



**Desarrollo de un Modelo de Piloto Utilizando Redes Neuronales para Ejecución
de Maniobras Discretas**

Jose Manuel Gil Puerta

Trabajo de grado presentado para optar al título de Ingeniero Aeroespacial

Asesor

Diego Francisco Hidalgo López, Doctor (PhD) en Dinámica de Fluidos Computacional

Universidad de Antioquia

Facultad de Ingeniería

Ingeniería Aeroespacial

El Carmen de Viboral, Antioquia, Colombia

2024

Cita	Gil Puerta, 2024 [1]
Referencia	[1] J. M. Gil Puerta, “Desarrollo de un Modelo de Piloto Utilizando Redes Neuronales para Ejecución de Maniobras Discretas”, Trabajo de grado profesional, Ingeniería Aeroespacial, Universidad de Antioquia, El Carmen de Viboral, Antioquia, Colombia, 2024.
Estilo IEEE (2020)	



Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano/Director Julio César Saldarriaga Molina/Juan Carlos Amaya Castrillón.

Jefe departamento: Pedro León Simancas.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Dedico esto a mi familia, que siempre fueron un gran apoyo en cada instante mientras realizaba mis estudios.

A mi madre Rosalba, quien ha sido y sigue siendo un pilar fundamental en mi vida. Por todo el apoyo incondicional que me ha brindado desde el día que nací, inculcándome valores que me han formado no solo como profesional, sino también como una buena persona. Su amor, dedicación y sabiduría han sido el motor que me ha impulsado a superar los desafíos y alcanzar mis metas.

A mi padre Juan Pablo, por los valiosos consejos que me ha dado y que seguirá brindándome. Por todos los momentos que vivimos juntos, especialmente por las enseñanzas y los valores impartidos. Por enseñarme a no darme por vencido hasta conseguir mis metas y, en especial, por su amor incondicional.

A mis dos hermanos Juan Pablo y Santiago, quienes son el regalo más grande que me ha podido dar la vida, ya que son mis consejeros, mi polo a tierra en situaciones donde todo se nubla. Juntos hemos compartido risas, sueños y momentos difíciles; ellos dos me enseñaron el significado del amor de hermanos.

A mi abuela Rosalba, que en su momento me brindó un amor incondicional que aún puedo sentir, y sé que donde está, se siente orgullosa de su nieto

A mi abuela Inés, que día a día se preocupa por mi bienestar, siendo una persona que alimenta mi alma contándome las anécdotas que vivió, compartiendo todas sus enseñanzas y valores. Su dedicación, sabiduría y cariño son un regalo constante que ella me brinda.

A mi tía Genoveva por todo su apoyo incondicional, siempre estuvo dispuesta a tenderme la mano, buscando lo mejor para mí. Siendo una gran fuente de inspiración, demostrándome que con esfuerzo y dedicación se pueden alcanzar los sueños.

Agradecimientos

Un profundo agradecimiento a mi asesor Ph. D. Diego Francisco Hidalgo López, por su apoyo, dedicación y conocimientos brindados a lo largo de este proceso. Su orientación y experiencia han sido fundamentales para la culminación de este trabajo, aportándome las críticas constructivas en todo momento para terminar todo en excelencia.

Agradezco a mi familia, que siempre estuvo dispuesta a ayudarme económica y emocionalmente. Su apoyo incondicional ha sido un pilar fundamental en mi vida, brindándome la fuerza y la motivación necesarias para superar los desafíos que se han presentado en el camino. Cada consejo, cada gesto de cariño y cada palabra de aliento me han inspirado a seguir adelante.

Agradezco a mis compañeros y amigos de clase, con los que compartí todo el proceso de formación académica para la obtención de mi grado.

TABLA DE CONTENIDO

RESUMEN	12
ABSTRACT	13
I INTRODUCCIÓN	14
II PLANTEAMIENTO DEL PROBLEMA	15
III JUSTIFICACIÓN	16
IV OBJETIVOS	17
A Objetivo general	17
B Objetivos específicos	17
V MARCO TEÓRICO	18
A Redes Neuronales	18
B Simuladores de Vuelo	20
1 Partes de un simulador	21
2 Clasificación:	21
C Maniobras discretas	23
1 Hovering Turn:	23
2 Side-Step o Roll-Sway:	24
3 Vertical maneuver o Bob-Up:	25
D Factores Humanos	26
1 Sistema Vestibular:	27
2 Sistema Visual:	30
3 Sistema propioceptivo:	31
VI METODOLOGÍA Y HERRAMIENTAS	32
A LSTM	32
B Matlab-Simulink	34

C	Simulador	34
D	Controladores de Vuelo	35
E	Dinámica de Maniobras Discretas	36
1	Hovering Turn	37
2	Side-Step	37
3	Vertical Maneuver	37
F	Caso de Validación	38
VI Experimento y Resultados		43
A	Resultados de los Pilotos	46
1	Bob-up:	46
a	Resultados y análisis:	47
2	Side-Step:	51
a	Resultados y análisis:	52
3	Hovering Turn:	56
a	Resultados y análisis:	57
B	Planteamiento de la Red Neuronal	60
C	Prueba de necesidad de retroalimentación	61
1	Red Neuronal sin Retroalimentación:	61
2	Red Neuronal con Retroalimentación:	63
D	Redes Neuronales para las Maniobras	66
1	Resultado de Red Neuronal para Maniobra Bob-Up:	66
2	Resultado de Red Neuronal para Maniobra Side-Step:	69
3	Resultado de Red Neuronal para Maniobra Hovering-Turn:	72
VII CONCLUSIONES Y RECOMENDACIONES		76
REFERENCIAS		78

LISTA DE TABLAS

Tabla I	Parámetros de Filtro de Segundo Orden. Tabla extraída de [1]	40
Tabla II	Datos de vuelo y entradas de los pilotos	44

LISTA DE FIGURAS

Fig. 1	Arquitectura General de Redes Neuronales. Figura extraída de [2]	18
Fig. 2	Curso sugerido para la maniobra Piroutte. Figura extraída de [3]	24
Fig. 3	Curso sugerido para la maniobra Side-Step. Figura extraída de [3]	25
Fig. 4	Curso sugerido para la maniobra Vertical Maneuver. Figura extraída de [3]	26
Fig. 5	Arquitectura Redes Neuronales LSTM	33
Fig. 6	Controladores utilizados	36
Fig. 7	Configuración de Movimiento de Verical Maneuver. Figura extraída de [1]	39
Fig. 8	Diagrama de Flujo de Datos. Figura extraída de [4]	40
Fig. 9	Entrenamiento de la Red Neuronal para el Caso de Validación	42
Fig. 10	Predicción de la Red Neuronal en Caso de Validación	43
Fig. 11	Head-up Display (HUD) Predeterminado	45
Fig. 12	HUD: Bob-Up	46
Fig. 13	Entradas Realizadas por los Pilotos en el Colectivo	48
Fig. 14	Comparación de la Altitud del Helicóptero entre los Pilotos y el Modelo	49
Fig. 15	Comparación de la Velocidad Vertical del Helicóptero entre los Pilotos y el Modelo	51
Fig. 16	HUD: Side-Step	52
Fig. 17	Entradas Realizadas por los Pilotos en el Cíclico	53
Fig. 18	Comparación de Desplazamiento Lateral del Helicóptero entre los Pilotos y Modelo	54
Fig. 19	Comparación de la Velocidad Lateral del Helicóptero entre los Pilotos y Modelo	56
Fig. 20	HUD: Hovering Turn	57
Fig. 21	Entradas Realizadas por los Pilotos en los Pedales	58
Fig. 22	Comparación de Desplazamiento Lateral del Helicóptero entre los Pilotos y Modelo	59
Fig. 23	Entrenamiento Red Neuronal sin Retroalimentación	62

Fig. 24	Predicción de entrada de los Pedales de Red Neuronal sin Retroalimentación	63
Fig. 25	Predicción del Movimiento en el Ángulo de Yaw del Helicóptero de la Red Neuronal sin Retroalimentación	63
Fig. 26	Entrenamiento Red Neuronal con Retroalimentación	64
Fig. 27	Predicción de Entrada de los Pedales de la Red Neuronal con Retroalimentación	64
Fig. 28	Predicción del Movimiento en el Ángulo de Yaw del Helicóptero de la Red Neuronal con Retroalimentación	65
Fig. 29	Entrenamiento de las Redes Neuronales para la Maniobra Bob-up	66
Fig. 30	Comparación entre las Entradas del Colectivo hechas por los Pilotos y la Predicción de la Red Neuronal	67
Fig. 31	Comparación de la Altitud del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal	68
Fig. 32	Entrenamiento de las Redes Neuronales para la Maniobra Side-Step	69
Fig. 33	Comparación entre las Entradas del Cíclico hechas por los Pilotos y la Predicción de la Red Neuronal	70
Fig. 34	Comparación del Desplazamiento Lateral del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal	71
Fig. 35	Entrenamiento de las Redes Neuronales para la Maniobra Hovering-Turn	73
Fig. 36	Comparación entre las Entradas del los Pedales hechas por los Pilotos y la Predicción de la Red Neuronal	74
Fig. 37	Comparación del Movimiento en el Ángulo de Yaw del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal	75

Siglas, acrónimos y abreviaturas

m	Metro
kn	Nudos
rad/s	Radianes por segundo
deg	Grados
in	Pulgadas
m/s	Metros por segundo
G	Gravedades
C	Celsius
rpm	Revoluciones por minuto
sec⁻¹	Segundos inversos
rad/s²	Radianes por segundo cuadrado
LSTM	Long Short-Term Memory
RNN	Recurrent Neural Network
NN	Neural Network
EASA	European Union Aviation Safety Agency
FFS	Full Flight Simulator
FTD	Flight Training Device
FNPT	Flight and Navigation Procedures Trainer
NOE	Nap-of-the-earth
SNC	Sistema Nervioso Central
C++	Programming Language
CUDA	Compute Unified Device Architecture
PLC	Programmable Logic Controller
Verilog	Hardware Description Language
VHDL	VHSIC Hardware Description Language
FDM	Flight Dynamic Model
YaSim	Flight Dynamics Simulation Model

JSBSim	Open-source Flight Dynamics Model
Yaw Axis	Eje de guiñada
RMSE	Root Mean Square Error
HUD	Head-up Display

RESUMEN

Esta tesis presenta el desarrollo de un modelo de piloto utilizando redes neuronales para la ejecución de maniobras discretas en vehículos aéreos. El objetivo principal es mejorar la simulación del comportamiento del piloto, aumentando la fidelidad de las simulaciones de vuelo y reduciendo el error humano en escenarios de vuelo específicos. La metodología incorpora redes neuronales de memoria a largo y corto plazo (LSTM, por sus siglas en inglés), que fueron entrenadas utilizando datos de vuelo reales capturados en un simulador de helicóptero. Los resultados demuestran que el modelo de red neuronal replicó con éxito las entradas de los pilotos humanos en maniobras discretas clave, como giros estacionarios, maniobras de desplazamiento lateral y movimientos verticales, mostrando un alto grado de precisión en la predicción de las acciones de control. Este trabajo contribuye al creciente campo de la simulación de vuelo al proporcionar un modelo adaptativo de red neuronal capaz de mejorar la formación de pilotos y la seguridad operativa.

Palabras clave — Redes neuronales, simulación de vuelo, maniobras discretas, LSTM, modelo de piloto.

ABSTRACT

This thesis presents the development of a pilot model using neural networks for the execution of discrete maneuvers in aerial vehicles. The primary objective is to enhance the simulation of pilot behavior, improving the fidelity of flight simulations and reducing human error in specific flight scenarios. The methodology incorporates Long Short-Term Memory (LSTM) neural networks, which were trained using real flight data captured from a helicopter simulator. The results demonstrate that the neural network model successfully replicated human pilot inputs in key discrete maneuvers, such as hovering turns, side-step maneuvers, and vertical movements, showing a high degree of accuracy in predicting control actions. This work contributes to the growing field of flight simulation by providing an adaptive neural network model capable of improving pilot training and operational safety.

Keywords — Neural networks, flight simulation, discrete maneuvers, LSTM, pilot model.

I. INTRODUCCIÓN

El desarrollo de vehículos aéreos UAM (Urban Air Movelity), como los taxis aéreos o drones de pasajeros, ha generado la necesidad de mejorar la seguridad en este creciente ámbito de transporte. El vuelo en este tipo de vehículo se hace de forma suficientemente autónoma, sin embargo, tiene la necesidad de un piloto al mando. Este nuevo método de transporte por las ciudades más pobladas puede llegar a tener un gran impacto mediático en cuanto a la reducción de tiempos para el transporte de personas.

La implementación de un modelo de piloto basado en inteligencia artificial tiene como objetivo incrementar la seguridad operativa de este tipo de vehículo, con el fin de reducir la influencia de los errores humanos asociados, ya que se tienen que desarrollar nuevas tecnologías para el tráfico aéreo y las condiciones de viento en la ciudad, más específico, entre edificios puede causar una gran cantidad de turbulencias [5]. El poder simular el comportamiento de estos vehículos mediante entornos computacionales con una interfaz gráfica es vital, ya que con eso se puede predecir como será el comportamiento cuando ya se encuentre en una situación operativa real.

Con el avance la capacidad computacional y los diversos métodos de inteligencia artificial, es de interés desarrollar un modelo de piloto el cual pueda predecir el comportamiento de estos vehículos y que este pueda tomar acción durante una situación adversa que se presente durante la operación.

Teniendo todo lo anterior en cuenta, se pretende desarrollar un modelo de piloto capaz de realizar maniobras discretas mediante el empleo de redes neuronales como método de aprendizaje, para ello se utilizarán datos de vuelo recolectados con ayuda de una plataforma de vuelo realista con gráficos 3D que ofrecen una alta fidelidad.

II. PLANTEAMIENTO DEL PROBLEMA

En la actualidad, el desarrollador de sistemas de simulación de vuelo ha tenido gran relevancia, especialmente en el contexto de formación de pilotos y la investigación. El uso de estas herramientas para reducir el tiempo, riesgo y la cantidad de vuelos de testeo para la investigación de nuevos sistemas de aeronaves ha sido bien reconocido [6]. La capacidad de replicar el comportamiento humano en simulaciones es esencial para mejorar la efectividad de estos sistemas. Sin embargo, el modelar las diversas situaciones de vuelo de manera precisa conlleva un gran desafío.

A medida que nuevas tecnologías de inteligencia artificial se vuelven más robustas, se convierten en herramientas para modelar y predecir comportamientos, más específicamente el uso de redes neuronales que ofrecen la oportunidad de replicar el comportamiento de un piloto humano. No obstante, la implementación de estos métodos aún está lejos. La disponibilidad y calidad de los datos de entrenamiento son fundamentales para un buen aprendizaje.

El comportamiento de un piloto humano durante el vuelo se ve influenciado por miles de factores, incluyendo la experiencia, condiciones ambientales y las dinámicas del vuelo. Realizar el modelamiento de esto en una red neuronal es complejo, ya que requiere una arquitectura adaptativa que pueda aprender patrones de sistemas no lineales. El planteamiento del problema de este trabajo consiste en la implementación de una red neuronal entrenada con datos de vuelo y que esta sea capaz de replicar el comportamiento humano en maniobras discretas simples.

III. JUSTIFICACIÓN

La simulación de vuelo es una herramienta fundamental para la formación de pilotos, la validación de diseños aeronáuticos y la investigación en condiciones de vuelo específicas sin riesgos operativos. Sin embargo, uno de los mayores retos en los simuladores actuales es replicar el comportamiento humano de manera precisa y consistente en diversas maniobras de vuelo. En muchos casos, los modelos de piloto se basan en aproximaciones simplificadas que no reflejan adecuadamente la complejidad del comportamiento humano, lo que puede limitar la efectividad del entrenamiento y la validez de las simulaciones.

Esta investigación tiene como justificación la necesidad de mejorar la precisión en la simulación de los comportamientos de los pilotos, utilizando redes neuronales de tipo LSTM (Long Short-Term Memory) para replicar las decisiones y movimientos que realiza un piloto durante maniobras discretas. A través del desarrollo de un modelo de piloto más preciso, se espera mejorar la calidad de las simulaciones, lo que a su vez puede tener un impacto significativo en la formación de pilotos y en la seguridad operativa de las aeronaves.

El uso de redes neuronales para la simulación de maniobras complejas también representa una innovación tecnológica en el campo de la simulación de vuelo, al permitir que los simuladores aprendan y se adapten a patrones de comportamiento humano de manera más dinámica. Esto no solo beneficiará a la industria de la aviación, sino que también ofrecerá una contribución valiosa al campo de la inteligencia artificial y su aplicación en sistemas de simulación y entrenamiento.

En resumen, la relevancia de este trabajo radica en su capacidad para mejorar los sistemas de simulación de vuelo actuales, brindando una herramienta más eficiente para la formación y evaluación de pilotos, y avanzando en el desarrollo de modelos adaptativos basados en inteligencia artificial.

IV. OBJETIVOS

A. Objetivo general

Desarrollar un modelo de piloto humano basado en redes neuronales en un entorno de simulación de vuelo para maniobras discretas.

B. Objetivos específicos

- Diseñar el(los) experimento(s) que permita capturar el comportamiento de un piloto humano en la ejecución de maniobras discretas seleccionadas.
- Implementar un modelo dinámico de un vehículo aéreo genérico compatible con las maniobras de vuelo discretas seleccionadas.
- Acoplar un entorno de simulación de vuelo compatible con el modelo dinámico e interactivo con un piloto humano

V. MARCO TEÓRICO

A. Redes Neuronales

Las redes neuronales (NN) son, en conjunto, un método de aprendizaje que busca que trabajen de manera similar a una neurona humana, es decir, se les da un valor de entrada, aprenden y predicen para luego arrojar un valor de salida adecuado según lo esperado. Se trata de un tipo de machine learning llamado deep learning, que utiliza nodos o neuronas interconectadas en una estructura de capas que se asemeja al cerebro humano [7]. Las redes neuronales en particular son útiles para el procesamiento y posterior reconocimiento de patrones de clasificación, como en sistemas de control, imágenes y voz, entre otros [2]. Los modelos de redes neuronales se estructuran en una serie de capas que reflejan la manera en que el cerebro procesa la información. Cada capa de la red tiene un propósito específico: las capas de entrada reciben los datos, las capas ocultas procesan y extraen características importantes, y las capas de salida generan predicciones o clasificaciones basadas en la información procesada [8]. Esto se puede observar mejor en la figura 1, donde se muestra la estructura general de una red neuronal. La clasificación de las redes neuronales depende de cuántas capas conectadas estén diseñadas. Las redes con dos o tres capas se conocen como redes neuronales superficiales, mientras que las redes aplicadas al deep learning pueden tener muchas capas, incluso cientos. Este método se ajusta muy bien a aplicaciones de identificación complejas, tales como el reconocimiento facial, la traducción de textos y el reconocimiento de voz.

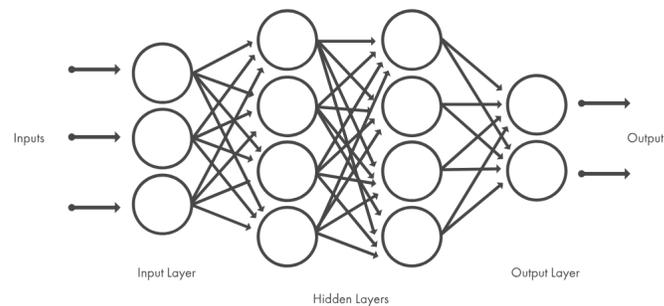


Fig. 1. Arquitectura General de Redes Neuronales. Figura extraída de [2]

Actualmente, hay varios tipos de redes neuronales aplicables a diferentes propósitos e industrias. Cada una está diseñada con una arquitectura particular que la hace más adecuada para ciertos tipos de tareas. A continuación, se presentarán algunos de los tipos más destacados de redes neuronales.

- **Convolutional neural network:** Esta red está diseñada para el procesamiento y análisis de imágenes, señales y datos de series temporales. Estas están compuestas por capas que aplican filtros para la identificación de patrones o características dentro de los datos de entrada. Su capacidad para reducir la dimensión de los datos sin perder información crítica les permite ser altamente eficientes en problemas que involucran grandes volúmenes de datos. [9]
- **Recurrent neural network:** Esta red se especializa en procesar datos secuenciales o temporales, como series de tiempo, texto o secuencias de vídeo. Las RNN tienen conexiones de retroalimentación que les permiten retener información de pasos anteriores, lo que les permite tener un estado de memoria. Sin embargo, esta red tiene una limitación en el aprendizaje de largo plazo. Para superar esto se desarrolló una variante de este tipo de red como las Long Short-Term Memory (LSTM), que mejora significativamente la capacidad de las RNN para almacenar y recordar información durante intervalos de tiempo más largos [10].

Las redes neuronales han demostrado ser una herramienta efectiva para el diseño de sistemas de control no lineales. Como lo indican Failler y Schreck en [11], los sistemas de control basados en redes neuronales pueden manejar las complejidades del control de una aeronave, especialmente cuando se trata de fuerzas dominadas por la mecánica de fluidos. Esto hace que técnicas como el control adaptativo y el uso de redes neuronales sean fundamentales para mejorar la maniobrabilidad de las aeronaves. Estas técnicas pueden aplicarse en el diseño de sistemas de control, donde la capacidad de las redes neuronales para aprender y adaptarse a las dinámicas no lineales resulta crucial para lograr un control eficaz.

B. Simuladores de Vuelo

Un simulador de vuelo es un dispositivo que funciona mediante software y hardware para imitar condiciones de vuelo y, así, permitir una gran cantidad de actividades para los pilotos, como entrenar y adquirir experiencia en entornos controlados. Los simuladores pueden variar en versiones según el enfoque, desde entornos para principiantes, como los utilizados por aficionados a la aviación, hasta simuladores en un ámbito profesional, como los usados por aerolíneas para el entrenamiento de pilotos o por empresas que diseñan y fabrican aeronaves. Durante el desarrollo de nuevas aeronaves, las empresas utilizan exhaustivamente los simuladores para probar el diseño y algunas condiciones de vuelo a las cuales el prototipo final se verá sometido.

El objetivo de estos simuladores no es duplicar un vuelo, sino simular con gran fidelidad para crear un entrenamiento y testeo lo más efectivo posible. El simulador de vuelo debe considerarse una herramienta de prueba o entrenamiento, en lugar de un sustituto de la aeronave [12]. Por más horas de vuelo que tenga una aeronave en certificación o un piloto en formación, es necesario acumular horas de vuelo reales para finalizar el entrenamiento. Esto ofrece una serie de ventajas como:

- **Situaciones de emergencia:** En los simuladores es posible configurar las aeronaves en situaciones donde se deba probar el comportamiento de la aeronave o entrenar al piloto para enfrentar condiciones adversas. Si bien es casi imposible simular al cien por ciento las situaciones de emergencia, ya que los factores humanos que experimenta un piloto durante una situación real son muy diferentes a los de un entorno controlado y previamente establecido, estas simulaciones pueden ser útiles para que el piloto, con un correcto entrenamiento, adquiera los conocimientos necesarios para reaccionar oportunamente ante una emergencia real.
- **Económica:** Para las empresas o aerolíneas, es mucho más rentable que un piloto se entrene en un simulador de vuelo que hacerlo constantemente en un vuelo real. El entrenamiento en una aeronave requiere su disponibilidad, así como el consumo de combustible, lo que aumenta considerablemente los costos. En cambio, en un simulador, el entrenamiento puede

repetirse cuantas veces sea necesario sin causar desgaste en la aeronave ni incurrir en gastos adicionales significativos.

