

UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA
FACULTAD DE INGENIERÍA

Maestría y Doctorado en Ciencias e Ingeniería



“Sistema alternativo de orientación en aeronaves”

T E S I S

que presenta para obtener el grado de MAESTRO EN CIENCIAS

Luis Jovanny Placencia Mejia

DIRECTOR DE TESIS:

Dr. Daniel Hernández Balbuena

COORDIRECTOR DE TESIS:

Dr. José Manuel Ramírez Zarate

Mexicali, Baja California, septiembre del 2022

Resumen

Los sistemas de orientación en la navegación, tienen un papel importante. Es por ello, que se emplean distintos dispositivos que nos permitan orientar tales como sensores inerciales, GPS, por mencionar algunos. En conjunto con métodos como el filtro de Kalman, Cuaterniones y Ángulos de Euler. Uno de los retos importantes de este enfoque es poder integrar algoritmos de Machine Learning y Deep Learning que permitan estimar la orientación de una aeronave.

En este trabajo de tesis se busca poder determinar la orientación de una aeronave mediante los Cuaterniones, que son datos sin procesar extraídos de una Unidad de Medición Inercial (IMU), colocada dentro del avión. La aeronave fue montada en un túnel de viento subsónico, y partiendo de los datos de Cuaterniones, se calculan los valores de Pitch, Roll y Yaw; además de aplicarles un filtrado que atenúa el ruido en la aeronave. Esta señal de salida nos sirve para entrenar los modelos de aprendizaje automático y aprendizaje profundo.

Se generaron algunos modelos de Machine Learning para regresión, tales como: Vecinos cercanos (k-NN), Support Vector Machine (SVM, con Kernel lineal, RBF, Gaussian y Polynomial). Y Deep Learning: perceptrón, y redes neuronales con algoritmos Bayesiano regularización, Levenberg-Marquardt y Scaled conjugated gradient; los 3 algoritmos se evaluaron con 4, 10 y 15 neuronas ocultas. Estas técnicas ofrecen un porcentaje de efectividad arriba del 90% y al igual que coeficiente de determinación ajustado; a excepción para el kernel de SVM – Polynomial que tuvo rendimiento inferior a los demás.

Los resultados presentados, demuestran que es posible determinar la orientación de una aeronave por medio de las lecturas de Cuaterniones sin procesar, generando modelos de predicción del ángulo de ataque de una aeronave incluso ante perturbaciones externas tales como variaciones del flujo de aire.

Abstract

Guidance systems in navigation play an important role. Its therefore, that different devices are used that allow us to orient such as inertial sensors, GPS, to mention a few. In conjunction with methods such as the Kalman filter, Quaternions and Euler Angles. One of the important challenges of this approach is to be able to integrate Machine Learning and Deep Learning algorithms that allow estimating the orientation of an aircraft.

In this thesis work, we seek to be able to determine the orientation of an aircraft through Quaternions, which are raw data extracted from an Inertial Measurement Unit (IMU), placed inside the aircraft. The aircraft was placed in a subsonic wind tunnel, and then using Quaternion data the Pitch, Roll and Yaw values are calculated, in addition to applying a filter that attenuates the noise in the aircraft. This output signal is used to train the machine learning and Deep Learning models.

Some Machine Learning models for regression were generated, such as: Near Neighbors (k-NN), Support Vector Machine (SVM, with Linear Kernel, RBF, Gaussian and Polynomial). And Deep Learning: perceptron, and neural networks with Bayesian regularization algorithms, Levenberg-Marquardt and Scaled conjugated gradient; the 3 algorithms were evaluated with 4, 10 and 15 hidden neurons. These techniques offer an effectiveness percentage above 90% and as well as an adjusted determination coefficient; except for the SVM – Polynomial kernel, which had lower performance than the others.

The results presented show that it is possible to determine the orientation of an aircraft by means of raw Quaternion readings, generating prediction models of the angle of attack of an aircraft even in the face of external disturbances such as airflow variations.

