proporcionando una visión clara del significado y la importancia de cada una de estas métricas en el análisis del comportamiento y la eficiencia del vuelo. Estos datos son cruciales para la identificación de problemas, la mejora de la estabilidad y la respuesta del cuadricóptero, así como para el avance general en el diseño de sistemas de control más sofisticados y adaptativos.

Tabla 2

Variables registradas en la caja negra con Betaflight.

Variable	Significado	Variable	Significado
loopIteration	Numero de iteración	Amperage	Consumo de corriente
time	Tiempo (s)	Battery volt.	Voltaje de la batería
PID P [roll] PID P [pitch] PID P [yaw]	Ganancia del controlador PID en la parte proporcional de cada movimiento (%).	PID Feedforward [roll] PID Feedforward [pitch] PID Feedforward [yaw]	Ganancia del controlador PID en la parte retroalimentada futura de cada movimiento (%).
PID I [roll] PID I [pitch] PID I [yaw]	Ganancia del controlador PID en la parte integral de cada movimiento (%).	RC Command [roll] RC Command [pitch] RC Command [yaw] RC Command [throttle]	Comandos de los canales de la radioemisora (μ s)
PID D [roll] PID D [pitch]	Ganancia del controlador PID en la parte derivativa de cada movimiento (%).	Heading [roll] Heading [pitch] Heading [yaw]	Posición del cuadrotor en cada eje de rotación ($^{\circ}$)

Variable	Significado	Variable	Significado
Accel. [X]	Aceleración lineal	Gyro [roll]	Velocidad angular
Accel. [Y]	del cuadrotor en	Gyro [pitch]	del cuadrotor en
Accel. [Z]	cada eje (g)	Gyro [yaw]	cada eje (deg/s)
Motor [1]	Ciclo de trabajo	PID Sum [roll]	Sumatoria de tér-
Motor [2]	de cada motor del	PID Sum [pitch]	minos del PID (%)
Motor [3] Motor [4]	cuadrotor (%)	PID Sum [yaw]	
Setpoint [roll]	Valores objetivo	PID Error [roll]	Diferencia entre el
Setpoint [pitch]	de cada uno de los	PID Error [pitch]	Setpoint y la lectu-
Setpoint [yaw]	movimientos del	PID Error [yaw]	ra actual (deg/s).
Setpoint [throttle]	cuadrotor (deg/s).		

Fuente: Elaboración propia.

Metodología

La propuesta de este artículo introduce una metodología innovadora centrada en el análisis avanzado de los datos provenientes de la caja negra de un cuadricóptero, con el fin de mejorar el modelado y la comprensión de las dinámicas no lineales que caracterizan su funcionamiento. Este enfoque metodológico comienza con un meticuloso proceso de extracción de datos de la caja negra, asegurando la captura de información detallada y relevante para el estudio. A continuación, se lleva a cabo un análisis exhaustivo de las variables obtenidas, utilizando gráficas que permiten visualizar el comportamiento del sistema de control PID, los motores, el acelerómetro y giroscopio, así como los comandos emitidos por la emisora, todos en función del tiempo. Esta representación gráfica facilita la identificación de patrones y tendencias de las distintas variables involucradas. Finalmente, se construye una matriz de correlación para cuantificar y visualizar la relación entre estas variables, proporcionando una base sólida para la selección de aquellas más significativas para el entrenamiento del modelo de aprendizaje profundo. Este enfoque metodológico no solo promete mostrar detalles clave sobre el comportamiento y la dinámica de los cuadricópteros, sino que también establece un precedente para la aplicación de técnicas de aprendizaje profundo en el análisis de sistemas complejos.

Proceso de extracción de datos desde la caja negra del cuadrotor

La extracción de datos de la caja negra es un paso crítico en la metodología propuesta, permitiéndonos acceder a información valiosa sobre el comportamiento y rendimiento del cuadricóptero durante el vuelo. Utilizando el firmware Betaflight (Betaflight, s. f.), este proceso se realiza a través de los siguientes pasos:

Conexión del dron: Iniciar conectando el cuadricóptero a la computadora mediante un cable USB, asegurando una conexión física directa entre ambos dispositivos.

Apertura del configurador de Betaflight: Proceder abriendo el Configurador de Betaflight en una computadora. Esta herramienta es esencial para interactuar con la configuración del dron.

Conexión al controlador de vuelo: Una vez en el software de Betaflight, hacer clic en el botón “Connect” para establecer una conexión con el controlador de vuelo del cuadricóptero. Esto permite acceder a sus configuraciones y datos internos.

Acceso a la caja negra: Navegar por el menú lateral de Betaflight hasta encontrar y seleccionar la opción “Blackbox”. Esta sección brinda acceso a los datos de vuelo almacenados.

Descarga de datos: Dentro del menú de la caja negra, identificar opciones para descargar los datos de vuelo. Dependiendo de la configuración de su cuadricóptero, los datos podrían estar en la memoria interna del controlador de vuelo o en una tarjeta SD.

Guardar los datos: Seleccionar el registro de vuelo que desea descargar para guardar en una computadora para su análisis posterior.

Análisis de datos: Utilizar herramientas como el Blackbox Log Viewer (Betaflight/Blackbox-Log-Viewer, s. f.) para analizar los datos descargados. Esta herramienta, integrada en el Configurador de Betaflight o disponible de manera independiente, facilita la visualización y el análisis de los registros de vuelo.

Análisis de las variables obtenidas de la caja negra

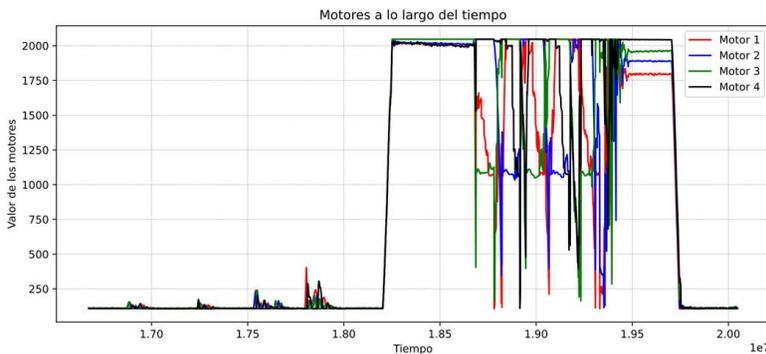
El análisis de las variables obtenidas de la caja negra constituye un aspecto fundamental en este trabajo de investigación, estableciendo la base sobre la cual se construirán las etapas sucesivas del estudio. La comprensión detallada de las variables que interactúan dentro del sistema del cuadricóptero es crucial para el modelado eficaz y la implementación de estrategias de control optimizadas (trabajo futuro). En la siguiente tabla, se examinan meticulosamente las variables de interés extraídas del archivo de la caja negra, proporcionando una visión exhaustiva de los elementos que influyen en el comportamiento dinámico del cuadricóptero. Este paso inicial no solo permite identificar las relaciones fundamentales entre las distintas variables, sino que también sienta las bases para la aplicación de técnicas de aprendizaje profundo que buscan mejorar la precisión y la adaptabilidad de los modelos desarrollados.

Una vez establecido el significado de las variables, se procede a buscar relaciones entre ellas, obtener estadísticas diferenciales e inferenciales, se optó por utilizar Python, ya que contiene librerías útiles para este fin, se analizan los datos sin procesar.

- Comportamiento de los motores en función del tiempo (vuelo ejemplo):

Figura 1.

Gráfica que describe el comportamiento de los motores en función del tiempo.



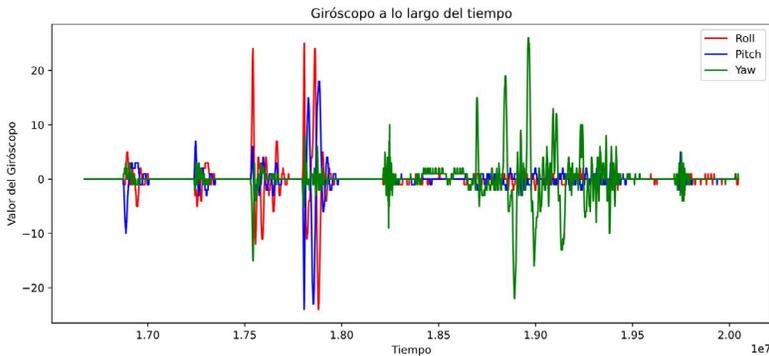
En la figura 1, cada línea representa uno de los cuatro motores del dron, mostrando cómo varía su salida a lo largo del tiempo registrado. Estos

datos son valiosos para entender cómo el dron responde a los comandos y cómo se maneja el equilibrio y la propulsión durante el vuelo.

- Comportamiento del acelerómetro y giroscopio en función del tiempo (vuelo ejemplo):

Figura 2

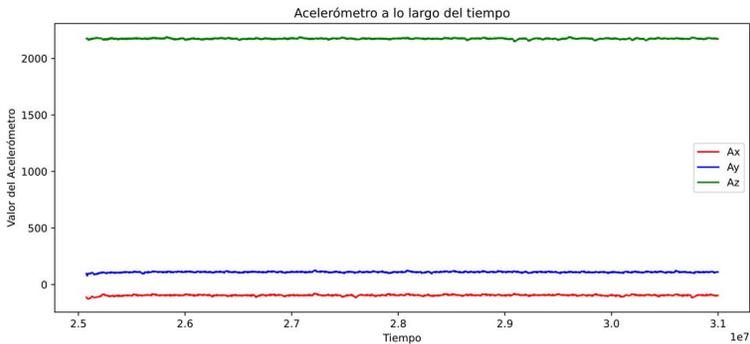
Gráfica que describe la lectura del giroscopio en función del tiempo.



La figura 2, muestra un gráfico de líneas que representa los valores de un giroscopio a lo largo del tiempo. Hay tres líneas de diferentes colores: la línea roja representa el Roll, la línea azul representa el Pitch y la línea verde representa el Yaw. En el eje x se muestra el tiempo, mientras que en el eje y se muestra el valor del giroscopio.

Figura 3

Gráfica que describe la lectura del acelerómetro en función del tiempo.



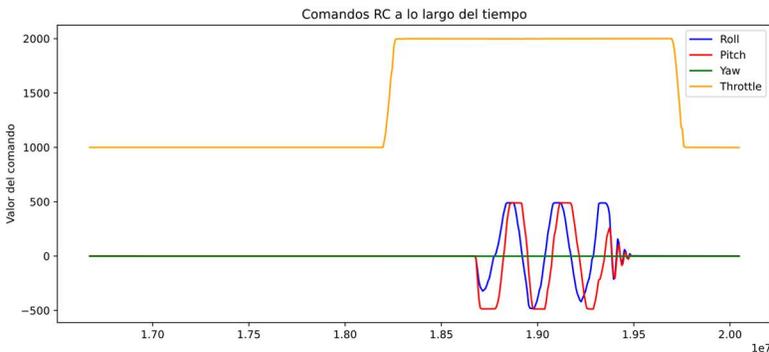
La figura 3 muestra un gráfico de líneas que representa los valores de un acelerómetro a lo largo del tiempo. Hay tres líneas de diferentes colores: la línea roja representa la aceleración en el eje X, la línea azul representa la aceleración en el eje Y, y la línea verde representa la aceleración en el eje Z. En el eje x se muestra el tiempo, mientras que en el eje y se muestra el valor del acelerómetro.

En las gráficas del acelerómetro, se observa la aceleración lineal a lo largo de los tres ejes del espacio, y en las gráficas del giroscopio, se puede ver la velocidad angular, que indica cómo de rápido gira el dron alrededor de cada eje.

Comportamiento de los comandos de la emisora en función del tiempo (vuelo ejemplo):

Figura 4

Gráfica que describe la lectura de los comandos de la radioemisora en función del tiempo.



Cada gráfica representa uno de los cuatro canales típicos de un control remoto de dron: Acelerador (Throttle), Guiñada (Yaw), Inclinación (Pitch) y Alabeo (Roll)

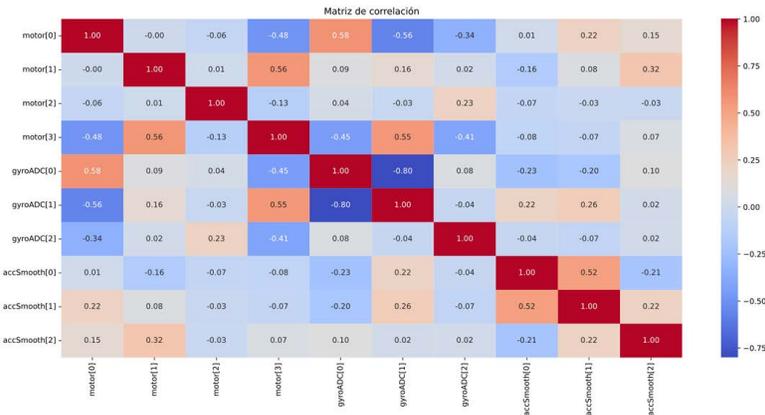
Estas gráficas son útiles para visualizar cómo el piloto ha manejado el cuadrotor durante el vuelo, mostrando los comandos de entrada para cada uno de los controles principales.

Resultados

Esta sección, se centra en la presentación y análisis de la matriz de correlación obtenida a partir de los datos recopilados de la caja negra con firmware Betaflight del cuadricóptero. La matriz de correlación es una herramienta estadística que nos permite visualizar y cuantificar la relación lineal entre las diferentes variables registradas durante el vuelo. A través de este análisis, buscamos identificar patrones significativos, posibles dependencias o independencias entre variables, y cómo estas relaciones influyen en el comportamiento y rendimiento del cuadricóptero. La interpretación de esta matriz nos proporcionará perspectivas valiosas para la toma de decisiones en cuanto a la selección de variables de entrenamiento. La comprensión de estas correlaciones es fundamental para avanzar hacia un modelo de vuelo más estable, eficiente y seguro, ajustando precisamente el firmware para alcanzar un rendimiento óptimo.

Figura 5

Matriz de correlación entre las variables interesadas.



La matriz de correlación muestra cómo cada variable se relaciona con las demás, con valores de correlación que varían de -1 a 1. Un valor de 1 indica una correlación positiva perfecta, lo que significa que a medida que una variable aumenta, la otra también lo hace de manera proporcional. Un valor de -1 indica una correlación negativa perfecta, donde una

variable disminuye a medida que la otra aumenta. Un valor cercano a 0 sugiere que no hay una relación lineal significativa entre las dos variables.

En la matriz, las celdas coloreadas representan diferentes niveles de correlación, donde los tonos más rojos indican correlaciones positivas fuertes y los tonos más azules indican correlaciones negativas fuertes. Las celdas blancas o de tonos neutros señalan correlaciones débiles o inexistentes.

Al realizar el análisis de las correlaciones, se muestra que, una de las correlaciones más destacadas es la fuerte correlación positiva entre `gyroADC[0]` y `motor[0]` con un valor de 0.58, lo que indica que a medida que los valores de `gyroADC[0]` aumentan, los valores de `motor[0]` también tienden a aumentar. De manera similar, hay una correlación positiva moderada entre `gyroADC[1]` y `motor[3]` con un valor de 0.55, sugiriendo que un aumento en `gyroADC[1]` está asociado con un aumento en `motor[3]`.

Por otro lado, se observan correlaciones negativas fuertes, como la existente entre `gyroADC[1]` y `gyroADC[0]` con un valor de -0.80. Esta relación indica que un aumento en `gyroADC[1]` está asociado con una disminución en `gyroADC[0]`. Además, `gyroADC[0]` y `motor[3]` presentan una correlación negativa moderada de -0.45, lo que sugiere que un aumento en `gyroADC[0]` está relacionado con una disminución en `motor[3]`.

Otras correlaciones moderadas incluyen la relación positiva entre `motor[1]` y `motor[3]` con un valor de 0.56, y entre `accSmooth[1]` y `accSmooth[0]` con un valor de 0.52, indicando que estas parejas de variables tienden a aumentar juntas. También hay una correlación positiva moderada entre `gyroADC[1]` y `accSmooth[1]` con un valor de 0.26.

La mayoría de las demás correlaciones son bajas, lo que indica poca o ninguna relación lineal significativa entre esas variables. Estas correlaciones pueden ser útiles para entender cómo las distintas variables de motores y sensores (giroscopios y acelerómetros) están relacionadas entre sí. Este conocimiento es particularmente relevante para ajustar modelos de control y simulación en aplicaciones como drones, donde las interacciones entre motores y sensores son cruciales para un rendimiento óptimo.

En conclusión, para entrenar el modelo, se utilizarán la lectura del acelerómetro y giroscopio como salidas, y el comportamiento de los motores como entradas.

Discusión

Las correlaciones observadas en la matriz proporcionan una comprensión más profunda de las interacciones entre los componentes del sistema de vuelo del dron, las lecturas de los sensores de movimiento (giroscopios y acelerómetros) que muestran correlaciones significativas con los comandos y motores resaltan la efectividad del sistema de control en la traducción de los movimientos deseados en acciones concretas. Sin embargo, cualquier correlación débil o inesperada debe examinarse más detalladamente, ya que podría señalar ineficiencias o latencias en la cadena de control que podrían optimizarse.

Es esencial destacar que estas correlaciones deben interpretarse con cautela. Las relaciones lineales capturadas por la matriz de correlación no siempre implican causalidad, y la presencia de correlaciones altas no necesariamente significa que haya una influencia directa. Además, las correlaciones no capturan las dinámicas no lineales o las relaciones complejas que pueden estar en juego. Por lo tanto, estos resultados deben complementarse con pruebas empíricas y análisis más detallados para justificar cualquier ajuste en el diseño o configuración del dron (se pretende realizar más experimentos).

Conclusiones

En el presente artículo se mostró el desarrollo de una metodología para la selección de variables de entrenamiento para una red neuronal que generará el modelo matemático de un cuadrotor, se mostraron artículos relacionados y relevantes, así como técnicas usadas de manera general para la selección de estas variables de entrenamiento, se optó por usar correlación para este artículo.

Analizando los resultados, se observó una alta correlación entre el comportamiento de los motores y el sensor IMU (acelerómetro y giroscopio), lo que demuestra, en esencia, que dichas variables serán seleccionadas para el entrenamiento.

Al realizar una revisión sistemática de literatura, se encontraron otras técnicas usadas en la selección de variables de entrenamiento, por lo cual,

se planteará un trabajo futuro con relación al uso de otras técnicas, donde se muestre una comparativa para el caso que se presenta en este trabajo (caja negra y BetaFlight).

Finalmente, se tiene que destacar que el objetivo de este trabajo es seleccionar las variables de entrenamiento para una red neuronal que generará el modelo matemático del cuadrotor, por consiguiente, el trabajo final que se pretende con esto es obtener dicho modelo y plantear una arquitectura y metodología para cualquier cuadrotor que use Betaflight como firmware.

Referencias

- Abdelmaksoud, S. I., Mailah, M., & Abdallah, A. M. (2021). Practical Real-Time Implementation of a Disturbance Rejection Control Scheme for a Twin-Rotor Helicopter System Using Intelligent Active Force Control. *IEEE Access*, 9, 4886–4901. <https://doi.org/10.1109/ACCESS.2020.3046728>
- Abdulkareem, A., Oguntosin, V., Popoola, O. M., & Idowu, A. A. (2022). Modeling and Nonlinear Control of a Quadcopter for Stabilization and Trajectory Tracking. *Journal of Engineering (United Kingdom)*, 2022. <https://doi.org/10.1155/2022/2449901>
- Ahn, S., Kim, J., Park, S. Y., & Cho, S. (2021). Explaining Deep Learning-Based Traffic Classification Using a Genetic Algorithm. *IEEE Access*, 9, 4738–4751. <https://doi.org/10.1109/ACCESS.2020.3048348>
- Ali, K. M., & Jaber, A. A. (2022). Comparing dynamic model and flight control of plus and cross quadcopter configurations. *FME Transactions*, 50(4), 683–692. <https://doi.org/10.5937/FME2204683M>
- Ayyad, A., Chehadeh, M., Awad, M. I., & Zweiri, Y. (2020). Real-Time System Identification Using Deep Learning for Linear Processes with Application to Unmanned Aerial Vehicles. *IEEE Access*, 8, 122539–122553. <https://doi.org/10.1109/ACCESS.2020.3006277>
- Betaflight. (s. f.). Pushing the Limits of UAV Performance. Retrieved May 28, 2024, from <https://betaflight.com/>
- Ccari, L. F. C., & Yanyachi, P. R. (2023). A Novel Neural Network-Based Robust Adaptive Formation Control for Cooperative Transport

- of a Payload Using Two Underactuated Quadcopters. *IEEE Access*, 11, 36015–36028. <https://doi.org/10.1109/ACCESS.2023.3265957>
- Cooper, Y. N., Ganesh Ram, R. K., Kalaichelvi, V., & Bhatia, V. (2014). Stabilization and Control of an Autonomous Quadcopter. *Applied Mechanics and Materials*, 666, 161-165. <https://doi.org/10.4028/WWW.SCIENTIFIC.NET/AMM.666.161>
- Duan, J., Zhou, C. G., Zhao, L. C., Jia, Y. Y., & Liu, Z. X. (2023). Finite-time control based on RBF neural network for quadrotor UAVs with varied mass load. *Journal of Physics: Conference Series*, 2612(1), 012008. <https://doi.org/10.1088/1742-6596/2612/1/012008>
- Eltayeb, A., Rahmat, M. F., Basri, M. A. M., Mohammed Eltoun, M. A., & Mahmoud, M. S. (2022). Integral Adaptive Sliding Mode Control for Quadcopter UAV Under Variable Payload and Disturbance. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2022.3203058>
- Esfandiari, M. J., Haghghi, H., & Urgessa, G. (2023). Machine Learning-based Optimum Reinforced Concrete Design for Progressive Collapse. *Electronic Journal of Structural Engineering*, 23(2), 1–8. <https://doi.org/10.56748/ejse.233642>
- Esmail, M. S., Merzban, M. H., Khalaf, A. A. M., Hamed, H. F. A., & Hussein, A. I. (2022). Attitude and Altitude Nonlinear Control Regulation of a Quadcopter Using Quaternion Representation. *IEEE Access*, 10, 5884-5894. <https://doi.org/10.1109/ACCESS.2022.3141544>
- Froud, R., Hansen, S. H., Ruud, H. K., Foss, J., Ferguson, L., & Fredriksen, P. M. (2021). Relative performance of machine learning and linear regression in predicting quality of life and academic performance of school children in Norway: Data analysis of a quasi-experimental study. *Journal of Medical Internet Research*, 23(7), e22021. <https://doi.org/10.2196/22021>
- Betaflight/blackbox-log-viewer: Interactive log viewer for flight logs recorded with blackbox. (s. f.). GitHub. Retrieved May 28, 2024, from <https://github.com/betaflight/blackbox-log-viewer>
- González-Hernández, I., Salazar, S., Lozano, R., & Ramírez-Ayala, O. (2022). Real-Time Improvement of a Trajectory-Tracking Control Based on Super-Twisting Algorithm for a Quadrotor Aircraft. *Drones*, 6(2), 36. <https://doi.org/10.3390/DRONES6020036>

- Gotov, B. E., Tserendondog, T., Choimaa, L., & Amar, B. (2022). Quadcopter Stabilization using Neural Network Model from Collected Data of PID Controller. *ICT Focus*, 1(1), 10-21. <https://doi.org/10.58873/SICT.V1I1.28>
- Gusev, V. N., Blishchenko, A. A., & Sannikova, A. P. (2022). Study of a set of factors influencing the error of surveying mine facilities using a geodesic quadcopter. *Journal of Mining Institute*, 254, 173-79. <https://doi.org/10.31897/PMI.2022.35>
- Heidari, H., & Saska, M. (2021). Trajectory Planning of Quadrotor Systems for Various Objective Functions. *Robotica*, 39(1), 137-152. <https://doi.org/10.1017/S0263574720000247>
- Ho, D., Linder, J., Hendebay, G., & Enqvist, M. (2017). Mass estimation of a quadcopter using IMU data. *International Conference on Unmanned Aircraft Systems, ICUAS 2017*, 1260–1266. <https://doi.org/10.1109/ICUAS.2017.7991417>
- Huang, X., Kroening, D., Ruan, W., Sharp, J., Sun, Y., Thamo, E., Wu, M., & Yi, X. (2020). A survey of safety and trustworthiness of deep neural networks: Verification, testing, adversarial attack and defence, and interpretability. *Computer Science Review*, 37, 100270. <https://doi.org/10.1016/J.COSREV.2020.100270>
- Jazar, R. N. (2022). Robot Dynamics. *Theory of Applied Robotics*, 609–684. https://doi.org/10.1007/978-3-030-93220-6_11
- Khaki, S., Wang, L., & Archontoulis, S. V. (2020). A CNN-RNN Framework for Crop Yield Prediction. *Frontiers in Plant Science*, 10, 492736. <https://doi.org/10.3389/FPLS.2019.01750/BIBTEX>
- Kremer, P., Sanchez-Lopez, J. L., & Voos, H. (2022). A Hybrid Modelling Approach for Aerial Manipulators. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 105(4), 1-21. <https://doi.org/10.1007/S10846-022-01640-1/METRICS>
- Lee, M. Y., Chen, B. Sen, Tsai, C. Y., & Hwang, C. L. (2021). Stochastic H_∞ Robust Decentralized Tracking Control of Large-Scale Team Formation UAV Network System with Time-Varying Delay and Packet Dropout under Interconnected Couplings and Wiener Fluctuations. *IEEE Access*, 9, 41976-41997. <https://doi.org/10.1109/ACCESS.2021.3065127>
- Li, H., He, B., Yin, Q., Mu, X., Zhang, J., Wan, J., Wang, D., & Shen, Y.