- **Variabilidad de escenarios:** Al ser un simulador, es posible configurar una amplia variedad de situaciones donde se pueden entrenar y/o poner a prueba las habilidades del piloto. Esto representa una gran ventaja al momento de probar una aeronave en etapa de certificación, ya que permite reducir significativamente las horas de vuelo totales necesarias, optimizando tanto el tiempo como los recursos involucrados.

1) Partes de un simulador :

Un simulador de vuelo está compuesto por varias partes que trabajan en armonía para recrear una experiencia de vuelo lo más realista posible. A continuación, se describen las partes principales de un simulador de vuelo:

- **Cabina:** Es la réplica física de la cabina de un avión, donde se incluyen todos los controles y sistemas necesarios para la operación.
- **Sistema de visualización:** Se compone de pantallas que muestran el entorno externo, simulando las vistas que tendría el piloto desde la cabina. Para una simulación más fiel, es necesario utilizar gráficos de alta resolución para representar el terreno, condiciones climáticas, entre otros.
- **Plataforma de movimiento:** Es responsable de generar las sensaciones físicas de movimiento, como la aceleración, giros y cambios de inclinación. Las plataformas de seis grados de libertad ofrecen una experiencia de vuelo más realista.
- **Sistemas de sonido:** Se encarga de replicar los sonidos de un avión real, como el ruido de los motores, el ambiente, alertas sobre instrumentos y otros efectos sonoros externos.
- **Instrumentación:** Son las pantallas o réplicas de los instrumentos que muestran al piloto toda la información del avión, como altitud, velocidad, rumbo, entre otros.

Toda la información fue extraída de [13]

2) Clasificación: La EASA en [14] clasifica los simuladores de vuelo de helicópteros en tres clases:

- **FFS (Full Flight Simulator):** Es una réplica a escala de una aeronave o helicóptero específico de la cabina, que incluye todo el ensamblaje de equipamiento y software necesarios para representar misiones de tierra y aire, un sistema visual y de movimiento. Se clasifica en cuatro niveles:
 - **Nivel A:** 3 grados de movimiento/visuales nocturnas.
 - **Nivel B:** 3 grados de movimiento/visuales nocturnas y simulación de maniobras en tierra.
 - **Nivel C:** 6 grados de movimiento/visuales nocturnas y al atardecer, con carga dinámica en los controles.
 - **Nivel D:** 6 grados de movimiento/visuales nocturnas, al atardecer y diurnas, con carga dinámica en los controles y máxima fidelidad
- **FTD (Flight Training Device):** Consta de una réplica a tamaño real de los instrumentos, paneles de vuelo y controles de un tipo específico de aeronave, incluyendo la instalación de equipos y software necesarios para representar la aeronave en condiciones de tierra y vuelo. Este no requiere un sistema de retroalimentación de movimiento.
- **FNPT (Flight and Navigation Procedures Trainer):** Representa el entorno de la cabina, con los equipos y software necesarios instalados para representar una aeronave en operaciones de vuelo.

C. Maniobras discretas

Las maniobras discretas comprenden una clase de tareas que debe realizar el piloto de la aeronave. Entre estas se incluyen maniobras como el aterrizaje (Landing), bob-up, rollsway, vuelo nap-of-the-earth (NOE) de helicópteros, quickstop, entre otras. Las maniobras discretas se pueden definir como la transición de una tarea a otra, por ejemplo, interrumpir el estado estable de una aeronave en crucero para realizar un cabeceo hasta alcanzar otro estado estable. Esa transición puede considerarse una maniobra discreta [15].

Basado en el manual ADS-33 [3] en el cual se definen las misiones operativas y se especifican las tareas de misión que el fabricante debe considerar en el diseño de una aeronave de ala rotatoria, se seleccionaron tres maniobras clave para realizar. Estas maniobras fueron escogidas porque representan el principio básico de operación de un helicóptero, al generar tanto una dinámica de actitud como una de desplazamiento. Además, se incluyó una maniobra representativa que involucra el movimiento vertical, donde se evalúa el control del colectivo y la compensación del rotor de cola en la aeronave de ala rotatoria.

Las maniobras realizadas y analizadas fueron: Hovering Turn, Sidestep, y Vertical Maneuver. Estas maniobras fueron seleccionadas porque generan tanto una dinámica de actitud como de desplazamiento. Asimismo, se tomó en cuenta otra maniobra representativa que contiene el movimiento vertical, donde se evalúa el control del colectivo de la aeronave de ala rotatoria y la compensación por parte del rotor de cola.

1) *Hovering Turn*: La figura 2 muestra una vista superior de cómo se ejecuta la maniobra Pirouette, sin embargo, el diagrama de ejecución será utilizado como referencia para la maniobra de Hovering Turn. En esta maniobra, el piloto se situará en el punto de referencia, ubicado en el centro, manteniendo un hover a una altura de 6 m. El piloto deberá realizar un giro de 180 grados con respecto al eje vertical de la aeronave, procurando generar las menores perturbaciones posibles en cualquiera de los otros ejes.

El objetivo de esta maniobra es verificar la capacidad de la aeronave para recuperarse de un giro en vuelo estacionario a velocidad moderada, con una precisión razonable. El

desempeño aceptable para esta maniobra es que, una vez finalizada, la aeronave mantenga la posición longitudinal y lateral dentro de un margen de ± 1.82 m y la altitud dentro de ± 1.82 m. El tiempo requerido para completar la maniobra no debe exceder los 15 segundos.

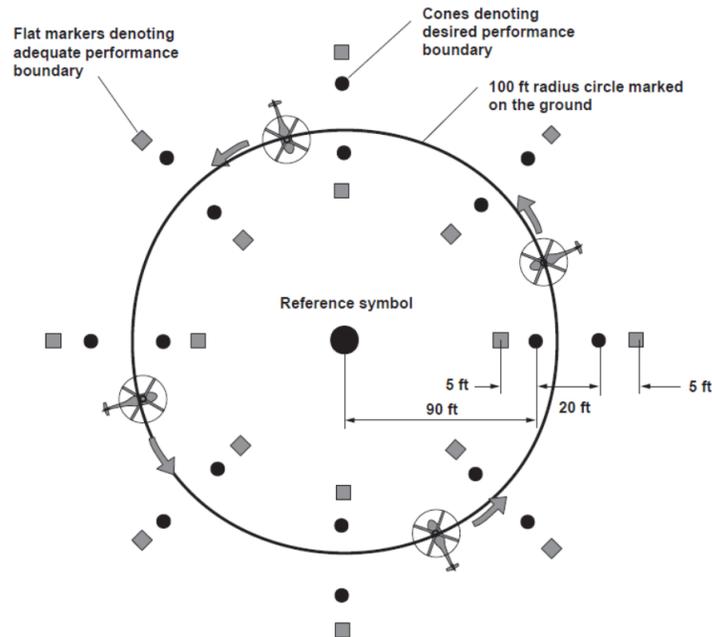


Fig. 2. Curso sugerido para la maniobra Pirouette. Figura extraída de [3]

2) *Side-Step o Roll-Sway*: La maniobra comienza en un vuelo estable a 17 m de altura. El piloto deberá realizar un desplazamiento lateral con un ángulo de dirección de al menos 25 grados, manteniendo una velocidad y altura constantes durante cinco segundos. Una vez completado este tiempo, debe realizar una desaceleración constante hasta estabilizarse nuevamente en un *hover* durante otros cinco segundos. Luego, el piloto repetirá la misma maniobra con las mismas instrucciones, pero desplazándose hacia el lado contrario. Una vez finalizada, se da por concluida toda la maniobra. Para la ejecución, no se dispone de los instrumentos de la aeronave. La maniobra está ilustrada en la figura 3.

El objetivo de esta maniobra es verificar las cualidades del manejo lateral durante las maniobras y la capacidad de coordinar el ángulo de roll con el control colectivo para

mantener una altitud constante. El desempeño aceptable consta de lograr, como mínimo, un ángulo de 25 grados de roll desde la posición inicial en los primeros tres segundos, alcanzar una velocidad de desplazamiento lateral inferior a 40 kn, y lograr al menos 30 grados de cambio en el ángulo de roll durante la desaceleración en los primeros tres segundos. Además, el piloto debe mantener un punto de referencia de la aeronave con respecto al punto de llegada dentro de un margen de ± 4.5 m y mantener una altitud de ± 4.5 m. Finalmente, se debe lograr estabilizar la aeronave en hover dentro de los primeros 10 segundos después de llegar al punto final.

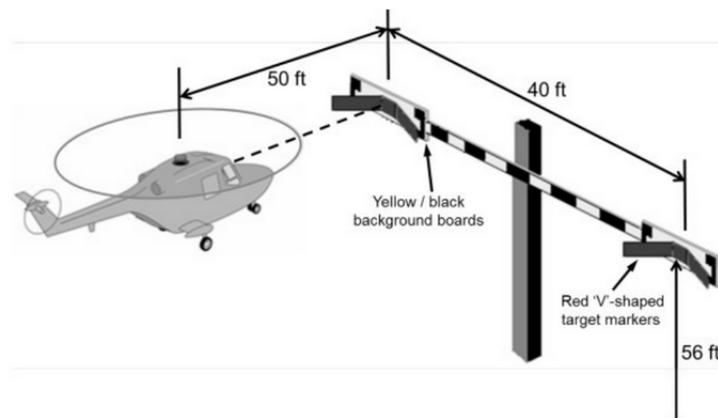


Fig. 3. Curso sugerido para la maniobra Side-Step. Figura extraída de [3]

3) *Vertical maneuver o Bob-Up*: La figura 4 muestra gráficamente cómo debe ejecutarse la maniobra. Esta comienza con un hover a 4.5 m pies sobre el suelo. Al darse la orden de inicio, el piloto debe realizar un ascenso estable de 3 m, procurando la menor cantidad de perturbaciones a lo largo del eje vertical de la aeronave. Una vez alcanzada la altitud deseada, debe estabilizarse durante dos segundos, y posteriormente regresar a la altura inicial. El piloto cuenta únicamente con referencias visuales, ya que los instrumentos no estarán disponibles y solo se utilizará la percepción humana para la ejecución de la maniobra.

El objetivo de esta maniobra es medir la capacidad de iniciar y detener con precisión la velocidad vertical, a su vez verificar las características del controlador del eje vertical. El

desempeño aceptado manteniendo la posición longitudinal y lateral es de un error de ± 3 m, la altitud final debe de ser al menos de ± 1 m y completar la maniobra en un tiempo menor o igual a 15 segundos.

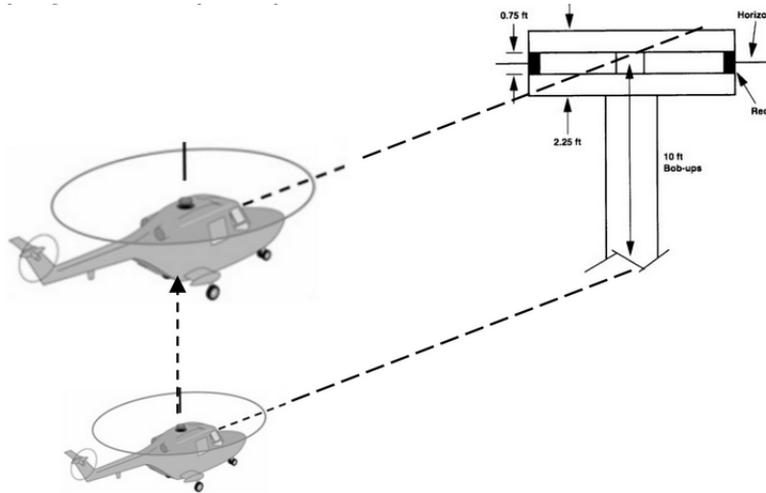


Fig. 4. Curso sugerido para la maniobra Vertical Maneuver. Figura extraída de [3]

D. Factores Humanos

En los inicios de la aviación, los factores humanos no eran estudiados ni tomados en cuenta. Se forzaba a los pilotos a realizar un trabajo excesivo, lo que ocasionaba accidentes debido a la fatiga. Los mecánicos encargados del mantenimiento también sufrían las consecuencias del exceso de trabajo, lo que generaba errores en estos procesos. Con el tiempo, el término "factores humanos" ha ido ganando popularidad a medida que la industria de la aviación se dio cuenta de que la causa principal de la mayoría de los accidentes está asociada al error humano, lo que ha dado lugar a una intensa investigación en áreas como la psicología y la percepción de los pilotos [16].

La percepción es la capacidad que tienen las personas de captar sensaciones a través de los sentidos, como el vestibular, visual, auditivo, propioceptivo y táctil. Estos, en conjunto, permiten la interpretación del entorno, ayudando a los pilotos en la toma de decisiones. Estos sistemas funcionan de manera integrada constantemente en la aviación, ya que son esenciales

para mantener la conciencia situacional en caso de emergencia y para conservar el control. Sin estos mecanismos de percepción, sería casi imposible controlar una aeronave, ya que no se podría percibir correctamente el entorno ni responder adecuadamente a cualquier situación.

El sistema de orientación y equilibrio humano está regulado por el Sistema Nervioso Central (SNC), el cual recibe, percibe e interpreta la información proveniente de una serie de sistemas sensoriales periféricos, entre los cuales destacan principalmente el sistema de la visión, el sistema vestibular del oído interno, el sistema propioceptivo y el sistema auditivo [17].

1) *Sistema Vestibular*: Este sistema es el encargado de mantenernos en equilibrio, medir la velocidad y la dirección con la que nos movemos. En la aviación, las entradas gravitacionales y estacionales, que se originan a partir de fuerzas de aceleración lineales y angulares, se transforman en información orientativa gracias al sistema vestibular. Aunque su papel en el mantenimiento de la orientación espacial no es tan predominante como el del sistema visual, las funciones vestibulares son cruciales, especialmente en condiciones de discapacidad visual, como volar entre nubes o durante la noche [18]. Los humanos hemos evolucionado sintiendo siempre la misma fuerza de gravedad, pero solo desde hace poco más de 100 años, con el desarrollo de la aviación, se han creado aeronaves capaces de aumentar la fuerza gravitacional. Nuestro sistema vestibular tiene dificultades para percibir estos cambios, lo que puede causar que los pilotos reciban información errónea durante la ejecución de maniobras que incrementen esta fuerza. El sistema vestibular es altamente sensible a las fuerzas de aceleración, por lo que incluso pequeñas cantidades de estas fuerzas pueden generar alteraciones considerables. Los canales semicirculares y los órganos otolitos responden de manera diferente a estas fuerzas, las cuales se producen con los cambios de velocidad (aceleración o desaceleración) y varias maniobras de la aeronave, como el roll, el lanzamiento, el banco y el giro [18].

El sistema vestibular está compuesto por los conductos semicirculares y los órganos otolíticos, que son sensibles a las aceleraciones angulares y lineales, respectivamente. Los conductos semicirculares son tres tubos llenos de líquido que están en ángulo recto entre sí y detectan la rotación de la cabeza. El movimiento de la cabeza hace que el líquido dentro

de los conductos se desplace. Dependiendo de la dirección en que se mueva la cabeza, uno de los conductos experimenta un mayor movimiento del líquido en comparación con los otros. Los conductos contienen células ciliadas que responden a este movimiento del líquido [19].

Estos conductos están dispuestos en tres planos, formando aproximadamente un ángulo de 90 grados entre ellos. Los conductos son: el anterior (superior), ubicado en un plano sagital; el lateral (horizontal), ubicado en un plano transverso; y el posterior (inferior), ubicado en un plano frontal [20].

El utrículo y el sáculo componen los órganos vestibulares, que se encuentran ubicados en el vestíbulo óseo del oído interno. El utrículo se comunica con los conductos semicirculares, mientras que el sáculo se encuentra ubicado anteriormente al utrículo y es significativamente más pequeño en comparación con este [20].

Un mal funcionamiento o una sobreestimulación del sistema vestibular puede causar que los pilotos sufran de ilusiones, las cuales dependen de qué parte del sistema se vea afectada. Existen ilusiones provocadas tanto por los canales semicirculares como por los órganos vestibulares. Las ilusiones provocadas por los canales semicirculares son:

- **Ladeos:** Son las ilusiones más frecuentes y se producen debido a que el movimiento del avión no estimula adecuadamente los canales semicirculares.
- **Barrena:** Se produce por la estimulación constante de un canal semicircular. Cuando el piloto comprueba los instrumentos, intentará recuperar el avión, lo que estimulará su canal semicircular en sentido opuesto. Si intenta corregir esta falsa sensación, volverá a entrar en la barrena original.
- **Efecto Coriolis:** Ocurre debido a la estimulación cruzada de dos canales semicirculares en planos diferentes. Se produce cuando, durante un giro, el piloto realiza un movimiento brusco de la cabeza, generando la sensación de que está rodando por una pendiente.
- **Ilusión oculogira:** Es la sensación de que un objeto está en movimiento cuando se observa bajo los efectos de aceleraciones angulares. La estimulación del aparato vestibular, debido a las interconexiones vestíbulo-oculares, origina un movimiento de los globos oculares, lo que provoca la sensación de que el objeto se está moviendo.

Las ilusiones provocadas por el órgano otolítico son:

- **Inversión gravitoinercial:** Ocurre al nivelar la aeronave bruscamente a una altura deseada, durante su ascenso en forma de parábola. Como consecuencia de ello, el piloto se somete a una fuerza $-Gz$ hasta el momento de nivelar, a la que se añade otra $+Gx$, además de la fuerza gravitoinercial normal, $1G$
- **Ilusión en ascensor:** Se origina en caso de aceleraciones $+GZ$ en sentido vertical; el resultado es la fijación de la mirada hacia el horizonte primitivo, es decir, hacia abajo. El piloto experimentará que el morra del avión se eleve.
- **Ilusión oculogravica:** Se define como la sensación de movimiento de un objeto que realmente está fijo, en relación con el cambio de magnitud o dirección de la fuerza gravitacional.

Toda la información sobre las ilusiones provocadas por el sistema vestibular fue obtenida de [21].

Se puede determinar el comportamiento del sistema vestibular mediante dos funciones de transferencia, una para cada órgano que lo compone.

$$H_{\text{oto}} = \frac{FR}{f} = \frac{1 + j\omega}{(1 + 0,5j\omega)(1 + 0,016j\omega)} \quad (1)$$

La función de transferencia dada en la ecuación 1 representa al órgano otolítico, donde omega es la frecuencia en rad/s, con un rango que va de 0.1 a 10 rad/s. Este órgano tiene una función principal en la orientación espacial vertical, siendo sensible a las aceleraciones lineales, y se estima que su umbral mínimo es de alrededor de 2 grados [22]

$$H_{\text{ssc}} = \frac{FR}{\omega} = \frac{j\omega(1 + 0,11j\omega)}{(1 + 5,9j\omega)(1 + 0,005j\omega)} \quad (2)$$

La función dada en la ecuación 2 representa el comportamiento de los conductos semicirculares, donde también depende de la frecuencia omega. Este órgano es el encargado de detectar las aceleraciones angulares, tiene una activación rápida y un umbral de detección bajo. Un problema importante asociado a este órgano es que la percepción de estar sometido a una aceleración angular constante disminuye con el tiempo, lo que provoca la aparición de falsas sensaciones, incluso cuando la aeronave puede estar realizando un giro.

2) Sistema Visual:

El sistema visual humano es la fuente principal de información para mantener la orientación espacial fija. Este opera en dos modos: ambiental y focal. El primero ayuda principalmente en la orientación espacial, y el modo focal se enfoca en la identificación de objetos [22]. En la aviación, el sistema visual es fundamental, ya que su interacción con otros sistemas sensoriales, como el vestibular, ayuda a mantener la conciencia situacional y a reaccionar adecuadamente en situaciones de vuelo complejas.

Una limitación del sistema visual es su dependencia de señales exteriores claras y definidas. Por ejemplo, en situaciones de poca visibilidad, los pilotos pueden tener dificultades para interpretar correctamente la distancia al suelo o la inclinación de la aeronave. En estos casos, la falta de puntos de referencia claros puede llevar a desorientación espacial, lo que hace que el sistema visual sea menos efectivo para el control [23].

Algunas de las ilusiones provocadas por el sistema visual son:

- **Perspectiva aérea:** Se produce durante la aproximación y aterrizaje, cuando el piloto tiene una idea preconcebida y asume la anchura y largo de la pista. Estas pueden ser mal interpretadas si el terreno a su alrededor tiene vegetación o si la pista tiene una inclinación sobre el terreno.
- **Agujero negro:** Ocurre cuando hay una aproximación a una pista sin iluminación previa o cuando hay terreno iluminado detrás. El piloto percibe que está aproximándose a mayor altitud de la real y responde con una aproximación más baja.
- **Autocinesis:** Este efecto genera la sensación de que un objeto fijo y luminoso se está moviendo. Esta percepción puede crear la sensación de que el objeto va a colisionar con la aeronave. Por esta razón, las señales suelen utilizar luces intermitentes.
- **Flicker vertigo:** Esta ilusión es consecuencia de la rotación de las palas de un helicóptero que reflejan las luces anticolidión o la luz solar que incide sobre ellas. Si la frecuencia de oscilación está entre 4-15 revoluciones por segundo, puede generar cuadros de náuseas y vértigo.

Toda la información sobre las ilusiones provocadas por el sistema visual fue obtenida

de [24]

3) *Sistema propioceptivo*: La propiocepción es la capacidad que tiene nuestro cerebro de saber la posición exacta de todas las partes de nuestro cuerpo en cada momento. Dicho de otra manera, a nuestro cerebro le llegan diferentes órdenes desde las articulaciones y los músculos, informando sobre su posición exacta [25]. Este sistema cuenta con receptores en músculos, tendones y articulaciones, y está relacionado con las sensaciones de posición, movimiento de las articulaciones, vibración y presión. También participa en las sensaciones discriminativas como las texturas, la localización de un punto que ha sido tocado, la sensación de peso y el reconocimiento de números o letras escritas sobre la piel [26].

Usualmente, el sistema propioceptivo no tiene la capacidad de generar desorientación espacial por sí solo. Sin embargo, cuando los órganos visuales y vestibulares no funcionan de manera armoniosa, puede ocurrir una ilusión somatosensorial. Esta se presenta cuando el piloto está sometido a fuerzas G, y los receptores propioceptivos entran en conflicto con la fuerza gravitacional, lo que provoca que se perciban posiciones incorrectas. Este desajuste puede llevar a que los receptores propioceptivos envíen señales erróneas al cerebro, generando una falsa percepción de la orientación espacial [27].