Dedicatoria

Me gustaría dedicar esta tesis a mis padres Martha y Liberio, por el apoyo que me han dado, tanto en los buenos como en los malos momentos. Me han enseñado a nunca rendirme por más difícil que sea la situación y ante cualquier adversidad. Especialmente a mi madre, por ser una gran mujer que nunca se detiene y siempre busca salir adelante.

También a cada uno de mis hermanos: Javier de quien admiro su determinación, Yuleni quien a pesar de todo nunca se rinde, Oscar quien siempre mostro pasión por el estudio y Karla por su fortaleza. Gracias por sus consejos y apoyo; así como sus cualidades únicas que han sido un ejemplo a seguir.

Además de mis niñas Samantha, Mia y Madeline, quienes son muy especiales para mí.

También le dedico especialmente a Bertha Olvera quien ha sido como una segunda madre para mí, y siempre me ha apoyado y por sus valiosos consejos, además de a Amador Godina que, aunque ya no nos acompañe también fue como un segundo padre para mí.

Y por último quiero dedicarle especialmente a Cesar Espinoza Ramírez a quien considero una gran persona, siempre me alentó a seguir adelante apoyándome a cumplir con esta meta en mi vida, y quien admiro por su fortaleza.

Gracias por estar presentes en esta etapa de mi vida profesional y que tanto me apasiona.

Agradecimientos

Estoy particularmente agradecido con mis directores de tesis, el Dr. Daniel Hernández Balbuena y al Dr. José Manuel Ramírez Zarate; les agradezco por todos los consejos que me dieron y todo el apoyo que me brindaron. Fue una grata experiencia y disfrute mucho haber colaborado con ustedes, fue muy divertido.

A los miembros del comité el Dr. Emmanuel Santiago Durazo Romero, el Dr. Alejandro Sebastián Ortiz Pérez y al Dr. Abraham Arias León por su valioso tiempo y apoyo, así como cada uno de los consejos que me brindaron y, por sus valiosas y constructivas sugerencias.

Y a cada una de las personas que me apoyaron, a mis amistades que siempre me alentaron en seguir adelante y cada uno de mis profesores por sus contribuciones.

Así como a la Universidad Autónoma de Baja California, por permitirme ser un profesional.

Muchas gracias por la confianza y creer en mí.

Índice general

Resumen.....	ii
Abstract.....	iii
Dedicatoria.....	iv
Agradecimientos	v
Índice general.....	vi
Índice de figuras.....	ix
Índice de tablas	xiii
Capítulo 1.....	14
1 Introducción.....	14
1.1 Alcance de la tesis.....	15
1.1.1 Objetivo general de la tesis.....	15
1.1.2 Objetivos específicos	15
1.1.3 Preguntas de investigación.....	15
Capítulo 2.....	17
2 Antecedentes.....	17
2.1 Estado del arte.....	17
Capítulo 3.....	22
3 Metodología.....	22
3.1 Diagrama de trabajo	26
3.2 Trabajo Adicional.....	29
3.2.1 Segundo prototipo de nivelador digital.....	32
3.3 Desarrollo de experimento 1:.....	36
3.3.1 Ensayo 1.....	36

3.3.2	Ensayo 2.....	36
3.3.3	Ensayo 3.....	36
3.4	Desarrollo de experimento 2:	36
3.5	Desarrollo de experimento 3:	37
3.6	Desarrollo de experimento 4:	37
3.6.1	Machine Learning	38
3.6.2	Deep Learning.....	39
Capítulo 4.....		40
4	Resultados de experimentación	40
4.1	Experimento 1:	40
4.1.1	Ensayo 1.....	40
4.1.2	Ensayo 2.....	48
4.1.3	Ensayo 3.....	50
4.2	Experimento 2	52
4.3	Experimento 3	55
Capítulo 5.....		59
5	Análisis de Resultados.....	59
5.1	Experimento 1	59
5.1.1	Ensayo 1.....	59
5.1.2	Ensayo 2.....	60
5.1.3	Ensayo 3.....	60
5.2	Experimento 2:	61
5.3	Experimento 3:	64
5.4	Experimento 4:	65
5.4.1	Machine Learning	66