- (2019). Fuzzy Optimized MFAC Based on ADRC in AUV Heading Control. *Electronics*, 8(6), 608. <https://doi.org/10.3390/ELECTRONICS8060608>
- Li, X., Tupayachi, J., Sharmin, A., & Martinez Ferguson, M. (2023). Drone-Aided Delivery Methods, Challenge, and the Future: A Methodological Review. *Drones*, 7(3), 191. <https://doi.org/10.3390/DRO- NES7030191>
- Lopez-Pacheco, M., & Yu, W. (2022). Complex Valued Deep Neural Networks for Nonlinear System Modeling. *Neural Processing Letters*, 54(1), 559-580. <https://doi.org/10.1007/S11063-021-10644-1/ TABLES/14>
- Ma, G., Wu, H., Zhao, Z., Zou, T., & Hong, K. S. (2023). Adaptive neural network control of a non-linear two-degree-of-freedom helicopter system with prescribed performance. *IET Control Theory & Applications*, 17(13), 1789-1799. <https://doi.org/10.1049/CTH2.12379>
- Ma, H., Xu, C. F., Shen, Z., Yu, C. H., & Li, Y. M. (2018). Application of Machine Learning Techniques for Clinical Predictive Modeling: A Cross-Sectional Study on Nonalcoholic Fatty Liver Disease in China. *BioMed Research International*. <https://doi.org/10.1155/2018/4304376>
- Martinez, W. M., Borges, J. A., Rodriguez, N. J., & Hunt, S. (1995). Natural language processor with neural networks. *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 4, 3156-3161. <https://doi.org/10.1109/ICSMC.1995.538268>
- Martini, S., Sonmez, S., Rizzo, A., Stefanovic, M., Rutherford, M. J., & Valavanis, K. P. (2022). Euler-Lagrange Modeling and Control of Quadrotor UAV with Aerodynamic Compensation. *2022 International Conference on Unmanned Aircraft Systems, ICUAS 2022*, 369-377. <https://doi.org/10.1109/ICUAS54217.2022.9836215>
- Merkert, R., & Bushell, J. (2020). Managing the drone revolution: A systematic literature review into the current use of airborne drones and future strategic directions for their effective control. *Journal of Air Transport Management*, 89, 101929. <https://doi.org/10.1016/J. JAIRTRAMAN.2020.101929>
- Mizouri, W., Najjar, S., Bouabdallah, L., & Aoun, M. (2020). Dynamic Modeling of a Quadrotor UAV Prototype. *Studies in Systems, Decision and Control*, 270, 281-299. <https://doi.org/10.1007/978-981-15-1819->

5_14/COVER

- Narendra, K. S., & Parthasarathy, K. (1990). Identification and Control of Dynamical Systems Using Neural Networks. *IEEE Transactions on Neural Networks*, 1(1), 4-27. <https://doi.org/10.1109/72.80202>
- Nguyen, N. P., Mung, N. X., Thanh, H. L. N. N., Huynh, T. T., Lam, N. T., & Hong, S. K. (2021). Adaptive Sliding Mode Control for Attitude and Altitude System of a Quadcopter UAV via Neural Network. *IEEE Access*, 9, 40076-40085. <https://doi.org/10.1109/ACCESS.2021.3064883>
- Rajendra, P., & Brahmajirao, V. (2020). Modeling of dynamical systems through deep learning. *Biophysical Reviews*, 12(6), 1311. <https://doi.org/10.1007/S12551-020-00776-4>
- Rashdi, R., Ali, Z., Larik, J. R., Jamro, L. A., & Baig, U. (2019). Controller Design for the Rotational Dynamics of a Quadcopter. *Mehran University Research Journal of Engineering and Technology*, 38(2), 269–274. <https://doi.org/10.22581/MUET1982.1902.03>
- Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*, 198, 107017. <https://doi.org/10.1016/J.COMPAG.2022.107017>
- Shauqee, M. N., Rajendran, P., & Suhadis, N. M. (2021). An effective proportional-double derivative-linear quadratic regulator controller for quadcopter attitude and altitude control. *Automatika*, 62(3-4), 415–433. <https://doi.org/10.1080/00051144.2021.1981527>
- Springer, T., Eiroa-Iledo, E., Stevens, E., & Linstead, E. (2021). On-Device Deep Learning Inference for System-on-Chip (SoC) Architectures. *Electronics*, 10(6), 689. <https://doi.org/10.3390/ELECTRONICS10060689>
- Ullah Khan, R., & Kumar, R. (2018). Optimizing a Deep Learning Model in Order to Have a Robust Neural Network Topology. *International Journal of Modeling and Optimization*, 8(3), 145-149. <https://doi.org/10.7763/IJMO.2018.V8.639>
- Wenhui, Z., Hongsheng, L., Xiaoping, Y., Jiakai, H., & Mingying, H. (2018). Adaptive robust control for free-floating space robot with unknown uncertainty based on neural network. *International Journal of Advanced Robotic Systems*, 15(6). <https://doi.org/10.1177/1729881418811518/ASSET/IMAGES/LARGE/10.117>

7_1729881418811518-FIG11.JPEG

- Ye, J., Wang, J., Song, T., Wu, Z., & Tang, P. (2021). Nonlinear modeling the quadcopter considering the aerodynamic interaction. *IEEE Access*, 9, 134716–134732. <https://doi.org/10.1109/ACCESS.2021.3116676>
- Zhan, T. (2022). DL 101: Basic introduction to deep learning with its application in biomedical related fields. *Statistics in Medicine*, 41(26), 5365-5378. <https://doi.org/10.1002/SIM.9564>
- Zhang, X., Zhao, Z., Wang, Z., & Wang, X. (2021). Fault Detection and Identification Method for Quadcopter Based on Airframe Vibration Signals. *Sensors*, 21(2), 581. <https://doi.org/10.3390/S21020581>
- Zhenhuan, C. A. I., Zhang, S., & Jing, X. (2021). Model predictive controller for quadcopter trajectory tracking based on feedback linearization. *IEEE Access*, 9, 162909–162918. <https://doi.org/10.1109/ACCESS.2021.3134009>
- Zhilenkova, E., Cvetkov, P., & Epifantsev, I. (2021). Approaches to assessing the characteristics of a vehicle body based on a virtual test bench. *E3S Web of Conferences*, 258, 09077. <https://doi.org/10.1051/E3SCONF/202125809077>
- Zhou, Y., Tian, Z., & Lin, H. (2023). UAV based adaptive trajectory tracking control with input saturation and unknown time-varying disturbances. *IET Intelligent Transport Systems*, 17(4), 780-793. <https://doi.org/10.1049/ITR2.12303>

Capítulo 2

Una propuesta de alternador para vant multirotor

José Luis Cervantes González¹
Isaac Alfredo Ochoa Segundo²
Gilberto Bojórquez Delgado³

<https://doi.org/10.61728/AE24004510>



¹ Universidad Autónoma Indígena de México. Email: joseluis.cervantes81@gmail.com

² Universidad Autónoma Indígena de México. Email: profeisaacsegundo@gmail.com

³ Tecnológico Nacional de México – ITS Guasave, Sinaloa, México. Email: itsg.gbojorquez@gmail.com

Resumen

Este estudio explora la viabilidad de integrar un alternador como fuente primaria de energía en vehículos aéreos no tripulados (VANT) multirrotores, considerando que estos han ganado popularidad en diversas aplicaciones como vigilancia, cartografía y servicios de entrega, aunque su eficiencia operativa se ve limitada por la capacidad de almacenamiento de energía de las baterías de polímero de litio (Li-Po). Para abordar esta limitación, se propone el uso de un alternador que convierte la energía mecánica en eléctrica como fuente principal de energía para los VANT, ya que su potencial para generar más energía de manera eficiente y fiable que las baterías podría extender significativamente los tiempos de vuelo y mejorar el rendimiento general del VANT. Las ventajas de los alternadores sobre las baterías tradicionales incluyen una mayor generación de energía, mejor eficiencia en la conversión de energía y mayor fiabilidad, lo que se demuestra en el diseño de un sistema de energía híbrido que incorpora un motor de combustión acoplado a un alternador, además de baterías Li-Po como respaldo para asegurar un suministro continuo de energía. Los resultados experimentales evidencian la viabilidad de esta configuración, mostrando que el alternador puede proporcionar el voltaje necesario para una operación estable del VANT, lo cual promete mejorar la sostenibilidad y eficiencia de los VANT, haciéndolos adecuados para misiones más largas y reduciendo la dependencia de las baterías tradicionales. Este enfoque innovador, al compararse con las soluciones energéticas existentes en la literatura, destaca el potencial de los alternadores para revolucionar la gestión de energía en los VANT, allanando el camino hacia una aviación no tripulada más sostenible y eficiente.

Introducción

La tecnología avanza a pasos agigantados, y el surgimiento reciente de los vehículos aéreos no tripulados (VANT), forma parte de esos avances que ha revolucionado en los últimos años distintos quehaceres relacionados con la comunicación, monitoreo del espacio, seguridad ciudadana, agricultura y tráfico automotor, entre otros (Montilla Pacheco et al., 2021).

Los VANT se han vuelto cada vez más populares en los últimos años para diversas aplicaciones, como vigilancia, cartografía y servicios de entrega. Sin embargo, uno de los principales desafíos que enfrentan los VANT es el tiempo limitado de vuelo debido a la limitada capacidad de almacenamiento de energía de las baterías convencionales. Para superar este desafío, el uso de alternadores como fuentes de energía primarias ha ganado una atención significativa en la industria de los vehículos aéreos no tripulados.

Según Márquez (2018), el uso principal de los VANT está enfocado en el campo militar, en misiones de reconocimiento. Por otro lado, los VANT tienen usos muy variados, como por ejemplo, publicidad, pesca, construcción, búsqueda de personas, prevención de incendios forestales, construcción, etc.

Otro uso que se le da a los VANT es la polinización el cual no es un tema común pero Montilla Pacheco et al., (2021), nos habla sobre un uso para los VANT el cual no está muy explorado, aquí hay una ventana de oportunidad para que la tecnología ayude al sector agrícola. Cada vez hay menos insectos que puedan hacer la polinización a la escala que se requiere y aquí es donde entran los VANT.

La energía que se necesita para que un VANT pueda volar, es mediante baterías de Polímero de Litio (Li-Po), las cuales no requieren de mantenimiento, son 20 % más ligeras que otro tipo de baterías de la misma capacidad, además una gran densidad energética comúnmente en el rango de 115 a 165 Wh/kg., el rango de descarga por no usarlas es de aproximadamente 5 % por mes (Khan et al., 2021).

Un alternador es un dispositivo que convierte la energía mecánica en energía eléctrica (Real Academia Española, s. f., definición 1). Se utiliza habitualmente en vehículos para cargar la batería y alimentar el sistema

eléctrico. En los vehículos aéreos no tripulados, se puede utilizar un alternador como fuente de energía primaria generando electricidad para alimentar los motores y otros componentes eléctricos. Las ventajas de utilizar un alternador sobre baterías convencionales como fuente de energía principal en un VANT son numerosas. En primer lugar, los alternadores pueden generar más energía que las baterías, lo que significa tiempos de vuelo más prolongados. En segundo lugar, los alternadores son más eficientes que las baterías a la hora de convertir energía, lo que significa que se desperdicia menos energía. En tercer lugar, los alternadores son más fiables que las baterías, ya que no se degradan con el tiempo y la potencia de salida es constante.

Un sistema de respaldo de baterías es una fuente de energía secundaria que se utiliza cuando la fuente de energía primaria falla o no puede suministrar la energía requerida. Las ventajas de contar con un sistema de respaldo de batería en un VANT son importantes. En primer lugar, proporciona redundancia, lo que significa que el VANT puede seguir funcionando incluso si falla la fuente de energía principal. En segundo lugar, proporciona una red de seguridad, lo que significa que el VANT puede aterrizar de forma segura en caso de emergencia. Por último, proporciona flexibilidad, lo que significa que el VANT puede diseñarse para funcionar en diversas condiciones, como poca luz o viento fuerte, sin comprometer la seguridad o el rendimiento. La comparación de los sistemas de respaldo de batería con sistemas de respaldo alternativos, como las celdas de combustible, muestra que los sistemas de respaldo de batería son más confiables, eficientes y rentables.

Existen alternativas para las baterías que actualmente se siguen estudiando (Depcik et al., 2020), como mejores baterías de Iones de Litio (Li-Ion), motores de combustión interna que funcionan con hidrógeno y celdas de hidrógeno para poder aumentar la autonomía de vuelo.

Un VANT que tenga dos tipos de alimentación energética puede ser muy beneficioso para el tiempo de vuelo y que no dependa 100 % de las baterías (He et al., 2020).

Al diseñar un sistema de integración para un alternador dentro de aplicaciones del VANT, se deben considerar los requisitos de energía únicos de estos vehículos aéreos. Un diseño típico podría incorporar un motor

de combustión acoplado a un alternador que genera la corriente eléctrica necesaria. Esta configuración es fundamental ya que los VANT, al igual que sus homólogos de vehículos terrestres, requieren una fuente confiable de electricidad para diversas funciones, desde la propulsión hasta la gestión de sistemas a bordo. El alternador, en particular, desempeña un papel crucial, ya que convierte la energía mecánica del motor en energía eléctrica, asegurando que las baterías del VANT estén constantemente cargadas durante el vuelo. También es importante tener en cuenta que el alternador debe ser capaz de entregar su potencia nominal incluso a regímenes de bajas revoluciones, lo que resulta especialmente ventajoso para los vehículos aéreos no tripulados que pueden operar a velocidades variables o flotar en el lugar, imitando la naturaleza intermitente de las ciudades. Tráfico de vehículos. Esta característica es esencial para mantener la estabilidad del suministro de energía, independientemente de la velocidad operativa del VANT, garantizando así el rendimiento ininterrumpido de la misión y la confiabilidad general del sistema.

El documento está estructurado en siete apartados: el primero consiste en la presente introducción; el segundo, se ven los trabajos relacionados; el tercero, aborda el marco teórico; el cuarto, presenta la propuesta; el quinto, detalla la experimentación; y finalmente, en el sexto expone las conclusiones y referencias en las que está sustentada la investigación.

Trabajos relacionados

La investigación en VANT ha alcanzado hitos significativos, impulsando innovaciones en diversas aplicaciones desde la seguridad hasta la gestión ambiental. A pesar de estos avances, persisten retos críticos que limitan su plena integración y eficiencia. Este trabajo revisa los desarrollos recientes y examina las áreas que presentan oportunidades para innovaciones futuras, destacando la importancia de superar las limitaciones actuales para ampliar las capacidades y aplicaciones de los VANT.

Zhang et al. (2022) describe un estudio detallado sobre los sistemas híbridos de suministro de energía electroquímica y las estrategias de gestión de energía inteligente para vehículos aéreos no tripulados (VANT) en servicios públicos. Cubre clasificaciones y aplicaciones de VANT,

sistemas de suministro de energía como células de combustible, baterías y células solares, y aborda estrategias de gestión energética inteligente, incluyendo control basado en reglas, gestión optimizada y aprendizaje automático. El documento también discute la importancia de seleccionar una estructura híbrida adecuada para la operación eficiente de los VANT y proporciona perspectivas sobre el futuro de estos sistemas.

El desarrollo de sistemas de energía para vehículos aéreos no tripulados es un desafío importante que debe abordarse. Uno de los principales desafíos es la necesidad de vuelos prolongados a largas distancias. Esto requiere el uso de sistemas de energía eficientes y confiables que puedan sostener el tiempo de vuelo del VANT. El uso de fuentes de energía renovables como la solar o la eólica es una posible solución para ampliar el tiempo de misión. Sin embargo, la tecnología detrás de los sistemas de recolección y almacenamiento de energía de los VANT está en constante evolución. Se espera que las tecnologías emergentes, como las pilas de combustible de hidrógeno y los sistemas eléctricos híbridos, mejoren la potencia y la fiabilidad de los drones en el futuro. A pesar de las tecnologías prometedoras, el desarrollo de sistemas de energía para vehículos aéreos no tripulados sigue siendo un desafío importante que requiere esfuerzos continuos de investigación y desarrollo.

De Wagter et al. (2021) detallan el desarrollo y las pruebas de un VANT híbrido alimentado por hidrógeno, diseñado para despegue y aterrizaje vertical (VTOL) y vuelo eficiente en modo avión. Destaca la selección e integración de sistemas de hidrógeno, incluyendo celdas de combustible y almacenamiento, y enfatiza en la seguridad y eficiencia energética. Se presenta el diseño del VANT, sus características aerodinámicas, electrónica y control de vuelo, y se muestra los resultados de pruebas de vuelo, incluyendo un vuelo de 3 horas y 38 minutos en condiciones marítimas. Además, se discuten los desafíos y ventajas del uso de hidrógeno como fuente de energía en VANT.

Apeland et al. (2021) abordan un análisis de sensibilidad de los parámetros de diseño en drones multirrotor alimentados por pilas de combustible. El estudio se centra en cómo diversos factores, como la configuración del sistema de propulsión, la masa y la energía específica, influyen en el rendimiento de los drones. También se discuten las implicaciones de las

mejoras en las baterías, la presión de hidrógeno y el grado de hibridación en el sistema de energía. El documento proporciona orientación para el diseño óptimo de sistemas de energía en drones multirotor, considerando diferentes configuraciones y tecnologías.

Zhang et al., (2021) aborda la optimización del sistema de propulsión eléctrico para VANT híbridos. Se centra en mejorar la capacidad del VANT para resistir perturbaciones del viento en el modo quadrotor. El estudio utiliza un enfoque de optimización multidisciplinaria, integrando varios aspectos de diseño para lograr un sistema óptimo. Se modelan y analizan diferentes módulos, como el sistema de propulsión, la resistencia al viento y la eficiencia energética. El documento concluye con la validación de la metodología propuesta a través de pruebas de vuelo y comparaciones con resultados teóricos.

Marco teórico

El desarrollo de VANT se ha apoyado tradicionalmente en baterías como su principal fuente de energía, limitando su autonomía y eficiencia en aplicaciones prolongadas. Sin embargo, la creciente demanda de sistemas más sostenibles y de mayor duración ha impulsado la búsqueda de alternativas energéticas. En este contexto, el marco teórico de nuestra investigación se centra en el análisis de las tecnologías de generación de energía alternativas, con especial atención en el uso de alternadores para la alimentación de VANT. Este marco explora los principios de la generación de energía eléctrica mediante alternadores, las adaptaciones necesarias para su integración en VANT, y el impacto potencial de esta innovación en la autonomía y sostenibilidad de las operaciones aéreas no tripuladas. Al revisar las bases teóricas y los desarrollos tecnológicos relacionados, establecemos las bases para comprender cómo la integración de un alternador puede representar un avance significativo hacia el diseño de VANT más eficientes y ecológicos.

Según Zhang et al., (2021), el creciente interés en vehículos aéreos no tripulados (VANT) eléctricos se deben a su capacidad para realizar tareas difíciles o peligrosas, así como numerosos servicios públicos como monitoreo en tiempo real, cobertura inalámbrica, búsqueda y rescate, estudios

de vida silvestre y agricultura de precisión. Sin embargo, el principal desafío radica en el sistema de suministro de energía electroquímico de los VANT, especialmente en términos de densidades de energía/potencia y la durabilidad para la resistencia del servicio.

También detalla que un solo tipo de fuente de energía electroquímica es insuficiente para soportar vuelos de larga duración de los VANT, lo que hace necesaria la arquitectura de un sistema de energía híbrido. Para aprovechar las ventajas de cada tipo de fuente de energía, con el objetivo de aumentar la resistencia y lograr un buen rendimiento, se deben desarrollar sistemas híbridos que contengan dos o tres tipos de fuentes de energía (celdas de combustible, baterías, células solares y supercapacitores). La selección de una estructura de energía híbrida apropiada junto con un sistema de gestión de energía optimizado es crucial para la operación eficiente de un VANT. Se ha encontrado que los modelos impulsados por datos con inteligencia artificial (IA) son prometedores en la gestión inteligente de la energía, lo que puede proporcionar ideas y pautas para futuras investigaciones y desarrollos en el diseño y fabricación de sistemas de energía avanzados para VANT.

Se discute la importancia de la hibridación de fuentes de energía y las estrategias de gestión energética inteligente. La integración de tecnologías avanzadas y estrategias de gestión energética adaptativas promete superar las limitaciones actuales, mejorando la eficiencia del vuelo y reduciendo el consumo de combustible. La investigación futura en optimización multiobjetivo basada en aprendizaje automático se identifica como un camino prometedor para el desarrollo de sistemas de propulsión híbridos en VANT, apuntando a una mejora sustancial en la operación y la sostenibilidad de estas plataformas en aplicaciones de servicio público. Este enfoque holístico hacia la revisión de tecnologías de suministro de energía y gestión en VANT resalta la complejidad y la interdisciplinariedad del campo, subrayando la necesidad de innovación continua y adaptación a nuevos desafíos y oportunidades en el desarrollo y aplicación de VANT en el sector público.

De Wagter et al., (2021) se centra en el desarrollo y la evaluación del NederDrone, un vehículo aéreo no tripulado (VANT) híbrido impulsado por hidrógeno, diseñado para combinar las ventajas de los VANT de despegue

y aterrizaje vertical (VTOL) con las eficiencias de vuelo de alas fijas. Este VANT utiliza una combinación de celdas de combustible de membrana de intercambio de protones (PEM) alimentadas por hidrógeno para la resistencia y baterías de litio para situaciones de alta demanda de energía, almacenando el hidrógeno en un cilindro presurizado. El documento detalla el proceso de selección de concepto, los aspectos de seguridad implementados, la electrónica, el control de vuelo y presenta datos de vuelo reales, incluido un vuelo significativo sobre el mar, destacando la capacidad del VANT para despegar y aterrizar desde un barco en movimiento.

La necesidad de un sistema híbrido de suministro de energía surge de las limitaciones de las baterías actuales para satisfacer los requisitos de energía de muchas aplicaciones de VANT, especialmente aquellas que requieren capacidades VTOL. Los VANT híbridos, que combinan alas fijas eficientes con la capacidad de volar en estacionario de los vehículos de rotor, ofrecen una solución prometedora al permitir tanto el vuelo eficiente a larga distancia como la capacidad de despegar y aterrizar verticalmente en espacios confinados.

El NederDrone aprovecha las celdas de combustible PEM, que son ideales para sistemas portátiles micro debido a su tamaño compacto, peso ligero y funcionamiento a temperatura ambiente. Aunque el hidrógeno es un combustible ideal por su alta densidad energética y su combustión limpia, el almacenamiento de hidrógeno presenta desafíos significativos, especialmente en términos de peso y forma del cilindro de presión necesario para almacenarlo.

Para superar las limitaciones de potencia de las celdas de combustible y satisfacer las demandas de energía durante el vuelo estacionario y otras fases de alta demanda de energía, el NederDrone integra baterías de litio de alta capacidad. Esta integración se realiza de manera pasiva, conectando las fuentes de energía en paralelo sin la necesidad de electrónica de potencia pesada, aprovechando un enfoque que maximiza la eficiencia y la redundancia del sistema.

El control del NederDrone se basa en un enfoque de inversión dinámica no lineal incremental (INDI), que no depende en gran medida de la modelación aerodinámica y utiliza una aproximación basada en sensores para identificar las fuerzas externas actuantes sobre el vehícu-

lo. Este método de control ha demostrado ser efectivo para manejar las dinámicas complejas y las perturbaciones externas que enfrentan los VANT de tipo tail-sitter durante el vuelo, particularmente en el modo de vuelo estacionario y durante las transiciones entre vuelo estacionario y vuelo hacia adelante.

El desarrollo del NederDrone ilustra un enfoque integrado para abordar los desafíos de diseño, energía y control de los VANT híbridos, destacando el potencial de los sistemas de energía híbrida basados en hidrógeno para mejorar significativamente la resistencia y la versatilidad de los VANT en una variedad de aplicaciones.

Según Apeland et al., (2021) realiza un estudio exhaustivo sobre el uso de sistemas híbridos de células de combustible para mejorar la autonomía y el rendimiento de los drones multirrotor. Se centra en analizar cómo los diferentes parámetros de diseño afectan el rendimiento de un dron multirrotor X8 equipado con un sistema híbrido de células de combustible de 2 kW. Se destaca que, a diferencia de las baterías de iones de litio tradicionales, los sistemas híbridos de células de combustible pueden ofrecer una densidad energética significativamente mayor, lo que se traduce en tiempos de vuelo prolongados.

Se discute la necesidad de un diseño cuidadoso del sistema para maximizar las ventajas de rendimiento, dado que los drones multirrotor tienen perfiles de carga más dinámicos y demandantes en comparación con los VANT de ala fija. Además, se abordan las barreras técnicas, regulatorias y operativas para la adopción de células de combustible en drones, destacando la importancia de superar estos desafíos para mejorar la propuesta de valor de los drones alimentados por células de combustible.

La investigación incluye un análisis de sensibilidad que examina el impacto de parámetros clave del sistema, como la configuración del sistema de propulsión, la sensibilidad de la masa, la energía específica y el grado de hibridación. Se utilizan datos experimentales para desarrollar un modelo empírico de consumo de energía, lo que mejora la validez del estudio de sensibilidad. Este enfoque proporciona orientación en las etapas conceptuales tempranas y ofrece perspectivas sobre cómo se pueden mejorar y optimizar los sistemas de potencia basados en células de combustible para multirrotos.

Se presentan ejemplos de drones multirotor alimentados por células de combustible en uso y en desarrollo, destacando sus capacidades y el potencial de las células de combustible para extender la duración del vuelo y la autonomía. La discusión también abarca la importancia de considerar la eficiencia del sistema de propulsión, la sensibilidad de la masa y la energía específica en el diseño de sistemas de energía para drones, así como los desafíos y oportunidades para una mayor adopción de células de combustible en aplicaciones de drones.

Zhang et al. (2021) proporciona una investigación exhaustiva sobre la optimización del diseño multidisciplinario (MDO) de un sistema de propulsión eléctrica (EPS) para un VANT híbrido, centrándose en su capacidad para rechazar perturbaciones del viento en modo cuadricóptero. Este VANT híbrido combina los modos de propulsión cuadricóptero para el vuelo vertical y ala fija para el vuelo de crucero, enfrentando desafíos únicos debido a la asimetría lateral y el área expuesta al viento en el modo cuadricóptero, lo que lo hace susceptible a las perturbaciones del viento cruzado. El estudio destaca la importancia de considerar la capacidad de rechazo de perturbaciones del viento en el diseño del EPS, lo que es crucial para garantizar un vuelo seguro y estable.

La metodología MDO aplicada busca optimizar el peso y la eficiencia del EPS al tiempo que mejora la capacidad de rechazo del viento, utilizando un enfoque integral que considera varios componentes del EPS, como el propulsor/rotor, el motor de corriente continua sin escobillas (BLDC), el control electrónico de velocidad (ESC) y la batería de polímero de litio (LIPO). Esta metodología aborda las limitaciones de los métodos de diseño tradicionales que suelen tratar los sistemas de propulsión cuadricóptero y ala fija de manera independiente, sin considerar la capacidad de rechazo de perturbaciones del viento, lo que puede llevar a diseños subóptimos con exceso de peso y consumo de energía.

Revela un conflicto inherente entre los objetivos de diseño del EPS, incluyendo la capacidad de rechazo de perturbaciones del viento, la masa del EPS y su eficiencia, lo que requiere un equilibrio cuidadoso y compromisos entre diferentes actuaciones. Utiliza un procedimiento de optimización multiobjetivo para identificar un conjunto de soluciones

óptimas de Pareto, de las cuales se seleccionan configuraciones específicas basadas en requisitos de aplicación práctica, como la capacidad de operar de manera segura en brisas moderadas.

El estudio concluye con la validación de los resultados de optimización a través de pruebas de vuelo, demostrando que el rendimiento en vuelo del VANT está en línea con las expectativas, lo que confirma la viabilidad y razonabilidad del método MDO propuesto. Este enfoque no solo tiene implicaciones significativas para el diseño de VANT híbridos cuadricóptero-ala fija, sino que también puede ser relevante para una amplia gama de configuraciones de VANT eléctricos, ofreciendo una valiosa referencia para el diseño del EPS en otras configuraciones de VANT.

Además, anticipa investigaciones futuras para considerar la perturbación del viento turbulento tridimensional y la respuesta dinámica del EPS en el diseño, con el objetivo de mejorar aún más la capacidad de rechazo de perturbaciones del viento y optimizar el rendimiento aerodinámico del VANT bajo diversas condiciones ambientales.

Metodología

Los avances en la tecnología de vehículos aéreos no tripulados han sido impulsados por diversos métodos para la obtención de energía, que van desde el uso de celdas de hidrógeno hasta supercapacitores, cada uno con sus propias ventajas y limitaciones. Sin embargo, este estudio se propone un enfoque verdaderamente innovador al integrar un alternador como fuente primaria de energía. Esta propuesta representa un salto cualitativo en la sostenibilidad y eficiencia energética de los VANT, marcando un hito significativo en su diseño y funcionalidad.

Al utilizar la energía generada durante el vuelo, este sistema no solo promete prolongar de manera considerable la autonomía de los VANT, sino también mejorar su capacidad de carga y su tiempo de operación de forma sin precedentes. Esta innovación abre un abanico de nuevas posibilidades para aplicaciones en misiones de larga duración, como el monitoreo ambiental y la vigilancia, al tiempo que reduce drásticamente la dependencia de las baterías tradicionales y minimiza el impacto ambiental negativo asociado con su uso.

Este proyecto no solo busca avanzar en el ámbito de la aviación no tripulada, sino también establecer un nuevo referente para el diseño y la operación de VANT en el futuro.

Esta investigación representa un avance tecnológico de gran importancia y marca un paso significativo hacia un futuro más sostenible y eficiente en términos energéticos para la aviación no tripulada.

Al diseñar un sistema de integración para un alternador dentro de aplicaciones del VANT, se deben considerar los requisitos de energía únicos de estos vehículos aéreos. Un diseño típico podría incorporar un motor de combustión acoplado a un alternador que genera la corriente eléctrica necesaria. Esta configuración es fundamental ya que los VANT, al igual que sus homólogos de vehículos terrestres, requieren una fuente confiable de electricidad para diversas funciones, desde la propulsión hasta la gestión de sistemas a bordo. El alternador, en particular, desempeña un papel crucial, ya que convierte la energía mecánica del motor en energía eléctrica, asegurando que las baterías del VANT estén constantemente cargadas durante el vuelo. También es importante tener en cuenta que el alternador debe ser capaz de entregar su potencia nominal incluso a regímenes de bajas revoluciones, lo que resulta especialmente ventajoso para los vehículos aéreos no tripulados que pueden operar a velocidades variables o flotar en el lugar, imitando la naturaleza intermitente de las ciudades. Esta característica es esencial para mantener la estabilidad del suministro de energía, independientemente de la velocidad operativa del VANT, garantizando así el rendimiento ininterrumpido de la misión y la confiabilidad general del sistema.

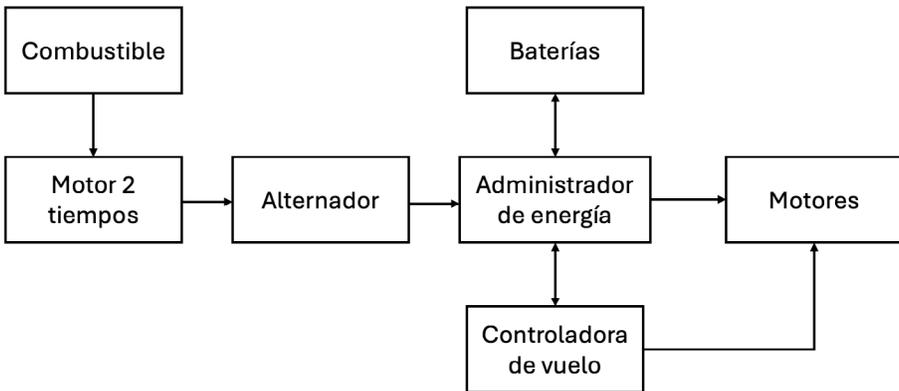
En la gestión de energía dentro de los VANT las baterías desempeñan un papel fundamental como respaldo del alternador, asegurando un suministro constante de energía en diversos escenarios operativos. Por ejemplo, el alternador, tiene la tarea de generar la corriente eléctrica necesaria para el funcionamiento del vehículo. Esta corriente eléctrica se produce de manera eficiente a bajas revoluciones por minuto (RPM), lo que la convierte en una opción adecuada para vehículos aéreos no tripulados que pueden operar a velocidades variables o en condiciones en las que las revoluciones por minuto del motor pueden no ser consistentemente altas. Sin embargo, en situaciones en las que la salida

del alternador puede fallar o cuando se requiere energía adicional, las baterías del VANT son a prueba de fallas e intervienen para mantener el suministro de energía sin interrupciones. Este cambio continuo a la energía de la batería es fundamental, particularmente durante misiones prolongadas o en caso de un mal funcionamiento del alternador, lo que garantiza que no se comprometan las capacidades operativas del VANT. Por lo tanto, el papel de la batería como respaldo no es solo una función auxiliar sino un aspecto central de la resistencia y confiabilidad de un VANT en diversas condiciones de vuelo.