VI. METODOLOGÍA Y HERRAMIENTAS

A. LSTM

Como se mencionó en la sección V, existen una gran variedad de redes neuronales aplicables en diferentes ámbitos. Para este trabajo se utilizará la arquitectura de la red LSTM (Long Short-Term Memory), que, a diferencia de otras arquitecturas de redes neuronales, incorpora conexiones de retroalimentación. Esto le permite procesar secuencias y series de tiempo de manera eficiente.

Las redes LSTM son una mejora de las redes RNN (Recurrent Neural Networks). Está diseñada para trabajar con datos secuenciales o series de tiempo. Sus aplicaciones principales abarcan desde el procesamiento de la voz, la traducción automática entre lenguajes, hasta la generación de subtítulos en vídeos. Las LSTM tienen la capacidad de recordar valores pasados según su importancia para la aplicación. A través del entrenamiento, la red toma decisiones sobre qué información debe conservarse y cuál debe eliminarse, evitando sobrecargar la memoria y asegurando que los valores pasados relevantes no se pierdan.

Una de las principales ventajas de las LSTM es que permiten ajustar el peso de la auto-circulación mediante la incorporación de una estructura de compuertas. Esto posibilita cambiar dinámicamente la escala de integración en diferentes momentos, incluso cuando los parámetros del modelo permanecen constantes, lo que ayuda a evitar problemas como la desaparición o la expansión del gradiente [28].

En la figura 5, tomada de [29], se aprecia la arquitectura de la red LSTM. Esta se divide en tres partes: **Forget Gate**, **Input Gate** y **Output Gate**. La primera parte de la arquitectura es la *Forget Gate*, que se encarga de determinar cuáles de los datos ingresados deben ser ignorados o aceptados. Los valores relevantes obtienen valores cercanos a 1, mientras que los no relevantes se acercan a 0. La siguiente parte es la *Input Gate*, que decide qué valores o qué información se debe incorporar en la memoria a largo plazo. Para esto, tiene dos funciones: la sigmoidea, que actúa como filtro para identificar la información relevante y genera valores de 0 a 1; y la función de activación tanh, que considera el estado oculto anterior y los datos de entrada actuales, permitiendo que los valores de salida varíen entre

-1 y 1 [29]. Por último, se encuentra la *Output Gate*, que toma en cuenta los estados ocultos anteriores y los resultados producidos por la *Forget Gate* y la *Input Gate*. La *Output Gate* utiliza una función sigmoidea como filtro, decidiendo qué información es relevante o no, generando valores de 0 a 1. Luego, con este nuevo estado, se utiliza nuevamente la función \tanh para limitar los valores entre -1 y 1, con el fin de generar un estado final, que a su vez es el resultado final de la red [29]. Como este es un proceso iterativo, el resultado final se utiliza como entrada a la siguiente capa de la red. Esto depende completamente del usuario, quien decide cuántas capas ocultas incluir. A mayor número de capas, mejor será el aprendizaje de la red, aunque el costo computacional también será mayor.

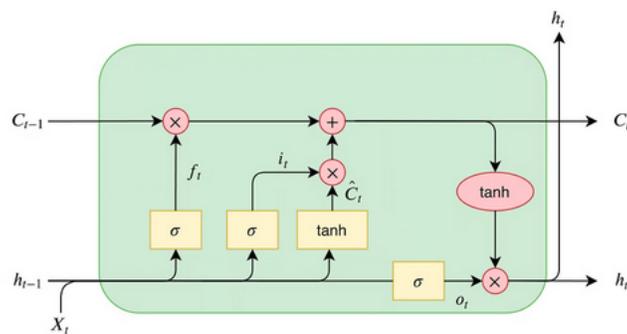


Fig. 5. Arquitectura Redes Neuronales LSTM

El propósito de la red neuronal es que esta pueda ser entrenada con datos de vuelo reales, de manera que pueda aprender a interpretar y procesar las entradas realizadas por los pilotos, generando una respuesta adecuada que emule el comportamiento de la aeronave. Durante el entrenamiento, la red ajusta sus pesos internos para correlacionar las entradas (acciones del piloto) con las salidas esperadas (respuesta del helicóptero), lo que permite que, en simulaciones futuras, la red pueda predecir y replicar cómo respondería la aeronave en diferentes situaciones, mejorando así su precisión en la simulación del control de vuelo.

B. Matlab-Simulink

Matlab es un programa desarrollado por la empresa MathWorks. Es una plataforma de cálculo numérico y programación que combina un entorno para el análisis iterativo y los procesos de diseño. [30]. Simulink es una herramienta robusta con un entorno de diagramas de bloques que se puede utilizar para el diseño de modelos físicos antes de ser implementados, simular procesos de control, entre otros. Simulink se puede utilizar para simular y probar el sistema en las primeras etapas de desarrollo, generar código en diferentes lenguajes de programación como C, C++, CUDA, PLC, Verilog y VHDL con una alta calidad, pudiendo extender los modelos a los sistemas en funcionamiento para así realizar mantenimientos predictivos. [31]. Simulink, dentro de sus herramientas, posee la librería “Aerospace Toolbox”. Esta tiene la capacidad de implementar cientos de funciones que simulan desde los instrumentos de las aeronaves hasta modelos dinámicos de seis grados de libertad, además de tener bloques donde se presta para la incorporación de interfaces gráficas de simuladores de vuelo como FlightGear. No solo se limita a un entorno de aviación, ya que permite diseñar y analizar escenarios con satélites y estaciones terrestres, calcular trayectorias satelitales a partir de elementos orbitales [32]

C. Simulador

Como se abordó anteriormente, la interfaz gráfica es parte fundamental de todo simulador, ya que es la encargada de mostrar visualmente el comportamiento de la aeronave con los modelos dinámicos que se van a utilizar. Para ello, se utilizó FlightGear, un simulador desarrollado por y para la comunidad, siendo ampliamente utilizado en la investigación y educación.

FlightGear, como plataforma de código abierto ampliamente reconocida en la comunidad, destaca por su desarrollo continuo y acceso gratuito. Su base de datos, que abarca una amplia gama de aeronaves comerciales y militares, brinda a los usuarios la libertad de simular distintas configuraciones y maniobras según sus necesidades. Además, su filosofía colaborativa ha impulsado el crecimiento de FlightGear en entornos profesionales gracias a

su precisión y capacidad para simular escenarios complejos [33]. En un estudio realizado por [34], se exploraron las dinámicas no lineales en oscilaciones inducidas por pilotos utilizando FlightGear, lo que resalta la relevancia de esta plataforma en la investigación aeroespacial.

Para una interacción detallada con modelos de dinámica de vuelo (FDM), especialmente cuando se aborda la creación de nuevas configuraciones de aeronaves o la simulación de pruebas de vuelo, es esencial establecer una conexión sinérgica con los modelos preconfigurados disponibles en plataformas especializadas. Entre estos modelos se encuentran opciones como YaSim, que se centra principalmente en simular los efectos del flujo de aire sobre la estructura de la aeronave, y JSBSim, que se distingue por ser una librería de código abierto capaz de incorporarse a diferentes entornos de simulación [35].

D. Controladores de Vuelo

En el mercado existen múltiples marcas y modelos de controladores de vuelo, cada uno diseñado para un tipo específico de aplicación. Los controles principales para la manipulación de un helicóptero constan del cíclico, que permite al piloto mover el helicóptero en las direcciones: hacia adelante, atrás, izquierda y derecha. El propósito de este controlador es inclinar las palas en la dirección deseada para el movimiento horizontal. Controla la dirección del rotor respecto al horizonte, dirigiendo el empuje en la dirección del desplazamiento deseado [36]. El colectivo es otro controlador primario en un helicóptero; generalmente se ubica al lado izquierdo del piloto y es el encargado de cambiar el ángulo de pitch del rotor principal. Al cambiar el ángulo de pitch de las palas, se modifica el ángulo de incidencia de cada una, lo que altera la resistencia aerodinámica y, por ende, influye en la velocidad o las revoluciones por minuto (rpm) del rotor principal [36]. Por último, los pedales antitorque, que se encuentran en la posición de los pies del piloto, tienen la función de compensar el torque generado por el rotor principal. Según la tercera ley de Newton, el rotor de cola aplica un empuje en dirección contraria al torque del rotor principal. Los pedales antitorque permiten al piloto ajustar el ángulo de las palas del rotor de cola, manteniendo el helicóptero en un vuelo estable y permitiendo giros de 360° en vuelo estacionario [36]. Dado que se va a abordar el uso de un simulador de vuelo, los controladores comerciales que se escogieron

son el THRUSTMASTER T.1600M (ver figura 6b), que actúa como el cíclico del helicóptero; el THRUSTMASTER TWCS THROTTLE (ver figura 6a), encargado de funcionar como el colectivo del helicóptero; y por último, los THRUSTMASTER Flight Rudder Pedals (ver figura 6c), que actúan como los pedales antitorque.



Fig. 6. Controladores utilizados

E. Dinámica de Maniobras Discretas

Las ecuaciones de los modelos dinámicos utilizados son funciones de transferencia generales para helicópteros utilitarios de mediano tamaño. Estas ecuaciones logran representar el comportamiento del helicóptero en respuesta a una entrada realizada por un controlador de vuelo, permitiendo predecir el comportamiento de la aeronave bajo algunas condiciones de vuelo. Son esenciales para la simulación y análisis de la estabilidad y el control en cada

uno de los ejes del helicóptero, proporcionando una base sólida para evaluar el rendimiento del helicóptero en diferentes escenarios. A continuación, se abordará la dinámica de las maniobras discretas que fueron seleccionadas.

1) *Hovering Turn* En esta maniobra, el piloto debe controlar el helicóptero para moverse únicamente en el eje de guiñada o dirección (*Yaw axis*) utilizando los pedales antitorque. La dinámica de esta maniobra está representada en la ecuación (3), donde δ_{ped} es la entrada realizada por el piloto con los pedales antitorque. Esta representa una dinámica de bajo orden de un helicóptero en *hover*. El factor de amortiguamiento de dirección N_r para este caso es de $-0,33 \text{ sec}^{-1}$. La sensibilidad de los pedales, N_δ , es de $0,25 \text{ rad/s}^2$. [37]

$$\frac{\ddot{\psi}}{\delta_{\text{ped}}}(s) = \frac{N_\delta s}{s - N_r} \quad (3)$$

El rotor de cola también genera una fuerza en dirección lateral junto con el movimiento direccional; sin embargo, para este caso, se optó por modelar únicamente el movimiento direccional con el fin de simplificar el diseño.

2) *Side-Step* Esta maniobra tiene solo dos grados de libertad: el desplazamiento lateral y el ángulo de inclinación lateral o alabeo (*Roll angle*). Las ecuaciones de movimiento (4) y (5) representan un modelo matemático de un helicóptero que está completamente coordinado en el centro de masa de la aeronave, lo que simplifica la dinámica al no considerar las fuerzas laterales que contribuyen al movimiento direccional del helicóptero. [1].

$$\dot{\phi} = -4,5\dot{\phi} + 1,7\delta_{\text{lat}} \quad (4)$$

$$\dot{v} = g \sin \phi \quad (5)$$

Donde $\dot{\phi}$ es la aceleración del ángulo de inclinación, \dot{v} es la aceleración en el marco del cuerpo, y σ_r es la entrada realizada por el piloto a través del control del cíclico.

3) *Vertical Maneuver* La dinámica de esta maniobra se basa en un modelo matemático general de un helicóptero. La función de transferencia representativa está descrita en la

ecuación (6). Extraído de [1]

$$\frac{\ddot{h}}{\delta_c}(s) = \frac{9s}{s + 0,3} \quad (6)$$

Donde δ_c es la entrada realizada por el piloto utilizando el colectivo. Usualmente, se debe agregar un retraso a la señal para aproximar la demora que causa la dinámica del motor. Para ello, se emplean los filtros ‘*WashOut*’, que proporcionan un retraso en la señal y ajustan las entradas realizadas por el piloto, simulando más fielmente el comportamiento real del helicóptero.

F. Caso de Validación

Una prueba inicial básica fue diseñada para ser simple y directa, permitiendo demostrar a través de un pequeño ejemplo si el enfoque propuesto está alineado con los resultados esperados y validar la viabilidad del enfoque con los objetivos establecidos.

Para este primer caso de validación, se utilizó un piloto amateur en la ejecución de la maniobra *Vertical Maneuver*. En esta ocasión, la maniobra fue tratada de manera diferente a lo previamente planteado. El helicóptero fue situado a una altitud de 200 pies sobre el suelo en vuelo estacionario (*hover*), con el objetivo de ascender hasta los 300 pies a una velocidad constante. Una vez alcanzada la altitud deseada, el piloto debía mantener el vuelo estacionario durante al menos dos segundos, sin exceder una duración total de 15 segundos.

El modelo matemático utilizado durante esta prueba básica fue el que se muestra en la ecuación (6). Debido a la inexperiencia del piloto y para minimizar el ruido en la toma de datos, se decidió utilizar únicamente el control del colectivo, permitiendo mover la aeronave exclusivamente en el eje vertical. De esta manera, se evitó la necesidad de controlar los otros ejes de movimiento, facilitando el análisis de los resultados en condiciones más simples y controladas.

Un filtro de segundo orden de alto paso, ver ecuación (7), es usualmente utilizado en las simulaciones de vuelo. En este caso, el filtro se coloca entre los comandos que el piloto manda y el modelo matemático utilizado.

$$\frac{\ddot{h}_{com}}{\ddot{h}}(s) = \frac{Ks^2}{s^2 + 2\zeta\omega s + \omega^2} \quad (7)$$

Donde \ddot{h}_{com} son las entradas realizadas por el piloto y \ddot{h} es la respuesta entregada al modelo matemático. La calibración de las ganancias y la frecuencia fueron la v4 de la tabla I que hace referencia a la figura 7, ya que esta configuración genera una mayor fidelidad al modelo. El *damping ratio* ζ tiene un valor de 0.7.

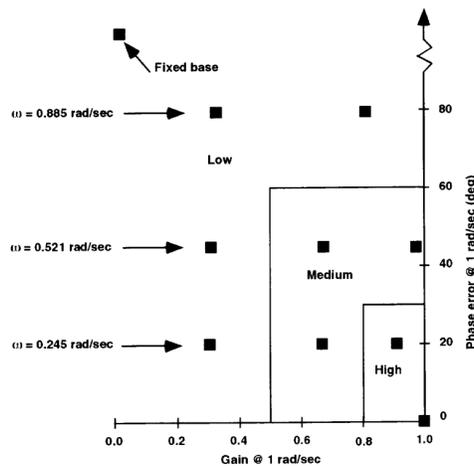


Fig. 7. Configuración de Movimiento de Vertical Maneuver. Figura extraída de [1]

Se realizaron un total de 10 vuelos, de los cuales los primeros 5 fueron utilizados para el entrenamiento de la red neuronal LSTM, mientras que los últimos 5 se destinaron a la prueba de la red. El rendimiento y la precisión del modelo dependen del número de iteraciones y de la estructura de la red que se emplee. En el entorno de MATLAB, existen dos modos de salida específicos según la función que se desea realizar: 'sequence' y 'last'. En este caso, se utilizó el modo 'sequence', que es adecuado cuando se requiere realizar predicciones o tomar decisiones en cada paso de una secuencia. Este modo es útil en sistemas de control continuo, donde se necesita una respuesta constante, en lugar de una predicción final. Dado que en este caso se trata de un sistema en el que es fundamental conocer la respuesta de la red en función de las entradas proporcionadas por el piloto, el modo 'sequence' es el más apropiado.

TABLA I
PARÁMETROS DE FILTRO DE SEGUNDO ORDEN. TABLA EXTRAÍDA DE [1]

Configuration	K	ω (rad/sec)
V1	1.000	0.010
V2	0.901	0.245
V3	1.000	0.521
V4	1.000	0.885
V5	0.650	0.245
V6	0.670	0.521
V7	0.300	0.245
V8	0.309	0.521
V9	0.377	0.885
V10	0.000	-

El flujo de información que se utilizó se muestra en la figura 8, como se observa, los datos que se usaron para entrenar la red fueron extraídos directamente de la entrada del colectivo y posteriormente entrenados por la red.

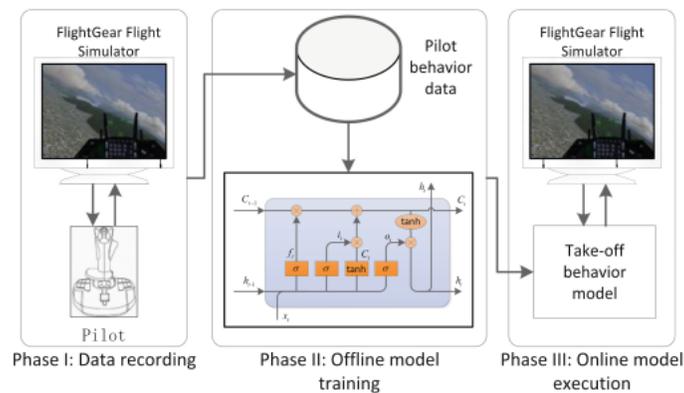


Fig. 8. Diagrama de Flujo de Datos. Figura extraída de [4]

La red fue diseñada con un total de 200 nodos o neuronas, y se realizaron 300 iteracio-

nes. Determinar con exactitud la cantidad adecuada de nodos y el número de iteraciones es complejo, ya que no existen métodos establecidos para estimar estos valores. Estos parámetros dependen de factores como la cantidad de datos a entrenar, el poder de cómputo y la arquitectura de la red neuronal. Por esta razón, se opta por el método de ensayo y error.

En un entrenamiento preliminar de la red, se probó con 500 nodos y 700 iteraciones, obteniéndose un valor de error cuadrático medio (RMSE) de 0.0541. Esto puede inducir a pensar que a mayor cantidad de nodos e iteraciones, el error seguirá disminuyendo. Sin embargo, al utilizar una cantidad de 200 nodos y 300 iteraciones, se logró un RMSE de 0.0436, no solo siendo este un valor inferior, sino también teniendo un costo computacional menor. Esto demuestra que no siempre una mayor cantidad de nodos asegura una mejor precisión, y que se debe buscar siempre el rendimiento más óptimo sin dejar de lado la fidelidad ni comprometer el costo computacional. La figura 9 muestra la gráfica del RMSE y la pérdida que está experimentando la red, donde se observa que a medida que se realizan las iteraciones y se calcula en cada uno de los nodos, este va disminuyendo hasta estabilizarse en el valor antes mencionado. La pérdida con valores altos indican que la red no está realizando predicciones precisas, mientras que los valores bajos reflejan una mejora en estas. Al inicio, la pérdida es elevada, lo cual es normal ya que durante las primeras fases del entrenamiento, la red ajusta sus parámetros. A medida que avanzan las iteraciones, la pérdida disminuye de manera significativa, lo que sugiere un aprendizaje adecuado, proporcionando resultados más precisos. Después de aproximadamente 250 iteraciones, la pérdida se estabiliza, alcanzando un valor constante. Esto indica que la red ha llegado a un punto donde no puede mejorar significativamente y el error es mínimo.

La gráfica mostrada en la figura 10 compara los valores del colectivo proporcionados por el piloto y la predicción generada por la red neuronal LSTM. La línea morada más definida representa la respuesta obtenida por la red, y sigue razonablemente algunas tendencias de los valores reales. Se observa que los vuelos se extienden hasta aproximadamente el segundo 15, donde los ajustes en el colectivo se vuelven casi nulos.

La red neuronal también logra capturar correctamente los intervalos donde las variaciones en el colectivo son más rápidas, lo que indica un aprendizaje adecuado. Sin embargo,

existen algunas desviaciones en zonas donde no hay datos de entrenamiento, lo cual es un fenómeno común en este tipo de modelos.

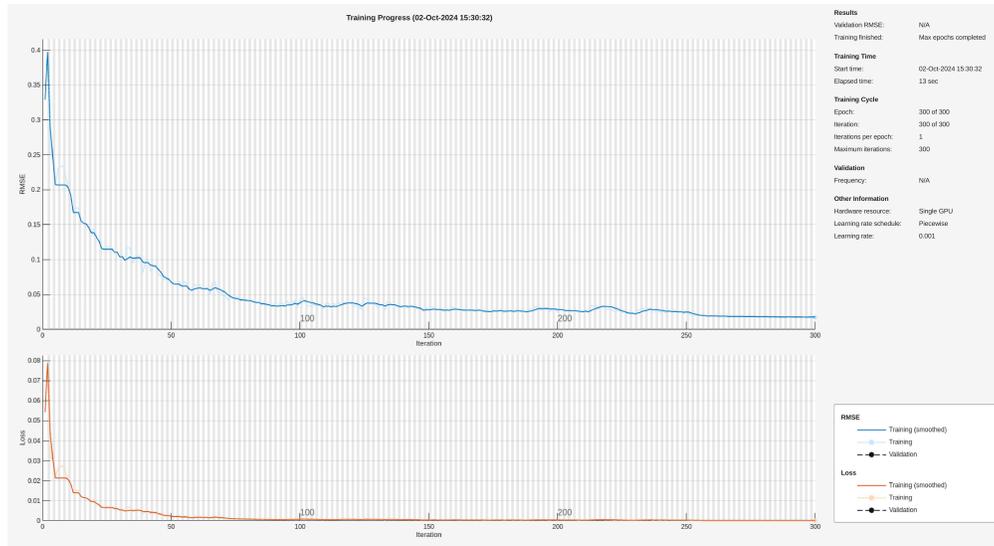


Fig. 9. Entrenamiento de la Red Neuronal para el Caso de Validación

En conclusión, este ejemplo establece una base sólida para el desarrollo de un caso más complejo, en el que las maniobras previamente descritas y los modelos que las interpretan puedan ser empleados para que los pilotos realicen vuelos, entrenando así una red neuronal LSTM con el objetivo de minimizar la influencia de errores humanos. Esto resulta esencial para avanzar en el desarrollo de nuevas tecnologías orientadas al control del tráfico aéreo.