5.4.2	Deep Learning.....	76
5.5	Estabilidad longitudinal	90
Capítulo 6.....		95
6	Conclusiones.....	95
6.1	Contribuciones	95
6.2	Limitaciones del estudio	96
6.3	Trabajo futuro.....	96
Bibliografía		97

Índice de figuras

Figura 2-1 Diagrama de revisión.	18
Figura 2-2 Scoping Review.	19
Figura 2-3 Sensores utilizados en los artículos encontrados.	20
Figura 2-4 Técnicas utilizadas en los artículos encontrados.....	21
Figura 3-1 Túnel de viento AF100 subsónico.	24
Figura 3-2 Configuración de la aeronave en túnel de viento.....	24
Figura 3-3 Modelo de avión.....	25
Figura 3-4 Avión Modificado.	26
Figura 3-5 Configuración del avión en el túnel de viento.	26
Figura 3-6 Diagrama de trabajo.	27
Figura 3-7 Desglose del modelado.	27
Figura 3-8 Fases d experimentación.	28
Figura 3-9 Desglose de experimentación.....	28
Figura 3-10 Desglose pruebas numéricas.	29
Figura 3-11 Diagrama de flujo de trabajo.....	30
Figura 3-12 Diseño de nivelador experimental.....	30
Figura 3-13 Tapa del nivelador.....	30
Figura 3-14 Impresión y ensamble del nivelador	30
Figura 3-15 Impresión de vaiables Arduino.	30
Figura 3-16 Nivelador puesto a 90 grados sobre superficie.	30
Figura 3-17 Nuevo modelo de pruebas.....	30
Figura 3-18 Tapa del nuevo modelo	30
Figura 3-19 Impresión y ensamble del nuevo modelo.....	30
Figura 3-20 Comparacion del modelo propuesto vs sensor comercial.....	30
Figura 3-21 Sensor comercial	30
Figura 3-22 Modelo propuesto	30
Figura 3-13 Tapa del nivelador.....	31
Figura 3-14 Impresión y ensamble del nivelador.	31
Figura 4-1 Datos del giroscopio en sus 3 ejes.	41
Figura 4-2 Datos de Cuaterniones en sus componentes.	41

Figura 4-3 Datos de los ángulos de Euler dados en radianes.....	42
Figura 4-4 Primera prueba preliminar.	43
Figura 4-5 Corrección del punto de origen.....	43
Figura 4-6 Filtro movmean.....	44
Figura 4-7 Filtro Golay.....	44
Figura 4-8 Filtro Gauss.....	44
Figura 4-9 Filtro Movmedian.....	44
Figura 4-10 Filtro Rloess.....	44
Figura 4-11 Modelo propuesto para generar perturbaciones controladas en túnel de viento.	45
Figura 4-12 Soporte del avión.....	46
Figura 4-13 Primera prueba por encima de los 26 m/s.....	47
Figura 4-14 Segunda prueba por encima de los 26 m/s.....	47
Figura 4-15 Ángulo de ataque vs no de pruebas.....	48
Figura 4-16 Ruido de la señal. Gráfico grados vs número de muestras.....	49
Figura 4-17 Ángulo de ataques número de muestras después del filtro.....	49
Figura 4-18 Prueba individual por secciones de velocidad.....	50
Figura 4-19 Señal filtrada mediante movmean del ensayo No. 3.....	51
Figura 4-20 Filtrado de la señal.....	51
Figura 4-21 Primeras pruebas con sensor YostLabs.....	52
Figura 4-22 Filtrando las 30 pruebas realizadas.....	53
Figura 4-23 Sección de velocidad a comparar ángulo de ataque vs número de muestras.....	53
Figura 4-24 Sección de velocidad 1.....	54
Figura 4-25 Velocidad angular respecto al tiempo de una prueba.....	54
Figura 4-26 Velocidad angular de un conjunto de 5 pruebas.....	55
Figura 4-27 Primeras pruebas con sensor Xsens.....	56
Figura 4-28 Se agregaron 20 pruebas.....	56
Figura 4-29 Sección de velocidad a evaluar.....	57
Figura 4-30 Comparativa de las velocidades por sección.....	57
Figura 4-31 Comparativa total de las velocidades entre ambos sensores.....	58
Figura 5-1 Desviación estándar grupal velocidad 1.....	62