En la figura 1 se describe el funcionamiento completo del sistema de alimentación de energía para un VANT utilizando un alternador como fuente primaria de energía, el combustible es nitrometano, este combustible es el ideal para el motor de 2 tiempos, este a su vez mueve el alternador generando así la energía necesaria para todo el sistema.

Figura 1

Diagrama del alternador implementado en un VANT.



A continuación se detalla el funcionamiento de cada bloque:

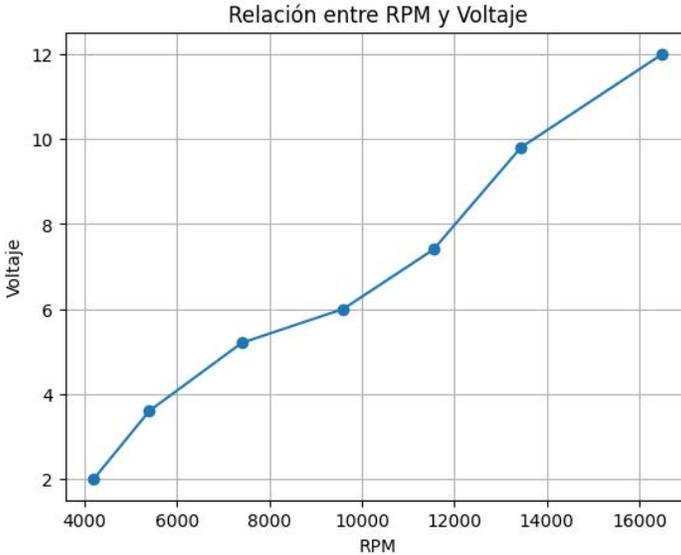
- **Combustible:** Nitrometano 20 %, aceite 14 %, también conocido como “Nitro” es una mezcla de 3 componentes:
 - **Metanol:** Libera más energía que la gasolina por libra, es muy fácil de encender con una bujía incandescente.
 - **Nitrometano:** Ayuda a aumentar la potencia, el resultado es más caballos de fuerza y revoluciones más altas.

- **Aceite:** Se mezcla con el combustible al 14 % para lubricar el motor.
- **Motor 2 tiempos:** Motor HSP 02060 VX 18, 2.74 cc, RC 1/10, el cual será el encargado de hacer girar el alternador, es pequeño y muy eficiente.
- **Alternador:** Motor sin escobillas Turnigy G46, el cual es capaz de generar la energía necesaria para todo el sistema eléctrico del VANT.
- **Baterías:** El VANT requiere una batería Li-po de 4 a 6 celdas (4S-6S) a 5000mAh, la cual será utilizada como respaldo en caso de que el alternador se detenga por alguna falla inesperada.
- **Administrador de energía:** Este es el sistema que convierte la corriente alterna (AC) a corriente directa (DC) para la alimentación del VANT, también se encarga de hacer el cambio de manera autónoma de funcionamiento con alternador a baterías.
- **Controladora de vuelo:** Es donde se encuentra el centro neurálgico del VANT y se encarga de entregar los pulsos necesarios a los motores del VANT.
- **Motores:** Son lo que impulsan al VANT.

En la figura 2 podemos apreciar el voltaje generado en relación a las revoluciones del alternador, el VANT requiere al menos 12 V para tener un vuelo estable, las RPM (revoluciones por minuto) fueron medidas con un tacómetro.

Figura 2

Voltaje generado por el alternador.



Resultados

Los resultados de esta investigación demuestran la viabilidad de integrar un alternador como fuente primaria de energía en VANT multirroto, evidenciando que el sistema propuesto, compuesto por un motor de combustión interna acoplado a un alternador, es capaz de generar y mantener un suministro constante de energía eléctrica suficiente para un vuelo estable. Durante las pruebas, el alternador mantuvo consistentemente una salida de 12 V bajo carga, superando en eficiencia energética a las baterías tradicionales y permitiendo tiempos de vuelo más largos. Además, el alternador mostró ser capaz de entregar su potencia nominal incluso a bajas RPM, asegurando la estabilidad del VANT en diversas condiciones operativas. A diferencia de las baterías Li-Po, que tienden a degradarse con el tiempo, el alternador mantuvo una salida de potencia constante, lo que sugiere un menor requerimiento de mantenimiento y mayor longevidad del sistema. La inclusión de baterías como respaldo añadió una capa adicional de seguridad, garantizando la operación continua del VANT en caso de fallo del alternador o en situaciones de alta

demanda energética, lo que valida la propuesta de esta investigación y abre nuevas posibilidades para su aplicación en misiones más exigentes y de mayor duración.

Discusión

El análisis de los resultados obtenidos con la implementación de un alternador como fuente primaria de energía en VANT multirotor revela ventajas significativas respecto a las tecnologías tradicionales basadas en baterías de polímero de litio (Li-Po). Estos resultados son consistentes con los hallazgos de Zhang et al., (2022) quien destaca la necesidad de sistemas híbridos de suministro de energía para mejorar la eficiencia y la duración del vuelo de los VANT. La propuesta de un sistema que integra un alternador con baterías de respaldo responde a esta necesidad, proporcionando una solución que permite una generación continua de energía, lo cual es crucial para misiones prolongadas y exigentes. Por otro lado, estudios como el de Wagter et al., (2021) y Apeland et al., (2021) enfatizan la importancia de contar con fuentes de energía redundantes para maximizar la autonomía y fiabilidad de los VANT. En este sentido, la combinación de un alternador con un sistema de baterías de respaldo ofrece una respuesta eficiente a los desafíos identificados en dichas investigaciones. A pesar de que existen tecnologías emergentes, como las celdas de hidrógeno Depcik et al., (2020) y He et al., (2020), que también buscan mejorar la autonomía y eficiencia, el alternador propuesto en este estudio presenta una solución intermedia más fácilmente integrable con la tecnología actual, lo que podría facilitar su adopción en el corto plazo. Además, la implementación de un administrador de energía que optimiza la conversión de corriente y la transición entre fuentes de energía, como sugiere Zhang et al. (2022), asegura un rendimiento óptimo y continuo del sistema, alineándose con las estrategias de gestión energética inteligente recomendadas en la literatura reciente.

Conclusión

La integración de un alternador como fuente primaria de energía en los VANT multirotor se demuestra como una solución viable y prometedora para superar las limitaciones actuales de las baterías de polímero de litio

(Li-Po). Este enfoque no solo extiende significativamente el tiempo de vuelo de los VANT, sino que también mejora la eficiencia energética y la fiabilidad operativa, al proporcionar una fuente de energía constante que no se degrada con el tiempo. Los resultados experimentales indican que el alternador puede generar la energía necesaria de manera más eficiente y confiable, lo cual posiciona esta tecnología como una opción viable para su implementación en misiones que requieren una alta autonomía y fiabilidad. En resumen, la propuesta desarrollada en este estudio ofrece una solución innovadora que contribuye al avance de la tecnología de VANT hacia sistemas más sostenibles y eficientes, adaptándose a las demandas actuales y futuras de la aviación no tripulada.

Estas modificaciones permiten que el artículo cumpla con la observación recibida, separando claramente la discusión comparativa de la literatura de las conclusiones específicas de los resultados obtenidos en el estudio.

Trabajo futuro

El trabajo futuro para la investigación sobre el uso de alternadores como fuente primaria de energía en VANT se centrará en varias áreas clave para mejorar la eficiencia, fiabilidad y sostenibilidad de esta tecnología. En primer lugar, se investigará la optimización del diseño del alternador, desarrollando dispositivos más eficientes y ligeros específicamente diseñados para aplicaciones en VANT. Se estudiará la integración de materiales avanzados que puedan mejorar la eficiencia energética y reducir el peso del alternador.

La gestión inteligente de energía es otra área crucial para el futuro de esta investigación. Se desarrollarán sistemas avanzados de gestión de energía utilizando inteligencia artificial y aprendizaje automático, lo que permitirá optimizar la distribución y el uso de la energía en tiempo real. Esto contribuirá a maximizar la autonomía y eficiencia del VANT durante el vuelo.

Para validar la viabilidad y eficiencia del sistema de alternador, se realizarán pruebas extensivas en escenarios de vuelo reales y misiones específicas. La recopilación y análisis de datos de estas pruebas proporcionará información valiosa para mejorar el diseño y funcionamiento del sistema.

Por último, se investigarán las normativas y regulaciones aplicables al uso de alternadores en VANT. Trabajar en el desarrollo de estándares industriales para su implementación segura y eficiente será esencial. Colaborar con organismos reguladores y la industria asegurará el cumplimiento de las normativas y promoverá la adopción de esta tecnología.

Estas áreas de trabajo futuro no solo ayudarán a mejorar la eficiencia y fiabilidad de los VANT, sino que también contribuirán al desarrollo de soluciones energéticas más sostenibles y avanzadas en la aviación no tripulada.

Referencias

- Diccionario de la lengua española RAE - ASALE. (s. f.). Alternador
Recuperado el 12 de agosto de 2024, de <https://dle.rae.es/alternador>
- Apeland, J., Pavlou, D. G., & Hemmingsen, T. (2021). Sensitivity Study of Design Parameters for a Fuel Cell Powered Multirotor Drone. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 102(1). <https://doi.org/10.1007/s10846-021-01363-9>
- De Wagter, C., Remes, B., Smeur, E., van Tienen, F., Ruijsink, R., van Hecke, K., & van der Horst, E. (2021). The NederDrone: A hybrid lift, hybrid energy hydrogen UAV. *International Journal of Hydrogen Energy*, 46(29), 16003–16018. <https://doi.org/10.1016/j.ijhydene.2021.02.053>
- Depcik, C., Cassady, T., Collicott, B., Burugupally, S. P., Li, X., Alam, S. S., Arandia, J. R., & Hobeck, J. (2020). Comparison of lithium ion Batteries, hydrogen fueled combustion Engines, and a hydrogen fuel cell in powering a small Unmanned Aerial Vehicle. *Energy Conversion and Management*, 207. <https://doi.org/10.1016/j.enconman.2020.112514>
- He, C., Jia, Y., & Ma, D. (2020). Optimization and Analysis of Hybrid Electric System for Distributed Propulsion Tilt-Wing UAV. *IEEE Access*, 8, 224654–224667. <https://doi.org/10.1109/ACCESS.2020.3044449>
- Khan, M. A., Khan, A., Ahmad, M., Saleem, S., Aziz, M. S., Hussain, S., & Khan, F. M. (2021). A Study on Flight Time Enhancement of Unmanned Aerial Vehicles (UAVs) Using Supercapacitor-Based Hy-

- brid Electric Propulsion System (HEPS). *Arabian Journal for Science and Engineering*, 46(2), 1179–1198. <https://doi.org/10.1007/s13369-020-04941-5>
- Márquez Díaz, J. E. (2018). Seguridad metropolitana mediante el uso coordinado de Drones. *Revista Ingenierías USBMed*, 9(1), 39-48. (Ejemplar dedicado a: Ingenierías USBMed). <https://doi.org/10.21500/20275846.3299>
- Montilla-Pacheco, A. de J., Pacheco-Gil, H. A., Pastrán-Calles, F. R., Rodríguez-Pincay, I. R., Montilla-Pacheco, A. de J., Pacheco-Gil, H. A., Pastrán-Calles, F. R., & Rodríguez-Pincay, I. R. (2021). Polinización con drones: ¿Una respuesta acertada ante la disminución de polinizadores entomófilos? *Scientia Agropecuaria*, 12(4), 509-516. <https://doi.org/10.17268/SCI.AGROPECU.2021.055>
- Zhang, C., Qiu, Y., Chen, J., Li, Y., Liu, Z., Liu, Y., Zhang, J., & Hwa, C. S. (2022). A comprehensive review of electrochemical hybrid power supply systems and intelligent energy managements for unmanned aerial vehicles in public services. *Energy and AI*, 9. <https://doi.org/10.1016/j.egyai.2022.100175>
- Zhang, H., Song, B., Li, F., & Xuan, J. (2021). Multidisciplinary design optimization of an electric propulsion system of a hybrid UAV considering wind disturbance rejection capability in the quadrotor mode. *Aerospace Science and Technology*, 110. <https://doi.org/10.1016/j.ast.2020.106372>

Capítulo 3

Metodología de captura de imágenes en cultivos de maíz utilizando vehículos aéreos no tripulados recreativos

*Giovanni Mora Castro*¹

*José de Jesús Valenzuela Hernández*²

*Gilberto Bojórquez Delgado*³

<https://doi.org/10.61728/AE24004527>



¹ Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: gmora0601@gmail.com

² Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: josevalenzuela_93@outlook.com

³ Instituto Tecnológico Nacional de México – ITS Guasave, Sinaloa, México.
Email: itsg.bojorquez@gmail.com

Resumen

El uso de vehículos aéreos no tripulados (VANT) equipados con cámaras RGB (del inglés Red, Green, Blue, y en español rojo, verde y azul, estamos haciendo referencia a un sistema de composición de colores basado en la adición de los colores primarios de la luz en el ambiente) ha revolucionado la agricultura de precisión, ofreciendo una metodología avanzada para el monitoreo de cultivos de maíz. Este estudio propone un procedimiento estructurado para la captura de imágenes aéreas en cultivos de maíz utilizando VANT recreativos, específicamente el DJI Mavic Mini 2. La investigación se llevó a cabo en colaboración con “Agroproductores Cadena de Sinaloa S. A. de C. V.”, monitoreando el crecimiento de maíz blanco en diversas alturas y orientaciones. Los resultados demuestran que esta metodología es adecuada y efectiva, proporcionando imágenes de alta calidad que permiten una evaluación detallada del crecimiento y la salud del cultivo. Los beneficios de esta técnica incluyen su capacidad para ofrecer una alternativa económica y accesible en comparación con sistemas de alta capacidad, sin comprometer la calidad de los datos obtenidos. Este estudio sugiere que la combinación de VANT recreativos con herramientas avanzadas de procesamiento de imágenes puede mejorar significativamente la gestión agrícola, permitiendo a los agricultores tomar decisiones informadas basadas en datos precisos y oportunos.

Introducción

En el ámbito de la innovación agrícola, el uso de vehículos aéreos no tripulados (VANT) equipados con cámaras RGB ha ganado fuerza para monitorear los cultivos de maíz. Estas tecnologías ofrecen una forma no invasiva y eficiente de recopilar datos durante la temporada de crecimiento, lo que permite a los agricultores tomar decisiones informadas sobre fertilización, riego, control de plagas y manejo de enfermedades

(Burglewski et al., 2023). La capacidad de monitorear las condiciones de los cultivos es crucial, especialmente considerando el impacto de diversos factores de estrés en la productividad de los cultivos, lo que requiere tecnologías de monitoreo avanzadas (Torres-Madronero et al., 2022).

En este estudio, proponemos una metodología innovadora para la captura de imágenes aéreas utilizando VANT recreativos, específicamente el DJI Mavic Mini 2. Esta metodología incluye la preparación minuciosa del VANT, la planificación detallada de las rutas de vuelo con el software Grid Mission Designer, y la captura de imágenes a diferentes alturas y orientaciones. Este enfoque sistemático asegura una cobertura completa y precisa del área de estudio, proporcionando datos valiosos para el análisis y la toma de decisiones en la gestión agrícola. Las imágenes obtenidas permiten identificar patrones de crecimiento y variaciones en el desarrollo del cultivo desde las etapas tempranas, facilitando intervenciones oportunas y efectivas.

Un aspecto clave del seguimiento de los cultivos de maíz es la evaluación del acame, que puede proporcionar información valiosa sobre el estado de crecimiento del cultivo. El seguimiento oportuno y preciso del alojamiento mediante tecnologías de teledetección puede ofrecer datos beneficiosos para los departamentos de agricultura, las reclamaciones de seguros y el ajuste de las políticas de producción (Qu et al., 2022). Además, la estimación del contenido de agua de las hojas de maíz mediante técnicas de aprendizaje automático y datos basados en vehículos aéreos no tripulados es esencial para desarrollar un marco de seguimiento sólido que sirva como indicador de la salud de los cultivos y la productividad general (Ndlovu et al., 2021).

La integración de diferentes tecnologías, como imágenes hiperespectrales y cámaras RGB en vehículos aéreos no tripulados, puede proporcionar datos valiosos para monitorear pastizales y áreas de cultivo. Las imágenes RGB calibradas han demostrado potencial para respaldar o incluso reemplazar las mediciones de campo hiperespectrales, facilitando las decisiones de gestión en entornos agrícolas (Lussem et al., 2017). Además, el uso de tecnología de teledetección satelital ha avanzado significativamente en el monitoreo de áreas de vegetación, ofreciendo una amplia cobertura, revisiones frecuentes y diversas resoluciones espaciales y temporales (Wei et al., 2023).

En el contexto del cultivo intercalado de maíz, los estudios han demostrado que la combinación de maíz con otros cultivos como caupí o legumbres puede mejorar la productividad, la rentabilidad y la fertilidad del suelo. Las estrategias de cultivos intercalados tienen como objetivo optimizar la utilización de recursos y mejorar el rendimiento general de los cultivos (Biruk et al., 2021; Shukla et al., 2022). Además, la inclusión de leguminosas en los sistemas de cultivo puede desempeñar un papel crucial en la restauración de la fertilidad del suelo y la mejora de la productividad de los cultivos (Shukla et al., 2022).

Las tecnologías de teledetección, como el índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) derivado de imágenes de vehículos aéreos no tripulados, han sido fundamentales para estimar el vigor y los rendimientos del maíz, particularmente en sistemas agrícolas complejos en regiones como el África subsahariana. El uso de VANT abre nuevas posibilidades para detectar remotamente el estado y el rendimiento de los cultivos, incluso en entornos agrícolas de pequeña escala (Wahab et al., 2018). Además, la integración de técnicas de fenotipado de alto rendimiento basadas en plataformas de detección remota de VANT permite la adquisición eficiente de rasgos fenotípicos dinámicos, cerrando la brecha entre el genotipado y los métodos tradicionales de perfil fenotípico de campo (Liang et al., 2019).

En conclusión, la integración de tecnologías avanzadas como vehículos aéreos no tripulados equipados con cámaras RGB, imágenes hiperespectrales y técnicas de aprendizaje automático está revolucionando el seguimiento y la gestión de los cultivos de maíz. Estas innovaciones ofrecen a los agricultores información valiosa sobre las condiciones de los cultivos, permitiéndoles tomar decisiones basadas en datos que pueden mejorar la productividad, optimizar la utilización de recursos y mejorar la sostenibilidad agrícola general.

Este artículo propone una metodología estructurada y efectiva para la captura de imágenes aéreas utilizando vehículos aéreos no tripulados recreativos, destacando su aplicabilidad y beneficios en la agricultura moderna. Busca no solo comprender su impacto actual sino también proyectar su futuro en la mejora de los procesos aBIRgrícolas, contribuyendo a una agricultura más eficiente, sostenible y productiva, alineada con las necesidades y retos del siglo XXI.

Estructura del artículo

Este artículo ha sido estructurado de la siguiente manera para facilitar la comprensión de la investigación y los avances propuestos en el campo de la agricultura de precisión. Se inicia con una “Introducción” que contextualiza el estudio dentro del panorama actual y subraya su importancia. A continuación, la sección “Trabajos relacionados” realiza una revisión crítica de la literatura existente, proporcionando el soporte académico a la investigación. El “Marco teórico”, nos adentra en las bases conceptuales que fundamentan la hipótesis y metodología. La “Propuesta” del artículo, describe con detalle el enfoque innovador que se ha adoptado, preparando el escenario para las secciones “Experimentación” y “Diseño del Experimento”, donde se explican los procedimientos metodológicos y las pruebas realizadas. Los “Resultados” son presentados de manera clara y concisa, seguidos por una “Discusión” reflexiva que busca interpretar los hallazgos en un contexto más amplio. Se finaliza el trabajo con “Conclusiones y reflexiones”, donde se describe acerca de la relevancia de los resultados y su contribución al avance de la agricultura de precisión, estableciendo posibles caminos para futuras investigaciones.

Trabajos relacionados

En esta sección, se presentan estudios previos que han abordado algunas aplicaciones de la tecnología en la agricultura de precisión y otros campos relacionados. Los trabajos destacan los avances en el procesamiento de imágenes, el uso de tecnologías de información y comunicación, el cómo se implementaron metodologías para la recolección y análisis de imágenes, el desarrollo de prototipos económicos para el monitoreo agrícola, la arquitectura para el Internet de las Cosas (IoT) en agricultura, la evaluación automatizada de daños en infraestructuras, y el uso de imágenes multiespectrales para la gestión de pasturas. Estos trabajos de estudio proporcionan un contexto valioso y relevante para la investigación que se está llevando a cabo, destacando la importancia de la tecnología en la mejora de la eficiencia y sostenibilidad en diversas aplicaciones agrícolas.

En Ponce et al. (2023), el artículo se centra en la mejora del procesamiento de imágenes agrícolas obtenidas a través de VANT, utilizando algoritmos paralelos para optimizar la segmentación de estas imágenes. La implementación se realiza en lenguajes de programación C o C++ usando la librería OpenMP (que es una biblioteca de programación en paralelo que se utiliza principalmente para sistemas de memoria compartida) en sistemas Linux con arquitecturas multicore (o arquitectura de múltiples núcleos, se refiere a un tipo de diseño de procesadores en el cual un solo chip integra dos o más núcleos de procesador independientes). Se comparan los algoritmos secuenciales tradicionales con una versión paralela para demostrar la reducción significativa en el tiempo de procesamiento. El estudio subraya la utilidad de los algoritmos paralelos en el procesamiento de imágenes agrícolas, lo cual es crucial para aplicaciones tales como la agricultura de precisión. La paralelización no solo mejora el tiempo de procesamiento, sino también optimiza el uso de los recursos computacionales, haciendo el proceso más eficiente y rápido.

Además, Orozco y Llano Ramírez (2016) ofrecen una revisión amplia sobre el uso de sistemas de información basados en tecnologías de agricultura de precisión aplicadas al cultivo de caña de azúcar. Se enfoca en cómo las tecnologías de la información y la comunicación (TIC) están siendo implementadas a lo largo del ciclo de vida de la caña de azúcar, destacando su importancia para incrementar la eficiencia del cultivo y optimizar el uso de recursos. Los autores, en su artículo, subrayan la importancia de integrar las TIC en la agricultura de precisión para mejorar la productividad y sostenibilidad de los cultivos de caña de azúcar. Además, en el estudio, se resalta la necesidad de futuras investigaciones y desarrollos en la implementación práctica del sistema propuesto.

En Ribeiro Gomes et al. (2015), el artículo presenta el desarrollo de una metodología para optimizar el proceso de adquisición y tratamiento de imágenes de alta resolución capturadas por vehículos aéreos no tripulados. La metodología que presentan se centra en la automatización de la selección de imágenes no borrosas y en la simplificación de la georreferenciación (el proceso de asignar coordenadas espaciales a datos que inicialmente no tienen una ubicación geográfica específica, permitiendo su ubicación en un mapa o en un sistema de coordenadas

geográficas), lo que reduce significativamente el tiempo y esfuerzo requerido en el proceso. La metodología, propuesta en el estudio, ofrece una mejora significativa en la eficiencia del proceso de adquisición y procesamiento de imágenes aéreas, facilitando la implementación rápida y a menor costo de la tecnología de vehículos aéreos no tripulados en la agricultura de precisión.

Por otro lado, en Gama-Moreno et al. (2022), este estudio presenta un prototipo de cámara infrarroja de bajo costo diseñado para obtener el Índice Diferencial de Vegetación Normalizado (NDVI), que es crucial en la agricultura de precisión. El prototipo permite capturar imágenes en los espectros visible e infrarrojo cercano para calcular el NDVI, que evalúa la salud y el crecimiento vegetativo a través de la reflectancia de la luz en diferentes bandas del espectro. El prototipo propuesto demuestra ser una herramienta valiosa para la agricultura de precisión, ofreciendo una solución económica y accesible para el monitoreo de la salud vegetal mediante la tecnología NDVI. Este desarrollo representa un avance significativo en la aplicación de tecnologías de bajo costo para mejorar la gestión agrícola.

Además, en Gutiérrez Arce et al. (2020), el artículo investiga la aplicación de imágenes multiespectrales (capturas fotográficas que recolectan información de múltiples bandas del espectro electromagnético) tomadas con vehículos aéreos no tripulados para estudiar las pasturas en Cajamarca, un enfoque relativamente nuevo en la región que promete aumentar la eficiencia en la gestión de pastos. El estudio se enfoca en la evaluación de raigrás (conocidas científicamente bajo el género *Lolium*, son un grupo de gramíneas muy utilizadas tanto en la agricultura como en la jardinería) y trébol para medir indicadores como biomasa, composición florística, altura de planta, tasa de crecimiento y contenido de materia seca. La utilización de imágenes multiespectrales tomadas con vehículos aéreos no tripulados se presenta como una herramienta valiosa para mejorar la gestión de pasturas en Cajamarca, proporcionando información detallada y actualizada que facilita una gestión más eficiente y sostenible.

Marco Teórico

El uso de VANT en el monitoreo agrícola ha ganado mucha atención debido a su capacidad para proporcionar información valiosa para la toma de decisiones en las prácticas agrícolas. Los VANT, también conocidos como vehículos aéreos no tripulados, ofrecen un medio para monitorear continuamente variables cruciales para la producción agrícola (Ramos Cruz et al., 2022). Al capturar imágenes agrícolas mediante VANTs y procesarlas mediante algoritmos avanzados, los agricultores pueden acceder a información vital para tomar decisiones más informadas y eficientes (Ponce et al., 2022a). La integración de la tecnología de VANT en la agricultura va más allá del seguimiento de cultivos; también desempeña un papel en la mejora de las medidas de seguridad en las zonas urbanas y en la investigación arqueológica (Bermúdez Cifuentes et al., 2021; Villar et al., 2023).

Las cámaras RGB, que capturan imágenes en tres canales de color (rojo, verde y azul), han encontrado diversas aplicaciones en tecnología. Por ejemplo, se han utilizado en VANT para obtener imágenes de alta resolución en el análisis de la vegetación a través de la percepción remota (Vega-Puga et al., 2023a). Estas cámaras segmentan las imágenes en pequeños parches llamados superpíxeles para identificar la posición y orientación de cada uno de ellos (Lorente Rubio et al., 2022). Además, en entornos como platos virtuales de televisión, las cámaras son fundamentales para capturar la escena real donde se encuentran los presentadores mientras que los ordenadores generan fondos virtuales y los chroma-keyers combinan los mundos reales y virtuales (Fernández, 2023). En el ámbito de la robótica, se ha desarrollado un sistema de navegación autónoma para robots móviles basado en cámaras RGB-D, permitiéndoles moverse en entornos desconocidos (Muñoz et al., 2022). La accesibilidad a cámaras de alta resolución a precios accesibles ha aumentado su uso en aplicaciones como la navegación autónoma en interiores (Rico-Mendoza et al., 2022). Además, las cámaras térmicas de bajo costo han demostrado ser confiables en el diagnóstico de condiciones médicas como la neuropatía periférica diabética (Rodríguez Alonso y Cabrejo Paredes, 2022).

En la agricultura de precisión, el análisis de imágenes RGB es esencial para obtener información detallada sobre los cultivos y tomar decisiones informadas. Las imágenes obtenidas con VANT proporcionan datos valiosos para actividades relacionadas con la agricultura de precisión (Ponce et al., 2022b; Vega-Puga et al., 2023b). Estas imágenes permiten monitorear el estado de los cultivos de forma automática, extrayendo la información relevante mediante herramientas de procesamiento de imágenes (Giménez-Gallego et al., 2022). En la evaluación de cultivos, las imágenes RGB se han utilizado para analizar el fenotipo de las plantas, como en el caso de la evaluación de los efectos de herbicidas en los cultivos de maíz (Ramírez-Rojas et al., 2022). Además, se ha demostrado la utilidad de las imágenes RGB y de la fluorescencia de la clorofila para evaluar los efectos de los herbicidas de manera no invasiva.

El uso de imágenes multiespectrales en la agricultura de precisión ha demostrado ser una herramienta práctica para la gestión de sistemas pastoriles, permitiendo la construcción de índices de vegetación relacionados con características productivas y fisiológicas de las plantas (Giraldo et al., 2023). Asimismo, la utilización de cámaras infrarrojas para obtener el Índice NDVI ha contribuido al desarrollo de la agricultura de precisión (Gama-Moreno et al., 2022). En la detección de enfermedades en cultivos como el Banana Bunchy Top Virus (BBTV) y *Xanthomonas Wilt of Banana* (XWB), se ha empleado el uso de imágenes RGB y modelos de detección de objetos basados en Deep Learning (Guzmán-Alvarez et al., 2022). Esto resalta la importancia de la tecnología en la identificación temprana de problemas en los cultivos.