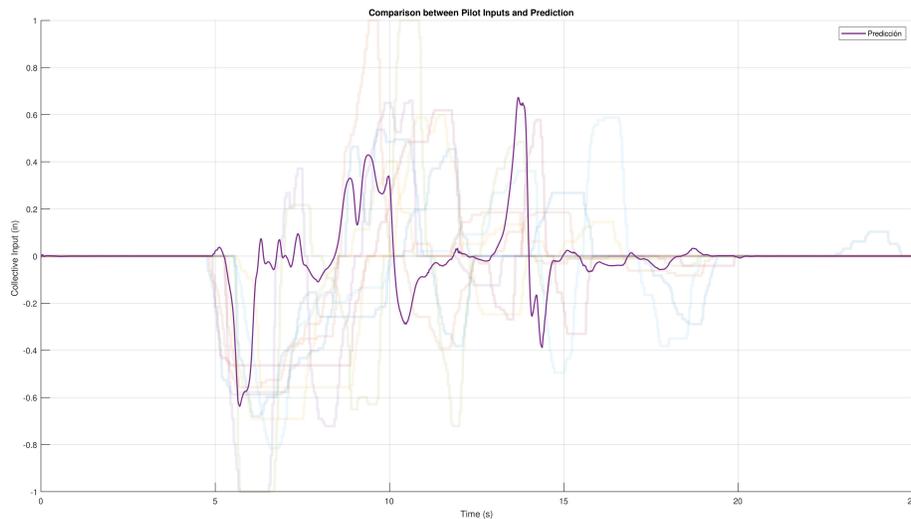


Fig. 10. Predicción de la Red Neuronal en Caso de Validación

VII. EXPERIMENTO Y RESULTADOS

El planteamiento del experimento se basó en la ejecución de las maniobras discretas que anteriormente fueron mencionadas. Para ello, se contó con un total de 24 personas voluntarias, quienes ayudaron en la recolección de los datos, donde cada una realizó cuatro intentos por maniobra, obteniendo un total de 16 vuelos por persona. Es importante resaltar que cada voluntario tenía poca o nula experiencia en simuladores, lo que permitió formular una hipótesis según la cual, a medida que se vayan realizando los intentos, los voluntarios irán mejorando paulatinamente sus habilidades. Este aspecto es relevante, ya que no se contó con personal entrenado y calificado para la obtención de datos, compensando la falta de experiencia con la cantidad de intentos realizados por los voluntarios. Los tipos de datos recopilados de cada maniobra se muestran en la tabla II.

Con todos los vuelos realizados, se pretende utilizar una red neuronal para cada intento de cada maniobra, sumando un total de 12 redes. El objetivo es evaluar la capacidad de aprendizaje de la red según la maniobra y el intento realizado. Se busca implementar este enfoque mediante un entrenamiento offline, donde los resultados servirán como entradas para cada maniobra. Posteriormente, se realizará una ejecución online para observar cómo la red

realiza cada maniobra en tiempo real.

TABLA II
DATOS DE VUELO Y ENTRADAS DE LOS PILOTOS

Datos de vuelo				Entradas de los pilotos	
Nombre	Unidad	Nombre	Unidad	Nombre	Unidad
Distancia Vertical	m	Ángulo de roll	deg	Colectivo	in
Distancia Lateral	m	Ángulo de yaw	deg	Cíclico	in
Velocidad Vertical	m/s	Velocidad de roll	rad/s	Pedales	in
Velocidad Lateral	m/s	Velocidad de yaw	rad/s	-	-

MATLAB ofrece un método de implementación de redes neuronales completo, en el que se pueden ajustar varios parámetros según la necesidad del usuario. Por ejemplo, se puede modificar la cantidad de nodos o neuronas que tendrá cada capa oculta, además de la posibilidad de utilizar más de una capa oculta y otras opciones para personalizar el entrenamiento de la red según los requisitos del usuario. Esto es beneficioso para monitorear el rendimiento de la red. Además, MATLAB muestra el error que tiene el entrenamiento, aunque entender a qué se refiere exactamente este error puede ser complicado, ya que se trata de procesos internos a los que el usuario no tiene acceso directo.

A diferencia de lo establecido en el ADS-33 [3], se seleccionaron otros parámetros para evaluar las mismas maniobras con el objetivo de adaptar el experimento a los pilotos voluntarios. Las normas descritas en el ADS-33 están diseñadas para pilotos entrenados, y si se hubieran utilizado los mismos parámetros de evaluación, no habría sido posible obtener datos útiles para un análisis posterior. Dado que la mayoría de los voluntarios tenía poca o nula experiencia en simuladores, fue necesario ajustar los criterios de evaluación.

El orden de ejecución de las maniobras para cada piloto siempre fue el mismo, comenzando con el bob-up o vertical maneuver, seguido por el roll-sway o sidestep, luego el hovering turn, y como última maniobra, se repetía el bob-up, con la diferencia de que en esta ocasión se evaluaba la capacidad del piloto para controlar el movimiento del helicóptero en el eje de dirección. Cada vuelo tuvo una duración máxima de 25 segundos. No se estableció

un umbral final para evaluar el error cometido por cada piloto en la simulación, aunque se solicitó a los participantes que intentaran ser lo más precisos posible para obtener datos de alto valor.

El entorno gráfico de FlightGear permite adicionar estructuras a los escenarios, que en este caso serían útiles para que los pilotos tuvieran una guía visual de cada maniobra. Sin embargo, esta opción fue descartada, ya que habría añadido complejidad para los pilotos. En su lugar, se optó por realizar una modificación al head-up display (HUD) predeterminado (ver figura 11), lo que facilitó la comprensión de las maniobras y redujo la carga visual y de análisis del piloto.



Fig. 11. Head-up Display (HUD) Predeterminado

FlightGear, al ser un programa de código abierto, permite la visualización y modificación del código fuente. La adaptabilidad que ofrece el software, junto con los manuales incluidos en la instalación que detallan cómo realizar estas modificaciones, fue aprovechada para ajustar el HUD (head-up display) y adaptarlo a las necesidades específicas de cada maniobra. Esto proporcionó una experiencia de manejo más sencilla y efectiva para los pilotos.

A continuación se explicará cómo fueron diseñadas las maniobras para equilibrar la pericia de los pilotos, así como los resultados y análisis.

A. Resultados de los Pilotos

1) *Bob-up*: En esta maniobra, el piloto, utilizando únicamente el control del colectivo, debe realizar un vuelo controlado. Al iniciar la simulación, el helicóptero se encontrará a una altitud de 15 metros respecto al suelo. Posteriormente, el piloto deberá elevarse y mantenerse en un vuelo estable, durante al menos un segundo, a una altitud de 21 metros sobre el nivel del suelo. Una vez alcanzada esta altura, deberá descender nuevamente a la altitud inicial.

El dispositivo utilizado para simular el control del colectivo fue el Thrustmaster Throttle (ver figura 6a). La sensibilidad fue ajustada para simular con mayor precisión la respuesta de un helicóptero de mediana capacidad, donde pequeños ajustes en el control resultarían en cambios significativos en la altitud.

El HUD implementado, como se muestra en la figura 12, tiene una barra a la izquierda que representa la posición actual del colectivo en todo momento. En la barra central se observan dos flechas: la de la izquierda indica la altitud actual del helicóptero, mientras que la de la derecha actúa como una guía visual que el piloto debe seguir durante la maniobra. Además, en la parte superior del HUD se muestra el ángulo de dirección del helicóptero.



Fig. 12. HUD: Bob-Up

A diferencia del HUD predeterminado, esta versión incluye menos información, lo que

ayuda a reducir la fatiga visual que podrían experimentar los pilotos. Se decidió mostrar solo los datos esenciales para la ejecución de las maniobras, permitiendo a los participantes concentrarse en los elementos clave para el control de la aeronave.

El modelo dinámico utilizado en esta maniobra fue el descrito en la sección anterior, y fue implementado en el software Simulink. Además, la guía visual en el HUD también hace uso del mismo modelo dinámico, con la diferencia de que fue calibrada para seguir una trayectoria ideal sin cometer errores, proporcionando así una referencia precisa para que el piloto pudiera seguirla durante la maniobra. Esto facilitó que los pilotos no entrenados tuvieran una mayor facilidad para completar la maniobra con éxito.

a) Resultados y análisis: Los resultados obtenidos proporcionaron una visión clara del desempeño de cada piloto, donde se evaluó el control del helicóptero en las condiciones previamente establecidas. El análisis de estos datos recolectados tiene como objetivo identificar si hubo patrones de mejora a medida que se realizaban los intentos y observar si la guía visual fue capaz de influir en el control proporcionado por el piloto. También serán útiles para determinar si los datos adquiridos son de alto valor para el entrenamiento de la red neuronal, y si esta puede representar un comportamiento humano coherente.

En la figura 13 se observa cómo fueron las entradas realizadas por cada uno de los pilotos en el control del colectivo. Sin embargo, la interpretación resulta difícil debido a la gran dispersión visual de los datos, y no se percibe un patrón claro que indique una buena correlación entre los datos, sugiriendo que no existe una consistencia entre las entradas de los pilotos a lo largo de los intentos.

Esta alta variabilidad puede ser resultado de la inexperiencia de los pilotos en los simuladores, lo que complica la identificación de patrones claros en el uso del colectivo, sugiriendo que cada piloto pudo haber interpretado las condiciones de la maniobra de manera diferente y respondieron según lo que creyeron que era más acertado.

La ausencia de un punto de referencia claro y un patrón en las entradas del colectivo podría indicar que los pilotos no lograron seguir de manera consistente la guía visual proporcionada. Además, los picos observados en las gráficas podrían estar relacionados con

correcciones bruscas o erráticas realizadas por los pilotos, siendo más evidentes en el primer intento, donde los picos son más altos y frecuentes. Esto suele ser común en pilotos con poca experiencia, ya que tienden a compensar de forma agresiva para ajustarse a la maniobra, lo que resulta en fluctuaciones notables.

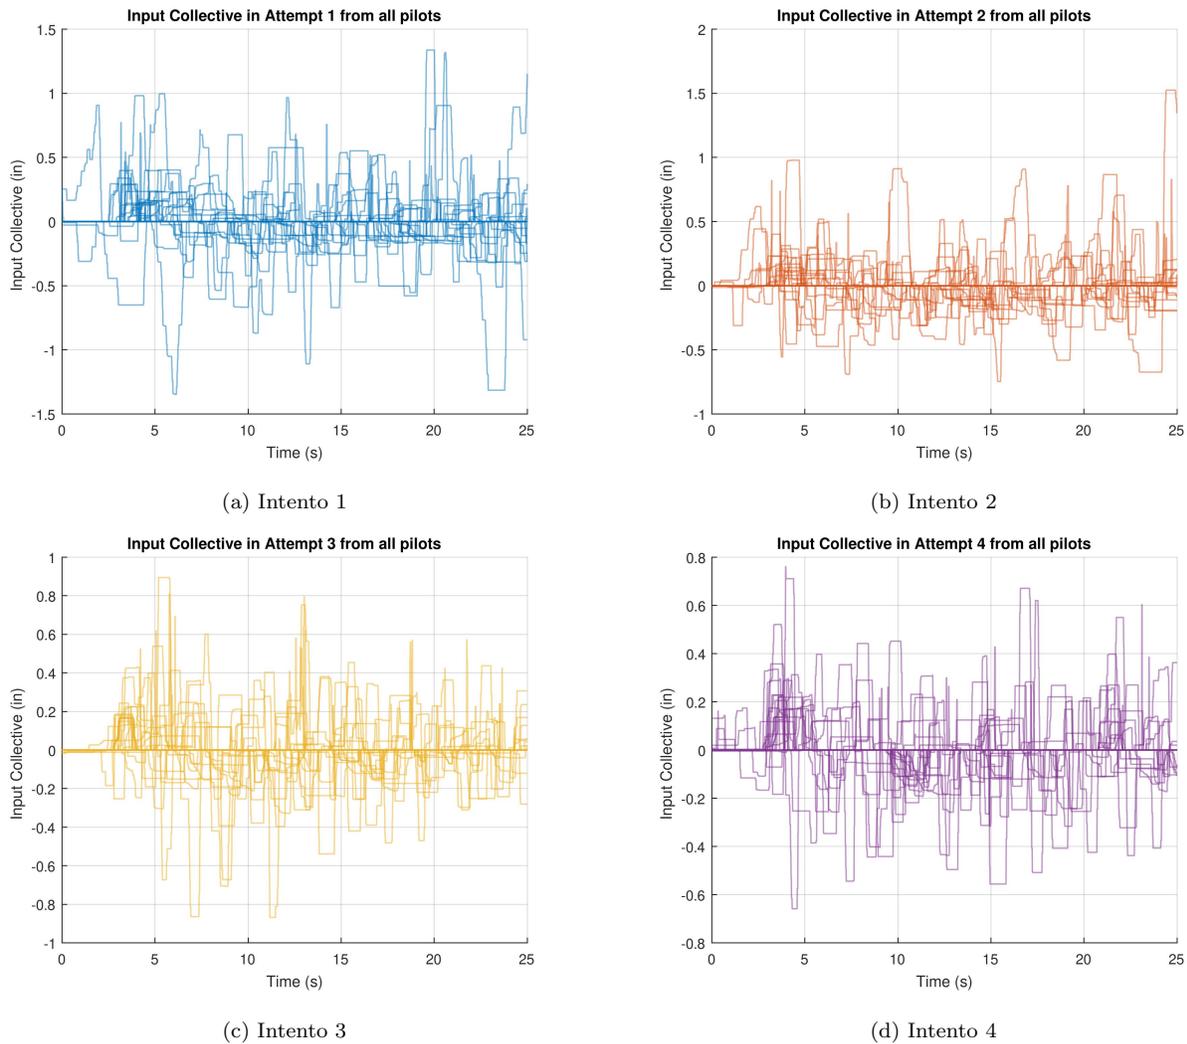


Fig. 13. Entradas Realizadas por los Pilotos en el Colectivo

En la figura 14 se observan las variaciones de altitud registradas en cada uno de los intentos realizados por los pilotos. Cada gráfico muestra el comportamiento de la altitud del helicóptero a lo largo del tiempo. Se evidencia una alta variabilidad, lo que sugiere que no todos lograron seguir de manera consistente la guía visual. Esto es especialmente notable

en el primer intento, donde se observa una mayor dispersión de los datos, en el que algunos pilotos llegan a superar los 21 m de manera exagerada.

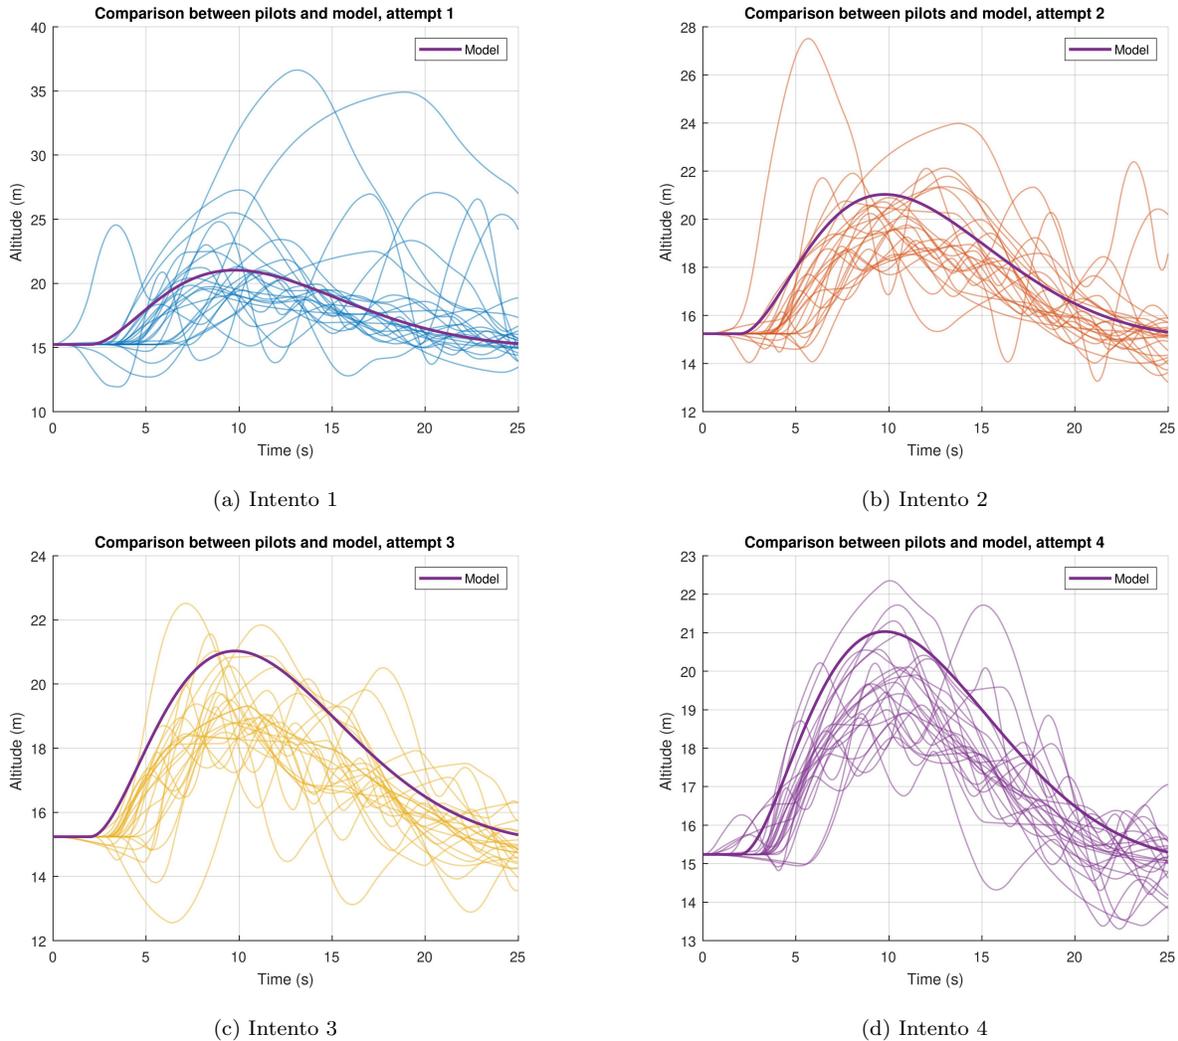


Fig. 14. Comparación de la Altitud del Helicóptero entre los Pilotos y el Modelo

Sin embargo, se puede identificar un patrón a lo largo de los intentos y, aunque en el primero la variabilidad fue considerable, en los siguientes se nota una mejora progresiva. Esto se aprecia especialmente en el último intento, donde los pilotos mostraron un control más preciso del helicóptero, con fluctuaciones menos notorias en la altitud y menos error respecto a la altitud objetivo.

Este comportamiento sugiere que, aunque los pilotos al principio tuvieron dificultades

en el manejo del colectivo, se fueron adaptando progresivamente a los controles y a la situación, lo que llevó a una mejora en sus habilidades con el paso de los intentos. Aunque no se esperaba que los pilotos ejecutaran la maniobra de manera perfecta, sí se logró una mejora significativa en los resultados.

En la figura 14, también se muestra cómo fue el desempeño de los pilotos en comparación con el comportamiento ideal de la maniobra. Se observa que, en general, los pilotos lograron, aunque con variaciones significativas, acercarse al modelo. En el primer intento hay una dispersión mayor, lo que refleja el desafío que enfrentaron para controlar el colectivo y seguir la guía visual.

A pesar de que los pilotos no lograron alcanzar o imitar de forma perfecta la maniobra con respecto al modelo, las gráficas sugieren una curva de aprendizaje positiva, en la cual la precisión de la altitud fue mejorando con cada intento. Cabe destacar que las fluctuaciones en cada intento fueron menores respecto al modelo, lo que indica una creciente familiaridad con los instrumentos y el modelo dinámico utilizado.

Las velocidades que experimentó el helicóptero en cada intento realizado por los pilotos, en comparación con el modelo ideal, se muestran en la figura 15. Se observa que el comportamiento de la mayoría de los pilotos tiende a asemejarse, en cierta medida, a la velocidad ideal. No obstante, también se identifican datos que se desvían significativamente de la media esperada, lo que refleja la variabilidad en el desempeño de los pilotos y su falta de experiencia en el control del helicóptero.

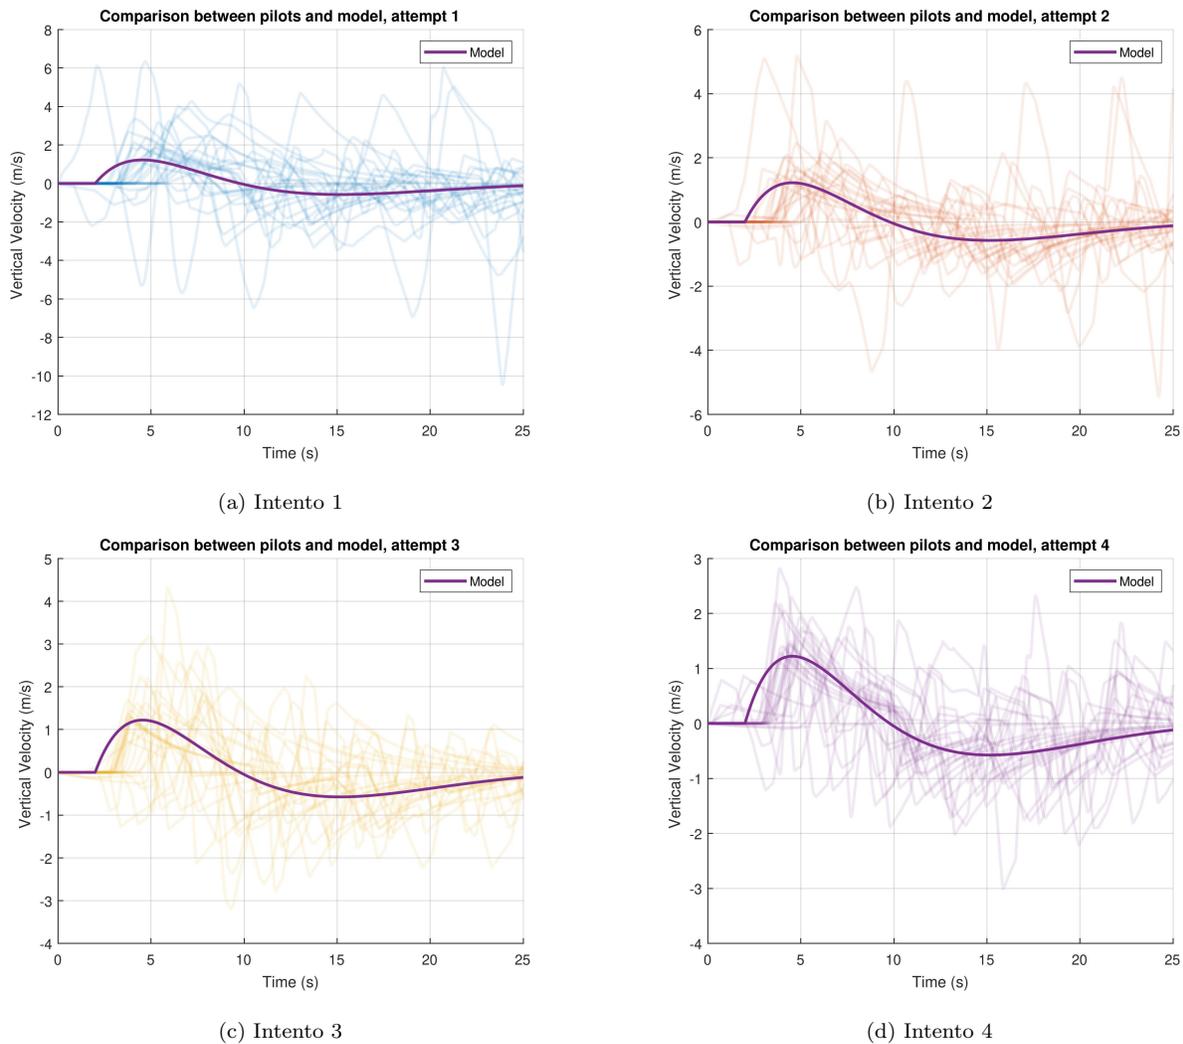


Fig. 15. Comparación de la Velocidad Vertical del Helicóptero entre los Pilotos y el Modelo

2) *Side-Step*: En esta maniobra, el piloto, utilizando únicamente el control del cíclico, deberá realizar un vuelo controlado. Al iniciar la simulación, se ubicará en un hover a 15 m de altitud respecto al suelo. Posteriormente, el piloto deberá inclinar el helicóptero en un ángulo de roll para realizar un desplazamiento lateral. Una vez alcanzada cierta velocidad, deberá cambiar el ángulo de roll hacia el lado contrario para frenar, ubicándose finalmente a 50 m de distancia con respecto a la posición original.