Figura 5-2 Desviación estándar grupal velocidad 2.....	63
Figura 5-3 Desviación estándar grupal velocidad 3.....	63
Figura 5-4 Diagrama de bloques del proceso de aprendizaje.	65
Figura 5-5 Partición del 100% del conjunto de datos para 3 vecinos cercanos.	66
Figura 5-6 Partición del 80% del conjunto de datos para 5 vecinos cercanos.	67
Figura 5-7 Partición del 60% del conjunto de datos para 3 vecinos cercanos.	67
Figura 5-8 Partición del 40% del conjunto de datos para 7 vecinos cercanos.	67
Figura 5-9 Partición del 10% del conjunto de datos para 9 vecinos cercanos.	68
Figura 5-10 Prueba evaluada fuera del set de datos de entrenamiento y validación.	68
Figura 5-11 Grafico comparativo del RMSE para k-NN.....	69
Figura 5-12 Comparativo valor real (grafico color naranja) vs predicho (grafico color azul). Kernel Gaussiano.	71
Figura 5-13 Grafico de regresión para el Kernel Gaussiano.	71
Figura 5-14 Comparativo valor real (grafico color naranja) vs predicho (grafico color azul). Kernel RBF.	72
Figura 5-15 Grafico de regresión para el Kernel RBF.....	72
Figura 5-16 Comparativo valor real vs predicho. Kernel Polynomial.....	73
Figura 5-17 Grafico de regresión para el Kernel Polynomial.....	74
Figura 5-18 Comparativo valor real vs predicho. Kernel Lineal.	74
Figura 5-19 Grafico de regresión para el Kernel Lineal.....	75
Figura 5-20 Evaluación del conjunto de datos por una red neuronal.	76
Figura 5-21 Grafico de regresión para una red neuronal.	77
Figura 5-22 Variación del RMSE.	77
Figura 5-23 Evaluacion de la neurona con una prueba nueva fuera del set de datos de entrenamiento y validacion.	78
Figura 5-24 Grafico de regresión para la prueba nueva.....	78
Figura 5-25 Evaluación del conjunto de datos por una red neuronal con $\mu=0.001$	79
Figura 5-26 Grafico de regresión para la nueva neurona $\mu=0.001$	80
Figura 5-27 Evaluación de la neurona con prueba 1 fuera del set de datos de entrenamiento y validación $\mu=0.001$	80

Figura 5-28 Evaluación de la neurona con prueba 1 fuera del set de datos de entrenamiento y validación $\mu=0.001$	81
Figura 5-29 Grafico de regresión para la prueba 2.	81
Figura 5-30 Modelo de la red neuronal con 4 entradas, 4 neuronas ocultas y una salida. ...	82
Figura 5-31 Grafico de regresión para una red neuronal de 4 neuronas ocultas.	83
Figura 5-32 Variación del RMSE para el modelo de 4 neuronas ocultas.....	83
Figura 5-33 Variación del gradiente, μ y validación respecto al número de épocas.	84
Figura 5-34 Grafico de regresión para una red neuronal de 10 neuronas ocultas.	85
Figura 5-35 Histograma para una red neuronal de 10 neuronas ocultas.....	85
Figura 5-36 Variación del RMSE para el modelo de 10 neuronas ocultas.....	86
Figura 5-37 Grafico de regresión para una red neuronal de 15 neuronas ocultas.	87
Figura 5-38 Histograma para una red neuronal de 15 neuronas ocultas.....	87
Figura 5-39 Variación del RMSE para el modelo de 15 neuronas ocultas.....	88
Figura 5-40 Variación del gradiente, μ y validación respecto al número de épocas.	88
Figura 5-41 Modelo de la red neuronal con 4 entradas, 15 neuronas ocultas y una salida. .	89
Figura 5-42 Tiempo de recuperación de la aeronave.....	90
Figura 5-43 Variación del ángulo de ataque respecto al tiempo por las ecuaciones de la cuartica de estabilidad.[19].	91
Figura 5-44 Predicción del modelo generado por técnicas de IA.....	92