El uso de VANT recreativos equipados con cámaras RGB para la monitorización de cultivos ha surgido como una alternativa viable en la agricultura inteligente. Estos VANT permiten la captura de imágenes aéreas de alta resolución que pueden utilizarse para monitorear el estado nutricional, fitosanitario y de estrés de los cultivos (Guevara-Bonilla et al., 2023). Además, la combinación de VANT con algoritmos de inteligencia artificial promete automatizar la recopilación y análisis de datos, lo que facilita la toma de decisiones en la gestión agrícola (Guevara-Bonilla et al., 2023). La utilización de VANT en la agricultura posibilita una monitorización continua y precisa de los cultivos a través de diversos

sensores, lo que permite identificar las necesidades de las plantas de manera eficiente (De la Riva Fernández, Pérez Cabello, et al., 2022). Estos VANT pueden equiparse con diferentes tipos de sensores como cámaras RGB, multiespectrales, hiperespectrales, térmicas o sensores lidar, lo que amplía las capacidades de recopilación de datos para la agricultura de precisión (De la Riva Fernández, Pérez Cabello et al., 2022).

En resumen, la integración de tecnologías avanzadas como VANT equipados con cámaras RGB, imágenes hiperespectrales y técnicas de aprendizaje automático está revolucionando el seguimiento y la gestión de los cultivos de maíz. Estas innovaciones ofrecen a los agricultores información valiosa sobre las condiciones de los cultivos, permitiéndoles tomar decisiones basadas en datos que pueden mejorar la productividad, optimizar la utilización de recursos y aumentar la sostenibilidad agrícola.

Metodología

Este estudio se llevó a cabo utilizando una metodología estructurada para asegurar la precisión en la recolección y análisis para la clasificación de datos aéreos de cultivos de maíz. La elección de herramientas y técnicas se fundamentó en la necesidad de obtener imágenes de alta resolución y datos precisos, que son importantes para evaluar las condiciones del cultivo. A continuación, se detalla el procedimiento y el equipo utilizado, desde la preparación del VANT hasta el análisis final de los datos capturados.

Procedimientos metodológicos detallados

Para lograr los objetivos planteados en esta investigación y garantizar la exactitud de los resultados, la investigación se desarrolló a través de seis etapas importantes, cada una de las cuales contribuye de manera integral al éxito del estudio. Estas etapas están diseñadas para maximizar la eficacia de la recopilación de datos y asegurar su relevancia y confiabilidad. A continuación, se describe cada paso en detalle, proporcionando una visión completa de las técnicas y procesos implementados.

1. Preparación del Drone

La preparación del VANT es un paso fundamental para garantizar la seguridad y eficacia de las misiones de vuelo. Este proceso implica varias verificaciones y ajustes previos al despegue, asegurando que el equipo esté en óptimas condiciones para realizar la captura de datos.

Inicialmente, se realizó una inspección y configuración del VANT para garantizar su operatividad. Esto incluyó la verificación del estado de la batería, la calibración de sensores y la instalación de la cámara con sus ajustes óptimos de resolución y estabilización.

Proceso de preparación

Inspección física: se realiza una inspección visual detallada del VANT (DJI Mavic Mini 2) para verificar que no haya daños físicos, que las hélices estén bien aseguradas y libres de defectos, y que la estructura general del VANT no presente irregularidades.

Actualización de software y firmware: se verifica que el VANT y su controlador estén actualizados con la última versión de firmware disponible. Esto es esencial para asegurar la compatibilidad con las aplicaciones de vuelo y la optimización de las funciones del VANT.

Calibración de sensores: se calibran los sensores del VANT, incluyendo el sistema de GPS (global position system, por sus siglas en inglés) y la brújula interna. Esta calibración es crucial para mejorar la precisión del vuelo y la estabilidad del VANT durante las operaciones aéreas.

Configuración de la cámara: se ajustan los parámetros de la cámara, como la exposición, el balance de blancos y la resolución. Estos ajustes se personalizan según las condiciones de luz esperadas y los objetivos específicos de la captura de imágenes. A continuación se detalla cómo se programó el VANT en este apartado.

El VANT fue un DJI Mavic Mini 2, que posee un peso de despegue inferior a 249 gramos, lo cual lo hace ideal para maniobras en campos agrícolas sin perturbar los cultivos. Las dimensiones de la aeronave en su estado desplegado son 159 mm × 203 mm × 56 mm, proporcionando una estructura compacta y manejable para el vuelo entre los surcos del maíz.

El VANT fue seleccionada por su habilidad para ascender a una velocidad máxima de 5 m/s en modo S (modo Sport, donde el VANT actúa con una mayor velocidad), lo que facilitó un rápido desplazamiento vertical para obtener las perspectivas requeridas a las alturas de 3 m, 5.7 m y 17 m. Su capacidad de resistencia al viento de 8.5-10.5 m/s permitió realizar vuelos estables incluso en condiciones de viento moderado.

El VANT está equipado con una cámara con sensor CMOS 1/2.3" capaz de capturar imágenes de 12 MP y video en resolución 4K, lo que aseguró la obtención de imágenes detalladas y de alta calidad del cultivo. La apertura de f/2.8 del objetivo permitió capturar imágenes claras, incluso en condiciones de iluminación variable durante el periodo de vuelo.

La captura de datos se programó a intervalos regulares, utilizando el modo de fotografía de intervalo de la cámara para tomar una serie de imágenes que luego serían analizadas para identificar patrones de crecimiento y salud del maíz. Los modos Quicksort del VANT, no se utilizaron ya que nuestra prioridad era la recolección sistemática de imágenes fijas en lugar de video o imágenes en movimiento.

El VANT utilizó un sistema de navegación satelital (GNSS) que incluye GPS, GLONASS y GALILEO, lo cual ofreció una precisión de vuelo excepcional necesaria para mantener la consistencia en las rutas de vuelo durante la captura de imágenes. La batería de vuelo inteligente del VANT proporcionó una duración de hasta 31 minutos (nominales), suficiente para completar cada sesión de vuelo programada sin interrupciones.

Prueba de funcionamiento: antes de cada sesión de vuelo, se realiza una breve prueba de funcionamiento para verificar la respuesta del VANT a los comandos de control y asegurar que todos los sistemas operativos funcionen correctamente.

Consideraciones de Seguridad

Durante la preparación, también se revisan las normativas de seguridad vigentes para la operación de VANT. Se establecen medidas para mitigar riesgos, incluyendo la definición de un área segura de despegue y aterrizaje y la programación de rutas de vuelo que eviten zonas pobladas o restringidas (Sct11_C, 2019).

2. Establecimiento del mapa de captura con el Programa Grid Mission Designer

Se utilizó el software Grid Mission Designer (Grid Mission Designer, s. f.) para planificar las rutas de vuelo. Se seleccionó el área de estudio en el mapa y se configuró un patrón de vuelo en cuadrícula que cubría parte del campo, asegurando que el cultivo fuera capturado desde múltiples ángulos y alturas.

Descripción de Grid Mission Designer

Grid Mission Designer (Grid Mission Designer, s. f.) es un software de planificación de vuelo utilizado para programar y automatizar la ruta de vuelo de VANT, especialmente diseñado para aplicaciones en mapeo aéreo y fotogrametría. Este programa permite a los usuarios establecer patrones de vuelo precisos sobre áreas geográficas específicas, creando una cuadrícula o patrón llamada “grid” (malla) que el VANT seguirá durante la recolección de datos. La función principal de Grid Mission Designer es garantizar que el VANT capture imágenes aéreas sistemáticas y completas de un área de interés, lo que es crucial para aplicaciones como la agricultura de precisión, el monitoreo ambiental y la planificación urbana.

Ventajas de Usar Grid Mission Designer

Usar Grid Mission Designer en proyectos de mapeo aéreo ofrece varias ventajas:

- **Automatización eficiente:** automatiza completamente el proceso de vuelo, lo que reduce el error humano y asegura la repetibilidad y consistencia en la captura de datos.
- **Optimización de recursos:** optimiza el uso del tiempo y la batería del VANT al planificar rutas que maximizan la cobertura del área mientras minimizan el tiempo de vuelo necesario.
- **Mejora en la calidad de datos:** asegura una cobertura completa y uniforme del área de estudio, lo que es fundamental para análisis detallados y la generación de modelos digitales de terreno o mapas de vegetación.

- Interfaz de usuario amigable: ofrece una interfaz sencilla que permite a los usuarios menos experimentados en pilotaje de VANT configurar misiones complejas de forma intuitiva y eficaz.

En el contexto de esta investigación, Grid Mission Designer jugó un papel crucial al permitir la planificación detallada y ejecución de vuelos sobre el campo de maíz, garantizando que cada segmento del área estudiada fuera documentado con precisión. Esto facilitó la recolección sistemática de imágenes, lo cual es esencial para la monitorización de la evolución y salud de los cultivos en estudios agronómicos.

3. Carga del Archivo a la Plataforma Flylitchi

Una vez el plan de vuelo se configuró en Grid Mission Designer, se cargó en la plataforma Flylitchi (Litchi for DJI Drones, s. f.) para su ejecución. Este paso fue crucial para sincronizar el plan de vuelo con el VANT, incluyendo los waypoints (puntos de seguimiento de ruta) y la altura específica de vuelo para cada segmento del mapa.

Flylitchi, comúnmente conocido como Litchi, es una aplicación avanzada de planificación y control de vuelo para VANT (Litchi for DJI Drones, s. f.), diseñada para mejorar la funcionalidad de vuelos autónomos y la captura de imágenes aéreas. Esta aplicación es ampliamente utilizada por operadores de VANT para ejecutar misiones preprogramadas con alta precisión, lo que es fundamental en aplicaciones de fotografía, videografía y mapeo aéreo.

Preparación del plan de vuelo: una vez que el plan de vuelo se establece en Grid Mission, se exporta como un archivo compatible con Flylitchi.

Carga del archivo: el archivo de plan de vuelo se carga en la plataforma Flylitchi a través de su interfaz web o directamente en la aplicación móvil. Este proceso implica seleccionar el archivo desde el dispositivo de almacenamiento y subirlo a la cuenta del usuario en la aplicación Flylitchi.

Sincronización con el VANT: después de la carga, el plan de vuelo se sincroniza con el VANT. Se realiza una verificación de la ruta y los waypoints para asegurar que la misión se ajuste a las especificaciones deseadas y que no existen errores en la configuración.

Configuración final: antes de ejecutar la misión, se revisan y ajustan los últimos detalles, como la altitud de vuelo, la velocidad del dron y los ajustes específicos de la cámara, para asegurar que las imágenes capturadas cumplan con los requisitos de calidad y cobertura necesarios para el estudio.

Importancia de flylitchi en la investigación

Utilizar Flylitchi facilitó la ejecución precisa y eficiente de las misiones de vuelo programadas, permitiendo la captura sistemática de datos aéreos con mínima intervención manual. Esto no solo mejoró la eficiencia operativa, sino que también garantizó la repetibilidad de las misiones, un aspecto crucial para estudios comparativos y longitudinales en el campo de la agricultura de precisión.

4. Configuración del dron

Antes del despegue, se realizaron ajustes finales en el VANT, incluyendo la configuración del rango ISO, la velocidad del obturador, y la apertura de la cámara para adaptarse a las condiciones de luz del día de vuelo. También se ajustaron los parámetros de vuelo para mantener una altitud constante y evitar obstáculos.

Descripción general

La configuración del VANT es un paso crítico que precede al vuelo, donde se ajustan específicamente los parámetros técnicos del “DJI Mavic Mini 2” para alinearse con los objetivos y requerimientos del proyecto de investigación. Este proceso asegura que las imágenes y datos capturados sean de la máxima calidad y precisión posible.

Proceso de configuración

- Ajustes de la batería: se verifica el nivel de carga de la batería para asegurar una duración suficiente que cubra el plan de vuelo sin interrupciones. Además, se realiza una inspección del estado físico de la batería para descartar cualquier problema que pueda afectar su rendimiento.

Configuración de la Cámara:

- Resolución y Calidad: se selecciona la máxima resolución disponible para la captura de imágenes, ajustando también la calidad de compresión para evitar la pérdida de detalles (mencionadas en el apartado preparación del VANT).
- Ajustes de exposición: se configura la exposición manualmente para adaptarse a las condiciones de iluminación previstas durante la misión, con ajustes específicos en ISO, velocidad de obturación y apertura, para obtener la mejor calidad de imagen (mencionadas en el apartado preparación del VANT).

Parámetros de vuelo:

- Altura y velocidad: Se programan la altura y la velocidad del vuelo en función de los requerimientos del estudio, considerando la topografía del terreno y los objetivos de la captura de imágenes.

Importancia de la configuración adecuada

- Una configuración adecuada del VANT es fundamental para garantizar que las operaciones de campo se realicen sin contratiempos y que los datos recopilados sean de alta fiabilidad y utilidad para el análisis posterior. Este proceso reduce la probabilidad de errores o datos faltantes debido a configuraciones inadecuadas, asegurando que el proyecto cumpla con sus metas científicas.

5. Realización del vuelo y captura de fotos

Selección de la muestra y colaboración con la empresa

La investigación se desarrolló en colaboración con la empresa “Agroproductores Cadena de Sinaloa S. A. de C. V.”, una compañía de producción agrícola establecida en los valles del Carrizo y Río Fuerte, específicamente en los predios Santa Rosa y Corerepe. Con el permiso y apoyo

de la empresa, se seleccionó un campo de maíz blanco para realizar el estudio, lo que permitió un acceso sin precedentes a datos de alta relevancia agronómica y operacional.

Ubicación de la investigación

El sitio específico de investigación fue seleccionado por su relevancia para la producción de maíz blanco en la región, ofreciendo una muestra representativa de las prácticas agrícolas y condiciones de crecimiento locales. Los campos de “Grupo CADENA” en Bachoco, Sinaloa, proporcionaron el entorno ideal para llevar a cabo la recolección de datos y observar la evolución del cultivo desde la siembra hasta las primeras etapas de crecimiento.

Periodo de recolección de datos

Las capturas de imágenes se realizaron a lo largo de un periodo de cinco semanas, desde la siembra de las semillas hasta la quinta semana de crecimiento del cultivo, específicamente desde el 11 de noviembre hasta el 09 de diciembre de 2023. Este rango temporal permitió monitorear las diversas etapas tempranas de desarrollo del maíz.

Tecnología de recolección de datos

Los datos se almacenaron en tarjetas microSD recomendadas por el fabricante para asegurar la integridad y seguridad de los datos. El uso de tarjetas de alta velocidad y capacidad fue crucial para capturar y transferir grandes cantidades de datos de imagen sin pérdida de calidad o corrupción de archivos.

Procedimiento de recolección de datos

Las imágenes se tomaron desde alturas de 3 m, 5.7 m, y 17 m, y en orientaciones paralela, diagonal, y perpendicular a los surcos, garantizando una amplia cobertura y diversidad de perspectivas del campo. Esta me-

todoología buscó capturar detalles variados sobre la salud y el desarrollo del cultivo en sus diferentes etapas.

6. Clasificación de las imágenes

Posterior al vuelo, las imágenes capturadas fueron descargadas y clasificadas según los parámetros de interés del estudio, como el estado de crecimiento del maíz y la presencia de posibles anomalías. Utilizamos un software de edición para organizar las imágenes por fecha y ubicación, facilitando el análisis posterior. Como se describen en la tabla posterior.

7. Consideraciones adicionales

Consideraciones técnicas y legales

Durante la recolección de datos, se tuvo en cuenta que el peso estándar de la aeronave DJI Mavic Mini 2 es de 242 gr, lo cual está por debajo del límite para muchos países que requieren registro de VANTs más pesados. Sin embargo, el peso real del VANT puede variar, y en algunos países y regiones, es necesario realizar un registro de acuerdo con la normativa local antes de operar el VANT. Además, conforme a las especificaciones más recientes obtenidas con el firmware actualizado, las actualizaciones subsiguientes podrían mejorar aún más el rendimiento del VANT, lo cual resalta la importancia de mantener el VANT actualizado para el óptimo rendimiento durante la recolección de datos.

Limitaciones por normativa local

Se respetaron todas las normativas locales pertinentes durante el estudio. Específicamente, se cumplió con las regulaciones que restringen el uso de la banda de frecuencia de 5.8 GHz en ciertos países. Por lo tanto, se utilizó la banda de frecuencia de 2.4 GHz para evitar posibles modificaciones en el rendimiento que pudieran afectar la calidad de los datos recopilados. La banda de frecuencia utilizada está sujeta a regulaciones específicas de cada país y región, y en este estudio, la operación del VANT

se adhirió estrictamente a dichas regulaciones, asegurando la compatibilidad y legalidad del proceso de recolección de datos (Sct11_C, 2019).

Consideraciones éticas

Se obtuvo el consentimiento explícito de “Grupo CADENA” para la realización de este estudio, asegurando que la recolección y uso de los datos cumplieran con todas las normativas éticas para vuelo de vants (Sct11_C, 2019) y de privacidad correspondientes que la empresa maneja.

Evaluación de la metodología y limitaciones

La eficacia de nuestra metodología será evaluada por el uso y la precisión que presenten las imágenes para que en un futuro y como continuación de nuestro proyecto sean analizadas por redes neuronales convolucionales (RNC) y con ello poder determinar las características detectadas en las imágenes del cultivo. Se contemplarán pruebas de validación y ajustes al modelo para maximizar su precisión y robustez. Entre las limitaciones de este estudio, se incluye la dependencia de las condiciones climáticas para la captura óptima de imágenes y la resolución de la cámara del VANT, que podría no ser suficiente para capturar los detalles más finos del cultivo.

Resultados

Introducción a la sección de resultados

Se utilizó un vehículo aéreo no tripulado (VANT) para capturar imágenes de cultivos de maíz blanco en el cultivo de la empresa Grupo Cadena en el poblado Bachoco, con el objetivo de monitorear, mediante el uso de imágenes aéreas, el número de plantas de maíz que germinan una vez que son sembradas en el cultivo, además de monitorear el crecimiento durante un tiempo considerado... Durante el período de toma de imágenes aéreas que fue del 11 de noviembre al 09 de diciembre del 2023, se capturaron imágenes con varias alturas y direcciones de toma de imágenes en el

cultivo claves, proporcionando una perspectiva amplia de captación de imágenes y la evolución del cultivo durante el tiempo antes mencionado.

Descripción de los datos recopilados

Se recopilaron un número considerable de imágenes aéreas mediante el uso del VANT, durante un período de cinco semanas desde la siembra de las semillas de maíz blanco, mismas que fueron en cinco fechas distintas desde el 18 de noviembre al 19 de diciembre. Las alturas de captura variaron de 3 a 17 metros, lo que permitió obtener perspectivas diversas y detalladas del estado del cultivo en cada período de captura. A continuación se presenta la Tabla 1, con el número de imágenes aéreas capturadas por fecha.

Tabla 1
Número de Imágenes por semana.

#Semana	#Imágenes	Altura de la captura	Fecha de la captura
1	16	5 m	11/Noviembre
2	511	3 m	18/Noviembre
2	1117	5 m	18/Noviembre
2	180	17 m	18/Noviembre
3	936	5 m	25/Noviembre
4	284	3 m	02/Diciembre
5	148	3 m	09/Diciembre

Presentación de imágenes de localización

Se incluye una selección de las imágenes capturadas por satélite del área donde se llevó a cabo el experimento y la captura de las imágenes aéreas hechas por el VANT. Mediante el programa Grid Mission Designer. A continuación se detallan brevemente cada una de ellas.

En la Figura 1 se muestra una imagen, capturada utilizando el software Grid Mission Designer, donde se aprecia una vista aérea general del campo de cultivo de maíz. La captura ofrece una visión completa de la disposición del terreno, la distribución de las plantas y la estructura del cultivo en su totalidad. Es fundamental para comprender el entorno en

el que se desarrolló el estudio y sirve como referencia para las imágenes más detalladas tomadas posteriormente.

La Figura 2, presenta un acercamiento de una sección específica del campo de maíz. Esta toma permite observar con mayor detalle la densidad y alineación de las hileras de maíz, proporcionando información sobre la uniformidad en la siembra y posibles variaciones en el crecimiento a nivel de parcela.

En la Figura 3 se muestra una vista aún más detallada de una sección seleccionada del cultivo. Esta imagen se utilizó para analizar áreas específicas del campo, enfocándose en el estado de crecimiento y posibles anomalías en el desarrollo de las plantas. Es útil para detectar problemas localizados y evaluar la efectividad de las prácticas agrícolas en esas áreas.

Figura 1

Vista del cultivo general.

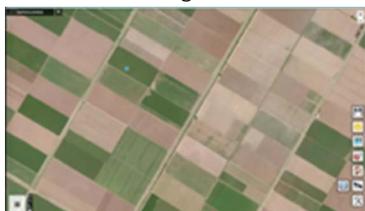


Figura 2

Vista del cultivo acercamiento.

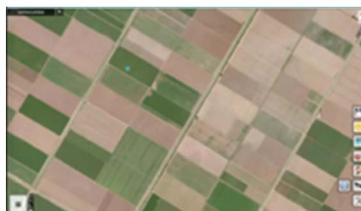


Figura 3

Vista específica del cultivo.



Imágenes capturadas con FlyLitchi (programa de mapeo autónomo)

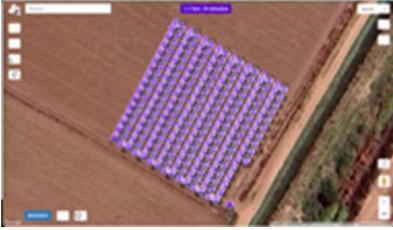
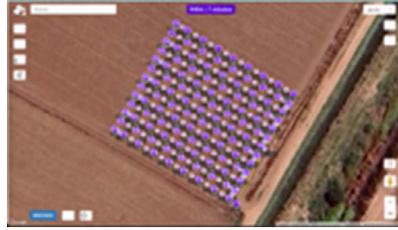
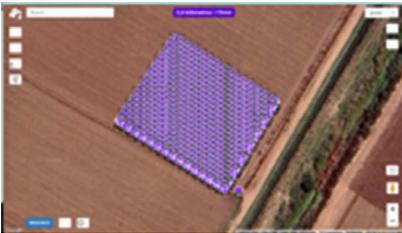
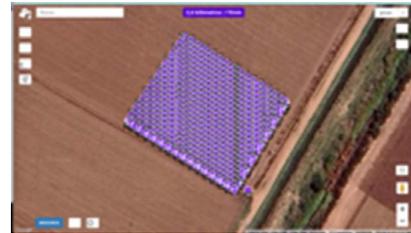
Para la captura de las imágenes en el cultivo de maíz a la par del uso de la plataforma Grid Mission Designer para complementar los vuelos autónomos en la metodología propuesta, se utilizaron las herramientas de la plataforma FlyLitchi para la captura de las imágenes aéreas a diferentes alturas. Estas imágenes fueron fundamentales para obtener una visión comprensiva del crecimiento y desarrollo del maíz a lo largo del periodo de estudio. A continuación, se presentan las imágenes obtenidas a través de esta plataforma, destacando las características específicas capturadas en cada una:

La Figura 4, fue capturada a una altura de 5 metros, esta imagen permite un análisis más cercano del estado de las plantas, mostrando detalles finos como el follaje y la cobertura del suelo. Es clave para identificar problemas de crecimiento en etapas tempranas que podrían no ser visibles desde una mayor altura.

En la Figura 5, se muestra una imagen capturada a una altura de 11 metros, utilizando la plataforma FlyLitchi. Ofrece una perspectiva intermedia del cultivo, donde se pueden apreciar tanto la disposición general de las hileras como detalles importantes del desarrollo del maíz. Es particularmente útil para evaluar la homogeneidad del crecimiento a esta altura específica.

La Figura 6, muestra una imagen tomada a 5.8 metros proporciona un equilibrio entre detalle y perspectiva general. Capturada en una fecha clave del estudio, ofrece información sobre el progreso del cultivo a nivel del suelo, ayudando a corroborar los datos obtenidos en las imágenes de otras alturas.

La Figura 7, fue capturada desde una altura de 29 metros, esta imagen ofrece una visión panorámica del campo, ideal para evaluar el estado general del cultivo en una etapa avanzada. Permite observar cómo las plantas han cubierto el terreno y cómo se ha desarrollado el cultivo en su conjunto.

Figura 4*Altura 5m - 25/noviembre.***Figura 5***Altura 11m - 25/noviembre.***Figura 6***Altura 5.8m - 02/diciembre.***Figura 7***Altura 29m - 02/diciembre.*

Imágenes capturadas con el VANT

Para un análisis detallado del desarrollo del cultivo de maíz, se realizaron capturas de imágenes aéreas utilizando un VANT. Estas imágenes, tomadas en diferentes semanas y a diversas alturas, proporcionan información crucial sobre el crecimiento y las condiciones del cultivo a lo largo del tiempo. A continuación, se describen las imágenes obtenidas por el VANT, destacando las características observadas en cada una:

La Figura 8 muestra una imagen tomada durante la primera semana de capturas a una altura de 5 metros. Muestra el estado inicial de germinación de las plantas de maíz, proporcionando una referencia para el desarrollo del cultivo en etapas posteriores. Específicamente, se observan las primeras plántulas emergiendo del suelo.

Figura 8

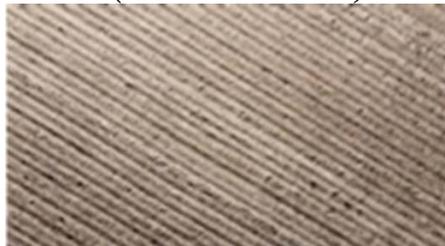
Semana 1 (5 m-11/noviembre).



En la segunda semana, se capturó esta imagen a una altura de 11.6 metros. Se puede observar un avance significativo en el crecimiento de las plantas, lo que permite evaluar la uniformidad del desarrollo y la densidad de las hileras en esta etapa temprana, esto se puede ver en la Figura 9.

Figura 9

Semana 2 (11.6 m - 18/noviembre).



La Figura 10 muestra una de las imágenes, también capturada a 11.6 metros de altura durante la tercera semana, muestra un mayor desarrollo en la altura de las plantas y una mayor cobertura del suelo. La imagen es útil para identificar áreas con crecimiento más vigoroso o donde podrían surgir problemas.

Figura 10

Semana 3 (11.6 m - 25/ noviembre).



Durante la cuarta semana, la imagen fue capturada a una altura más baja de 3 metros, permitiendo un análisis detallado del follaje y las condiciones del cultivo a nivel del suelo. Esta toma es clave para detectar posibles signos de estrés en las plantas, como deficiencias nutricionales o presencia de plagas, que podrían no ser visibles desde alturas mayores, esto se puede observar en la Figura 11.

Figura 11

Semana 4 (3m-02/diciembre).



La Figura 12, muestra una imagen de la quinta semana, capturada a 5 metros de altura, ofrece una visión general del cultivo en una etapa avanzada de crecimiento. En esta toma, se puede observar una cobertura más densa del suelo, lo que indica un desarrollo exitoso del cultivo en comparación con las semanas anteriores. Esta imagen final proporciona una referencia completa del progreso del maíz hasta el cierre del periodo de estudio.

Figura 11

Semana 4 (3m-02/diciembre).



Discusión de los resultados visuales

La revisión visual de las imágenes aéreas capturadas por el VANT proporciona una perspectiva valiosa sobre la dinámica del crecimiento de las plantas de maíz blanco. Las variaciones observadas en el crecimiento del cultivo desde los primeros días permiten establecer intervenciones tempranas y confirman la utilidad de la metodología empleada para la captura de imágenes. Estas imágenes demostraron ser una herramienta efectiva para monitorear la evolución del cultivo y tomar decisiones informadas.

Conclusiones

Este estudio ha demostrado la viabilidad y eficiencia del uso de VANT recreativos equipados con cámaras RGB para la monitorización de cultivos de maíz. Las imágenes aéreas capturadas proporcionaron datos valiosos sobre las tasas de germinación y el crecimiento temprano del maíz, permitiendo a los agricultores tomar decisiones oportunas. Los VANT recreativos como el DJI Mavic Mini 2 ofrecen una alternativa económica para el monitoreo de cultivos, aunque requieren capturar un número extenso de imágenes para seleccionar las más adecuadas, además de que se tienen que considerar algunas desventajas tales como la dependencia a las condiciones climáticas, la resolución de la cámara, la duración de la batería, así como las regulaciones de vuelo de drones. Futuras investigaciones deben enfocarse en la combinación de VANT

recreativos con herramientas avanzadas de procesamiento de imágenes para maximizar su precisión y aplicabilidad en la agricultura.