Esta maniobra presenta ciertos desafíos para los pilotos, especialmente porque no están acostumbrados a maniobrar este tipo de helicópteros y, en particular, desconocen cómo

controlar su dinámica. Un problema recurrente fue que los pilotos tuvieron dificultades para saber en qué momento comenzar a frenar, ya que no contaban con ninguna ayuda visual adicional, aparte de la que se mostraba en el HUD, ver figura 16.



Fig. 16. HUD: Side-Step

El HUD únicamente muestra la posición lateral actual del helicóptero con respecto a la posición inicial, representada por la flecha superior en la barra de la mitad. La flecha inferior es la guía visual que indica el movimiento ideal que el piloto debe seguir, obligando al piloto a depender exclusivamente de esta información para gestionar el frenado y la precisión del desplazamiento. El modelo dinámico que dicta el movimiento de la flecha inferior es el mismo que se usa para el helicóptero, haciendo que la maniobra sí pueda ser imitada con precisión.

El dispositivo que hará las veces de cíclico es el Thrustmaster T1600 (ver figura 6b). Este joystick es capaz de emitir un control preciso, emulando las funciones de uno real. La sensibilidad y configuración del mismo fueron ajustadas para replicar de manera realista las respuestas dinámicas esperadas.

a) Resultados y análisis: Esta maniobra, en particular, presentó grandes problemas para los pilotos, ya que no supieron en qué instante empezar a compensar y frenar el helicóptero.

A continuación, se presentarán los resultados de las entradas que realizó cada piloto en el control de cíclico durante cada intento. El manejo de este es fundamental para el dominio de la inclinación en ángulo de pitch y roll, permitiendo ajustar la dirección y mantener la estabilidad. Los datos recopilados muestran cómo los pilotos manejaron el helicóptero.

En la figura 17, se muestran las entradas realizadas por los pilotos. A diferencia de la maniobra anterior, se logra apreciar un patrón consistente en el comportamiento de cada intento, a excepción de algunos datos que se desvían de la media, sugiriendo un proceso de aprendizaje consistente y menos correcciones.

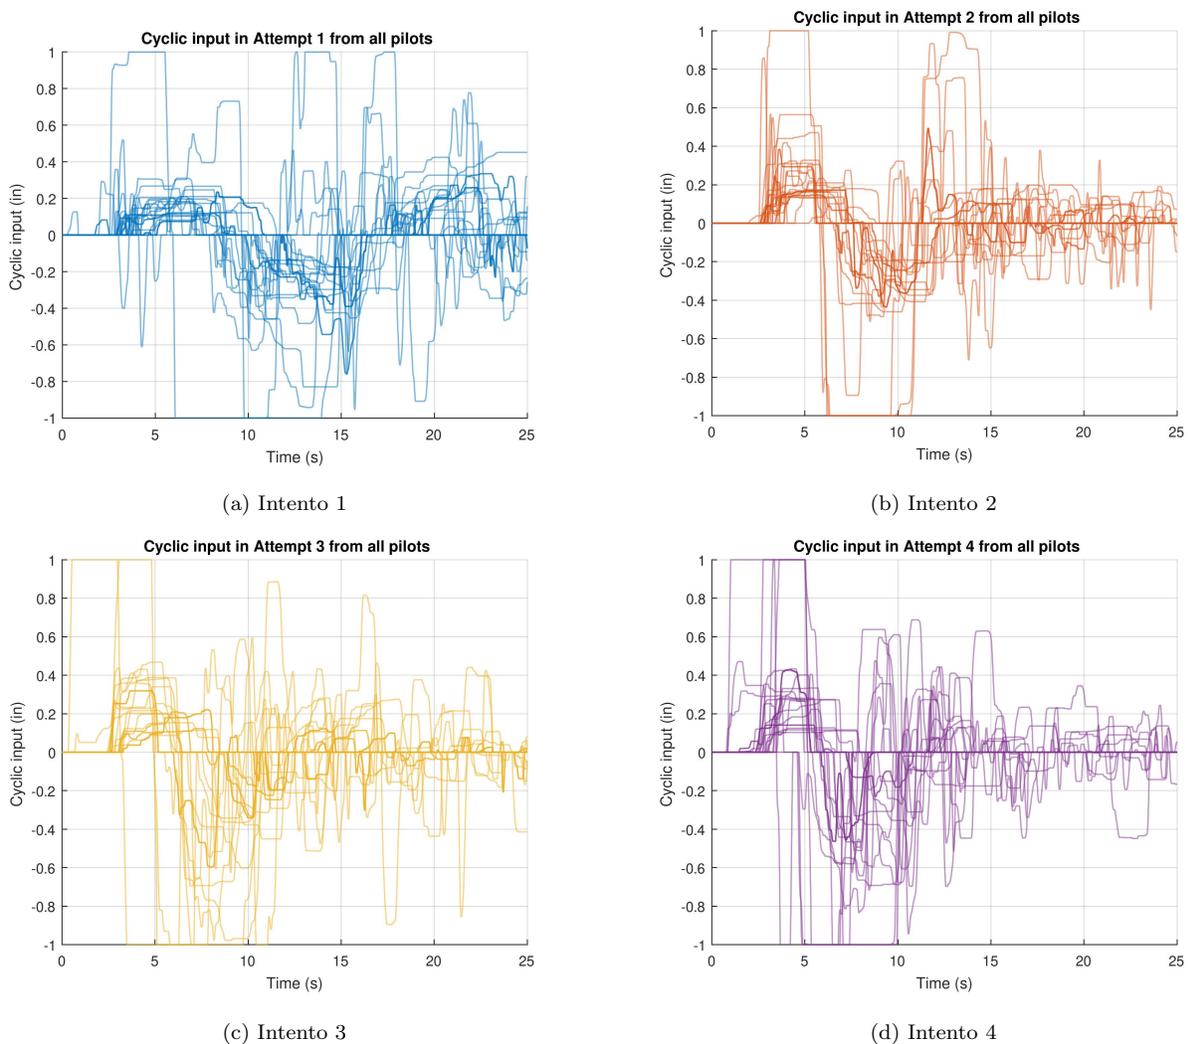


Fig. 17. Entradas Realizadas por los Pilotos en el Cíclico

El desplazamiento del helicóptero realizado por los pilotos se muestra en la figura 18. Como era de esperarse, en el primer intento los pilotos tuvieron desplazamientos más erráticos, donde incluso algunos alcanzaron los 120 m de distancia cuando la maniobra indicaba detenerse a los 50 m. Sin embargo, a medida que avanzaban en los intentos, el error fue disminuyendo, logrando en el último una mejor precisión. Esto indica que, si bien con la práctica los pilotos lograron una mejor comprensión del funcionamiento del cíclico, llevando a trayectorias más consistentes, algunos pilotos aún presentaban muchas desviaciones.

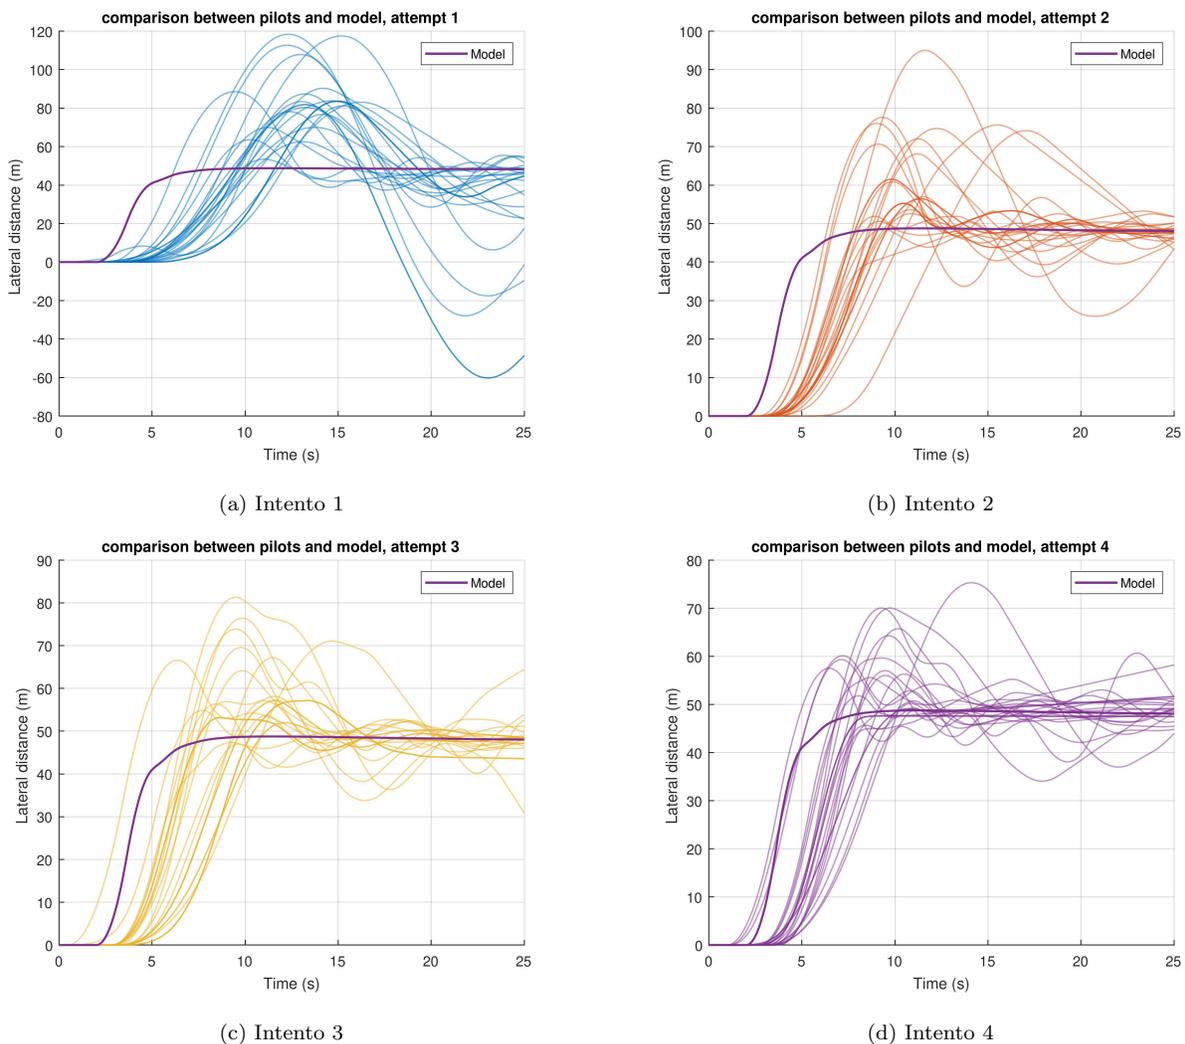


Fig. 18. Comparación de Desplazamiento Lateral del Helicóptero entre los Pilotos y Modelo

El desempeño de los pilotos, en comparación con la guía visual, fue bueno y se observó

una mejora notable en la precisión del vuelo, como se muestra en la figura 18. Además, se aprecia que en todos los intentos la reacción es tardía en comparación con el modelo. Esto se asocia a la demora existente en la conexión del sistema visual, el procesamiento de información en el cerebro, y la reacción del sistema propioceptivo. No obstante, esta demora es aceptable dentro de los parámetros establecidos para esta maniobra.

Es interesante observar que, aunque el modelo presenta una trayectoria rápida y sin errores, los pilotos lograron reducir significativamente el desfase a medida que realizaban los intentos. Esto sugiere que, con una mayor cantidad de intentos, y a pesar de su inexperiencia en simuladores de vuelo, los pilotos podrían haber realizado la maniobra de manera óptima.

En la figura 19, se muestra la velocidad lateral de los pilotos en todos los intentos, comparada con el modelo utilizado para la guía visual. En el primer intento, se observa una alta variabilidad, con varios pilotos alcanzando picos de velocidad y luego disminuyendo gradualmente. A medida que se avanza en los demás intentos, las velocidades se vuelven más similares entre sí y se acercan al modelo, aunque aún persisten algunos casos en los que las velocidades alcanzan valores más altos de lo ideal. En el último intento, se observa una mejora, mostrando una tendencia a seguir el comportamiento del modelo, con una reducción en la dispersión y una curva más alineada con el modelo.

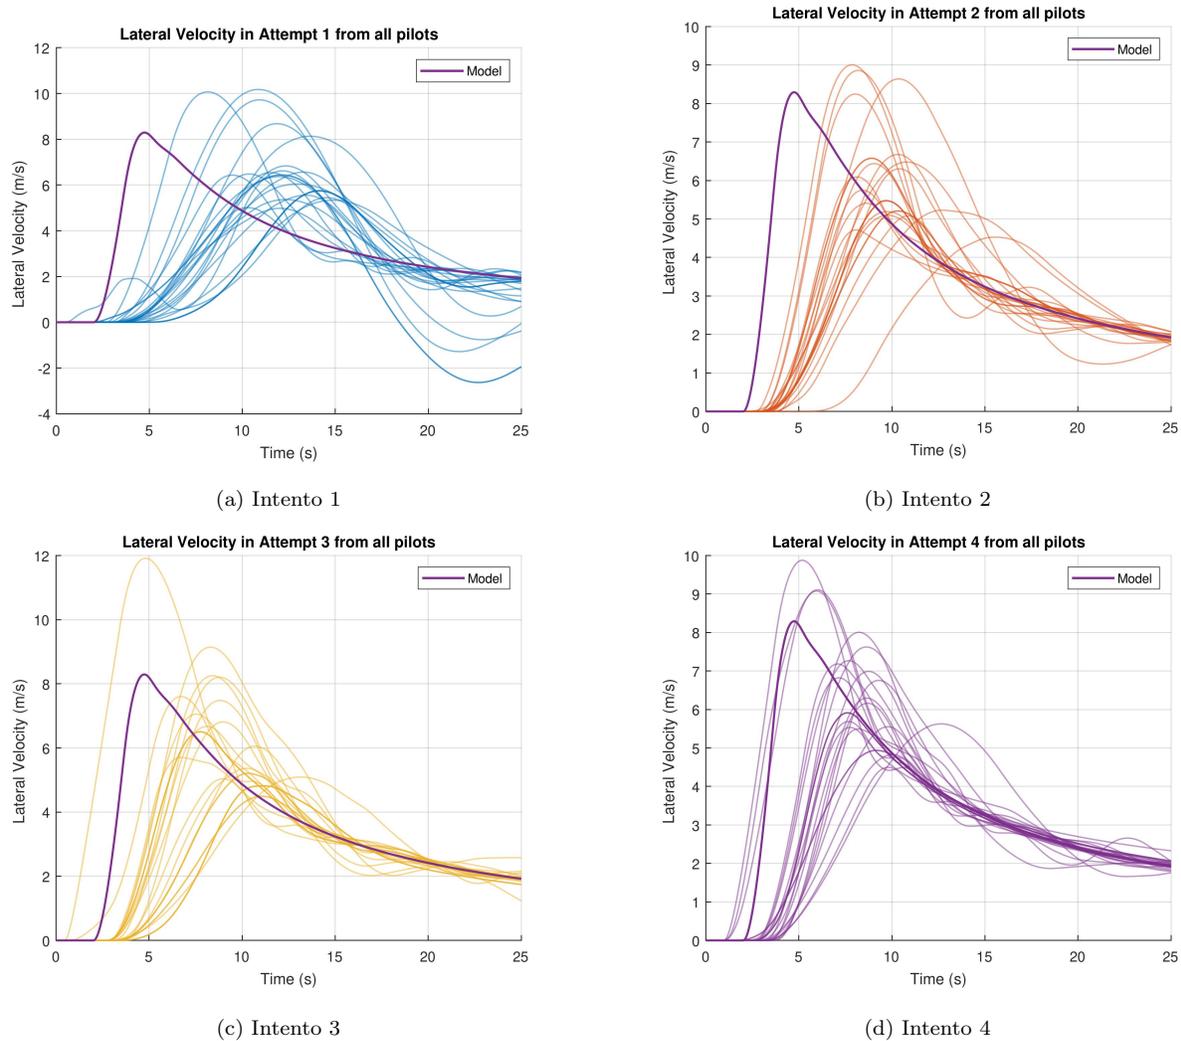


Fig. 19. Comparación de la Velocidad Lateral del Helicóptero entre los Pilotos y Modelo

3) *Hovering Turn*: En esta maniobra, el piloto, utilizando únicamente los pedales antitorque, deberá hacer una rotación controlada de 60 grados en el ángulo de yaw. El objetivo de esta maniobra es que los pilotos logren mantener un control preciso del helicóptero en todo momento, evitando desviaciones no deseadas y asegurando una rotación suave y estable.

El dispositivo utilizado para simular los pedales antitorque son los Thrustmaster Pedals Rudder (ver figura 6c). Fueron ajustados para que las respuestas se asemejaran a las de un helicóptero de mediana capacidad. Esto permite al piloto simular el control necesario para giros precisos y mantener la estabilidad durante el vuelo.

El HUD implementado es el que se muestra en la figura 20, donde la barra central horizontal actúa como el indicador del ángulo de dirección. La flecha superior representa el ángulo actual del helicóptero, mientras que la flecha inferior corresponde a la guía visual proporcionada al piloto. El objetivo de la maniobra es que el piloto logre seguir el movimiento de la flecha inferior, ajustando el ángulo de dirección del helicóptero al mismo ritmo con el que se desplaza la guía visual.

Esta maniobra presentó un desafío para los pilotos en los primeros intentos, ya que les dio dificultad coordinar los pies y seguir la guía visual proporcionada. La necesidad de ajustar continuamente el control de los pedales para mantener el ángulo de dirección en sincronía con la flecha de referencia resultó ser complejo durante los primeros intentos.



Fig. 20. HUD: Hovering Turn

a) Resultados y análisis: A continuación se presentarán los resultados de las entradas que realizó cada piloto en el control de los pedales durante cada intento y su respuesta a la dinámica de la maniobra. Estos resultados permitirán analizar cómo los pilotos ajustaron sus acciones para seguir la guía visual y su capacidad para coordinarse con el control de los pedales.

En la figura 21, se muestran las entradas realizadas por los pilotos. En este caso, no se puede identificar un patrón claro, lo que sugiere que los pilotos realizaron muchas correcciones durante toda la simulación. Estos ajustes constantes se reflejan en los picos de cada una de

las gráficas, lo que puede sugerir una dificultad para mantener un control estable durante la maniobra, posiblemente asociado a la falta de entrenamiento de los pilotos.

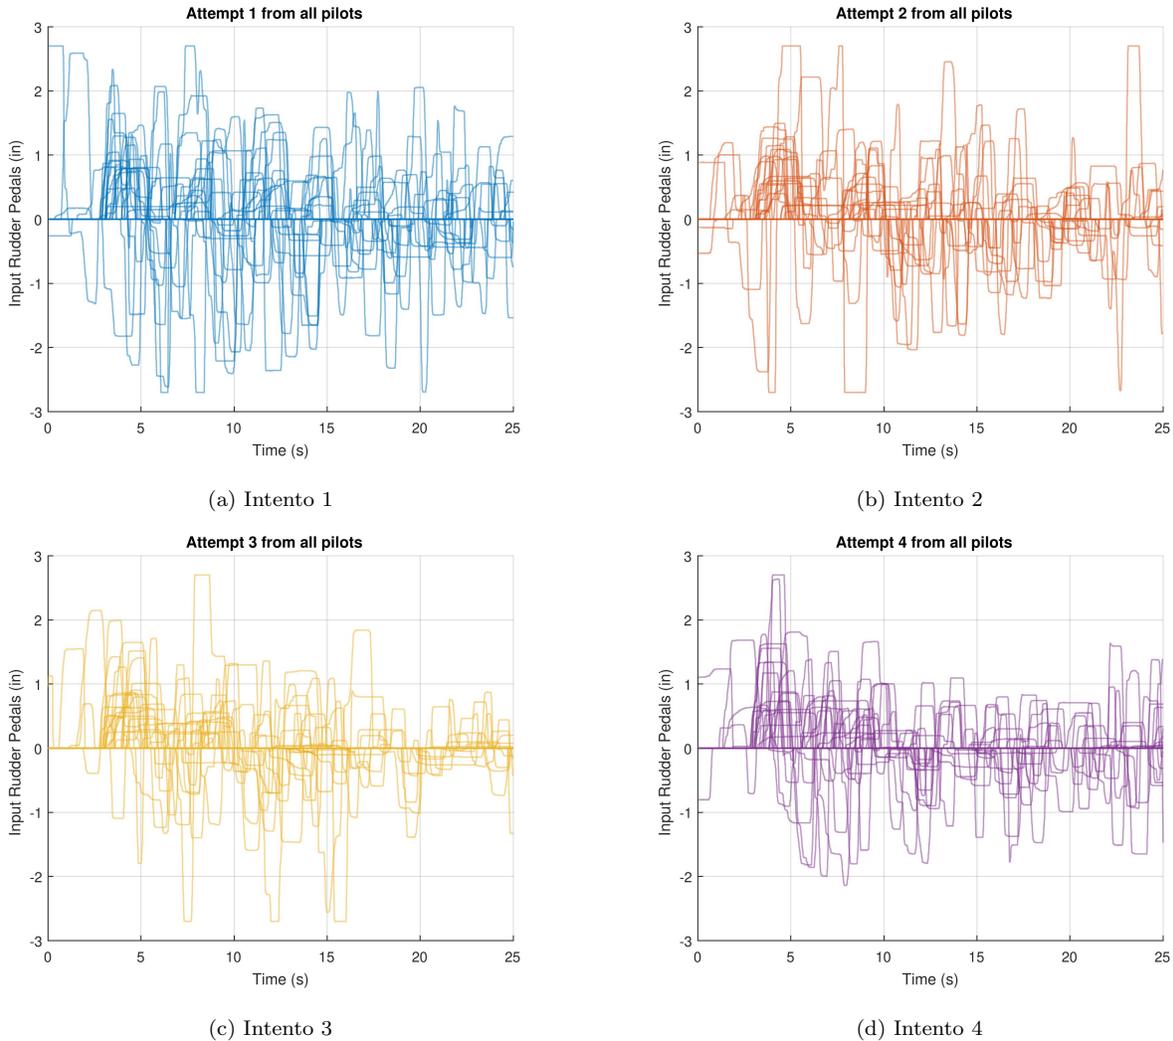


Fig. 21. Entradas Realizadas por los Pilotos en los Pedales

La rotación en el ángulo de dirección del helicóptero realizada por los pilotos se muestra en la figura 22. A lo largo de los diferentes intentos, se puede observar una mejora progresiva en el control de la maniobra. En el intento 4 se logró el mejor resultado con menores variaciones y un seguimiento más estable en comparación con el primer y segundo intento. Esto indica que los pilotos fueron adquiriendo habilidades y familiarización con los controles para la ejecución más precisa de la maniobra.