Índice de tablas

Tabla 1 Datos exportados del sensor.	40
Tabla 2 Exportación de datos capturados.	46
Tabla 3 Calculo de la desviación estándar.....	59
Tabla 4 Media de cada prueba de la velocidad 1, velocidad 2 y velocidad 3 respectivamente.	60
Tabla 5 Desviación estándar grupal.....	60
Tabla 6 Media de cada prueba.	60
Tabla 7 Desviación estándar.....	61
Tabla 8 Desviación estándar grupal de las secciones de velocidades.....	61
Tabla 9 Desviación estándar de pruebas adicionales.....	62
Tabla 10 Media de las pruebas totales.	64
Tabla 11 Desviación estándar de las medias.	64
Tabla 12 Métrica de desempeño de k-NN.	68
Tabla 13 Tiempo de ejecución CPU.....	69
Tabla 14 Tiempo de ejecución GPU.....	70
Tabla 15 Métrica de desempeño SVM.	75
Tabla 16 Métrica de desempeño 4 neuronas.....	84
Tabla 17 Métrica de desempeño 10 neuronas.....	86
Tabla 18 Métrica de desempeño 15 neuronas.....	89
Tabla 19 Métrica de desempeño en conjunto de 4, 10 y 15 neuronas.	89
Tabla 20 Tiempo de recuperación de la aeronave en segundos.....	92
Tabla 21 Resultados generales de los métodos evaluados.....	93

Capítulo 1

1 Introducción

En la actualidad, la mayoría de los sistemas de navegación cuentan con dispositivos electrónicos que permiten ubicarse ya sea en tierra, mar, espacio exterior, por mencionar algunos y los sensores inerciales permiten orientarse en el entorno 3D. Para su óptimo funcionamiento los datos registrados por los sensores deben ser interpretados de manera eficaz y de esta manera implementar alguno de los métodos existentes.

Una IMU (Inertial Measurement Unit) se compone de acelerómetro, giroscopio y magnetómetro, de los cual se obtiene la aceleración, velocidad angular y el ángulo respecto al norte magnético, respectivamente. Algunas de las aplicaciones son en la robótica [1], aeroespacial[2][3], drones[1], peatones[4][2][5][6] y satélites[6][7][8][9][10]; por mencionar algunas aplicaciones.

Sin embargo, los factores externos [11][9] ya sean del magnetómetro o acelerómetro, influyen de manera directa en los sensores produciendo ruido en las mediciones. Algunos autores han tratado de disminuir esta problemática por medio de un proceso de calibración [7].

La minimización de los errores se realiza por medio de un microprocesador que permita ejecutar los cálculos necesarios de manera eficaz o un algoritmo que realice las correcciones pertinentes. Uno de los métodos comúnmente utilizados por algunos autores son los ángulos de Euler[12][8][4], Filtro de Kalman[13][4][14][7][8][9][15], Cuaterniones[12][16][9][6][8] solo por mencionar algunos. No obstante, suelen tener margen de error [9][7][11][12][16]. En este trabajo de tesis se propone realizar una comparativa entre algunos métodos y observar su rendimiento.

Es por ello, en este trabajo de tesis que se propone un sistema alternativo de orientación para aeronaves basado en las lecturas sin procesar de los Cuaterniones haciendo uso de una IMU para estimar el ángulo de inclinación, con base en técnicas de Inteligencia Artificial (IA); que permita atenuar el error producido por las vibraciones de vuelo. Algunos autores han

trabajado en técnicas de Machine Learning y Deep Learning para predicción utilizando sensores [17][10][4].