Referencias

- Bermúdez Cifuentes, A., Ramirez Lugo, P. A., Herrera Mosquera, Y. C., & Olaya Romero, W. F. (2021). Propuesta de mejoramiento de la seguridad mediante drones en la ciudad de Bogotá (Project Selantrophus). <http://ojs.urepublicana.edu.co/index.php/ingenieria/article/view/795/597>
- Biruk, G., Awoke, T., & Anteneh, T. (2021). Effect of intercropping of maize and cowpea on the yield, land productivity and profitability of components crops in Bena- Tsemay Woreda, Southern Ethiopia. *International Journal of Agricultural Research, Innovation and Technology*, 11(2), 147–150. <https://doi.org/10.3329/IJARIT.V11I2.57268>
- Burglewski, N. M., Ketterings, Q. M., Shajahan, S., & Aardt, J. van. (2023). A comparison of traditional and machine learning corn yield models using hyperspectral UAS and Landsat imagery. <https://doi.org/10.1117/12.2663715>, 12519, 80–88. <https://doi.org/10.1117/12.2663715>
- De la Riva Fernández, J., Lamelas Gracia, M. T., Montorio Llovería, R., Pérez Cabello, F., & Rodrigues Mimbbrero, M. (2022). Actas del XIX Congreso de Tecnologías de la Información Geográfica. TIG al servicio de los ODS. Zaragoza, 12 a 14 de septiembre de 2022 - Repositorio Institucional de Documentos. <https://zaguan.unizar.es/record/119771>
- De la Riva Fernández, J., Pérez Cabello, F., Lamelas Gracia, M. T., Rodrigues Mimbbrero, M. (eds.), & Montorio Llovería, R. (2022). Actas del XIX Congreso de Tecnologías de la Información Geográfica. TIG al servicio de los ODS. Zaragoza, 12 a 14 de septiembre de 2022. Actas Del XIX Congreso de Tecnologías de La Información Geográfica. TIG al Servicio de Los ODS Zaragoza, 12 a 14 de Septiembre de 2022. <https://doi.org/10.26754/UZ.978-84-18321-49-8>
- Fernández, R. M. (2023). Capítulo 2. Platós Virtuales de Televisión: arquitectura, funcionamiento y tecnologías implicadas en la creación de contenidos audiovisuales en realidad mixta en tiempo real. Espe-

- jo de Monografías de Comunicación Social, 15, 37-52. <https://doi.org/10.52495/C2.EMCS.15.C45>
- Gama-Moreno, L. A., Plazola Soltero, V. H., Murguía Vadillo, C. G., Martínez Hernández, C., & López Carrillo, E. (2022). Prototipo de Cámara Infrarroja para obtener el Índice NDVI en Agricultura de Precisión. *Programación Matemática y Software*, 14(1). <https://doi.org/10.30973/progmat/2022.14.1/2>
- Giménez-Gallego, J., González-Teruel, J. D., Toledo-Moreo, A. B., Jiménez-Buendía, M., Soto-Valles, F., & Torres-Sánchez, R. (2022). Segmentación en imagen de frutos de granado usando deep learning con aplicación en agricultura de precisión. *XLIII Jornadas de Automática: Libro de Actas: 7, 8 y 9 de Septiembre de 2022, Logroño (La Rioja)*, 1001–1006. <https://doi.org/10.17979/SPUDC.9788497498418.1001>
- Giraldo, R. A. D., De León, M. Á., Castillo, Á. R., López, O. P., Rocha, E. C., & Asprilla, W. P. (2023). Estimation of forage availability and parameters associated to the nutritional quality of *Urochloa humidicola* cv Llanero based on multispectral images. *Tropical Grasslands-Forrajes Tropicales*, 11(1), 61-74. [https://doi.org/10.17138/TGFT\(11\)61-74](https://doi.org/10.17138/TGFT(11)61-74)
- Grid Mission Designer. (n.d.). Retrieved June 3, 2024, from <https://ancient.land/>
- Guevara-Bonilla, M., Ortiz-Malavasi, E., Hernández-Cole, J., & Villalobos-Barquero, V. (2023). *Revista Colombia Forestal*. Colombia Forestal, 26(1), 123–133. <https://doi.org/10.14483/2256201X.19250>
- Gutiérrez Arce, F., Gutiérrez Arce, W., Rojas Vásquez, Z., Vallejos Fernández, L., & Álvarez García, W. (2020). Inserción de nuevas tecnologías en el estudio de indicadores productivos de la pastura, en Cajamarca. *REVISTA PERSPECTIVA*, 20(4), 383–387. <https://doi.org/10.33198/rp.v20i2.00051>
- Guzman-Alvarez, J. A., González-Zuñiga, M., Fernandez, J. A. S., & Calvo-Alvarado, J. C. (2022). Use of remote sensing in agriculture: Applications in banana crop. *Agronomía Mesoamericana*, 48279–48279. <https://doi.org/10.15517/AM.V33I3.48279>
- Rico-Mendoza, I. H., Reyna-Rodríguez, M., Morales-Díaz, B. A., Ordaz Hernández, K., & Treesatayapun, C. (2022). Navegación autónoma en interiores basada en localización visual. *Pädi Boletín Científico*

- de Ciencias Básicas e Ingenierías Del ICBI, 10(Especial5), 146–151. <https://doi.org/10.29057/ICBI.V10IESPECIAL5.10112>
- Liang, H., Yang, G., Dai, H., Yang, H., Xu, B., Feng, H., Li, Z., & Yang, X. (2019). Fuzzy clustering of maize plant-height patterns using time series of UAV remote-sensing images and variety traits. *Frontiers in Plant Science*, 10, 461398. <https://doi.org/10.3389/FPLS.2019.00926/BIBTEX>
- Litchi for DJI Drones. (s. f.). Retrieved June 3, 2024, from <https://flylitchi.com/>
- Lorente Rubio, C., Niño Martín, D., Sáenz-Díez Muro, J. C., Jiménez Macías, E., & Blanco Fernández, J. (2022). Desarrollo de escaparate virtual para tienda de moda mediante dispositivo KINECT®. XLIII Jornadas de Automática: Libro de Actas: 7, 8 y 9 de Septiembre de 2022, Logroño (La Rioja), 908–920. <https://doi.org/10.17979/SPU-DC.9788497498418.0908>
- Lussem, U., Hollberg, J., Menne, J., Schellberg, J., & Bareth, G. (2017). Using Calibrated Rgb Imagery From Low-Cost Uavs For Grassland Monitoring: Case Study At The Rengen Grassland Experiment (Rge), Germany. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2-W6(2W6), 229–233. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLII-2-W6-229-2017>
- Muñoz, S. D. V., Zannatha, J. M. I., & González-Miranda, O. (2022). Desarrollo de un sistema de navegación autónoma para un robot móvil basado en una cámara RGB-D. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías Del ICBI*, 10(Especial5), 140–145. <https://doi.org/10.29057/ICBI.V10IESPECIAL5.10142>
- Ndlovu, H. S., Odindi, J., Sibanda, M., Mutanga, O., Clulow, A., Chimonyo, V. G. P., & Mabhaudhi, T. (2021). A Comparative Estimation of Maize Leaf Water Content Using Machine Learning Techniques and Unmanned Aerial Vehicle (UAV)-Based Proximal and Remotely Sensed Data. *Remote Sensing*, 13(20), 4091. <https://doi.org/10.3390/RS13204091>
- Orozco, Ó. A., & Llano Ramírez, G. (2016). Sistemas de Información enfocados en tecnologías de agricultura de precisión y aplicables a la caña de azúcar, una revisión. *Revista Ingenierías Universidad de*

- Medellín, 15(28), 103–124. <https://doi.org/10.22395/riium.v15n28a6>
- Ponce, P., Chulde, M. P., & Bustamante, M. O. (2022). Segmentación de imágenes agrícolas adquiridas con drone mediante algoritmos paralelos. *Innovation & Development In Engineering And Applied Sciences*, 4(2), 16–16. <https://doi.org/10.53358/IDEAS.V4I2.861>
- Ponce, P., Pusedá Chulde, M., & Ortega Bustamante, M. (2023). Segmentación de imágenes agrícolas adquiridas con drone mediante algoritmos paralelos. *Innovation & Development In Engineering And Applied Sciences*, 4(2). <https://doi.org/10.53358/ideas.v4i2.861>
- Qu, X., Shi, D., Gu, X., Sun, Q., Hu, X., Yang, X., & Pan, Y. (2022). Monitoring Lodging Extents of Maize Crop Using Multitemporal GF-1 Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 3800–3814. <https://doi.org/10.1109/JSTARS.2022.3170345>
- Ramírez-Rojas, C., Peña-Valdivia, C. B., García-Esteva, A., & Padilla-Chacón, D. (2022). Fenotipo de plantas de maíz con efecto del herbicida mesotrione. *Revista Mexicana de Ciencias Agrícolas*, 13(8), 1399–1410. <https://doi.org/10.29312/REMEXCA.V13I8.2886>
- Ramos Cruz, C. M., Ramos-Cruz, C. M., Trucios-Caciano, R., Raquel Pérez-Evangelista, E., Miguel-Valle, E., & Delgado-Ramírez, G. (2022). Uso de imágenes captadas mediante UAV para estimar el estado general de huertas cítricas: TECNOCENCIA Chihuahua, 16(2), e1007–e1007. <https://doi.org/10.54167/TCH.V16I2.1007>
- Ribeiro Gomes, K., Hernández Lopez, D., Ballesteros González, R., & Moreno Hidalgo, M. (2015). Desarrollo de una metodología para la optimización del flujo de trabajo en la adquisición y tratamiento de imágenes de alta resolución con vehículos aéreos no tripulados. 481–487. <https://doi.org/10.4995/cnriegos.2015.1467>
- Rodríguez Alonso, D., & Cabrejo Paredes, J. (2022). Excelente confiabilidad de la cámara termográfica de bolsillo para apoyar el diagnóstico de la neuropatía periférica diabética en atención primaria. *Revista Médica Vallejana / Vallejian Medical Journal*, 11(2), 11–20. <https://doi.org/10.18050/REVISTAMEDICAVALLEJANA.V11I2.01>
- sct11_C. (2019). https://www.dof.gob.mx/normasOficiales/8006/sct11_C/sct11_C.html

- Shukla, M., Sadhu, A. C., Patel, P., & Mevada, K. D. (2022). Effect of Inclusion of Legumes in Cropping System and their Residue Incorporation on the Yield of Maize. *LEGUME RESEARCH - AN INTERNATIONAL JOURNAL*, Of. <https://doi.org/10.18805/LR-4868>
- Torres-Madronero, M. C., Goez, M., Guzman, M. A., Rondon, T., Carmona, P., Acevedo-Correa, C., Gomez-Ortega, S., Durango-Flórez, M., López, S. V., Galeano, J., & Casamitjana, M. (2022). Spectral Library of Maize Leaves under Nitrogen Deficiency Stress. *Data*, 8(1), 2. <https://doi.org/10.3390/DATA8010002>
- Vega-Puga, M., Romo-Leon, J. R., Castellanos, A. E., Castillo-Gómez, R. A., Garatuza-Payán, J. y Ángeles-Pérez, G. (2023). Uso de imágenes aéreas de alta resolución para la detección de cambios en el almacén de carbono en biomasa aérea en comunidades semiáridas, tras la introducción de la especie exótica *Cenchrus ciliaris*. *Botanical Sciences*, 101(1), 41-56. <https://doi.org/10.17129/BOTSCI.3026>
- Villar, F. A., Candelario, S., & Díaz, J. (2023). Drones, fotogrametría y Sistemas de Información Geográfica. Algunos aportes a la arqueología de contextos industriales. *Comechingonia. Revista de Arqueología*, 27(1), 35–50. <https://doi.org/10.37603/2250.7728.V27.N1.38136>
- Wahab, I., Hall, O., & Jirström, M. (2018). Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa. *Drones*, 2(3), 28. <https://doi.org/10.3390/DRONES2030028>
- Wei, L., Song, X., & Yang, H. (2023). Extraction of maize planting area based on transformer and remote sensing data. <https://doi.org/10.1117/12.2689430>, 12748, 381–386. <https://doi.org/10.1117/12.2689430>

Capítulo 4

Selección y evaluación de modelos de inteligencia artificial para la detección de maleza en cultivos agrícolas

Karla Vanessa Ayala Cruz¹

José de Jesús Valenzuela Hernández²

Gilberto Bojórquez Delgado³

<https://doi.org/10.61728/AE24004534>



¹ Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: ayalacruz05@gmail.com

² Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: josevalenzuela_93@outlook.com

³ Tecnológico Nacional de México Campus Guasave, Guasave, Sinaloa, México.
Email: itsg.gbojorquez@gmail.com

Resumen

Los retos en la agricultura moderna cada vez más complejos y requieren de soluciones más avanzadas en el campo de las tecnologías aplicadas. Uno de los retos más importantes en el campo de la agricultura es la detección y control de malezas, ya que la presencia de ellas presenta pérdidas significativas en el rendimiento proyectado desde la programación del cultivo. El artículo aborda la necesidad de utilizar modelos avanzados de IA para mejorar la gestión de malezas en cultivos de maíz mediante el uso de drones. Se llevó a cabo una revisión sistemática de la literatura para identificar y evaluar los modelos de IA más relevantes: YOLO, Faster R-CNN, ResNet y VGG. El método de análisis fue la revisión sistemática de bibliografía la cual se dividió en tres pasos. Primero, se recopiló bibliografía sobre cada modelo mediante búsquedas exhaustivas en bases de datos académicas como IEEE Xplore, Google Scholar y ScienceDirect. Segundo, se evaluaron los estudios seleccionados según criterios de precisión, velocidad de procesamiento, requerimientos computacionales, robustez y facilidad de implementación. Tercero, se sintetizó la evidencia para determinar el modelo más adecuado. Los resultados indican que YOLO es el modelo más adecuado debido a su capacidad de procesamiento en tiempo real y eficiencia, a pesar de tener una precisión ligeramente inferior comparada con otros modelos. Faster R-CNN ofrece alta precisión y robustez, pero su velocidad es inferior. ResNet se destacó por su alta precisión al igual que VGG, pero sus altos requerimientos computacionales y velocidad limitada los hacen menos práctico.

Introducción

La agricultura, a lo largo de la historia, ha sido el fundamento esencial sobre el cual se erige el desarrollo y la subsistencia de las sociedades humanas. Desde los primeros asentamientos humanos hasta las complejas sociedades modernas, la agricultura ha sido el motor que impulsa

el progreso y el desarrollo. Su evolución a lo largo de milenios ha sido marcada por la innovación, la adaptación y la búsqueda constante de métodos más eficientes y sostenibles.

Desde tiempos inmemoriales, su importancia ha trascendido la mera producción de alimentos, abarcando dimensiones cruciales en términos de economía, sostenibilidad y seguridad alimentaria a escala global. En un contexto donde la población mundial sigue en aumento y los recursos naturales se vuelven cada vez más escasos y el panorama no es muy alentador, el papel de la agricultura en la nutrición y el bienestar humanos adquiere una relevancia sin precedentes. Sin embargo, a pesar de su importancia innegable, la agricultura se enfrenta a una serie de desafíos monumentales en el siglo XXI. La crisis alimentaria global, exacerbada por fenómenos como el cambio climático, conflictos políticos, manejo del agua y pandemias, ha subrayado la urgente necesidad de fortalecer y consolidar el sector agrícola (World Health Organization, 2022). En este escenario, es imperativo adoptar estrategias innovadoras que permitan enfrentar estos desafíos de manera efectiva y sostenible.

Uno de los desafíos más apremiantes en la agricultura moderna es el manejo de malezas, cuya presencia representa una amenaza significativa para la productividad y calidad de los cultivos (Westwood et al., 2018). La detección y control eficaces de estas malezas son fundamentales para maximizar la productividad agrícola, mejorar la eficiencia en el uso de recursos y reducir la dependencia de herbicidas químicos. En este sentido, el desarrollo y aplicación de tecnologías avanzadas, como la inteligencia artificial y la teledetección mediante drones, ofrecen nuevas oportunidades para abordar este desafío de manera más precisa y eficiente (Esposito et al., 2021).

En la agricultura moderna, el uso de tecnologías avanzadas para optimizar la producción y sostenibilidad de los cultivos es cada vez más crucial. Una de estas tecnologías emergentes es el procesamiento de imágenes tomadas desde drones, lo que permite una vigilancia precisa y continua de grandes extensiones de cultivos.

La tecnología de drones y sensores juega un papel crucial en la gestión sostenible de malezas, ofreciendo soluciones innovadoras para el monitoreo y control eficiente de las mismas. La integración de drones

con varios sensores, como hiperespectrales, multiespectrales y RGB, permite una detección y gestión precisa de malas hierbas (Roslim et al., 2021). Estas tecnologías facilitan la gestión de malas hierbas específica para cada sitio, lo que mejora la eficiencia a la vez que beneficia al medioambiente (Esposito et al., 2021). Los drones equipados con sensores pueden proporcionar datos valiosos sobre los niveles de infestación de malas hierbas, permitiendo intervenciones dirigidas y reduciendo el costo general de la producción agrícola (Huang et al., 2018). Conocer las bondades de diferentes modelos de procesamiento de imágenes es fundamental por varias razones. En primer lugar, la elección del modelo adecuado puede influir significativamente en la precisión y eficiencia del análisis de las imágenes, impactando directamente en la capacidad de los agricultores para tomar decisiones informadas y oportunas. Modelos de inteligencia artificial (IA) como las redes neuronales convolucionales (CNN), incluyendo ResNet, VGG, YOLO y Faster R-CNN, ofrecen distintas ventajas y desventajas en términos de precisión, velocidad y requerimientos computacionales.

Analizar estas propiedades permite identificar cuál de estos modelos es el más adecuado para las necesidades específicas del monitoreo de cultivos de maíz. De esta manera, el procesamiento de datos mediante modelos de IA presenta numerosos beneficios. La capacidad de estos modelos para analizar grandes volúmenes de datos de manera rápida y precisa mejora la detección de problemas como la presencia de malezas, plagas y enfermedades en las etapas tempranas. Esto no solo facilita una intervención más rápida y efectiva, sino que también puede conducir a una reducción significativa en el uso de herbicidas y pesticidas, promoviendo prácticas agrícolas más sostenibles. Además, el análisis automatizado reduce la necesidad de inspecciones manuales extensivas, ahorrando tiempo y recursos.

Desde una perspectiva económica, la inversión en tecnologías de procesamiento de imágenes y modelos de IA puede traducirse en un mayor rendimiento de la producción. La capacidad de identificar y abordar problemas de manera temprana y precisa ayuda a maximizar los rendimientos de los cultivos y minimizar las pérdidas. Esto, a su vez, puede mejorar significativamente la rentabilidad para los agricultores, justificando las inversiones iniciales en estas tecnologías avanzadas.

Además, los beneficios del rápido procesamiento y la accesibilidad a modelos más amigables no pueden ser subestimados. Modelos como YOLO, que son conocidos por su velocidad y eficiencia en tiempo real, permiten a los agricultores realizar monitoreos continuos y tomar decisiones inmediatas basadas en datos precisos. La facilidad de implementación y uso de estos modelos también los hace accesibles para una amplia gama de usuarios, incluyendo aquellos con menos experiencia técnica.

En la actualidad, el análisis de modelos de procesamiento de imágenes capturadas por drones en cultivos de maíz es esencial para mejorar la precisión y eficiencia del monitoreo agrícola. La adopción de modelos de IA no solo ofrece beneficios significativos en términos de sostenibilidad y eficiencia, sino que también justifica las inversiones económicas al aumentar el rendimiento y la rentabilidad de la producción agrícola.

Además, el uso de drones junto con sensores terrestres y tecnologías de inteligencia artificial permite la detección de malezas y procesos de toma de decisiones en línea, mejorando la sostenibilidad de las prácticas de control de malezas (Engineering, Technology & Applied Science Research, s. f.). Sin embargo, los avances tecnológicos han facilitado el desarrollo de soluciones basadas en drones para la detección de malezas y la medición de los niveles de infestación de malezas. Además, se han utilizado drones en vuelos poscosecha para medir el crecimiento de las malezas y las asociaciones de rendimiento, lo que proporciona información valiosa para estrategias efectivas de control de malezas (Miller et al., 2022). En este sentido el artículo pretende proporcionar una evaluación detallada de los diferentes modelos, ayudando a identificar las mejores prácticas y tecnologías para optimizar la gestión de cultivos de maíz mediante el uso de drones y procesamiento de imágenes.

El monitoreo constante del control de plagas y malezas en los cultivos de maíz blanco es fundamental para garantizar una producción agrícola eficiente y sostenible. Las malezas, en particular, son una amenaza significativa ya que compiten con los cultivos por recursos esenciales como nutrientes, agua y luz, afectando negativamente los rendimientos. Entre las malezas más comunes que se pueden encontrar en los campos de maíz blanco se incluyen el *Amaranthus palmeri* (amaranto), la *Echinochloa crus-galli* (pata de gallo) y la *Cyperus rotundus* (coquillo). Estas especies

invasoras pueden reducir significativamente la producción del maíz, interfiriendo en su crecimiento y desarrollo al competir agresivamente por los recursos del suelo. El *Amaranthus palmeri*, por ejemplo, es conocido por su rápido crecimiento y alta capacidad de dispersión, lo que lo convierte en una de las malezas más difíciles de controlar. La *Echinochloa crus-galli* puede competir eficazmente con el maíz en las primeras etapas de crecimiento, reduciendo la disponibilidad de luz y nutrientes para el cultivo. La *Cyperus rotundus* es particularmente resistente y puede sobrevivir a condiciones adversas, compitiendo con el maíz durante toda la temporada de crecimiento. La presencia de estas malezas no solo disminuye la cantidad de maíz cosechable, sino que también puede afectar la calidad del grano producido (BASF México, s. f.).

Estar a la vanguardia en tecnología aplicada y métodos de precisión para el control de malezas es crucial para superar estos desafíos. La adopción de tecnologías avanzadas como la inteligencia artificial (IA) y el uso de drones para el monitoreo de campos ha revolucionado la agricultura moderna. Estas tecnologías permiten una detección temprana y precisa de malezas, facilitando intervenciones rápidas y específicas que reducen la competencia de malezas y mejoran los rendimientos del cultivo. Los sistemas de monitoreo continuo basados en IA pueden analizar grandes volúmenes de datos de imágenes, identificando con precisión las áreas afectadas por malezas y plagas. En contraste, las técnicas de evaluación y control de malezas más antiguas, que todavía se utilizan en algunos casos, incluyen métodos manuales de inspección y la aplicación generalizada de herbicidas. Estos métodos son laboriosos y menos precisos, ya que dependen en gran medida de la observación humana, lo que puede llevar a una detección tardía y un control ineficiente. La aplicación indiscriminada de herbicidas no solo es costosa, sino que también puede dañar el medio ambiente y promover la resistencia de las malezas a los productos químicos.

Las acciones más comunes para controlar las malezas en caso de aparecer en el cultivo de maíz incluyen la aplicación de herbicidas selectivos, la rotación de cultivos y el uso de técnicas de cultivo mecánico. La rotación de cultivos ayuda a romper el ciclo de vida de las malezas, reduciendo su prevalencia en los campos. El cultivo mecánico, aunque eficaz en algunos casos, puede ser costoso y menos sostenible a largo

plazo debido al impacto en la estructura del suelo y la posible erosión. El monitoreo constante y el control efectivo de malezas y plagas son esenciales para mantener la productividad de los cultivos de maíz blanco y la adopción de tecnologías avanzadas y métodos de precisión para el control de malezas representa una mejora significativa sobre las técnicas tradicionales, ofreciendo una solución más sostenible y eficiente. Los agricultores que implementan estas tecnologías pueden esperar no solo mejorar sus rendimientos sino también reducir los costos operativos y minimizar el impacto ambiental, contribuyendo así a una agricultura más sostenible y rentable.

De acuerdo con lo anterior se considera importante la implementación de modelos de procesamiento de datos más amigables y con mayor velocidad de procesamiento ya que estas acciones traen consigo numerosos beneficios en el campo de la agronomía. En primer lugar, estos modelos permiten una toma de decisiones más rápida y precisa, lo que es crucial en un entorno donde las condiciones de los cultivos pueden cambiar rápidamente y las intervenciones deben ser oportunas. En este sentido es fundamental analizar diferentes modelos de procesamiento para seleccionar el más adecuado, ya que cada cultivo y cada situación específica puede requerir enfoques distintos. Por ejemplo, algunos modelos pueden ser más efectivos para detectar enfermedades en etapas tempranas, mientras que otros pueden ser más adecuados para la gestión del riego o la estimación de la biomasa.

Trabajos relacionados

En el artículo “Uso de sensores remotos y un sistema aéreo no tripulado para el manejo de malezas en cultivos agrícolas: Una revisión”, se señala que las malezas reducen el rendimiento de los cultivos al competir por recursos esenciales y que la integración de drones, IA y sensores (hiperespectrales, multispectrales y RGB) mejora significativamente el manejo de malezas. En este sentido, la detección remota es una herramienta multidisciplinaria que aborda desafíos futuros como la seguridad alimentaria y la resistencia a herbicidas. En esta investigación se destaca el uso de vehículos aéreos no tripulados (UAV) y técnicas de detección

remota en la gestión de malezas, demostrando su efectividad en superar desafíos agrícolas futuros (Roslim et al., 2021).

Para llevar a cabo la investigación se realizaron experimentos en campos de frijoles y espinacas utilizando imágenes capturadas por un dron DJI Phantom 3 Pro. El desempeño del método no supervisado propuesto se comparó con el etiquetado supervisado, mostrando resultados similares con pequeñas diferencias de precisión. El estudio encontró que el método no supervisado es efectivo, especialmente con el aumento de datos, y destacó la robustez de modelos de aprendizaje profundo como ResNet18. El documento concluye que el método completamente automático propuesto utilizando CNN con etiquetado de datos no supervisado es efectivo para la detección de malas hierbas en imágenes de UAV. El método ofrece flexibilidad y adaptabilidad para diferentes conjuntos de datos y podría ser valioso para la detección en línea de malas hierbas en la agricultura de precisión. Los trabajos futuros explorarán el uso de imágenes multiespectrales para mejorar la segmentación y la precisión de la clasificación.

Así mismo en el artículo “Detección de malezas basada en aprendizaje profundo mediante imágenes de UAV: Un estudio comparativo”, se concluye que la segmentación semántica es crucial en la agricultura de precisión para la detección de malezas. Aquí se analizaron varios modelos de segmentación basados en IA para la detección de malezas utilizando imágenes RGB de UAV y se encontró que UNet con EfficientNetB0 es el modelo de mejor rendimiento, sugiriendo que puede ser utilizado por agricultores para detectar malezas con mayor precisión, mejorando el rendimiento de los cultivos (Shahi et al., 2023). Entre los hallazgos se determina que la metodología propuesta muestra un rendimiento cercano al etiquetado supervisado en términos de precisión, con diferencias de AUC del 1.5 % en el campo de espinacas y del 6 % en el campo de frijoles. También concluye que el etiquetado no supervisado reduce significativamente la necesidad de intervención manual, lo que puede resultar en ahorros considerables en tiempo y costos. Por otra parte, concibe el método como flexible y con la característica de adaptarse fácilmente a nuevos conjuntos de datos, lo cual es esencial para diferentes condiciones agrícolas y tipos de cultivos. Así mismo, planea usar imágenes

multiespectrales para mejorar aún más la segmentación del fondo y la distinción entre plantas, incluso en condiciones de similitud espectral y forma de las hojas.

En el artículo “Tecnología de sensores y drones para el manejo sostenible de malezas: Una revisión”, se analiza el manejo integrado de malezas utilizando drones que permite un control específico y eficiente de malezas en sitios particulares. Este enfoque combina la adquisición de imágenes mediante drones y su procesamiento con técnicas de aprendizaje automático, entrenando algoritmos para gestionar la eliminación de malezas de manera autónoma. La revisión destaca la necesidad de comprender la dinámica de las malezas y su competencia con los cultivos para implementar este enfoque en contextos agrícolas reales (Esposito et al., 2021). La investigación concluye que el uso de UAV y las técnicas de aprendizaje automático permite la identificación precisa de parches de malezas en campos cultivados, mejorando la sostenibilidad del manejo de malezas. La integración de tecnologías emergentes en este campo mejorará significativamente la sostenibilidad del control de malezas, proporcionando una visión confiable del nivel y tipo de infestación, y permitiendo la gestión mediante robots autónomos. Sin embargo, se necesita una comprensión completa de la dinámica de las poblaciones de malezas y su competencia con los cultivos para implementar esta tecnología en contextos agrícolas reales.

En otro artículo llamado “Una revisión de las aplicaciones basadas en UAV para la agricultura de precisión”, se determina que las tecnologías emergentes como el Internet de las cosas (IoT) y UAV tienen un potencial significativo en la agricultura inteligente, permitiendo la toma de decisiones rápidas y precisas. Este artículo revisa las aplicaciones de UAV en la agricultura de precisión, discutiendo los métodos de adquisición y procesamiento de datos, y destacando los beneficios y desventajas de cada tecnología. También se aborda la falta de un flujo de trabajo estandarizado para el uso de UAV en estas aplicaciones (Tsouros et al., 2019).

Por otra parte, en la investigación “Avances de vehículos aéreos no tripulados y tecnologías de aprendizaje profundo para el manejo de malezas en tierras agrícolas”, se afirma que la tecnología UAV y las redes neuronales convolucionales (CNN) han mejorado significativamente la

detección de malezas, plagas y otros factores abióticos que afectan el rendimiento de los cultivos. Este estudio presenta los avances en plataformas UAV y CNN, y su aplicación en la agricultura, destacando las limitaciones actuales y las tendencias futuras en el manejo de malezas (Zhang et al., 2024).