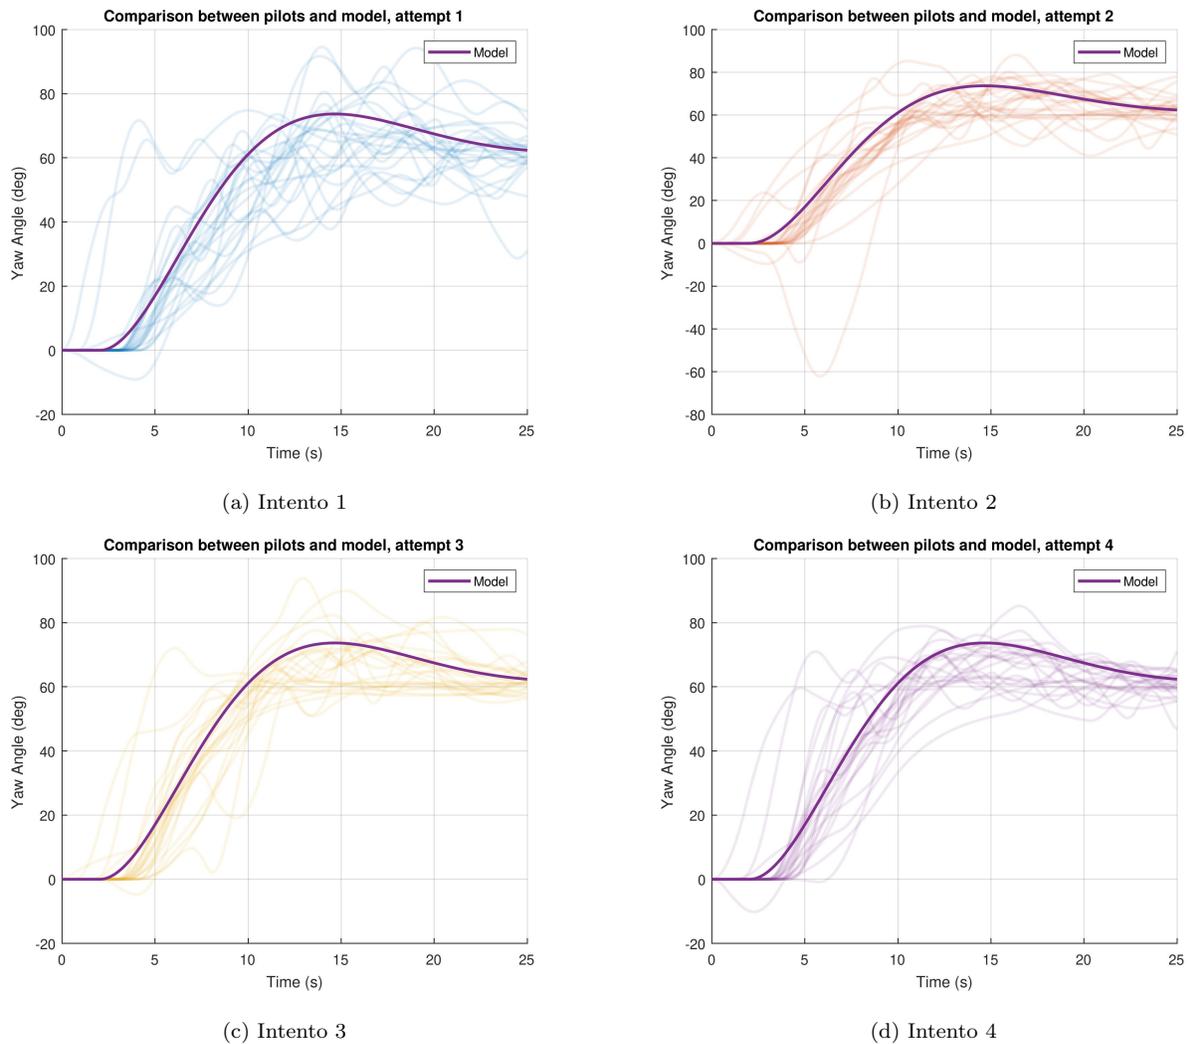


Fig. 22. Comparación de Desplazamiento Lateral del Helicóptero entre los Pilotos y Modelo

A diferencia de lo que se podría pensar al observar las entradas realizadas por los pilotos, los resultados de la maniobra en comparación con el modelo son bastante cercanos. Como se observa en la figura 22, la mayoría de los pilotos lograron seguir la guía del modelo de manera precisa en los cuatro intentos. A pesar de las variaciones en las entradas, el ángulo de dirección logrado al final de la maniobra tiende a coincidir con el modelo, lo que indica que la maniobra se ejecutó de manera satisfactoria, especialmente en los últimos intentos.

B. Planteamiento de la Red Neuronal

Matlab, dentro de su repositorio, ofrece varias soluciones para la implementación de deep learning, entre ellas, las redes neuronales. Es un modelo de computación cuya estructura de capas se asemeja a la estructura interconectada de las neuronas en el cerebro, con capas de nodos conectados. Una red neuronal puede aprender de los datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros [2]. Con esto en mente, se entrenó una red neuronal con los datos de vuelo recopilados, y así saber cómo esta puede responder ante las maniobras a las que se le va a someter.

Para lograr esto, y como se mencionó anteriormente, se va a utilizar redes LSTM (Sección VI). Se entrenó una red por cada intento de cada maniobra, lo que permitió observar el diferente comportamiento y mejora de la respuesta según iba avanzando en los intentos. Esto con el fin de que cada red fuera asociada a un solo intento y poder reducir el error, porque, como ya se abordó con antelación, a los pilotos al principio les daba más dificultad realizar la maniobra de forma óptima y, con el tiempo, lograron mejores resultados.

Otra razón importante para este enfoque fue, la limitante del poder de cómputo con el que se contaba, ya que el equipo disponible tenía restricciones al momento de entrenar las redes. Dado el gran volumen de datos, entrenar todos los intentos de una maniobra en una única red habría requerido un tiempo considerable. Al dividir el entrenamiento, se optimizó el uso de recursos y se redujo significativamente el tiempo de procesamiento sin comprometer la calidad del aprendizaje de las redes.

Si bien se utilizó el mismo tipo de red neuronal para el entrenamiento de cada maniobra, las opciones y parámetros de cada una fueron distintos, porque cada una de estas tiene una naturaleza y comportamiento únicos, lo que requiere ajustes específicos en la red para la optimización del aprendizaje. Los parámetros para cada una fueron obtenidos con prueba y error, ya que no se cuenta con información que indique cuáles son los más adecuados en cada caso. Además, Matlab cuenta con alrededor de 25 a 30 parámetros que se pueden ajustar a necesidad [38]. Solamente dos ajustes comparten todas las redes que fueron entrenadas, siendo estos: la capacidad de elegir la cantidad de capas ocultas y el modo de salida de es-

tas. Se decidió tener un total de dos capas ocultas, con la primera teniendo 450 nodos y la segunda 400; el tipo de salida de ambas se escogió en "sequence", porque este modo ofrece una regresión secuencia a secuencia [38], lo que resulta útil cuando la salida que se espera sea en series de tiempo.

Los datos de cada entrenamiento se dividieron en tres conjuntos: entrenamiento, validación y testeo. Esto con el fin de evaluar el rendimiento de la red.

- **Conjunto de entrenamiento:** Se utilizó para ajustar los parámetros de la red, lo que le permite que aprenda a partir de los patrones que encuentre en los datos.
- **Conjunto de validación:** Sirvió para el monitoreo del rendimiento de la red con datos a los cuales no había tenido acceso. Si en la validación comenzaba a divergir mientras avanzaba el entrenamiento, esto es un indicador de un posible sobreajuste.
- **Conjunto de testeo:** Se utilizó una vez que la red finalizó su entrenamiento, con el fin de generar, en base a este conjunto, una predicción de salida.

C. Prueba de necesidad de retroalimentación

1) *Red Neuronal sin Retroalimentación:* En un principio, la red únicamente fue entrenada con los datos recopilados por los controles de los pilotos, con la suposición de que iba a poder dar un resultado coherente. Sin embargo, el entrenamiento llegaba a demorarse un tiempo considerable y difícilmente llegaba a converger. Esto obligó a realizar ajustes de cada parámetro hasta alcanzar un buen resultado. A pesar de esto, la red nunca alcanzó los resultados esperados. Esto aportó a una nueva hipótesis: era necesario incorporar una retroalimentación de los datos de salida para que la red tuviera una referencia más clara de lo que debía predecir. Ante esta situación, se decidió dar una primera prueba con el intento 4 de la maniobra Hovering Turn.

A continuación, se mostrará primeramente el resultado de las predicciones hechas por la red sin la retroalimentación, siendo comparadas con las realizadas por los pilotos. Esto permitirá evaluar la red según la precisión que tuvo sin la influencia de datos adicionales que ayuden a ajustar su predicción.

En la figura 23, se observa el proceso de entrenamiento de la red a lo largo de 40 iteraciones. La gráfica superior muestra el error medio cuadrático (RMSE) tanto en el entrenamiento como en la validación. A pesar de que el RMSE del entrenamiento disminuye rápidamente en las primeras iteraciones y se mantiene relativamente bajo, la validación muestra una tendencia de no converger. Esto indica que la red podría estar haciendo un sobreajuste o que los parámetros necesitan más tiempo para estabilizarse. La gráfica inferior muestra las pérdidas que sufre la red, y esta refleja una tendencia similar, con un descenso del error pero que nunca llega a estabilizarse.

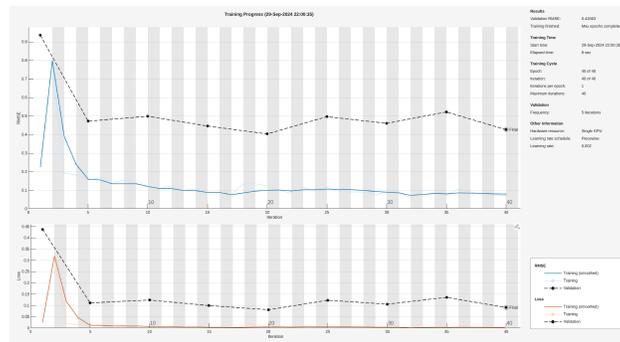


Fig. 23. Entrenamiento Red Neuronal sin Retroalimentación

La predicción hecha por la red se muestra en la figura 24. La línea morada más oscura representa el resultado predicho, mientras que las líneas más claras son las entradas realizadas por los pilotos. Se observa que la red pudo suavizar ligeramente la curva de las entradas; sin embargo, sigue teniendo altos picos donde la red consideró que serían necesarios ajustes mayores. Este comportamiento refleja que se está intentando aproximarse al comportamiento según los datos con los que fue alimentada. Como se abordó anteriormente, en esta maniobra no hubo un patrón claro de las entradas hechas por los pilotos, lo que dificultó que la red pudiera hacer comparaciones. La inconsistencia de los datos dificulta un entrenamiento efectivo de la red.

Aunque la red sí logró suavizar aparentemente la entrada de los pedales, no logró un resultado como se esperaba. Esto se muestra en la figura 25, donde se compara la salida del modelo con la predicción de la red, donde esta no logra seguir la tendencia y muestra un

comportamiento menos preciso comparado con los resultados obtenidos por los pilotos, lo que indica que la red no logró un funcionamiento adecuado sin la retroalimentación.

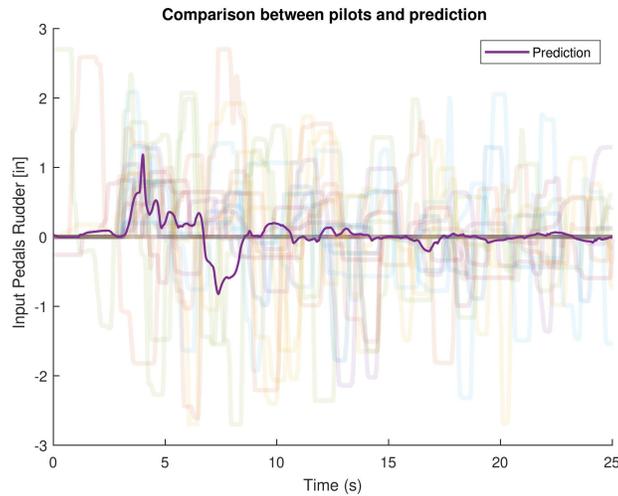


Fig. 24. Predicción de entrada de los Pedales de Red Neuronal sin Retroalimentación

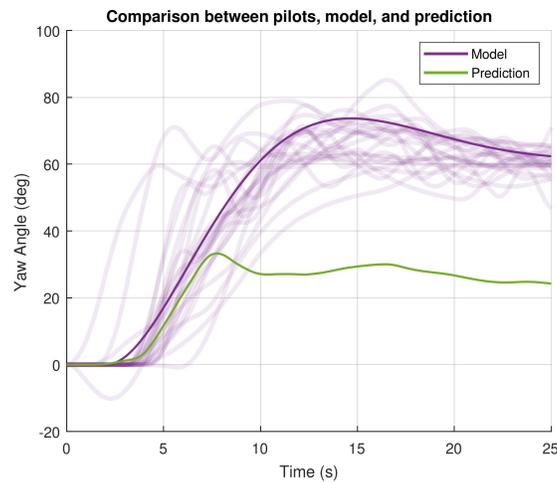


Fig. 25. Predicción del Movimiento en el Ángulo de Yaw del Helicóptero de la Red Neuronal sin Retroalimentación

2) *Red Neuronal con Retroalimentación*: En busca de una solución, se pensó en utilizar una retroalimentación que le indicara a la red qué resultado se espera. Para esto, se utilizaron

los datos de salida de cada vuelo hecho por los pilotos, donde se tuvieron que concatenar los datos de la entrada con la respuesta correspondiente. Esto se hizo así ya que MATLAB no ofrece una función específica para el ingreso de la retroalimentación.

El entrenamiento de la red se logró hacer en un menor tiempo y, a diferencia de la red sin retroalimentación, se logró una convergencia tanto en el RMSE como en las pérdidas. Esto indica que, al incluir las salidas de los pilotos como referencia, la red fue capaz de ajustarse mejor a los datos, logrando una mejor precisión durante el proceso de aprendizaje, incluso sin tener que realizar tantas iteraciones, como se observa en las gráficas de la figura 26.

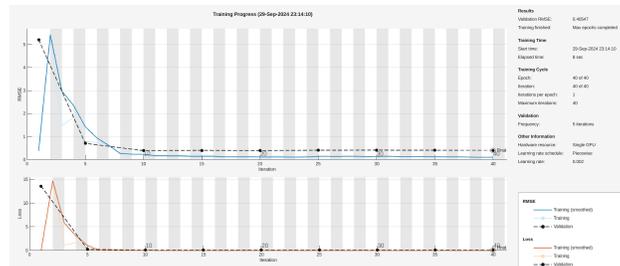


Fig. 26. Entrenamiento Red Neuronal con Retroalimentación

Esto no solo logró mejorar el entrenamiento, sino que también arrojó una predicción más acertada del control de los pedales, como se muestra en la figura 27. La red fue capaz de aproximarse mejor a los valores esperados, suavizando la respuesta y reduciendo la variabilidad de los datos en comparación con las entradas realizadas por los pilotos.

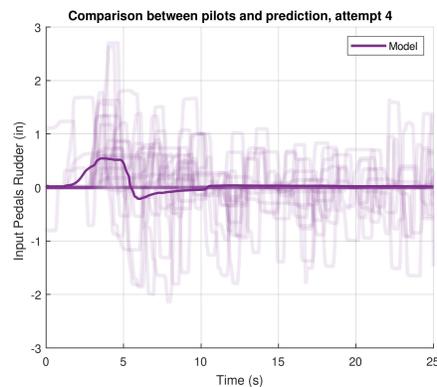


Fig. 27. Predicción de Entrada de los Pedales de la Red Neuronal con Retroalimentación

Por último, en la figura 28, se observa el resultado de la comparación entre el modelo y la red. Se puede notar una mejoría con respecto a la red que no tiene retroalimentación, ya que, aunque en un instante de tiempo se observa una diferencia muy grande, al final sí se logra el objetivo de la maniobra, que es llegar de forma controlada hasta los 60 grados en el ángulo de yaw. Esto indica un avance considerable en la precisión del comportamiento de la red.

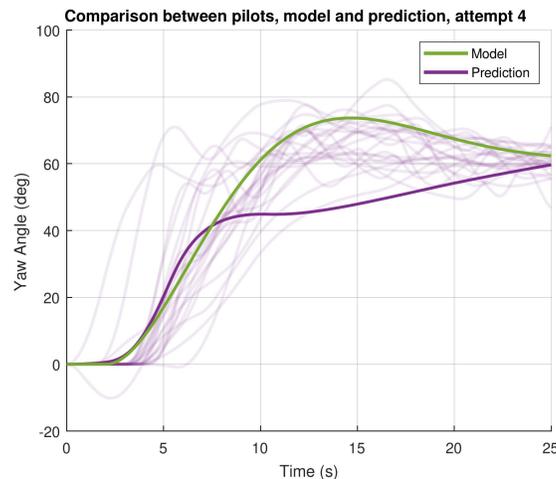


Fig. 28. Predicción del Movimiento en el Ángulo de Yaw del Helicóptero de la Red Neuronal con Retroalimentación

Al observar todas las mejoras que tuvo la red cuando se implementó una retroalimentación, se concluyó que este enfoque ofrecía una mejora significativa en el rendimiento de la red. Antes de su uso, la red presentaba dificultades para converger y ofrecer predicciones que fueran acertadas al comportamiento esperado de las maniobras. Con la retroalimentación, la red fue capaz de ajustar sus parámetros rápidamente, resultando en menores pérdidas y un RMSE más bajo. Por ende, se decidió aplicar el método de entrenar la red con retroalimentación a todas las maniobras. Esto permitió un incremento en la precisión de las predicciones, asegurando una respuesta acorde al comportamiento esperado en cada maniobra. Además, el uso de la retroalimentación redujo la cantidad de iteraciones necesarias y el tiempo de entrenamiento.

D. Redes Neuronales para las Maniobras

1) *Resultado de Red Neuronal para Maniobra Bob-Up*: A continuación se mostrarán los resultados de los entrenamientos de la red para la maniobra BOB-UP para cada intento. Como se mencionó anteriormente, se hizo con una retroalimentación para obtener mejores predicciones. En la figura 29 se muestran los resultados del entrenamiento de las redes para el intento 1, 2, 3 y 4, respectivamente. Se observa que cada una tuvo un comportamiento parecido, llegando a converger rápidamente hacia un error mínimo en todos los casos. Esto es un indicativo de que fue capaz de aprender los patrones hechos por los pilotos de manera eficiente. La reducción del error en las primeras iteraciones fue notoria, lo que refleja un aprendizaje rápido, con una estabilización rápida en valores bajos.

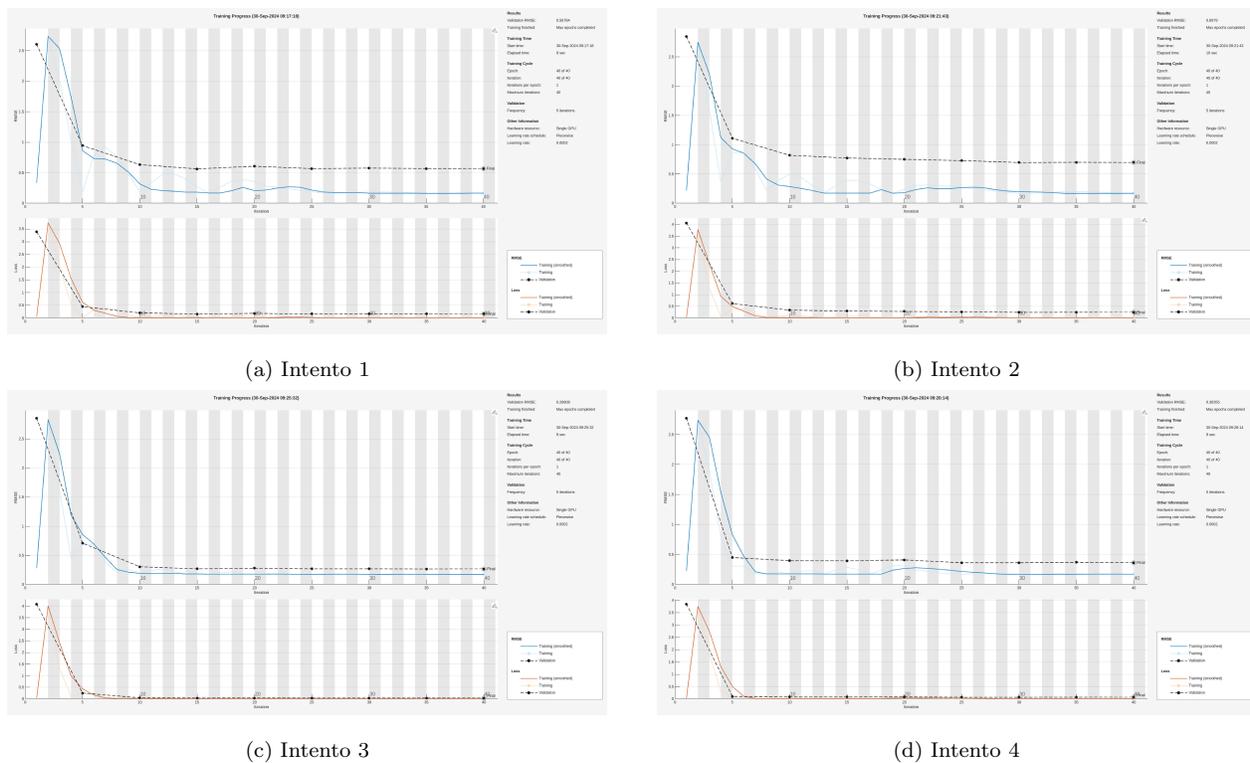


Fig. 29. Entrenamiento de las Redes Neuronales para la Maniobra Bob-up

La figura 30 muestran cómo fue el resultado de la predicción hecha por la red en los intentos 1 y 2. En comparación con lo hecho por los pilotos, se puede observar que la red suavizó las entradas al colectivo, reduciendo la cantidad de fluctuaciones sin comprometer el

resultado de la maniobra. Esto sugiere que la red pudo aprender patrones más estables para el control del colectivo, manteniendo la efectividad de la maniobra. En el intento 1, al ser esta la vez donde los pilotos tuvieron más errores, la red, tanto en el entrenamiento como en la predicción, tuvo un pico importante al principio, donde luego ya se logró una estabilización.

