

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

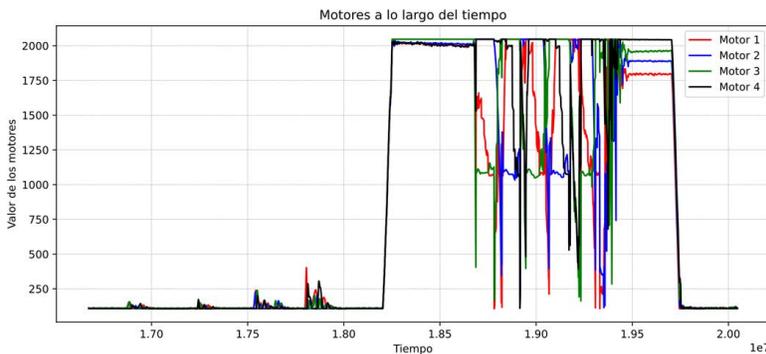
El análisis de las variables obtenidas de la caja negra constituye un aspecto fundamental en este trabajo de investigación, estableciendo la base sobre la cual se construirán las etapas sucesivas del estudio. La comprensión detallada de las variables que interactúan dentro del sistema del cuadricóptero 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.



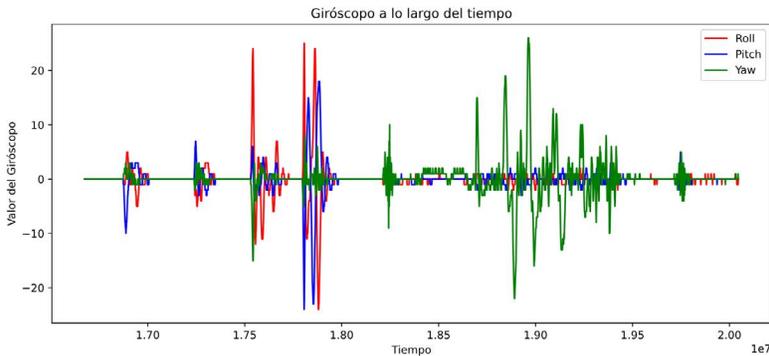
En la figura 1, cada línea representa uno de los cuatro motores del dron, mostrando cómo varía su salida a lo largo del tiempo registrado. Estos

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

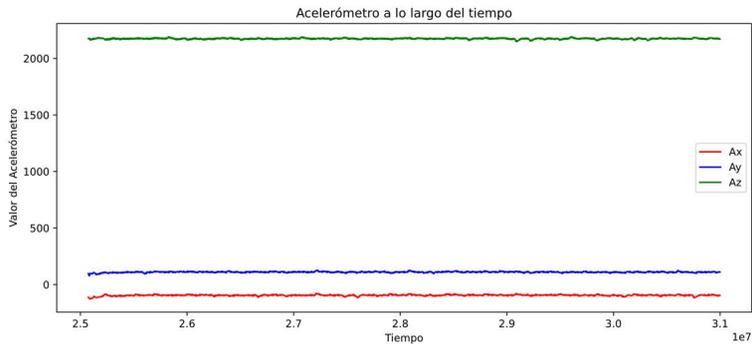
Gráfica que describe la lectura del giroscopio en función del tiempo.



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.



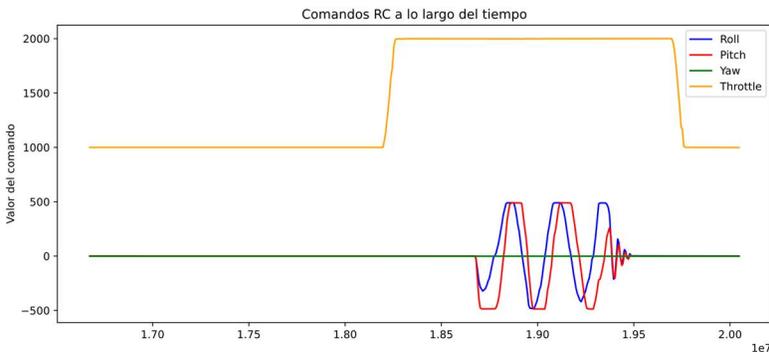
La figura 3 muestra un gráfico de líneas que representa los valores de un acelerómetro a lo largo del tiempo. Hay tres líneas de diferentes colores: la línea roja representa la aceleración en el eje X, la línea azul representa la aceleración en el eje Y, y la línea verde representa la aceleración en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

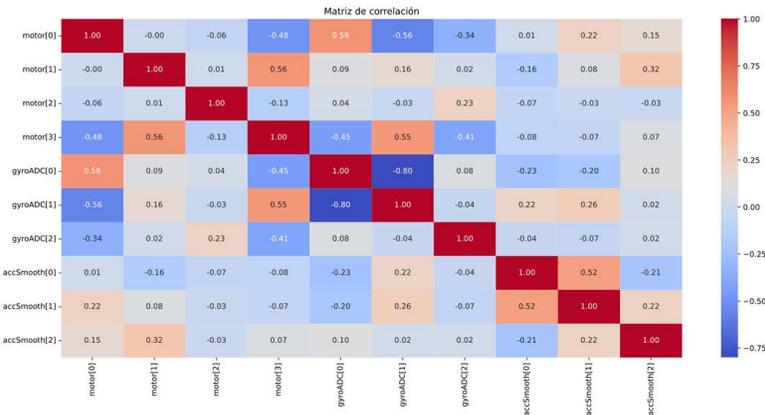
Estas gráficas son útiles para visualizar cómo el piloto ha manejado el cuadrotor durante el vuelo, mostrando los comandos de entrada para cada uno de los controles principales.

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 Eltoum, 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>