Al concluir la investigación se determinó, que las imágenes capturadas por drones a menudo se ven afectadas por factores como la iluminación, sombras y oclusión, lo que presenta dificultades para la identificación precisa de malezas, por lo que la precisión y confiabilidad de la identificación de malezas como elemento clave de la investigación puede ser errónea (Advancements in UAV Technology).

El documento también concluye que la investigación y aplicación de drones en la gestión de malezas han mostrado resultados positivos, pero aún enfrentan desafíos. La necesidad de mejorar la colaboración entre drones y equipos terrestres, así como la generalización y robustez de los modelos de aprendizaje profundo, es fundamental. Se enfatiza la importancia de aplicar esta tecnología en la producción agrícola real para soluciones más eficientes e inteligentes y que la investigación futura debe centrarse en mejorar la precisión de la identificación de malezas, la colaboración entre drones y equipos terrestres, y la aplicación práctica en la producción agrícola. Además, es necesario explorar formas de aplicar estas tecnologías a gran escala en la producción agrícola (Advancements in UAV Technology).

Así mismo en el documento “Inteligencia artificial en tareas de reconocimiento de malezas”, se determina que el uso de redes neuronales para el reconocimiento de malezas ha avanzado significativamente en la última década. Este manuscrito presenta un análisis de los resultados del uso de diversos algoritmos de redes neuronales para la clasificación y seguimiento de malezas, recomendando estándares que pueden mejorar la calidad de la investigación en este campo (Ildar, 2020).

La mayoría de los estudios revisados utilizan técnicas de procesamiento de imágenes como filtros de color, suavizado de imágenes, y transformaciones morfológicas para mejorar la calidad de las imágenes antes de ser procesadas por las redes neuronales. En este sentido, se determina que el procesamiento previo de las imágenes es crucial para mejorar la

calidad y precisión del reconocimiento de malezas. Se utilizan diversas técnicas de la biblioteca OpenCV, como filtros Gaussianos y Laplacianos, transformaciones afines y de perspectiva, y detección de bordes.

De igual manera, se concluye que las redes neuronales convolucionales (CNN) son ampliamente utilizadas para la extracción de características y la clasificación de objetos en imágenes agrícolas. Métodos como YOLO, Faster R-CNN y RetinaNet han mostrado buenos resultados en la detección de malezas, aunque enfrentan desafíos como la necesidad de alta potencia de cómputo y la limitación de recursos en dispositivos como Raspberry Pi. Los principales desafíos incluyen la complejidad de reconocer malezas en diferentes condiciones ambientales y la velocidad de reconocimiento.

En el documento “Métodos de aprendizaje automático para agricultura de precisión con imágenes de UAV: Una revisión”, se afirma que la teledetección basada en UAV ha ganado atención en la agricultura de precisión debido a los sensores avanzados y métodos de análisis de datos. Este artículo revisa y compara diversos métodos de aprendizaje automático y aprendizaje profundo para aplicaciones agrícolas, mostrando cómo la fusión de múltiples características puede mejorar el rendimiento de los modelos. También se discuten las tendencias recientes y los desafíos en este campo (Shahi et al., 2022).

Marco teórico

Inteligencia artificial (IA)

La inteligencia artificial (IA) ha evolucionado significativamente en las últimas décadas, convirtiéndose en una herramienta fundamental en diversos campos, incluida la agricultura de precisión. En lo que respecta al propio término de inteligencia artificial, el Ministerio de Ciencia, Innovación y Universidades (2019) lo define como “la Ciencia e Ingeniería que permite diseñar y programar máquinas capaces de llevar a cabo tareas que requieren inteligencia para ser realizadas” (p. 13). Sin embargo, para profundizar y poder comprender dicha tecnología, haremos referencia a los cuatro tipos de IA definidos por Arend Hintze (<http://hdl.handle.net/10654/39998>).

En primer lugar, se encuentran las llamadas máquinas reactivas. Son las más básicas y no pueden formar recuerdos ni utilizar experiencias pasadas para tomar decisiones. El segundo tipo (memoria limitada), a diferencia del primero, es capaz de adquirir información de experiencias pasadas, aunque su memoria es transitoria y no se puede utilizar para futuras experiencias. En tercer lugar, encontramos las máquinas con una “Teoría de la mente”, las cuales son capaces de formar representaciones del mundo y sobre otros agentes o entidades con los que interactúa. El cuarto y último tipo de IA es la autoconciencia. Se trata de una extensión de la “Teoría de la mente” y se basa en construir sistemas que sean capaces de crear representaciones sobre sí mismas.

Agricultura de precisión

Adamides (2020), menciona que “La agricultura de precisión es una metodología de gestión agrícola que utiliza tecnologías avanzadas para medir y analizar datos sobre las variaciones dentro de los campos, permitiendo a los agricultores optimizar el uso de insumos y mejorar la eficiencia y sostenibilidad de la producción”.

Rodrigues (2021) señala que “La agricultura de precisión es un enfoque de gestión agrícola que integra tecnologías de información y comunicación, incluyendo IoT y análisis de big data, para monitorear y gestionar los cultivos con alta precisión, mejorando la productividad y reduciendo el impacto ambiental”.

García y Jiménez (2021) concluyen que “La agricultura de precisión se refiere a la gestión agrícola basada en la observación y medición de las condiciones del suelo y el cultivo, y la aplicación de tratamientos específicos en tiempo real para mejorar la productividad y sostenibilidad de los cultivos”.

Según Rodríguez (2022), la Sociedad Internacional de Agricultura de Precisión define la agricultura de precisión como “una estrategia de gestión que recopila, procesa y analiza datos temporales, espaciales e individuales y los combina con otra información para apoyar decisiones de gestión según la variabilidad estimada, mejorando la eficiencia en el uso de recursos, productividad, calidad, rentabilidad y sostenibilidad de la producción agrícola”.

Malezas

Adamides (2020), sostiene que “Las malezas son plantas no deseadas que compiten con los cultivos por recursos esenciales y pueden reducir significativamente la cantidad y calidad de la producción agrícola. Además, pueden actuar como hospederos alternativos para plagas y patógenos, lo que agrava aún más su impacto negativo”. Además, Sulaiman (2021), sostiene que las malezas son plantas no deseadas que compiten con los cultivos por recursos esenciales como agua, nutrientes, luz y espacio. Esta competencia puede resultar en una reducción significativa del rendimiento de los cultivos, afectando tanto la cantidad como la calidad de la producción. En cultivos de maíz, malezas como *Amaranthus palmeri* (amaranto), *Echinochloa crus-galli* (pata de gallo) y *Cyperus rotundus* (coquillo) son especialmente problemáticas debido a su rápida propagación y resistencia a los herbicidas

Tecnologías de monitoreo y detección

Mishra (2022) define que “El uso de vehículos aéreos no tripulados (UAV) equipados con sensores avanzados (hiperespectrales, multiespectrales y RGB) ha revolucionado el monitoreo de cultivos. Estos drones pueden capturar imágenes de alta resolución que permiten la detección precisa y temprana de malezas. Las imágenes capturadas son procesadas mediante técnicas de inteligencia artificial (IA) para identificar y localizar malezas de manera eficiente.

Ayoub Shaikh (2023) menciona que “Las tecnologías de monitoreo y detección en la agricultura emplean una combinación de sensores remotos y técnicas de procesamiento de imágenes para identificar y gestionar problemas en los cultivos, como enfermedades y plagas. Estos sistemas pueden incluir cámaras de alta resolución, sensores de temperatura y humedad, y algoritmos de inteligencia artificial para analizar los datos recogidos y proporcionar recomendaciones precisas para la gestión agrícola”.

Modelos de inteligencia artificial

García y Jiménez (2021) sostienen que “Los modelos de IA para la agricultura de precisión incluyen algoritmos de aprendizaje automático (ML) y aprendizaje profundo (DL), que se utilizan para analizar datos de sensores de suelo, humedad y nutrientes. Estos modelos permiten tomar decisiones informadas para mejorar la productividad y sostenibilidad de la agricultura”.

Akbar (2023): “Los modelos de IA en la agricultura se utilizan para la detección y clasificación de enfermedades de los cultivos. Los modelos basados en aprendizaje automático (ML) y aprendizaje profundo (DL) permiten identificar y clasificar enfermedades mediante el análisis de imágenes de hojas u otras características de las plantas. Esto ayuda a los agricultores a manejar y controlar las enfermedades de manera más efectiva”. En este mismo sentido, Kaur y Sharma (2023) expresan que “Los modelos de IA en la detección de enfermedades de plantas incluyen algoritmos de aprendizaje automático (ML) como el clasificador c4.5 y las máquinas de vectores de soporte lineal (SVM), así como modelos de aprendizaje profundo (DL) como las redes neuronales convolucionales (CNN) y las redes de creencias profundas (DBN). Estos modelos son capaces de aprender características a partir de imágenes y detectar síntomas sutiles de enfermedades que los métodos tradicionales de procesamiento de imágenes pueden no identificar”.

Los modelos de IA, especialmente las redes neuronales convolucionales (CNN), han demostrado ser extremadamente efectivos para el procesamiento y análisis de imágenes agrícolas. Modelos como ResNet, VGG, YOLO y Faster R-CNN se utilizan ampliamente para tareas de detección de objetos y clasificación de imágenes.

- **ResNet (Residual Networks):** Conocido por su capacidad para manejar redes muy profundas, lo que mejora la precisión en la detección.
- **VGG (Visual Geometry Group):** Utiliza capas convolucionales pequeñas que ofrecen una arquitectura simple y efectiva.
- **YOLO (You Only Look Once):** Destaca por su velocidad y capacidad de procesamiento en tiempo real.

- **Faster R-CNN:** Combina una red de propuestas de regiones (RPN) con una CNN para lograr una alta precisión en la detección de múltiples objetos.

Comparación de modelos de IA

Un estudio comparativo de diversos modelos de segmentación semántica basados en IA para la detección de malezas utilizando imágenes RGB de UAV identificó que UNet combinado con EfficientNetB0 es el modelo de mejor rendimiento. Este modelo demostró una alta precisión, recall y puntuación F1, lo que lo hace ideal para aplicaciones agrícolas (Osorio et al., 2020).

Beneficios del uso de IA en la agricultura

El procesamiento de datos mediante modelos de IA ofrece numerosos beneficios, incluyendo:

- **Precisión en la Detección:** Mejora la identificación temprana y precisa de malezas, permitiendo intervenciones rápidas y específicas (Haq et al., 2023).
- **Mejora en los Rendimientos:** Al gestionar eficazmente las malezas, se optimiza el crecimiento del cultivo, aumentando la producción y calidad de la cosecha (Dasgupta et al., 2023).
- **Eficiencia Operativa:** Reduce la necesidad de inspecciones manuales extensivas y permite el uso selectivo de herbicidas, disminuyendo costos y el impacto ambiental (Prostko et al., 2024).

Metodología

Para garantizar la selección y aplicación de los modelos de IA más efectivos en el procesamiento de imágenes tomadas por drones, es esencial realizar una revisión sistemática de la literatura, ya que permite recopilar, evaluar y sintetizar de manera rigurosa la evidencia disponible sobre los diferentes modelos de IA utilizados en este contexto. Este enfoque no solo asegura una comprensión exhaustiva de las tecnologías actuales, sino que también identifica las mejores prácticas y las áreas que requieren más

investigación. La metodología estructurada y transparente de la revisión sistemática minimiza los sesgos y proporciona una base sólida para la toma de decisiones informadas en la implementación de tecnologías de IA en la agricultura.

Dada la variabilidad en las características y el rendimiento de los diferentes modelos de IA, como las redes neuronales convolucionales (CNN), las máquinas de vectores de soporte (SVM) y los algoritmos de aprendizaje profundo (DL), la revisión sistemática ofrece una evaluación crítica y comparativa que es fundamental para optimizar su uso en la detección de malezas. Además, la integración de imágenes de alta resolución capturadas por drones añade una capa de complejidad y oportunidad que puede ser mejor comprendida y explotada mediante una revisión exhaustiva de la literatura existente.

Revisión sistemática de literatura sobre modelos de IA para la detección de malezas en cultivos de maíz blanco

Paso 1: Recopilación de bibliografía sobre modelos de IA

El primer paso de la revisión sistemática consistió en la recopilación exhaustiva de bibliografía relacionada con los modelos de inteligencia artificial más relevantes utilizados en la detección de malezas en cultivos agrícolas. Los modelos específicos considerados fueron ResNet (Residual Networks), VGG (Visual Geometry Group), YOLO (You Only Look Once) y Faster R-CNN. Para llevar a cabo esta recopilación, se realizaron búsquedas en bases de datos académicas y científicas como IEEE Xplore, Google Scholar, ScienceDirect y MDPI, utilizando palabras clave como “ResNet weed detection”, “VGG crop analysis”, “YOLO agriculture”, y “Faster R-CNN plant diseases”.

Se identificaron y seleccionaron estudios relevantes publicados en los últimos cinco años (2019-2024) para asegurar que la información estuviera actualizada. Los estudios seleccionados incluyeron investigaciones empíricas, revisiones de literatura y artículos de conferencia que discutieran el desarrollo, implementación y evaluación de estos modelos de IA en el contexto de la agricultura de precisión.

Paso 2: Evaluación de la Información

Una vez recopilada la bibliografía, se procedió a la evaluación crítica de los estudios seleccionados. Los criterios de análisis utilizados para revisar y comparar los modelos de IA fueron los siguientes:

1. **Precisión de detección:** La capacidad del modelo para identificar correctamente las malezas en imágenes de cultivos, medida a través de métricas como la precisión, el recall y la puntuación F1.
2. **Velocidad de procesamiento:** El tiempo requerido por el modelo para procesar una imagen y generar resultados, evaluando su aplicabilidad en tiempo real.
3. **Requerimientos computacionales:** La cantidad de recursos computacionales necesarios para entrenar y ejecutar el modelo, incluyendo el uso de GPU y memoria.
4. **Robustez y generalización:** La capacidad del modelo para mantener un buen rendimiento en diferentes condiciones y escenarios de cultivo, evaluando su adaptabilidad y robustez frente a variaciones en los datos de entrada.
5. **Facilidad de implementación:** La simplicidad del proceso de implementación del modelo, incluyendo la disponibilidad de código abierto, la documentación y la facilidad de integración con otras tecnologías agrícolas.

Selección de modelos de IA

Tabla 1
Redes neuronales convolucionales (CNN).

Referencia	Nombre del artículo	Modelo usado	Cultivo	Características de las fotos
<p>https://iieta.org/journals/ria/paper/10.18280/ria.360102</p> <p>Este estudio de detección de malezas en el cultivo de guisantes, se utilizó el modelo Faster R-CNN con ResNet-50. La investigación mostró que esta combinación era capaz de identificar y localizar cultivos y malezas con alta precisión. La utilización de Google Colab y TensorFlow permitió un entrenamiento eficiente, y el modelo demostró una precisión promedio (mAP) alta, con resultados que se estabilizaron alrededor de un valor de pérdida inferior a 0.05, indicando un buen aprendizaje.</p>	<p>Weed Detection in Pea Cultivation with the Faster RCNN ResNet 50 Convolutional Neural Network</p>	<p>Para esta investigación se adoptó el modelo Faster R-CNN ResNet 50 para detectar el cultivo, combina las funcionalidades de dos modelos. (Faster R-CNN y ResNet 50)</p>	<p>Guisantes</p>	<p>Los datos de entrenamiento contienen 1156 imágenes, y para enriquecer el DataSet se procedió a aumentar los datos, utilizando métodos de procesamiento de imágenes con la biblioteca Python OpenCv. A partir de una sola imagen se generan 8 imágenes diferentes, rotación de 180°, aumentos y disminuciones de brillo, reflejo horizontal, mejora de contraste, ruido gaussiano y equalización de histograma. Con estos métodos se obtuvieron 9248 imágenes.</p>

<p>https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2023.1205151/full</p> <p>Este estudio propuso un modelo basado en VGG16 mejorado para identificar malezas en campos de maíz. Utilizando técnicas de aprendizaje por transferencia, el modelo alcanzó una precisión del 91.08 % en el conjunto de validación y del 80 % en campos reales. Este enfoque demuestra la efectividad de VGG16 en entornos agrícolas complejos</p>	<p>A new model based on improved VGG16 for corn weed identification</p>	<p>SE-VGG16</p>	<p>Plántula de maíz</p>	<p>Se recopilaron imágenes de plántulas de maíz y malezas de Gitee (https://gitee.com/Monster7/weed-dataset/tree/master/) a través de Internet, y el conjunto de datos sobre malezas del maíz se tomó de campos de plántulas de maíz en su entorno natural. Se utilizó una cámara Canon PowerShot SX600 HS, con la cámara apuntando verticalmente hacia el suelo para reducir el efecto de los reflejos de la luz solar. Después de la identificación de expertos y la selección manual, se obtuvo un total de 6.000 imágenes, incluidas imágenes de una plántula de maíz y cuatro especies de malezas de maíz, con las categorías de malezas Bluegrass, Chenopodium album, Cirsium setosum y Sedge.</p>
--	---	-----------------	-------------------------	---

Fuente: creación propia.

Tabla 2*Modelos de detección de objetos.*

Referencia	Nombre del Artículo	Modelo Usado	Cultivo	Características de las fotos
https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2022.1091655/full YOLO (You Only Look Once) es una familia de modelos de detección de objetos que se caracteriza por su alta velocidad y precisión en la identificación de objetos en tiempo real. Estos modelos dividen la imagen de entrada en una cuadrícula y predicen las cajas delimitadoras y las probabilidades de clase para cada cuadrícula. Esta arquitectura ha sido ampliamente utilizada en la agricultura para la detección de malezas debido a su capacidad de procesar imágenes de alta resolución rápidamente.	TIA-YOLOv5: An improved YOLOv5 network for real-time detection of crop and weed in the field	Se desarrolló una red YOLOv5 mejorada denominada TIA-YOLOv5TIA-YOLOv5	Remolacha azucarera	El número total de imágenes alcanzó 5536. El conjunto de datos mejorado contiene 4100 imágenes originales y 1436 imágenes sintéticas, se dividió en un conjunto de entrenamiento, un conjunto de validación y un conjunto de prueba.

<p>https://www.mdpi.com/2073-4395/12/12/2953 Faster R-CNN es un modelo de detección de objetos de dos etapas que utiliza una Red de Propuestas de Regiones (RPN) para generar propuestas de objetos y luego clasificar estas regiones usando una red CNN. Esta arquitectura ha demostrado ser altamente efectiva para la detección precisa de malezas en diversos entornos agrícolas debido a su capacidad para manejar múltiples escalas y tipos de objetos.</p>	<p>Intelligent Weed Management Based on Object Detection Neural Networks in Tomato Crops</p>	<p>El procedimiento se basa en redes neuronales de detección de objetos llamadas RetinaNet. Además, también se evaluaron dos modelos actuales de detección de objetos convencionales, a saber, YOLOv7 y FasterRCNN</p>	<p>Tomate</p>	<p>Todas las imágenes fueron recolectadas en campos comerciales bajo condiciones reales de iluminación no controlada durante varios días en diferentes momentos, con el fin de capturar diferentes fondos del suelo, sombras y condiciones de iluminación. Se capturaron un total de 1713 imágenes.</p>
---	--	--	---------------	---

Fuente: creación propia.

Tabla 3

Resultados de análisis de los modelos de IA

Modelo	Descripción	Ventajas	Desventajas	Aplicaciones relevantes
ResNet (Residual Networks)	Red neuronal profunda con múltiples capas residuales para evitar problemas de gradiente desvanecido.	Alta precisión Evita el problema de gradiente desvanecido	Requiere gran capacidad computacional Tiempo de entrenamiento largo	Clasificación de imágenes, detección de objetos complejos donde la precisión es crítica.

Modelo	Descripción	Ventajas	Desventajas	Aplicaciones relevantes
VGG (Visual Geometry Group)	Red profunda con arquitectura simple y capas convolucionales de tamaño fijo.	Arquitectura simple Buen rendimiento en DataSets grandes	Muy intensivo en recursos Tiempo de entrenamiento largo	Adecuada para tareas de clasificación de imágenes y donde la simplicidad del modelo es preferida.
YOLO (You Only Look Once)	Algoritmo de detección de objetos en tiempo real	Detección en tiempo real Alta velocidad	Menor precisión en comparación con otros modelos Requiere ajustes finos	Ideal para aplicaciones en tiempo real debido a su rapidez, como en sistemas de vigilancia y vehículos autónomos.
Faster R-CNN	Red de Convolución con región propuesta rápida	Alta precisión Manejo eficiente de detección de múltiples objetos	Lento en comparación con YOLO Complejo de implementar	Utilizado en tareas donde se requiere alta precisión en la detección y clasificación de múltiples objetos en imágenes de alta resolución

Fuente: creación propia.

Paso 3: Síntesis de la evidencia

La síntesis de la evidencia se realizó mediante un análisis comparativo de los resultados obtenidos de los estudios evaluados. Los principales hallazgos fueron los siguientes:

- **ResNet (Residual Networks):** Se destacó por su alta precisión en la detección de malezas, gracias a su capacidad para manejar redes

profundas y complejas. Sin embargo, su velocidad de procesamiento y altos requerimientos computacionales limitan su aplicabilidad en escenarios de tiempo real.

- **VGG (Visual Geometry Group):** Ofreció una arquitectura más simple y una precisión competitiva, pero al igual que ResNet, sus altos requerimientos computacionales y menor velocidad de procesamiento presentaron desafíos para su implementación en campo.
- **YOLO (You Only Look Once):** Se destacó por su rapidez y capacidad de procesamiento en tiempo real, siendo especialmente adecuado para aplicaciones que requieren monitoreo continuo y decisiones rápidas. Sin embargo, su precisión fue ligeramente inferior en comparación con ResNet y VGG en algunas condiciones.
- **Faster R-CNN:** Combinó una alta precisión con una robustez significativa frente a variaciones en los datos de entrada. Aunque su velocidad de procesamiento fue mejor que la de ResNet y VGG, todavía no alcanzó la eficiencia de YOLO.

Discusión y debate teórico

La revisión sistemática de literatura sobre modelos de inteligencia artificial (IA) para la detección de malezas en cultivos de maíz blanco reveló que los diferentes modelos tienen características únicas que los hacen más o menos adecuados para esta tarea específica. Aquí se presentan los hallazgos de manera resumida y ordenados del modelo más adecuado al menos adecuado.

YOLO (You Only Look Once)

El modelo YOLO es el más adecuado para la detección de malezas debido a su capacidad de procesamiento en tiempo real. Redmon et al. (2016) demostraron que YOLO es extremadamente rápido, permitiendo el monitoreo continuo y respuestas rápidas en el campo, lo cual es crucial para aplicaciones prácticas en la agricultura de precisión. Aunque su precisión es ligeramente inferior a la de algunos modelos más complejos, su eficiencia y velocidad lo hacen ideal para su implementación en drones y sistemas de monitoreo agrícola.

Faster R-CNN

Faster R-CNN combina alta precisión con robustez, lo que lo hace muy efectivo para la detección de malezas en diversas condiciones. Ren et al. (2015) destacaron que este modelo genera propuestas de objetos de alta calidad y es muy preciso. Sin embargo, su velocidad de procesamiento es menor que la de YOLO, lo que puede limitar su uso en aplicaciones que requieren análisis en tiempo real. Aun así, es una opción sólida cuando la precisión es prioritaria y la velocidad no es crítica.

ResNet (Residual Networks)

ResNet es conocido por su alta precisión debido a su capacidad para manejar redes profundas y complejas, como señalaron He et al. (2016). No obstante, sus altos requerimientos computacionales y su menor velocidad de procesamiento lo hacen menos práctico para aplicaciones en campo que requieren decisiones rápidas. ResNet es más adecuado para situaciones donde la precisión extrema es necesaria y hay disponibilidad de recursos computacionales suficientes.

VGG (Visual Geometry Group)

El modelo VGG ofrece una arquitectura simple y competitiva en términos de precisión. Simonyan y Zisserman (2014) mostraron que VGG es fácil de entrenar y ajustar. Sin embargo, su eficiencia computacional y velocidad de procesamiento son menores, lo que limita su aplicabilidad en escenarios de monitoreo en tiempo real en la agricultura.

Conclusión

En conclusión, la revisión sistemática de la literatura sugiere que YOLO es el modelo más adecuado para la detección de malezas en cultivos de maíz blanco debido a su velocidad y eficiencia en tiempo real. Faster R-CNN también es altamente efectivo, especialmente en términos de precisión y robustez, pero su velocidad inferior lo hace menos práctico para

aplicaciones en tiempo real. ResNet y VGG, aunque precisos, presentan limitaciones significativas en términos de requerimientos computacionales y velocidad de procesamiento, lo que los hace menos adecuados para su uso en el campo. Estos hallazgos proporcionan una base sólida para la implementación de tecnologías de IA en la agricultura de precisión, mejorando la gestión de cultivos y promoviendo prácticas agrícolas más sostenibles.

Referencias

- Adamides, (2020). Smart farming for improving agricultural management. ScienceDirect. <https://www.sciencedirect.com>
- AI Index Report. (2024). Artificial Intelligence Index. Stanford AI Index.
- Akbar, M. (2023). A comparative study of AI models for plant disease detection. *Journal of Big Data*. Recuperado de *Journal of Big Data*
- Ayoub Shaikh (2023). Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science*.
- Dasgupta, P. (2023). An image processing approach for weed detection using deep learning. Springer
- Food and Agriculture Organization (FAO). (2024). Integrated Weed Management. *FAO Integrated Weed Management*
- Garcia, L., & Jimenez, J. M. (2021). A Wireless Sensor Network Deployment for Soil Moisture Monitoring in Precision Agriculture. *Sensors*. <https://www.mdpi.com>
- GeoPard Agriculture (2023). Monitoring and Detection Technologies in Agriculture. *GeoPard Agriculture*
- GeoPard Agriculture (2023). Weed Control in Agriculture. *GeoPard Agriculture*
- Gonzalez-Andujar, J. L. (2023). Integrated Weed Management: A Shift towards More Sustainable and Holistic Practices. *MDPI Agronomy*. *MDPI Agronomy*
- Haq, S. I. U. (2023). Weed detection in wheat crops using image analysis and AI. *Applied Sciences*, 13(15), 8840.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

- Hong (2022). Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review. *Frontiers in Plant Science*. <https://www.frontiersin.org>
- IEEE Xplore (2022). *Advances in Monitoring and Detection Technologies for Agriculture*. IEEE Xplore
- IEEE (2021). *Machine Learning Applications for Precision Agriculture*. IEEE Xplore. <https://ieeexplore.ieee.org>
- Kaur, H., & Sharma, R. (2023). Plant disease detection using AI technologies. *Frontiers in Plant Science*. *Frontiers in Plant Science*.
- Mishra, P. (2022). Advances in UAV and sensor technology for precision agriculture. *Remote Sensing*, 14(3), 503.
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358-371.
- Osorio, L. (2020). Deep learning based image processing in lettuce crops for weed detection. *ScienceDirect*.
- Oxford Bibliographies. (2022). *Theory and Practice of Biological Control*. Oxford Bibliographies
- Prostko, E. (2024). Evaluation of inference performance of deep learning models for real-time weed detection in an embedded computer. *Sensors*, 24(2), 514.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Rodrigues, G. C. (2021). *Precision Agriculture: Strategies and Technology Adoption*. *Agriculture 4.0 Review*. <https://www.agriculture.com>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- Sulaiman, M. N. (2021). Weed detection in maize fields using UAV imagery and deep learning. *Computers and Electronics in Agriculture*, 182, 105998.