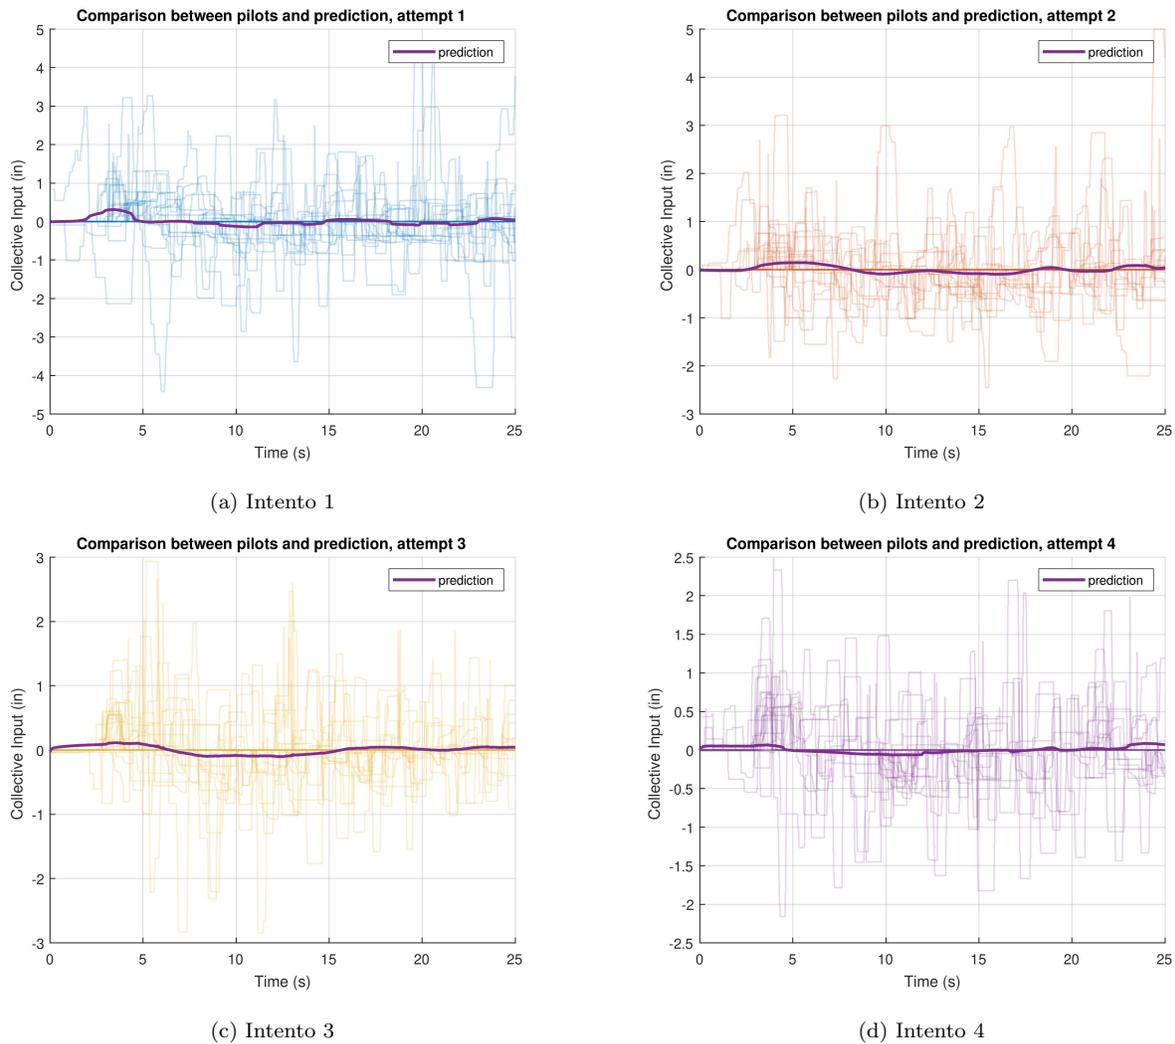


Fig. 30. Comparación entre las Entradas del Colectivo hechas por los Pilotos y la Predicción de la Red Neuronal

En la figura 30, se muestran a los intentos 3 y 4. Se observa un comportamiento más estable de la predicción hecha por la red. Además, el sobre ajuste en la predicción del colectivo es menor en comparación con los intentos 1 y 2. Esto era de esperarse, ya que los

datos con los que se entrenaron fueron de mejor calidad, lo que permitió a la red ajustarse mejor y producir resultados más precisos.

Finalmente, la figura 31 muestra el resultado de la maniobra con la predicción realizada por la red en los intentos 1 y 2. En ambas, se observa cómo la predicción se acerca al modelo, mostrando una tendencia similar al comportamiento esperado. Aunque aún existen algunas diferencias con respecto al modelo, la predicción logra suavizar y ajustar las entradas, lo que indica una buena capacidad de la red para aproximar la respuesta de la maniobra.

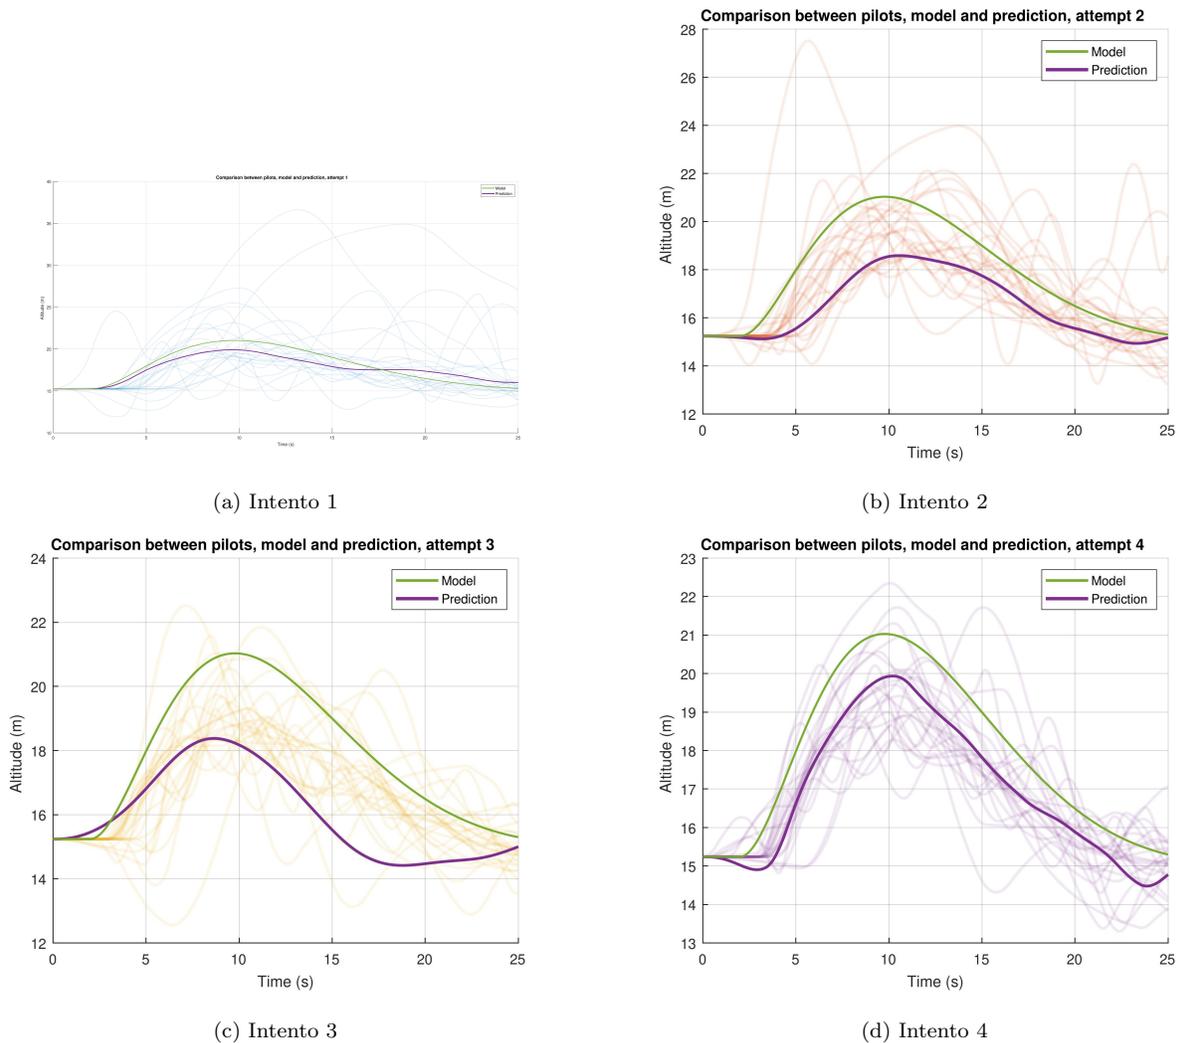


Fig. 31. Comparación de la Altitud del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal

La figura 31 muestra el resultado de la maniobra con la predicción realizada por la red en los intentos 3 y 4. En el intento 4, se observa una mejora significativa, ya que la curva se ajusta mucho más al modelo en comparación con los intentos anteriores. Esto sugiere que, para el cuarto intento, los datos obtenidos fueron de mejor calidad y la red pudo lograr capturar mejor el comportamiento de la maniobra, generando una predicción más precisa.

2) *Resultado de Red Neuronal para Maniobra Side-Step:* En la figura 32 se presentan los resultados de los entrenamientos de la red para la maniobra Side-Step de los intentos 1, 2, 3 y 4, respectivamente. Se observa una disminución en el error con el paso de las iteraciones, llegando a tener una estabilidad incluso antes de terminar el entrenamiento. Esto indica que la red fue capaz de aprender de manera eficiente los patrones de las maniobras realizadas por los pilotos. En particular, el entrenamiento de la primera red es la que muestra un mayor error con respecto a los datos de validación, aunque esto es completamente esperado ya que, como se explicó anteriormente, esta maniobra le costó más a los pilotos y más aún en el primer intento.

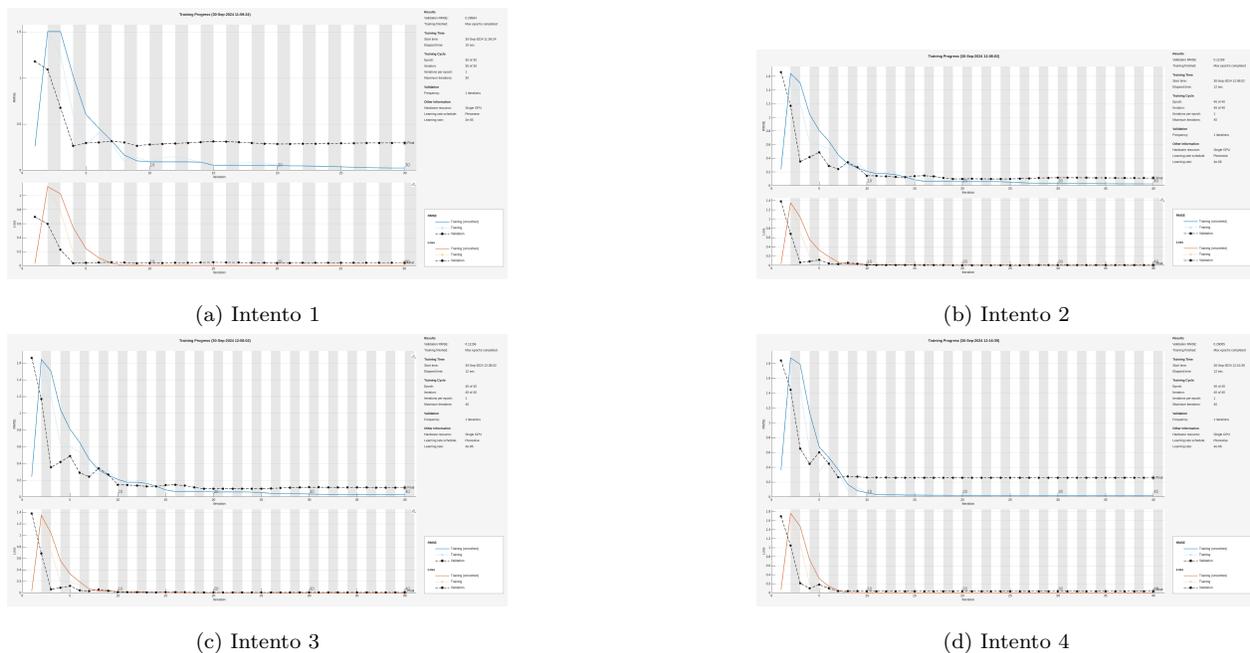


Fig. 32. Entrenamiento de las Redes Neuronales para la Maniobra Side-Step

Del resultado del entrenamiento, se obtiene la predicción hecha por la red. En la

figura 33 se observan las redes del intento 1 y 2. Las gráficas muestran cómo la predicción suaviza las entradas del cíclico en comparación con las realizadas por los pilotos, reduciendo las correcciones que hicieron y teniendo menos fluctuaciones. Sin embargo, aun en el primer intento se observa un comportamiento extraño hacia el final de la curva, lo cual podría ser un indicativo de dificultad que la red tuvo para ajustar correctamente en esa etapa.

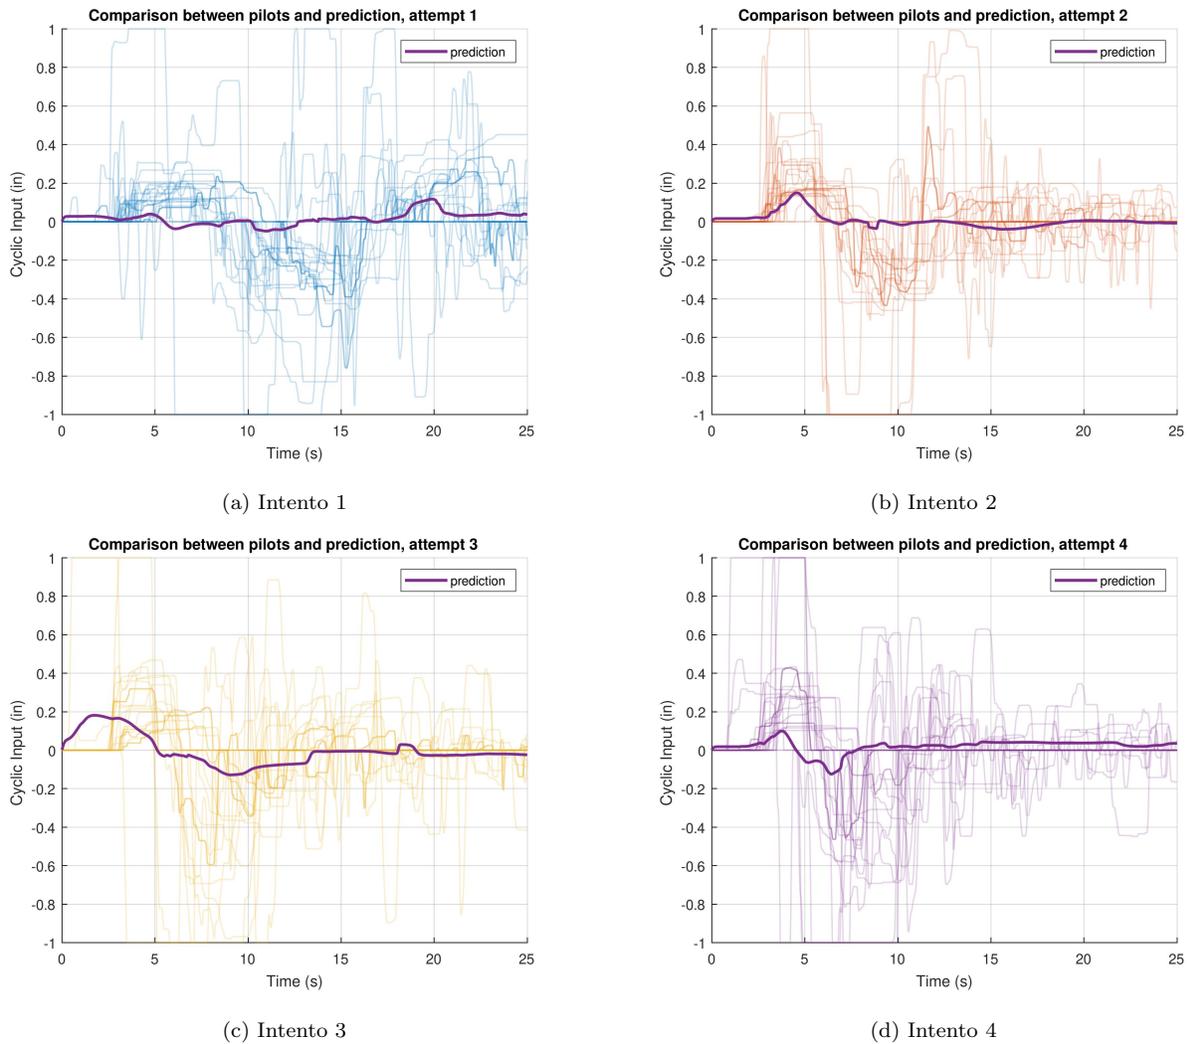
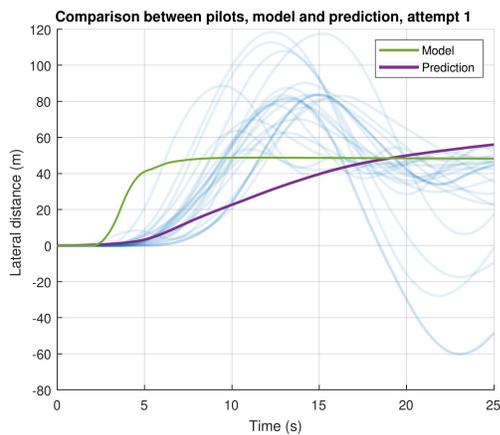


Fig. 33. Comparación entre las Entradas del Cíclico hechas por los Pilotos y la Predicción de la Red Neuronal

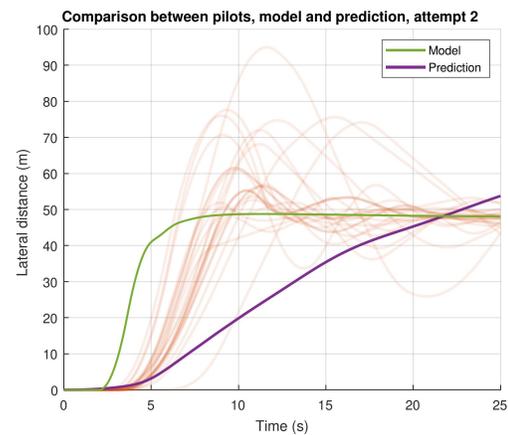
En la figura 33, muestra el resultado de la red en los intentos 3 y 4. En estas dos últimas, la red pudo capturar con más claridad el patrón que hicieron los pilotos en esta maniobra. Se

observa cómo, en un principio, la señal sube significativamente, y posteriormente se realiza el movimiento contrario para ir frenando el helicóptero. La predicción de la red refleja mejor estos comportamientos en comparación con los intentos anteriores.

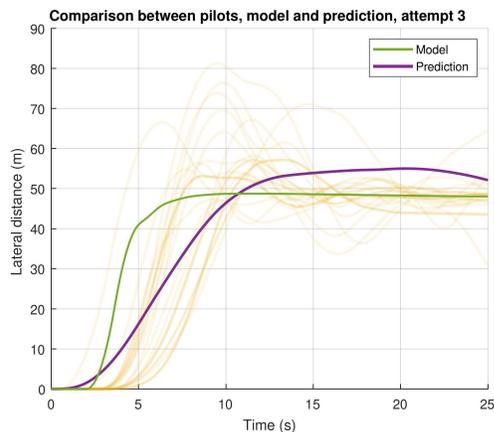
En la figura 34, se presentan los resultados de la comparación entre los pilotos, el modelo y el resultado de la predicción para los intentos 1 y 2. En ambos casos, se puede observar que la predicción realizada por la red sigue la tendencia del modelo, acercándose a los resultados más suavemente. Aunque el modelo muestre un resultado más rápido y agresivo, la red lo hace de forma más controlada, sin perder el objetivo de la maniobra, que es llegar a los 50 metros de desplazamiento lateral.



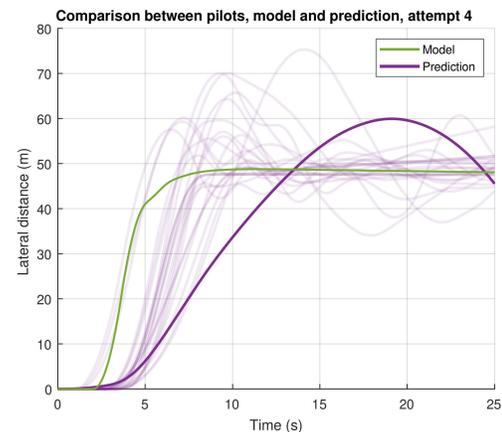
(a) Intento 1



(b) Intento 2



(c) Intento 3



(d) Intento 4

Fig. 34. Comparación del Desplazamiento Lateral del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal

En la figura 34, se presentan los resultados de la comparación entre los pilotos, el modelo y la predicción para los intentos 3 y 4. En estos dos casos, la red muestra un ajuste más cercano al comportamiento del modelo, especialmente en la fase inicial de la curva. Aunque el modelo sigue mostrando una respuesta más rápida, la predicción logra captar el comportamiento general de la maniobra de manera precisa, en especial en el intento tres, que fue en donde la red tuvo un mejor comportamiento y se logró mantener estable una vez llegó a la distancia deseada. En este último caso, la red ha sido capaz de corregir los picos observados en los intentos iniciales, lo que refleja una mayor estabilidad en la trayectoria de desplazamiento lateral. A pesar de que la predicción sigue sin alcanzar la rapidez del modelo, esta tendencia más controlada podría indicar que la red ha logrado aprender una representación más precisa del proceso de maniobra.

3) *Resultado de Red Neuronal para Maniobra Hovering-Turn:* En la figura 35 se presentan los resultados de los entrenamientos de la red para la maniobra Hovering-Turn en los intentos 1, 2, 3 y 4, respectivamente. Se observa una disminución del error a medida que se avanza en las iteraciones, logrando alcanzar una estabilidad incluso antes de terminar el entrenamiento. Sin embargo, se observa que el error inicial en los intentos 1 y 2 es más elevado en comparación con los intentos 3 y 4, lo que indica la dificultad que tuvo la red para aprender patrones con esos conjuntos de datos. Esto ya era esperado porque, como se explicó con anterioridad, a los pilotos les costó adaptarse un poco a los pedales y poder coordinar los pies con la señal visual. Esta falta de coordinación en los primeros intentos afectó los datos, lo que se refleja en un mayor error en el entrenamiento de la red. Ya en los últimos dos intentos, los pilotos pudieron mejorar la habilidad y los datos recopilados fueron de mejor calidad, haciendo que la red pudiera converger rápidamente y con un error menor.