- Engineering, Technology & Applied Science Research. (s. f.). Applications of Artificial Intelligence in Agriculture: A Review. Consultado el 4 de marzo de 2024 en <https://etasr.com/index.php/ETASR/article/view/2756/pdf>
- Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., & Maggio, A. (2021). Drone and sensor technology for sustainable weed management: a review. *Chemical and Biological Technologies in Agriculture*, 8(1), 1-11. <https://doi.org/10.1186/S40538-021-00217-8/TABLES/4>
- Huang, Y., Reddy, K. N., Fletcher, R. S., & Pennington, D. (2018). UAV Low-Altitude Remote Sensing for Precision Weed Management. *Weed Technology*, 32(1), 2-6. <https://doi.org/10.1017/WET.2017.89>
- Ildar, R. (2020). Artificial Intelligence in Weed Recognition Tasks. *Asian Journal of Applied Science and Technology*, 04(02), 70-81. <https://doi.org/10.38177/ajast.2020.4210>
- Miller, J. O., Shober, A. L., & VanGessel, M. J. (2022). Post-harvest drone flights to measure weed growth and yield associations. *Agricultural and Environmental Letters*, 7(1). <https://doi.org/10.1002/AEL2.20081>
- BASF México. (s. f.). Plagas y enfermedades en el cultivo del maíz: conoce las principales. <https://agriculture.basf.com/mx/es/contenidos-de-agricultura/plagas-enfermedades-maiz.html>
- Roslim, M. H. M., Juraimi, A. S., Che'ya, N. N., Sulaiman, N., Manaf, M. N. H. A., Ramli, Z., & Motmainna, M. (2021). Using Remote Sensing and an Unmanned Aerial System for Weed Management in Agricultural Crops: A Review. *Agronomy*, 11(9), 1809. <https://doi.org/10.3390/AGRONOMY11091809>
- Shahi, T. B., Dahal, S., Sitaula, C., Neupane, A., & Guo, W. (2023). Deep Learning-Based Weed Detection Using UAV Images: A Comparative Study. *Drones*, 7(10), 624. <https://doi.org/10.3390/DRONES7100624>
- Shahi, T. B., Xu, C.-Y., Neupane, A., Guo, W., Shahi, T. B., Xu, C.-Y., Neupane, A., & Guo, W. (2022). Machine learning methods for precision agriculture with UAV imagery: a review. *Electronic Research Archive*, 30(12), 4277-4317. <https://doi.org/10.3934/ERA.2022218>
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information* 2019, 10(11), 349. <https://doi.org/10.3390/INFO10110349>

- World Health Organization. (6 de junio de 2022). UN Report: Global hunger numbers rose to as many as 828 million in 2021. <https://www.who.int/news/item/06-07-2022-un-report--global-hunger-numbers-rose-to-as-many-as-828-million-in-2021>
- Westwood, J. H., Charudattan, R., Duke, S. O., Fennimore, S. A., Marrone, P., Slaughter, D. C., Swanton, C., & Zollinger, R. (2018). Weed Management in 2050: Perspectives on the Future of Weed Science. *Weed Science*, 66(3), 275-285. <https://doi.org/10.1017/wsc.2017.78>
- Zhang, J., Yu, F., Zhang, Q., Wang, M., Yu, J., & Tan, Y. (2024). Advancements of UAV and Deep Learning Technologies for Weed Management in Farmland. *Agronomy* 2024, 14(3), 494. <https://doi.org/10.3390/AGRONOMY14030494>

Capítulo 5

Desarrollo e implementación de un clasificador espectral para la discriminación de superficies terrestres y acuáticas utilizando datos de sentinel 2 y técnicas de aprendizaje automático

*Jesús Bojórquez Delgado¹
Gilberto Bojórquez Delgado²
Manuel Alfredo Flores Rosales³*

<https://doi.org/10.61728/AE24004541>



¹ Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México. Email: jesus.bd@guasave.tecnm.mx

² Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México. Email: gilberto.bd@guasave.tecnm.mx

³ Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Email: manuel.fr@guasave.tecnm.mx

Resumen

La clasificación precisa de superficies terrestres y acuáticas es fundamental para la gestión de recursos naturales, con aplicaciones en la agricultura de precisión y la gestión del agua. Este estudio desarrolló e implementó un clasificador espectral utilizando datos de Sentinel-2 y técnicas avanzadas de aprendizaje automático, evaluando algoritmos como CNN 1D, MLP, LSTM, GBM y Random Forest. Los resultados mostraron que el modelo CNN 1D alcanzó una precisión, recall y F1-score del 100 %, superando otros métodos tradicionales. La capacidad del modelo para capturar características espaciales complejas de los datos espectrales fue clave para su rendimiento. La matriz de confusión confirmó la efectividad del modelo sin errores de clasificación en el conjunto de prueba. Las implicaciones prácticas son significativas, permitiendo una clasificación confiable que mejora la gestión de recursos hídricos y terrestres. Sin embargo, se reconoce la necesidad de más recursos computacionales y una evaluación en conjuntos de datos más amplios y diversos. Futuras investigaciones deberían expandir el conjunto de datos y explorar la integración de otras técnicas para mejorar la robustez del modelo. Este estudio aporta al conocimiento académico y ofrece herramientas prácticas para la gestión y conservación de recursos naturales, proponiendo direcciones prometedoras para futuras investigaciones.

Introducción

La clasificación precisa de superficies terrestres y acuáticas es esencial para diversas aplicaciones en la gestión de recursos naturales, monitoreo ambiental y planificación del uso del suelo. La teledetección, especialmente con el uso de satélites como Sentinel-2, ha proporcionado datos espectrales de alta resolución que son fundamentales para estas tareas. Sentinel-2, lanzado por la Agencia Espacial Europea (ESA), ofrece una

cobertura global y una frecuencia de revisita de cinco días, características que lo hacen ideal para la monitorización continua del medioambiente (Huang et al., 2020).

La capacidad de Sentinel-2 para captar imágenes en 13 bandas espectrales permite una discriminación detallada entre diferentes tipos de superficies (López Calderón et al., 2023). Estas imágenes se utilizan ampliamente en la agricultura, la gestión de recursos hídricos y la vigilancia de cambios ambientales (Orynbaikyzy et al., 2020). La combinación de datos ópticos y de radar de apertura sintética (SAR) ha demostrado mejorar significativamente la precisión en la clasificación de la cobertura terrestre, facilitando un análisis más completo de las características biofísicas y estructurales de los objetos de interés (Eisfelder et al., 2024). Estudios han demostrado que la combinación de estas tecnologías puede aumentar la exactitud y robustez de los modelos de clasificación, proporcionando una herramienta valiosa para la gestión y conservación de recursos naturales (Eisfelder et al., 2024).

El uso de datos de Sentinel-2, en combinación con técnicas avanzadas de aprendizaje automático, representa una solución innovadora y eficaz para la clasificación de superficies terrestres y acuáticas (Phiri et al., 2020). Estudios recientes han mostrado que la integración de índices espectrales y características temporales puede mejorar significativamente la precisión de la clasificación en regiones propensas a nubosidad y otras perturbaciones atmosféricas (Gomez et al., 2019). Estos métodos permiten la utilización de análisis estadísticos temporales para caracterizar la variabilidad anual de la vegetación, proporcionando una mejor separabilidad entre diferentes tipos de cobertura terrestre (Yousefi et al., 2022). Además, se ha comprobado que la incorporación de datos multitemporales puede reducir la influencia de factores aleatorios como las condiciones meteorológicas, mejorando así la fiabilidad de los modelos predictivos (Huang et al., 2020).

La combinación de datos ópticos y de radar ha mostrado ser efectiva en la mejora de la precisión de la clasificación de cultivos y otras aplicaciones de monitoreo agrícola (Riego y Drenaje, 2021). Esta combinación permite una representación más amplia de la información biofísica y estructural de los objetos de interés, aumentando la exactitud y robu-

tez de los modelos de clasificación (Duan et al., 2023). En un estudio realizado en Etiopía, se demostró que la utilización conjunta de datos de Sentinel-1 y Sentinel-2 mejoraba la exactitud de la clasificación de tipos de cultivos, subrayando la importancia de disponer de un conjunto de datos de referencia suficiente para mejorar los resultados de los modelos (Eisfelder et al., 2024). Esta metodología también ha sido aplicada con éxito en otros contextos, como la clasificación de la textura del suelo y la identificación de especies de árboles, lo que resalta su versatilidad (Gomez et al., 2019).

El objetivo principal de este estudio es desarrollar e implementar un clasificador espectral para la discriminación de superficies terrestres y acuáticas utilizando datos de Sentinel-2 y técnicas de aprendizaje automático. Específicamente, se busca evaluar la eficacia de las bandas espectrales de Sentinel-2 para identificar las más relevantes en la discriminación entre superficies terrestres y acuáticas. Para ello, se desarrollará y entrenará un modelo de red neuronal que utilice estos datos espectrales, y se evaluará su rendimiento a través de métricas como precisión, recall y F1-score utilizando un conjunto de datos de prueba (Danuri y Mohd Pozi, 2024). Además, se analizará la capacidad del modelo para generalizar a diferentes regiones y condiciones ambientales, proporcionando así herramientas prácticas para el monitoreo y gestión de recursos naturales, con aplicaciones en agricultura de precisión, gestión del agua y conservación ambiental.

Este estudio no solo contribuirá al conocimiento académico, sino que también proporcionará herramientas prácticas para el monitoreo y gestión de recursos naturales. Las técnicas avanzadas de clasificación utilizando datos de Sentinel-2 y aprendizaje automático tienen el potencial de revolucionar la manera en que se gestionan los recursos naturales, permitiendo una toma de decisiones más informada y efectiva (Syrris et al., 2019).

El desarrollo de un clasificador espectral basado en datos de Sentinel-2 permitirá una mayor precisión en la discriminación de superficies terrestres y acuáticas, lo cual es esencial para la gestión eficaz de los recursos hídricos y la planificación del uso del suelo (Caballero Chávez y Duarte, 2023). Además, el uso de técnicas de aprendizaje automático permitirá automatizar y optimizar el proceso de clasificación, reduciendo

el tiempo y los recursos necesarios para obtener resultados precisos. La capacidad de este clasificador para generalizar a diferentes condiciones ambientales también lo hace una herramienta valiosa para su aplicación en diversas regiones y contextos, desde la agricultura de precisión hasta la conservación de ecosistemas críticos.

Metodología

Para desarrollar un clasificador espectral eficaz que discrimine entre superficies terrestres y acuáticas utilizando datos de Sentinel-2 y técnicas de aprendizaje automático, se ha diseñado una metodología rigurosa que incluye varias etapas clave: recolección y preprocesamiento de datos, desarrollo y entrenamiento del modelo, y evaluación y validación de su rendimiento. Este enfoque garantiza la precisión y robustez del modelo, además de su aplicabilidad en diferentes contextos geográficos y ambientales.

Materiales

Los materiales utilizados en este estudio son fundamentales para asegurar la calidad y precisión de los resultados obtenidos. A continuación, se detallan los principales componentes que incluyen datos satelitales, software y herramientas de procesamiento, hardware de alto rendimiento, y datos de referencia esenciales para la validación del modelo.

1. Datos Satelitales de Sentinel-2:

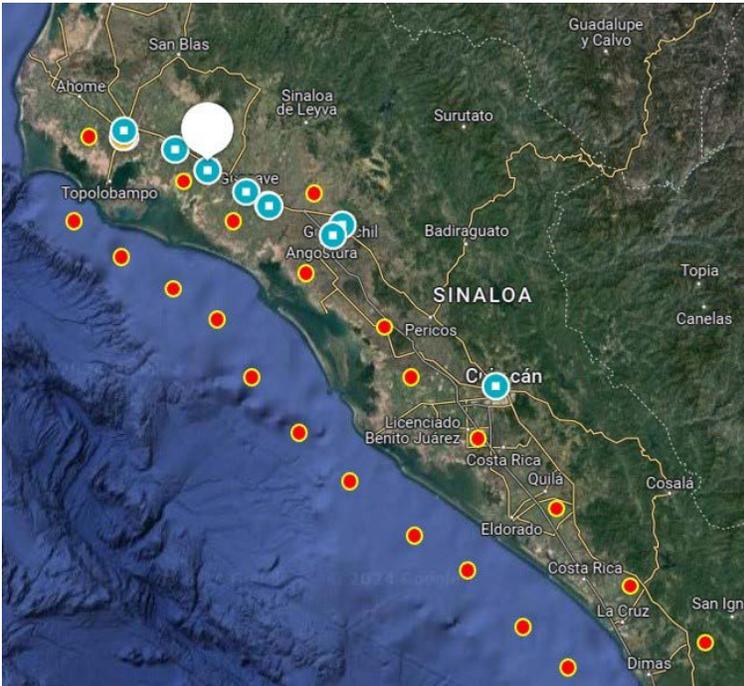
- **Imágenes multiespectrales:** Se utilizaron imágenes satelitales de Sentinel-2 que abarcan 13 bandas espectrales (B1 a B12 y B8A), proporcionando información en diferentes longitudes de onda desde el visible hasta el infrarrojo cercano y de onda corta. Las imágenes fueron obtenidas de la plataforma Sentinel Hub.
- **Resolución espacial y temporal:** Las imágenes seleccionadas tienen una resolución espacial de 10, 20 y 60 metros, dependiendo de la banda espectral, y una frecuencia de revisita de cinco días, lo que permite un monitoreo detallado y continuo de las áreas de estudio.
- **Niveles de procesamiento:** Se utilizaron datos de nivel 1C, que incluyen correcciones radiométricas y geométricas, y se procesaron a

nivel 2A para corrección atmosférica utilizando el algoritmo Sen2Cor, lo que proporciona reflectancias de superficie listas para análisis.

- Área de estudio: El área de estudio, ubicada en el estado de Sinaloa, México, abarca 22 puntos de muestreo, de los cuales 11 corresponden a superficies terrestres y 11 a cuerpos de agua. Dichos puntos, representados en la Figura 1 por círculos rojos, fueron seleccionados estratégicamente para asegurar una cobertura equilibrada y representativa de las distintas clases a discriminar. Esta distribución geoespacial permite validar la robustez del clasificador espectral al considerar tanto la variabilidad terrestre como la acuática dentro del contexto de la región de estudio.

Figura 1

Mapa del área de estudio en Sinaloa con los puntos de muestreo en tierra y agua.



2. Software y herramientas:

- **Google Earth Engine (GEE):** Esta plataforma se utilizó para la gestión y el procesamiento de grandes volúmenes de datos satelitales, aprovechando sus capacidades de computación en la nube para la generación de índices espectrales y la extracción de características.
- **Librerías de Python:** Se emplearon librerías como TensorFlow y Keras para el desarrollo y entrenamiento de modelos de aprendizaje automático, NumPy y Pandas para la manipulación y análisis de datos, y Scikit-learn para tareas de preprocesamiento y evaluación de modelos.
- **QGIS y SNAP:** Estas herramientas se utilizaron para la visualización y análisis geoespacial de las imágenes procesadas, permitiendo una inspección visual detallada y la generación de mapas temáticos.

3. Hardware:

- **Computadoras de alto rendimiento:** Se utilizaron estaciones de trabajo equipadas con unidades de procesamiento gráfico (GPU) NVIDIA, necesarias para acelerar el entrenamiento de modelos de redes neuronales profundas. Las especificaciones incluyen GPU de la serie NVIDIA RTX 3000, con 8 GB de memoria dedicada.
- **Almacenamiento y procesamiento:** Sistemas de almacenamiento de alta capacidad y velocidad (SSD) para manejar grandes volúmenes de datos de imágenes satelitales y facilitar un acceso rápido durante el preprocesamiento y entrenamiento del modelo.

4. Datos de referencia:

- **Ground Truth:** Datos de campo recogidos mediante campañas de muestreo que incluyen coordenadas geográficas precisas y clasificaciones de superficie (agua o tierra) para validar las predicciones del modelo. Estos datos son esenciales para entrenar y evaluar la precisión del clasificador.
- **Fuentes complementarias:** Información adicional obtenida de bases de datos geoespaciales públicas y estudios previos que proporcionan clasificaciones de uso del suelo y coberturas terrestres, utilizadas para complementar los datos de referencia.

Métodos

La metodología desarrollada se basa en un enfoque sistemático para asegurar la precisión y robustez del modelo. A continuación, se describen los métodos utilizados en cada una de las etapas del estudio, desde la recolección de datos hasta la validación del modelo.

1. Recolección de datos:

- Descarga de imágenes satelitales Sentinel-2 de alta resolución temporal y espacial, centradas en áreas de estudio específicas que incluyen superficies terrestres y acuáticas.
- Selección de imágenes multitemporales para capturar variaciones estacionales y reducir la influencia de condiciones atmosféricas temporales.
- Se tomaron muestras desde el primero de enero de 2018 hasta el 10 de julio de 2024, siendo 512 las seleccionadas, y descartadas las de menor calidad.

2. Preprocesamiento de datos:

- Aplicación de correcciones radiométricas y atmosféricas a las imágenes utilizando Sen2Cor.
- Generación de índices espectrales como NDVI (Normalized Difference Vegetation Index) y NDWI (Normalized Difference Water Index) para mejorar la discriminación de clases.
- Resampléo y normalización de las bandas espectrales para asegurar una consistencia en la resolución espacial.

3. Diseño del modelo:

- Desarrollo de un modelo de red neuronal convolucional (CNN) para la clasificación de imágenes, seleccionando hiperparámetros óptimos a través de técnicas de validación cruzada.
- Entrenamiento del modelo utilizando un conjunto de datos de entrenamiento balanceado que incluya ejemplos representativos de todas las clases (superficies terrestres y acuáticas).
- Implementación de técnicas de aumento de datos para mejorar la robustez del modelo y evitar el sobreajuste.

4. Experimentación y evaluación:

- División del conjunto de datos en subconjuntos de entrenamiento (70 %), validación (15 %) y prueba (15 %) para evaluar el rendimiento del modelo.
- Medición del rendimiento del modelo utilizando métricas como precisión, recall, F1-score y la matriz de confusión.
- Análisis de la capacidad de generalización del modelo mediante pruebas en diferentes regiones geográficas y bajo diversas condiciones ambientales.

5. Validación cruzada y optimización:

- Uso de validación cruzada k-fold para evaluar la estabilidad y robustez del modelo.
- Optimización de hiperparámetros mediante técnicas como Random Search y Bayesian Optimization para mejorar el rendimiento del modelo.

Resultados y discusión

En esta sección se presentan y analizan los resultados obtenidos del desarrollo e implementación de un clasificador espectral diseñado para discriminar entre superficies terrestres y acuáticas utilizando datos multi-espectrales de Sentinel-2 y técnicas avanzadas de aprendizaje automático. Se evaluaron múltiples algoritmos de clasificación, incluyendo redes neuronales convolucionales (CNN 1D), redes neuronales multicapa (MLP), modelos Long Short-Term Memory (LSTM), Gradient Boosting Machines (GBM) y Random Forest, con el objetivo de identificar el enfoque más preciso y robusto. Los resultados se detallan en términos de precisión, recall y F1-score, proporcionando una visión integral del rendimiento de cada modelo. Además, se discuten las implicaciones prácticas de estos hallazgos en la gestión de recursos naturales y se abordan las limitaciones del estudio, sugiriendo posibles direcciones para futuras investigaciones.

Distribución de las bandas espectrales

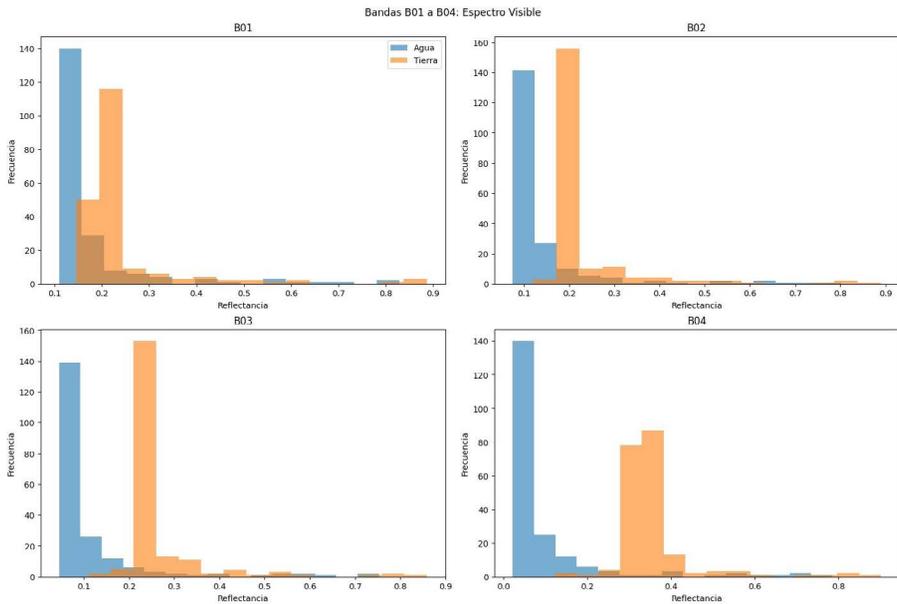
El análisis de la distribución de las bandas espectrales de Sentinel-2 para las superficies de agua y tierra proporciona una base sólida para la discriminación efectiva utilizando técnicas de aprendizaje automático. A continuación, se presentan los histogramas que muestran la distribución de reflectancias para cada banda espectral, diferenciando entre superficies de agua y tierra.

- Bandas B01 a B04: Espectro Visible
 - B01: Las superficies de agua tienen valores de reflectancia más bajos en comparación con las superficies de tierra.
 - B02: La reflectancia del agua es significativamente menor que la de la tierra.
 - B03: Las superficies de tierra muestran una mayor reflectancia en comparación con el agua.
 - B04: Las diferencias en la reflectancia son evidentes, con la tierra presentando valores más altos.

La Figura 2 muestra la distribución de reflectancia en el espectro visible. Se observa una clara separación entre las superficies de agua y tierra:

Figura 2

Distribución de Reflectancia en el Espectro Visible (B01 a B04).

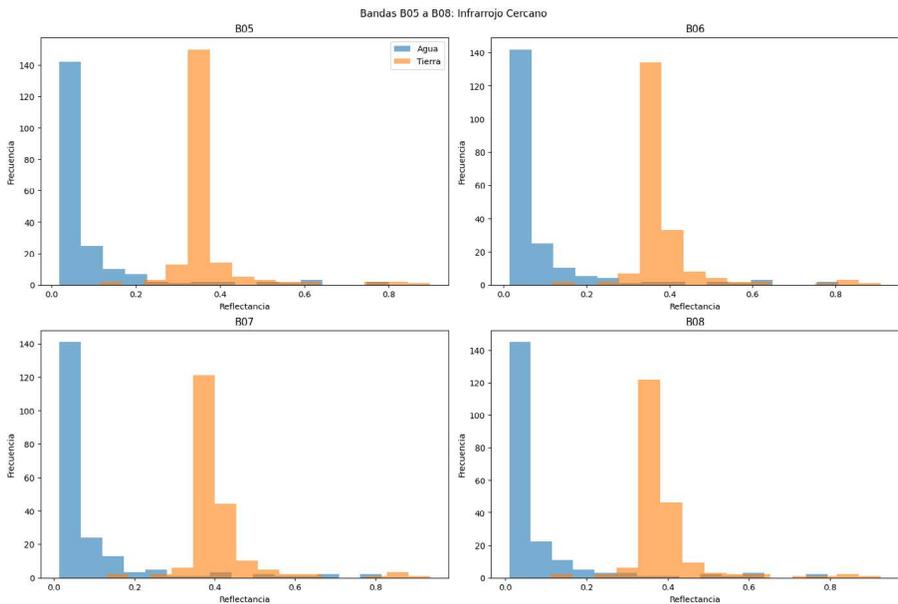


- **Bandas B05 a B08: Infrarrojo Cercano**
 - B05: La reflectancia del agua sigue siendo baja, mientras que la de la tierra es más alta.
 - B06: Se mantiene la tendencia de mayor reflectancia en superficies de tierra.
 - B07: La tierra presenta una mayor variabilidad en los valores de reflectancia.
 - B08: La discriminación entre agua y tierra es clara, con reflectancias significativamente diferentes.

La Figura 3 muestra la distribución de reflectancia en el infrarrojo cercano, con diferencias marcadas entre agua y tierra:

Figura 3

Distribución de Reflectancia en el Infrarrojo Cercano (B05 a B08).



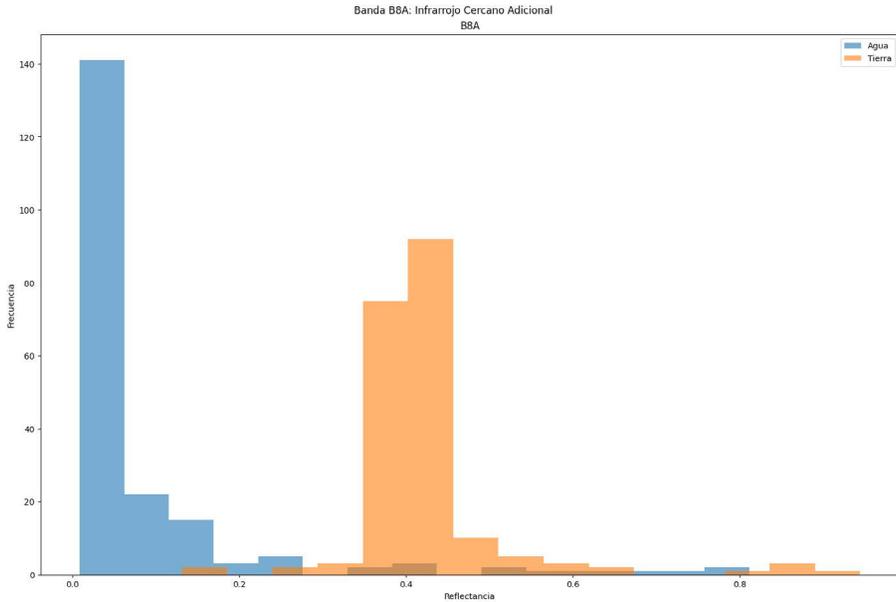
- Banda B8A: Infrarrojo Cercano Adicional
 - B8A: Los valores de reflectancia del agua son muy bajos en comparación con los de la tierra, lo que facilita su discriminación.

La Figura 4 evidencia una separación similar a las bandas anteriores del infrarrojo cercano, mostrando superficies de agua y tierra claramente diferenciadas en términos de reflectancia. Esta clara distinción en los patrones de reflectancia no solo confirma la utilidad de la banda B8A para la clasificación precisa de cuerpos de agua y suelos, sino que también refuerza su potencial como insumo crítico en modelos de predicción más sofisticados. La capacidad de esta banda para diferenciar superficies en imágenes satelitales resulta crucial en el monitoreo de recursos hídricos, facilitando la detección temprana de variaciones en cuerpos de agua y optimizando la gestión de ecosistemas. Asimismo, esta discriminación es

especialmente relevante en sistemas de agricultura de precisión, donde la identificación precisa de superficies es fundamental para una toma de decisiones informada y oportuna en la gestión de cultivos.

Figura 4

Distribución de Reflectancia en el Infrarrojo Cercano Adicional (B8A).

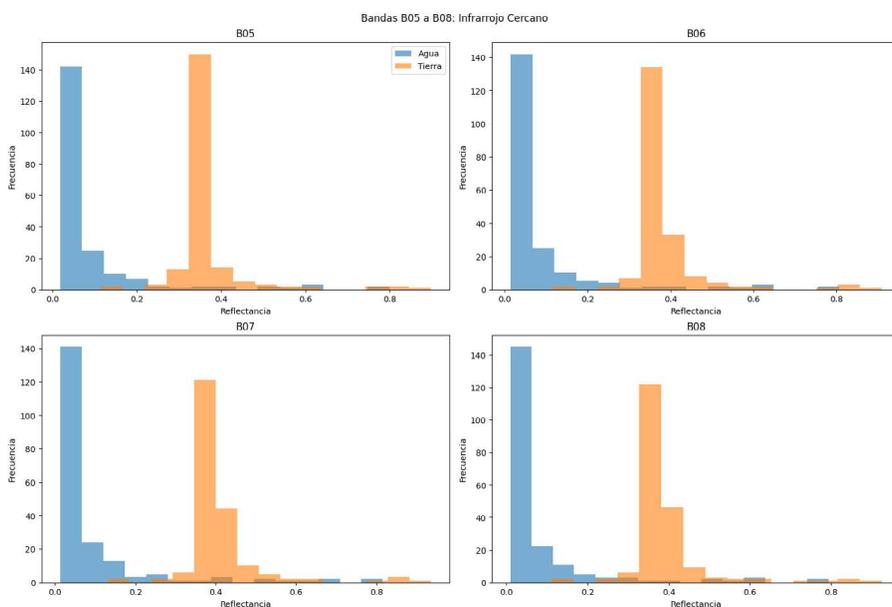


- Bandas B09 a B12: Infrarrojo de Onda Corta
 - B09: Las superficies de agua tienen valores de reflectancia muy bajos, mientras que las de tierra son más variadas.
 - B10: La reflectancia del agua sigue siendo baja, con la tierra mostrando una mayor variabilidad.
 - B11: La tierra presenta una reflectancia mucho más alta en comparación con el agua.
 - B12: La discriminación entre agua y tierra es muy marcada, con diferencias significativas en los valores de reflectancia.
- Las bandas del infrarrojo de onda corta (B09 a B12) complementan la discriminación entre agua y tierra observada en la banda B8A. En particular, la banda B09 muestra valores muy bajos para el agua, mientras que la tierra presenta mayor variabilidad. Conforme se avan-

za hacia B12, la separación entre ambos tipos de superficie se vuelve aún más evidente, consolidando la utilidad de estas bandas para la clasificación precisa del terreno y la gestión de recursos naturales.

La Figura 5 presenta la distribución de reflectancia en el infrarrojo de onda corta, destacando las diferencias entre agua y tierra:

Figura 5
Distribución de Reflectancia en el Infrarrojo de Onda Corta (B09 a B12).



Comparación de clasificadores

La Tabla 1 resume la precisión promedio y la desviación estándar de los diferentes algoritmos de clasificación. Estos resultados se obtuvieron mediante validación cruzada, lo que permite evaluar la estabilidad y la capacidad de generalización de cada modelo.

Tabla 1*Precisión promedio de validación cruzada de los clasificadores.*

Clasificador	Precisión promedio \pm Desviación estándar
Red Neuronal Convolutacional 1D (CNN 1D)	97.97 % \pm 2.06 %
Red Neuronal Multicapa (MLP)	97.20 % \pm 1.86 %
Long Short-Term Memory (LSTM)	97.20 % \pm 1.23 %
Gradient Boosting Machines (GBM)	96.18 % \pm 1.37 %
Random Forest	94.39 % \pm 1.70 %

Red Neuronal Convolutacional 1D (CNN 1D): Este clasificador obtuvo la mayor precisión promedio (97.97 %) con una desviación estándar de 2.06 %. Su rendimiento superior se puede atribuir a su capacidad para capturar características espaciales complejas en los datos espectrales.