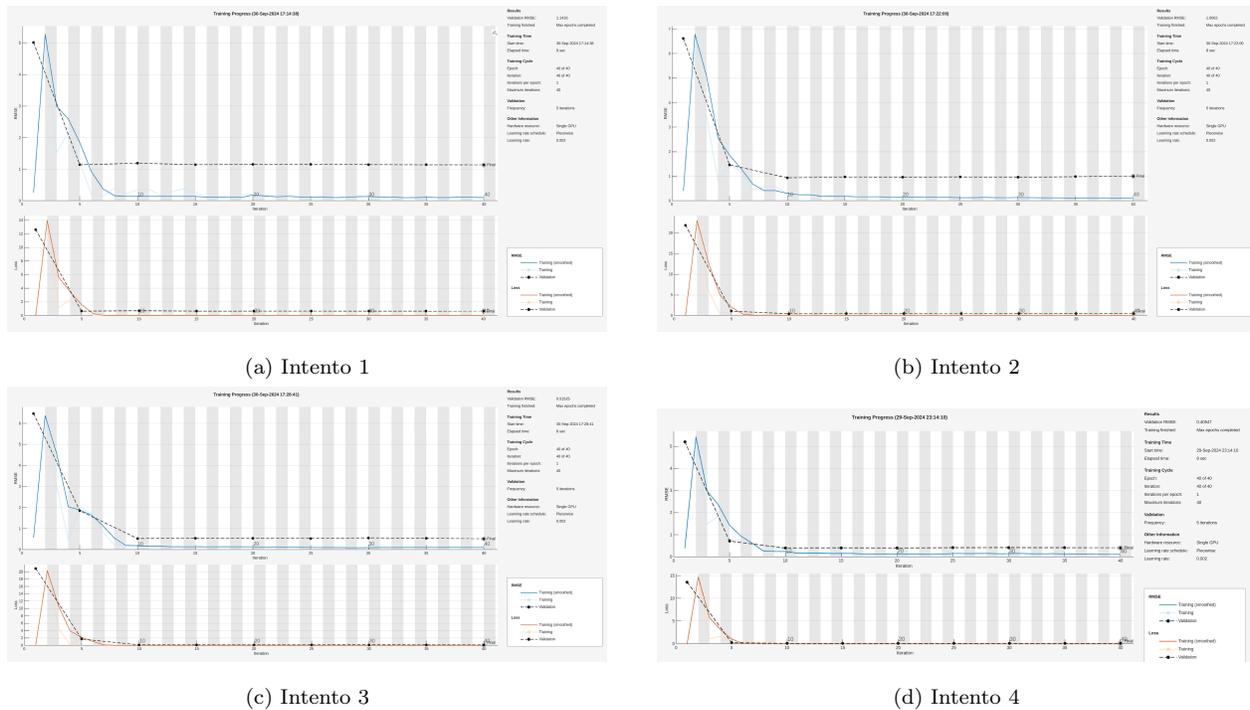


Fig. 35. Entrenamiento de las Redes Neuronales para la Maniobra Hovering-Turn

La figura 36 muestra las predicciones hechas por la red para los intentos 1 y 2 para la entrada de los pedales. En ambas gráficas se puede observar que, al inicio, la red predice un movimiento opuesto al esperado en los primeros segundos. Sin embargo, a medida que transcurre el tiempo, la predicción se corrige y sigue el comportamiento real. Esto puede ser debido a que la red le dio más importancia a los datos donde los pilotos empezaban a girar para el lado contrario para luego corregir y hacer correctamente la maniobra.

En cambio, en las predicciones de los intentos 3 y 4 que se muestra en la figura 36, se aprecia cómo la red, al ya no tener casi datos en dirección contraria de los pilotos, comienza a ajustar mejor las predicciones. Ya no se observa el inicio de la señal con un movimiento descendente contrario a lo esperado, sino que la predicción sigue y suaviza el patrón de las entradas realizadas por los pilotos.

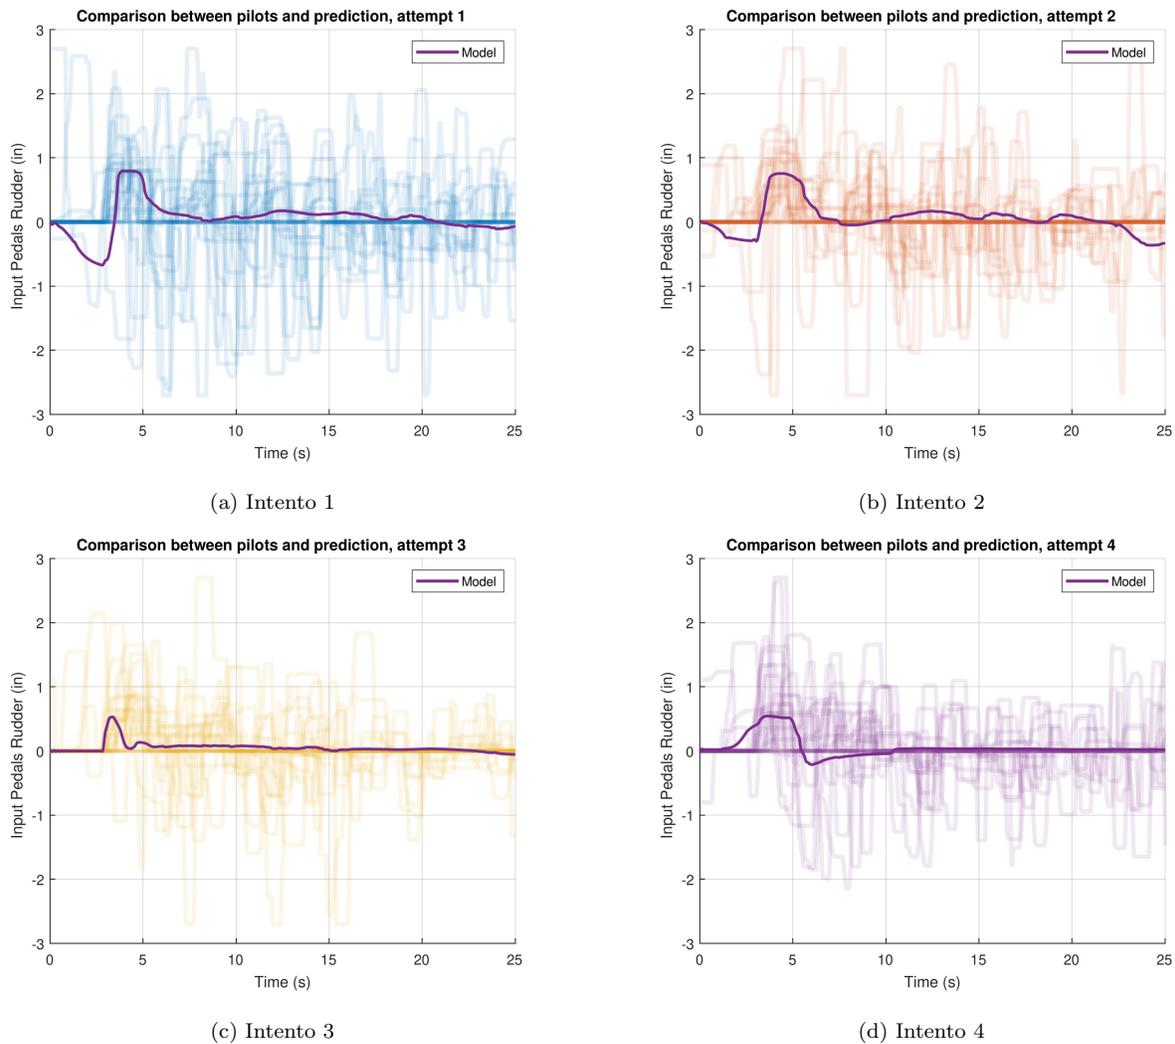


Fig. 36. Comparación entre las Entradas de los Pedales hechas por los Pilotos y la Predicción de la Red Neuronal

En las figura 37 se presentan las comparaciones entre los pilotos, el modelo y el resultado de las predicciones realizadas por la red para los intentos 1 y 2. En ambos casos, y como era de esperarse, presenta una desviación inicial considerable con respecto al modelo y casi todos los pilotos. Esto es notable durante los primeros segundos de la simulación; sin embargo, conforme avanza el tiempo, la predicción tiende a ajustarse con el modelo, indicando que la red eventualmente ajustará su comportamiento para seguir el patrón adecuado.

En la figura 37 se presenta la comparación entre los pilotos, el modelo y las predicciones

de la red correspondientes a los intentos 3 y 4 de la maniobra. A diferencia de los intentos anteriores, se observa una mejora notable en el ajuste de la predicción con el modelo, en especial en los últimos segundos de la simulación. Esto se debe a que los conjuntos de datos utilizados fueron cuando los pilotos ya tuvieron más habilidad con los pedales y supieron bien cómo era el comportamiento del helicóptero. Si bien la dispersión con respecto al modelo en el intento 3 es más notable, esta no incumple con el objetivo final de la maniobra de llegar en forma controlada hasta los 60 grados.

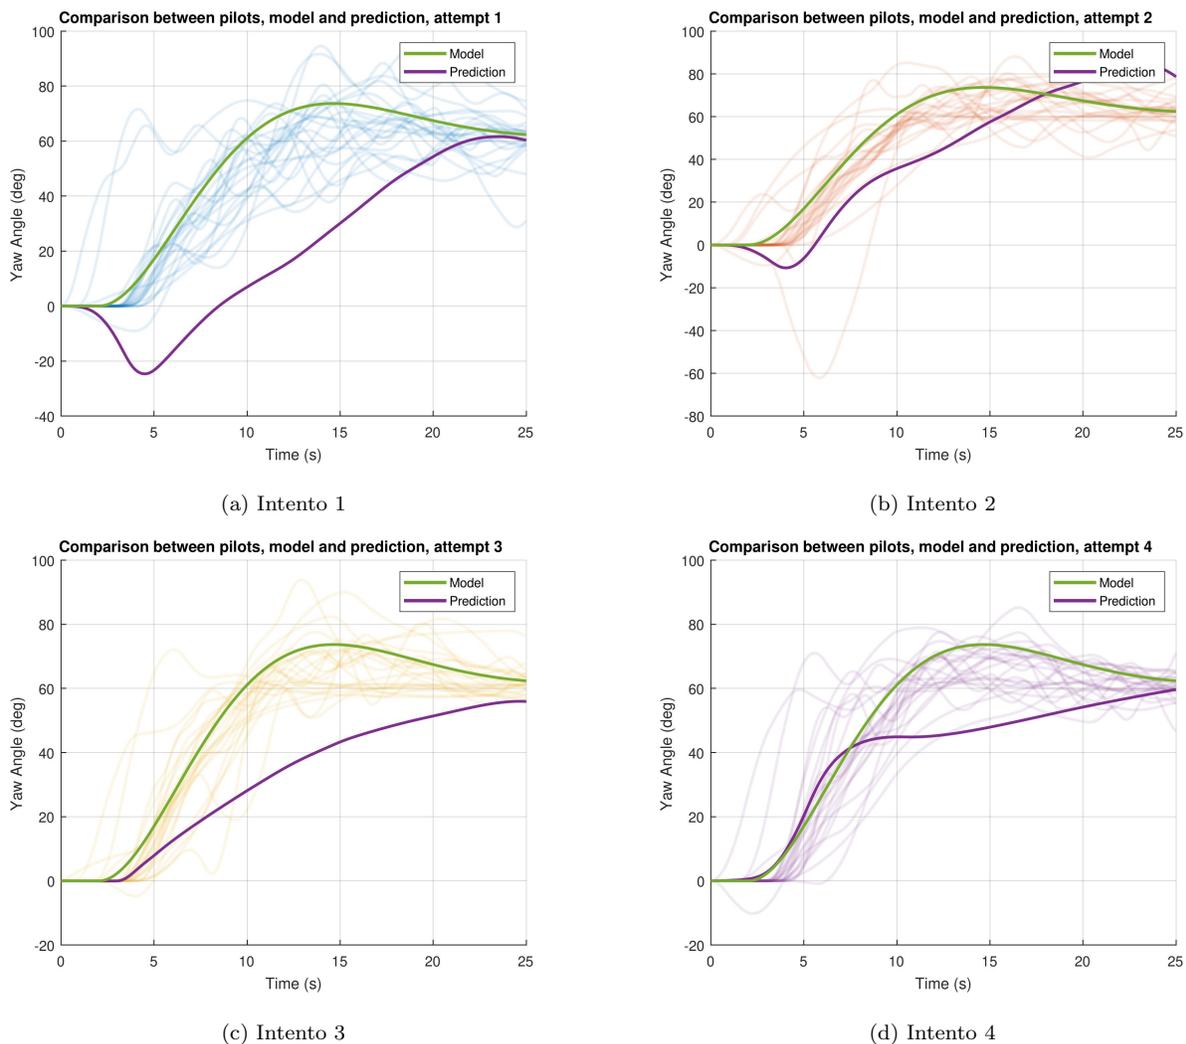


Fig. 37. Comparación del Movimiento en el Ángulo de Yaw del Helicóptero entre los Pilotos, el Modelo y la Predicción de la Red Neuronal

VIII. CONCLUSIONES Y RECOMENDACIONES

El modelo de comportamiento humano en cada una de las diferentes maniobras funcionó bien para controlar el helicóptero en tiempo real. Sin embargo, aún presenta varias limitaciones que deben superarse antes de que pueda implementarse completamente en una situación real. En primer lugar, el enfoque adoptado fue replicar maniobras discretas, aislando los demás ejes que actúan en un helicóptero real. Esto implica que el modelo no toma en cuenta la interacción simultánea de todos los ejes de control, lo que es fundamental en el vuelo de un helicóptero en condiciones reales.

Segundo, la interacción de la red va a depender siempre de cómo el usuario la configure y logre optimizarla. En muchos casos, se puede llegar a un estado de repeticiones donde difícilmente se puede encontrar una predicción adecuada, lo que lleva a un proceso de ensayo y error que consume una cantidad significativa de tiempo. Por otro lado, la capacidad computacional es un factor clave en este tipo de situaciones, ya que se deben calcular miles de datos y variables para obtener una respuesta adecuada sin consumir demasiado tiempo. La falta de pilotos calificados para realizar cada una de las pruebas agregó una complicación adicional, ya que los datos obtenidos provinieron de personas sin experiencia en simuladores de vuelo. Esto introduce una mayor dificultad en el desarrollo de la red neuronal, ya que los datos pueden no reflejar comportamientos precisos.

Sin embargo, en el desarrollo se obtuvieron resultados sobresalientes que ayudaron a acentuar el uso de redes neuronales. Aunque no se contó con pilotos calificados ni con una capacidad de cómputo adecuada, se logró que las maniobras fueran replicadas de forma exitosa. Estos resultados demuestran el potencial de este enfoque para futuros desarrollos, destacando la capacidad de las redes neuronales para adaptarse y aprender de los datos, incluso en condiciones menos ideales.

El trabajo futuro tiene como objetivo contar con pilotos calificados y entrenados para que los datos recopilados sean de mayor calidad, además de implementar una plataforma de movimiento con seis grados de libertad. Esto permitirá una experiencia de vuelo más realista y posibilitará analizar el comportamiento humano al estar sometido a estos movimientos, ob-

servando si la red neuronal es capaz de replicar dichos comportamientos. Asimismo, se busca implementar modelos dinámicos que involucren todos los grados de libertad, aumentando la complejidad y cantidad de las maniobras para los pilotos, y evaluando cómo la red neuronal responde a estos desafíos.

REFERENCIAS

- [1] J. A. Schroeder, “Helicopter flight simulation motion platform requirements,” 1998. [Online]. Available: <https://api.semanticscholar.org/CorpusID:40672046>
- [2] MathWorks, “Neural Network,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/discovery/neural-network.html>
- [3] C. L. Blanken, M. B. Tischler, J. A. Lusardi, T. Berger, C. M. Ivler, and R. Lehmann, “Proposed Revisions to Aeronautical Design Standard – 33E (ADS-33E-PRF) Toward ADS-33F-PRF,” September 2019, available: <https://www.dtic.mil/dtic/tr/fulltext/u2/1080657.pdf>.
- [4] Y. Zhou, Z. Fu, and G. Gong, “Pilot Behavior Modeling Using LSTM Network: A Case Study,” *Proceedings of the AsiaSim 2016/SCS AutumnSim 2016*, pp. 458–465, 2016.
- [5] R. McKercher, F. Khouli, A. Wall, and G. Larose, “Modelling and Control of an Urban Air Mobility Vehicle Subject to Empirically-Developed Urban Airflow Disturbances,” *Aerospace*, vol. 11, p. 220, 2024.
- [6] E. Johnson and S. Mishra, *Flight Simulation for the Development of an Experimental UAV*. [Online]. Available: <https://arc.aiaa.org/doi/abs/10.2514/6.2002-4975>
- [7] A. W. Services, “What is a Neural Network?” 2024, accessed: 2024-10-02. [Online]. Available: <https://aws.amazon.com/es/what-is/neural-network/>
- [8] MathWorks, “Neural Networks for Classification,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/help/stats/neural-networks-for-classification.html>
- [9] IBM, “Convolutional Neural Networks,” accessed: 2024-10-02. [Online]. Available: <https://www.ibm.com/topics/convolutional-neural-networks>
- [10] AWS, “What is a Recurrent Neural Network?” accessed: 2024-10-02. [Online]. Available: <https://aws.amazon.com/es/what-is/recurrent-neural-network/>

-
- [11] W. E. Failer and S. J. Schreck, “Neural Networks: Applications and Opportunities in Aeronautics,” *Progress in Aerospace Sciences*, vol. 32, pp. 433–456, 1996.
- [12] S. H. Koekebakker, “Model Based Control of a Flight Simulator Motion System,” Ph.D. dissertation, Technische Universiteit Delft, Delft, The Netherlands, 2001.
- [13] F. International, “Flight Simulators and Simulation Solutions,” accessed: 2024-10-02. [Online]. Available: <https://www.frasca.com/>
- [14] E. U. A. S. Agency, “Certification Specifications for Helicopter Flight Simulation Training Devices,” 2024, accessed: 2024-10-02. [Online]. Available: <https://www.easa.europa.eu/en/document-library/certification-specifications/group/cs-fstdh-helicopter-flight-simulation-training-devices>
- [15] R. HEFFLEY, *Pilot models for discrete maneuvers*. [Online]. Available: <https://arc.aiaa.org/doi/abs/10.2514/6.1982-1519>
- [16] U. S. F. A. Administration, *AMT Handbook Addendum: Human Factors*, n.d., accessed: 2024-10-02. [Online]. Available: <https://www.faa.gov/>
- [17] C. S. C. C. Cunliffe, *Desorientación espacial*, Document retrieved from a private source, 2024, unpublished manuscript.
- [18] N. C. for Biotechnology Information, “PMC Article,” accessed: 2024-10-02. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8329400/>
- [19] M. Manuals, “Trastornos Otorrinolaringológicos,” accessed: 2024-10-02. [Online]. Available: <https://www.msdmanuals.com/es/hogar/trastornos-otorrinolaringol%C3%B3gicos/trastornos-del-o%C3%ADdo-interno/introducci%C3%B3n-al-o%C3%ADdo-interno>
- [20] Kenhub, “Anatomía del Sistema Vestibular,” accessed: 2024-10-02. [Online]. Available: <https://www.kenhub.com/es/library/anatomia-es/sistema-vestibular>

-
- [21] Hispaviacion, “Desorientación Espacial,” accessed: 2024-10-02. [Online]. Available: <https://www.hispaviacion.es/desorientacion-espacial/>
- [22] M. M. Lone, “Pilot modelling for airframe loads analysis,” 2013. [Online]. Available: <https://api.semanticscholar.org/CorpusID:113698860>
- [23] M. Lone and A. Cooke, “Review of pilot models used in aircraft flight dynamics,” *Aerospace Science and Technology*, vol. 34, pp. 55–74, 2014. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1270963814000285>
- [24] “Desorientación Espacial,” Agencia Estatal de Seguridad Aérea, <https://www.kimerius.com/app/download/5783711094/Desorientaci%25C3%25B3n%2Bespacial.pdf>, accessed: 2024-10-02.
- [25] Barnaclinic, “Propiocepción y Rehabilitación,” accessed: 2024-10-02. [Online]. Available: <https://www.barnaclinic.com/blog/traumatologia-deportiva/2019/01/25/propiocepcion/>
- [26] Invanep, “Integración Sensorial y Procesamiento Vestibular,” accessed: 2024-10-02. [Online]. Available: https://invanep.com/blog_invanep/integracion-sensorial-procesamiento-vestibular-y-propioceptivo
- [27] N. C. for Biotechnology Information, “NCBI Article,” accessed: 2024-10-02. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK518976/>
- [28] K. Yang, M. Bi, Y. Liu, and Y. Zhang, “LSTM-based Deep Learning Model for Civil Aircraft Position and Attitude Prediction Approach,” in *2021 38th Chinese Control Conference (CCC)*. IEEE, 2021, pp. 8689–8694. [Online]. Available: <https://www.kimerius.com/app/download/5783711094/Desorientaci%25C3%25B3n%2Bespacial.pdf>
- [29] ProjectPro, “Understanding LSTM Model,” 2024, accessed: 2024-10-02. [Online]. Available: <https://www.projectpro.io/article/lstm-model/832>

-
- [30] MathWorks, “MATLAB,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/products/matlab.html>
- [31] —, “Simulink,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/products/simulink.html>
- [32] —, “Aerospace Toolbox,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/products/aerospace-toolbox.html>
- [33] FlightGear, “FlightGear Main Page,” accessed: 2024-10-02. [Online]. Available: https://wiki.flightgear.org/Main_Page
- [34] ResearchGate, “Experimental Investigation of Nonlinear Dynamics in Pilot Induced Oscillations Using FlightGear Flight Simulator,” accessed: 2024-10-02. [Online]. Available: https://www.researchgate.net/publication/358956955_Experimental_Investigation_of_Nonlinear_Dynamics_in_Pilot_Induced_Oscillations_Using_FlightGear_Flight_Simulator
- [35] SourceForge, “JSBSim Flight Dynamics Model,” accessed: 2024-10-02. [Online]. Available: <https://jsbsim.sourceforge.net/>
- [36] F. A. Administration, *Helicopter Flying Handbook*, 2024, accessed: 2024-10-02. [Online]. Available: https://www.faa.gov/sites/faa.gov/files/regulations_policies/handbooks_manuals/aviation/helicopter_flying_handbook/hfh_ch03.pdf
- [37] S. Hodge, P. Perfect, G. Padfield, and M. White, “Optimising the yaw motion cues available from a short stroke hexapod motion platform,” *The Aeronautical Journal*, vol. 119, no. 1211, p. 1–21, 2015.
- [38] MathWorks, “Long Short-Term Memory Networks,” accessed: 2024-10-02. [Online]. Available: <https://la.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>