Red Neuronal Multicapa (MLP) y Long Short-Term Memory (LSTM): Ambos clasificadores mostraron un rendimiento similar, con precisiones promedio de 97.20 % y desviaciones estándar de 1.86 % y 1.23 %, respectivamente. La MLP es eficiente en la clasificación de datos multidimensionales, mientras que el LSTM es particularmente útil para secuencias de datos temporales.

Gradient Boosting Machines (GBM): Este modelo alcanzó una precisión promedio de 96.18 % con una desviación estándar de 1.37 %. GBM es conocido por su capacidad de mejorar el rendimiento mediante la combinación de múltiples árboles de decisión débiles.

Random Forest: Aunque este clasificador tuvo la menor precisión promedio (94.39 %), su desviación estándar de 1.70 % indica una estabilidad razonable. Random Forest es efectivo para evitar el sobreajuste y manejar conjuntos de datos con muchas características.

Evaluación del modelo principal

En esta sección se presentan los resultados detallados del mejor clasificador, identificado como la Red Neuronal Convolutacional 1D (CNN 1D). Se incluyen métricas de evaluación como precisión, recall y F1-score, así como una matriz de confusión que visualiza la distribución de las

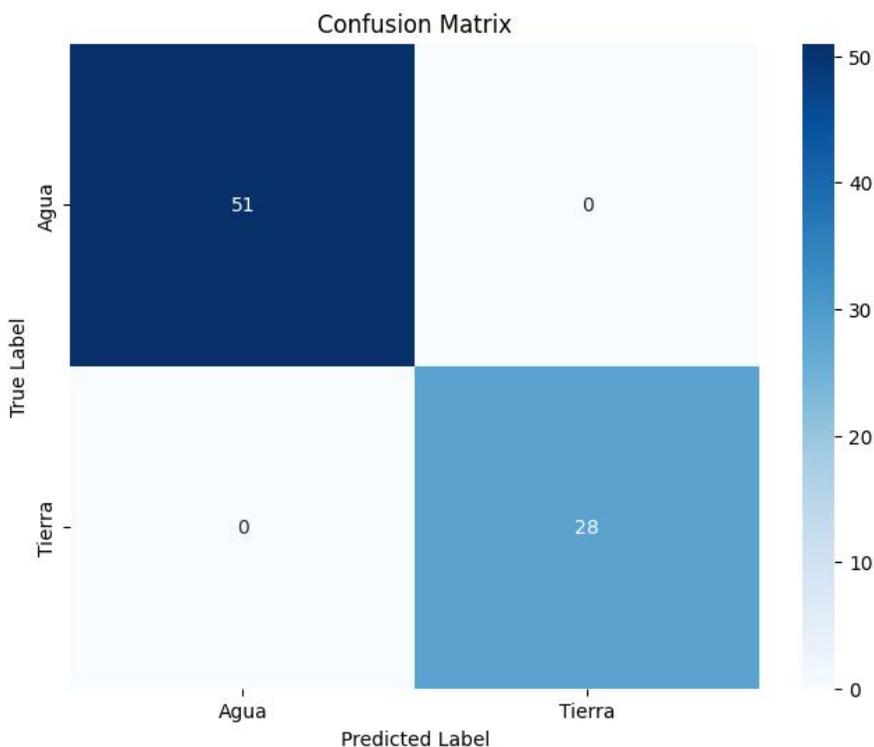
clasificaciones correctas e incorrectas del modelo. Este análisis permite comprender la efectividad del clasificador y su capacidad para distinguir entre superficies de agua y tierra.

- Matriz de confusión

La matriz de confusión presentada en la Figura 6 muestra la distribución de las clasificaciones realizadas por el modelo CNN 1D. En esta matriz, los valores en la diagonal principal representan las clasificaciones correctas, mientras que los valores fuera de la diagonal indican clasificaciones incorrectas.

Figura 6

Matriz de Confusión del Modelo CNN 1D.



La matriz de confusión muestra que el modelo CNN 1D clasificó correctamente todas las muestras de agua y tierra, con 51 muestras de agua y 28 muestras de tierra clasificadas correctamente. No hubo clasificaciones incorrectas, lo que indica un rendimiento perfecto en este conjunto de prueba.

Discusión

Los resultados obtenidos en este estudio demuestran la eficacia de la Red Neuronal Convolutiva 1D (CNN 1D) para la clasificación de superficies terrestres y acuáticas utilizando datos espectrales de Sentinel-2. La precisión, recall y F1-score del 100 % en el conjunto de prueba indican que el modelo es altamente preciso y no presenta errores de clasificación. Este rendimiento sobresaliente puede atribuirse a varias razones que se discuten a continuación.

La precisión y efectividad del modelo CNN 1D en este estudio superan las métricas reportadas en estudios previos que utilizan otros enfoques de clasificación para datos de teledetección. Por ejemplo, investigaciones que emplearon técnicas como Support Vector Machines (SVM) y Random Forests reportaron precisiones que oscilaban entre el 85 % y el 95 % (Hao et al., 2024). La capacidad del CNN 1D para capturar características espaciales complejas.

Conclusiones

El presente estudio ha demostrado la eficacia de la Red Neuronal Convolutiva 1D (CNN 1D) para la clasificación precisa de superficies terrestres y acuáticas utilizando datos espectrales de Sentinel-2. Los resultados obtenidos destacan varias conclusiones importantes:

Alto rendimiento del modelo CNN 1D: El modelo CNN 1D mostró una precisión, recall y F1-score del 100 % en el conjunto de prueba, superando significativamente otros métodos tradicionales de clasificación utilizados en estudios previos, como Support Vector Machines (SVM) y Random Forests, los cuales reportaron precisiones entre el 85 % y el 95 % (Hao et al., 2024), (Zhang et al., 2019).

Capacidad para capturar características espaciales complejas: La capacidad del CNN 1D para manejar grandes volúmenes de datos espectrales multibanda y capturar características espaciales complejas fue fundamental para su éxito. Este enfoque permitió una discriminación precisa entre superficies de agua y tierra, lo cual es crucial para aplicaciones prácticas como la gestión de recursos naturales y la agricultura de precisión.

Implicaciones prácticas significativas: La alta precisión del modelo CNN 1D tiene importantes implicaciones prácticas. En la agricultura de precisión, por ejemplo, la capacidad de diferenciar entre superficies de agua y tierra con alta exactitud puede mejorar significativamente las prácticas de riego y la gestión de cultivos. Además, en la gestión de recursos hídricos, una clasificación confiable de las superficies es crucial para monitorear y gestionar eficientemente los recursos disponibles.

Limitaciones y necesidades de recursos computacionales: Aunque el modelo CNN 1D mostró un rendimiento excelente, es importante reconocer sus limitaciones. El entrenamiento y ajuste de hiperparámetros requieren considerables recursos computacionales, lo cual puede limitar su aplicabilidad en entornos con restricciones de hardware. Además, la evaluación se realizó en un conjunto de datos relativamente pequeño y específico, lo que requiere una evaluación adicional para garantizar la generalización del modelo a otras regiones y condiciones ambientales.

Futuras direcciones de investigación: Para mejorar la robustez y la capacidad de generalización del modelo CNN 1D, futuras investigaciones deberían centrarse en expandir el conjunto de datos de prueba para incluir diversas regiones y condiciones ambientales. La integración de datos adicionales, como información topográfica y meteorológica, podría mejorar aún más la precisión del modelo. Además, la combinación de CNN 1D con otros enfoques de aprendizaje profundo, como redes neuronales recurrentes (RNN) o modelos híbridos, puede capturar tanto las características espaciales como las temporales de los datos espectrales. La implementación de técnicas de aprendizaje federado también representa una prometedora dirección para entrenar modelos colaborativos preservando la privacidad de los datos.

Referencias

Caballero Chávez, C., & Duarte, V. (2023). Análisis de la variación de la Temperatura de la Superficie Terrestre (TST) y del Índice Diferencial de Vegetación Normalizado (IVN) en el área metropolitana de Asunción. *Revista de la Sociedad Científica del Paraguay*, 28(2), 352-369. <https://doi.org/10.32480/rscp.2023.28.2.352>

- Danuri, D., & Mohd Pozi, M. (2024). Machine Learning Approaches for Fish Pond Water Quality Classification: Random Forest, Gaussian Naive Bayes, and Decision Tree Comparison. *Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023, September 21st, 2023, Bengkalis, Riau, Indonesia*. *Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023, September 21st, 2023, Bengkalis, Riau, Indonesia, Bengkalis, Indonesia*. <https://doi.org/10.4108/eai.21-9-2023.2342964>
- Duan, J., Wang, H., Wang, C., Nie, S., Yang, X., & Xi, X. (2023). Denoising and classification of urban ICESat-2 photon data fused with Sentinel-2 spectral images. *International Journal of Digital Earth*, 16(2), 4346-4367. <https://doi.org/10.1080/17538947.2023.2270513>
- Eisfelder, C., Boemke, B., Gessner, U., Sogno, P., Alemu, G., Hailu, R., Mesmer, C., & Huth, J. (2024). Cropland and Crop Type Classification with Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine for Agricultural Monitoring in Ethiopia. *Remote Sensing*, 16(5), 866. <https://doi.org/10.3390/rs16050866>
- Gomez, C., Dharumarajan, S., Féret, J.-B., Lagacherie, P., Ruiz, L., & Sekhar, M. (2019). Use of Sentinel-2 Time-Series Images for Classification and Uncertainty Analysis of Inherent Biophysical Property: Case of Soil Texture Mapping. *Remote Sensing*, 11(5), 565. <https://doi.org/10.3390/rs11050565>
- Hao, M., Dong, X., Jiang, D., Yu, X., Ding, F., & Zhuo, J. (2024). Land use classification based on high-resolution remote sensing imagery and deep learning models. *PLOS ONE*, 19(4), e0300473. <https://doi.org/10.1371/journal.pone.0300473>
- Huang, C., Zhang, C., He, Y., Liu, Q., Li, H., Su, F., Liu, G., & Bridhikitti, A. (2020). Land Cover Mapping in Cloud-Prone Tropical Areas Using Sentinel-2 Data: Integrating Spectral Features with Ndvi Temporal Dynamics. *Remote Sensing*, 12(7), 1163. <https://doi.org/10.3390/rs12071163>
- López-Calderón, M. J., Estrada-Ávalos, J., Martínez-Sifuentes, A. R., Trucíos-Caciano, R., & Miguel-Valle, E. (2023). Nitrógeno total en maíz forrajero (*Zea mays* L.) estimado mediante índices espectrales con el satélite Sentinel-2. *Revista Terra Latinoamericana*, 41. <https://doi.org/10.28940/terra.v41i0.1628>

- Orynbaikyzy, A., Gessner, U., Mack, B., & Conrad, C. (2020). Crop Type Classification Using Fusion of Sentinel-1 and Sentinel-2 Data: Assessing the Impact of Feature Selection, Optical Data Availability, and Parcel Sizes on the Accuracies. *Remote Sensing*, 12(17), 2779. <https://doi.org/10.3390/rs12172779>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), 2291. <https://doi.org/10.3390/rs12142291>
- Riego y Drenaje, Facultad de Agronomía de Buenos Aires, Buenos Aires, Argentina, Salgado, H., Zabala, S. M., Romay, C., Bernier, M., Jacome, A., Chokmani, K., Meteorología, Servicio de Hidrografía Naval, Ministerio de Defensa, Argentina, & Institut National de la Recherche Scientifique, Université du Québec, Québec, Canada. (2021). Estimación de la humedad superficial del suelo mediante datos SAR en banda X. *Meteorologica*, 46(1), e001-e001. <https://doi.org/10.24215/1850468Xe001>
- Syrris, V., Hasenohr, P., Delipetrev, B., Kotsev, A., Kempeneers, P., & Soille, P. (2019). Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of Sentinel-2 Imagery. *Remote Sensing*, 11(8), 907. <https://doi.org/10.3390/rs11080907>
- Yousefi, S., Mirzaee, S., Almohamad, H., Al Dughairi, A. A., Gomez, C., Siamian, N., Alrasheedi, M., & Abdo, H. G. (2022). Image Classification and Land Cover Mapping Using Sentinel-2 Imagery: Optimization of SVM Parameters. *Land*, 11(7), 993. <https://doi.org/10.3390/land11070993>
- Zhang, W., Tang, P., & Zhao, L. (2019). Remote Sensing Image Scene Classification Using CNN-CapsNet. *Remote Sensing*, 11(5), 494. <https://doi.org/10.3390/rs11050494>

Acerca de los autores

Ing. José de Jesús Valenzuela Hernández (ORCID: <https://orcid.org/0009-0009-6152-4186>), originario de Los Mochis, Sinaloa, nacido en 1993, es un docente que imparte clases en el CONALEP, el Instituto Tecnológico de Los Mochis y la Universidad Autónoma Indígena de México. Con formación en ingeniería mecatrónica con especialidad en automatización industrial, actualmente está cursando una maestría en Sistemas Computacionales con línea de investigación en drones en la Universidad Autónoma Indígena de México. Ha participado como instructor en talleres sobre MATLAB, control, automatización, impresión 3D y drones, y ha contribuido en robótica educativa con los sets de LEGO EV3 y WeDo 2.0. Además, ha sido jurado y asesor en concursos científicos y tecnológicos, destacándose en la World Robot Olympiad™ y FIRST Lego League Challenge. Entre sus obras destacadas se encuentran el análisis de sistemas mecatrónicos con MATLAB y Simulink, el diseño e implementación de algoritmos de control para prótesis antropomórficas y el desarrollo de manuales de prácticas en electrónica de potencia aplicada.

Ing. Giovanni Mora Castro (ORCID: <https://orcid.org/0009-0004-6108-9122>), es un ingeniero especializado en Electrónica Digital y Diseño Gráfico Digital, egresado del Instituto Tecnológico Nacional de México y del Instituto Tecnológico Superior de Los Mochis, donde se distinguió por su alto rendimiento académico. Actualmente, cursa el cuarto semestre de la Maestría en Sistemas Computacionales, centrando su investigación en el uso de vehículos aéreos no tripulados para la optimización de procesos agrícolas. Su proyecto, titulado “Evaluación cuantitativa de tasas de germinación en agroecosistemas mediante análisis espectrométrico de imágenes RGB capturadas por vehículos aéreos no tripulados y procesadas con redes neuronales convolucionales”, refleja su compromiso con la innovación tecnológica en la agricultura.

Dr. Gilberto Bojórquez Delgado (ORCID: <https://orcid.org/0009-0000-7829-6540>) tiene estudios en Ingeniería Electrónica por el Instituto Tecnológico de Los Mochis, Maestro en Ciencias en Ingeniería Electrónica por el Instituto Tecnológico de Chihuahua. Doctorado en Ciencias por la Universidad Autónoma Indígena de México. Investigador honorífico del Sistema Sinaloense de Investigadores y Tecnólogos de la Coordinación General para el Fomento a la Investigación Científica e Innovación del Estado de Sinaloa (SSIT- CONFIE), Cuenta con Reconocimiento a Perfil Deseable del Programa para el Desarrollo Profesional Docente (PRODEP). Es Integrante del Sistema Nacional de Investigadores de Conacyt Nivel II. Líder del cuerpo académico “Tecnologías estrategias de vanguardia aplicadas para el desarrollo sustentable de sistemas agroindustriales de precisión”, presidente del consejo de posgrado de la Maestra en ciencias en desarrollo regional y tecnológico del Instituto Tecnológico Superior de Guasave.

Profesor Investigador en el Instituto Tecnológico Superior de Guasave en el Programa Educativo de Ingeniería en Sistemas Computacionales. El Dr. Bojórquez ha publicado diversos artículos y capítulos de libro científicos y ha creado desarrollados tecnológicos enfocados a sistemas agroindustriales, ha participado en diversos proyectos de investigación vinculados al sector productivo regional, nacional e internacional, su línea de trabajo se enfoca en el desarrollo de tecnologías estratégicas de vanguardia como lo son el Internet de las cosas, inteligencia artificial, Bigdata, Agricultura de precisión con el objetivo de reducir la dependencia tecnología de México respecto a otros países y fomentar la tecnología para impulsar el desarrollo regional con un enfoque sostenible.

José Luis Cervantes es Licenciado en Informática, egresado del Instituto Tecnológico de Los Mochis en 2009. Actualmente, cursa una maestría en Sistemas Computacionales en la Universidad Autónoma Indígena de México. Ha participado en diversos congresos y ha ofrecido pláticas sobre ciencia. Además, es piloto de vehículos aéreos no tripulados (VANT) de ala fija y multirrotor, así como astrónomo amateur.

Correo electrónico: joseluis.cervantes81@gmail.com
ORCID <https://orcid.org/0009-0005-4169-359X>

Isaac Alfredo Ochoa Segundo es Licenciado en Diseño Gráfico, egresado de la Universidad del Noroeste (UNO), Hermosillo, Sonora. Actualmente, cursa una maestría en Sistemas Computacionales en la Universidad Autónoma Indígena de México. Además, ha participado y apoyado en diversos congresos y ha ofrecido capacitaciones en las áreas de manejo de plotter de gran formato en diferentes empresas. Actualmente, está emprendiendo como piloto de vehículos aéreos no tripulados (VANT). Correo electrónico: profeisaacsegundo@gmail.com
ORCID <https://orcid.org/0009-0003-8333-0629>

Dr. Gilberto Bojórquez Delgado tiene estudios en Ingeniería Electrónica por el Instituto Tecnológico de Los Mochis, maestro en Ciencias en Ingeniería Electrónica por el Instituto Tecnológico de Chihuahua. Doctorado en Ciencias por la Universidad Autónoma Indígena de México. Investigador honorífico del Sistema Sinaloense de Investigadores y Tecnólogos de la Coordinación General para el Fomento a la Investigación Científica e Innovación del Estado de Sinaloa (SSIT- CONFÍE). Cuenta con Reconocimiento a Perfil Deseable del Programa para el Desarrollo Profesional Docente (PRODEP). Es Integrante del Sistema Nacional de Investigadores de Conacyt Nivel II. Líder del cuerpo académico “Tecnologías estrategias de vanguardia aplicadas para el desarrollo sustentable de sistemas agroindustriales de precisión”, presidente del consejo de posgrado de la Maestra en ciencias en desarrollo regional y tecnológico del Instituto Tecnológico Superior de Guasave.

Profesor Investigador en el Instituto Tecnológico Superior de Guasave en el Programa Educativo de Ingeniería en Sistemas Computacionales. El Dr. Bojórquez ha publicado diversos artículos y capítulos de libro científicos y ha creado desarrollados tecnológicos enfocados a sistemas agroindustriales, ha participado en diversos proyectos de investigación vinculados al sector productivo regional, nacional e internacional, su línea de trabajo se enfoca en el desarrollo de tecnologías estratégicas de vanguardia como lo son el Internet de las cosas, inteligencia artificial, bigdata, Agricultura de precisión con el objetivo de reducir la dependencia tecnológica de México respecto a otros países

y fomentar la tecnología para impulsar el desarrollo regional con un enfoque sostenible.

Correo electrónico: itsg.gbojorquez@gmail.com

ORCID <https://orcid.org/0009-0000-7829-6540>

Ing. Giovanni Mora Castro, es un ingeniero apasionado por la tecnología y la innovación. Se graduó en Ingeniería Electrónica con especialidad en Electrónica Digital y en Diseño Gráfico Digital por el Instituto Tecnológico Nacional de México, campus Los Mochis. Actualmente cursa el cuarto semestre de la Maestría en Sistemas Computacionales, investigando el uso de vehículos aéreos no tripulados para mejorar procesos agrícolas. Es fundador y docente de la carrera Profesional Técnico en Pilotaje de Drones en el CONALEP Los Mochis 2, con capacitación en la WNMU. Ha recibido reconocimientos como Docente Destacado a nivel nacional. Su trabajo se centra en la innovación, la educación y el impacto positivo de la tecnología. Su investigación actual se titula “Evaluación cuantitativa de tasas de germinación en agroecosistemas mediante análisis espectrométrico de imágenes RGB capturadas por vehículos aéreos no tripulados y procesadas con redes neuronales convolucionales”. Este proyecto refleja su compromiso con la aplicación de tecnología en la agricultura.

Ing. José de Jesús Valenzuela Hernández, originario de Los Mochis, Sinaloa, nacido en 1993, es un docente que imparte clases en el CONALEP, el Instituto Tecnológico de Los Mochis y la Universidad Autónoma Indígena de México. Con formación en ingeniería mecatrónica con especialidad en automatización industrial, actualmente está cursando una maestría en Sistemas Computacionales con línea de investigación en drones en la Universidad Autónoma Indígena de México. Ha participado como instructor en talleres sobre MATLAB, control, automatización, impresión 3D y drones, y ha contribuido en robótica educativa con los sets de LEGO EV3 y WeDo 2.0. Además, ha sido jurado y asesor en concursos científicos y tecnológicos, destacándose en la World Robot Olympiad™ y FIRST Lego League Challenge. Entre sus obras destacadas se encuentran el análisis de sistemas

mecatrónicos con MATLAB y Simulink, el diseño e implementación de algoritmos de control para prótesis antropomórficas y el desarrollo de manuales de prácticas en electrónica de potencia aplicada.

Dr. Gilberto Bojórquez Delgado tiene estudios en Ingeniería Electrónica por el Instituto Tecnológico de Los Mochis, Maestro en Ciencias en Ingeniería Electrónica por el Instituto Tecnológico de Chihuahua. Doctorado en Ciencias por la Universidad Autónoma Indígena de México. Investigador honorífico del Sistema Sinaloense de Investigadores y Tecnólogos de la Coordinación General para el Fomento a la Investigación Científica e Innovación del Estado de Sinaloa (SSIT-CONFÍE), Cuenta con Reconocimiento a Perfil Deseable del Programa para el Desarrollo Profesional Docente (PRODEP). Es Integrante del Sistema Nacional de Investigadores de Conacyt Nivel II. Líder del cuerpo académico “Tecnologías estrategias de vanguardia aplicadas para el desarrollo sustentable de sistemas agroindustriales de precisión”, presidente del consejo de posgrado de la Maestra en ciencias en desarrollo regional y tecnológico del Instituto Tecnológico Superior de Guasave. Profesor Investigador en el Instituto Tecnológico Superior de Guasave en el Programa Educativo de Ingeniería en Sistemas Computacionales. El Dr. Bojórquez ha publicado diversos artículos y capítulos de libro científicos y ha creado desarrollados tecnológicos enfocados a sistemas agroindustriales, ha participado en diversos proyectos de investigación vinculados al sector productivo regional, nacional e internacional, su línea de trabajo se enfoca en el desarrollo de tecnologías estratégicas de vanguardia como lo son el Internet de las cosas, inteligencia artificial, bigdata, agricultura de precisión con el objetivo de reducir la dependencia tecnología de México respecto a otros países y fomentar la tecnología para impulsar el desarrollo regional con un enfoque sostenible.

Ing. Karla Vanessa Ayala Cruz, (ORCID: <https://orcid.org/0009-0009-6312-758X>) originaria de Los Mochis, Sinaloa, nacida en 1978, es docente de la preparatoria Ciudad Universitaria Mochis de la Universidad Autónoma de Sinaloa, también ha impartido clases en la Facultad de

Ingeniería Mochis en la carrera de Control de Procesos Industriales. Cuenta con formación profesional en Ingeniería Electrónica con especialidad en sistemas digitales, egresada del Instituto Tecnológico de Los Mochis, actualmente se desempeña como docente del área Físico-Matemático y cursa la Maestría en Sistemas Computacionales con línea de investigación en drones en la Universidad Autónoma Indígena de México. Cuenta con una maestría en educación en el área de la docencia e investigación por la Universidad Santander.

Ing. José de Jesús Valenzuela Hernández (ORCID: <https://orcid.org/0009-0009-6152-4186>), originario de Los Mochis, Sinaloa, nacido en 1993, es un docente que imparte clases en el CONALEP, el Instituto Tecnológico de Los Mochis y la Universidad Autónoma Indígena de México. Con formación en ingeniería mecatrónica con especialidad en automatización industrial, actualmente está cursando una maestría en Sistemas Computacionales con línea de investigación en drones en la Universidad Autónoma Indígena de México. Ha participado como instructor en talleres sobre MATLAB, control, automatización, impresión 3D y drones, y ha contribuido en robótica educativa con los sets de LEGO EV3 y WeDo 2.0. Además, ha sido jurado y asesor en concursos científicos y tecnológicos, destacándose en la World Robot Olympiad™ y FIRST Lego League Challenge.

Dr. Gilberto Bojórquez Delgado (ORCID: <https://orcid.org/0009-0000-7829-6540>) tiene estudios en Ingeniería Electrónica por el Instituto Tecnológico de Los Mochis, Maestro en Ciencias en Ingeniería Electrónica por el Instituto Tecnológico de Chihuahua. Doctorado en Ciencias por la Universidad Autónoma Indígena de México. Investigador honorífico del Sistema Sinaloense de Investigadores y Tecnólogos de la Coordinación General para el Fomento a la Investigación Científica e Innovación del Estado de Sinaloa (SSIT- CONFÍE), Cuenta con Reconocimiento a Perfil Deseable del Programa para el Desarrollo Profesional Docente (PRODEP). Es Integrante del Sistema Nacional de Investigadores de Conacyt Nivel II. Líder del cuerpo académico “Tecnologías estrategias de vanguardia aplicadas para el desarrollo

sustentable de sistemas agroindustriales de precisión”, presidente del consejo de posgrado de la Maestra en ciencias en desarrollo regional y tecnológico del Instituto Tecnológico Superior de Guasave. Profesor Investigador en el Instituto Tecnológico Superior de Guasave en el Programa Educativo de Ingeniería en Sistemas Computacionales.

El **MC. Jesús Bojórquez Delgado**, graduado en Sistemas Computacionales de la Universidad de Occidente, y de la Maestría en Sistemas Computacionales y actualmente estudia un Doctorado en la misma especialidad en la Universidad Autónoma Indígena de México. Es docente en el Instituto Tecnológico Superior de Guasave. Además, es miembro del cuerpo académico Tecnologías estratégicas de vanguardia aplicadas para el desarrollo sustentable de sistemas agroindustriales de precisión. Sus áreas de interés se centran en sistemas inteligentes, contribuyendo al avance y la aplicación de estas tecnologías en el contexto agroindustrial.

El **Dr. Gilberto Bojórquez Delgado** es egresado en Ingeniería Electrónica por el Instituto Tecnológico de Los Mochis, con una Maestría en Ciencias en Ingeniería Electrónica por el Instituto Tecnológico de Chihuahua y un Doctorado en Ciencias por la Universidad Autónoma Indígena de México. Como miembro del Sistema Nacional de Investigadores de Conahcyt con Nivel II, su especialización abarca tecnologías avanzadas aplicadas a sistemas agroindustriales, con énfasis en IoT, inteligencia artificial y big data. Su enfoque de investigación se centra en la promoción de la autosuficiencia tecnológica y el desarrollo regional sostenible, donde su trabajo incluye numerosas publicaciones y proyectos en investigación teórica y aplicada, que buscan generar soluciones innovadoras para el sector agrícola y optimizar el uso de los recursos en regiones rurales.

El **Ingeniero Manuel Alfredo Flores Rosales** es egresado del programa educativo de Ingeniería en Sistemas Computacionales del Instituto Tecnológico de Huatabampo. Posteriormente, realizó estudios de posgrado en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET). Actualmente, se desempeña como profesor de tiempo completo

en el Instituto Tecnológico Superior de Guasave, donde también ocupa el cargo de jefe de la carrera de la División de Ciencias Computacionales. Su labor de investigación se centra en el desarrollo de sistemas de telemetría y en la implementación de modelos avanzados de inteligencia artificial, con aplicaciones en la optimización de procesos y tecnologías emergentes en entornos industriales y académicos.

Investigaciones actuales de la computación
Se terminó de imprimir en diciembre de 2024
en los talleres de Astra Ediciones
Av. Acueducto No. 829
Colonia Santa Margarita, C. P. 45140
Zapopan, Jalisco, México.
33 38 34 82 36

E-mail: edicion@astraeditorial.com.mx
www.astraeditorialshop.com

Impresión digital con interiores en papel bond de 75 g.
El tiraje consta de 300 ejemplares

Investigaciones Actuales de la Computación reúne estudios que destacan el poder de la computación para resolver desafíos complejos en agricultura, medio ambiente y gestión de recursos naturales. Mediante aplicaciones avanzadas de inteligencia artificial, drones y teledetección, este libro explora soluciones prácticas y sostenibles en contextos donde la precisión y eficiencia son esenciales.

Los temas abarcan desde el uso de redes neuronales para detección de malezas hasta clasificadores espectrales que distinguen superficies terrestres y acuáticas con datos satelitales. En conjunto, esta obra ofrece una referencia indispensable para quienes buscan profundizar en el potencial transformador de la ciencia computacional en los desafíos actuales, resaltando cómo las tecnologías emergentes pueden optimizar la toma de decisiones y promover prácticas más sostenibles en sectores clave.

ISBN: 979-13-87631-27-7



9 791387 1631277



Consulta y descarga



Cuervo Académico
295
UAS

TECNOLOGIA
EDUCATIVA
HDI