Se presentan los resultados de la realización de pruebas numéricas como experimentales, para validar adecuado funcionamiento del sistema.

1.1 Alcance de la tesis

Esta tesis ofrece un panorama más amplio de las técnicas de orientación en modelos de aeronaves, permitiendo tener una mejora en el procesamiento de datos para la orientación de aeronaves; con la finalidad de implementarlos en drones o vehículos que requieran de sistemas de orientación de respuesta rápida y eficiente, apoyándose en la inclusión de técnicas basadas en Inteligencia Artificial (IA). Además, de proponer un sistema alternativo que permita orientar una aeronave en casos críticos.

1.1.1 Objetivo general de la tesis

- Determinar cuál de los métodos utilizados para la orientación de objetos en un espacio 3D tiene la mayor precisión con sensores inerciales.
- Determinar si por medio de la IA y el uso de Cuaterniones se obtiene una respuesta más rápida al procesamiento convencional de datos y sus respectivos parámetros de orientación.

1.1.2 Objetivos específicos

- Identificar los métodos de orientación convencionales en aeronaves.
- Implementar cada uno de los métodos seleccionados para determinar la orientación de un objeto en un espacio 3D.
- Evaluar los resultados obtenidos de cada uno de los métodos para identificar el que ofrezca mejor desempeño.

1.1.3 Preguntas de investigación

- ¿Cuál es el método más eficaz para orientar objetos en el espacio 3D?

- ¿Es posible que, mediante el uso de algún algoritmo de IA, se pueda inferir al ángulo de ataque de una aeronave, utilizando los datos de los Cuaterniones de un IMU?
- ¿Cuál es la precisión para detectar la orientación asociado con factores externos?

Capítulo 2

2 Antecedentes

2.1 Estado del arte

Tomando en cuenta la necesidad de fundamentar esta investigación, basándonos en resultados obtenidos por la comunidad científica, se realizó una revisión sistemática, con base en la metodología propuesta por Arksey y O'Malley [18].

La primera fase de esta revisión de alcance se realizó por el revisor 1, para ello se utilizó la base de datos SCOPUS. Para lo cual, se definió la cadena de búsqueda con las palabras claves “Cuaterniones, filtro de Kalman y ecuaciones de Euler”, de manera simultánea durante el proceso de búsqueda en la base de datos SCOPUS se agregaron filtros que nos permitieron obtener artículos, verbigracia, solo se agregaron artículos en el área ingenieril. Así como, se agregaron artículos que tuviesen relevancia con las palabras clave tales como IMU, Inteligencia artificial y GPS; para obtener resultados más puntuales.

Como resultado de la primera fase se obtuvieron 886 artículos de los cuales fueron puestos a un criterio de exclusión por título y resumen. Y finalmente se aceptaron 107 artículos.

Se procedió con la siguiente fase con el mismo criterio de exclusión, pero esta ocasión se aceptaron 258 artículos y se excluyeron 627, por un segundo revisor. En total se obtuvo concordancia entre ambos revisores en 66 artículos, es decir, solo se tomaron en cuenta aquellos artículos en los que ambos coincidieran. De los cuales 15 no se encontraron o estaban ilegibles, y finalmente solo se aceptaron 51.

Con ayuda de un tercer revisor se revisaron aquellos artículos que fueron aceptados por un revisor ya sea el revisor 1 o revisor 2, pero que no tuvieron el punto bueno por ambos con un total de 266 artículos a revisar. Se aplicó el mismo criterio de exclusión, obteniendo un total de 129 artículos aceptados por el tercer revisor; dando un total de 195 artículos aceptados entre los 3 revisores.

Previo a ello ya se tenían definido las preguntas de investigación la cual permitió tener un panorama más objetivo para poder realizar la búsqueda y así poder identificar aquellos artículos que tuviesen una mayor relevancia al tema de investigación.

A continuación, se muestra de forma gráfica como se realizó la búsqueda sistemática.

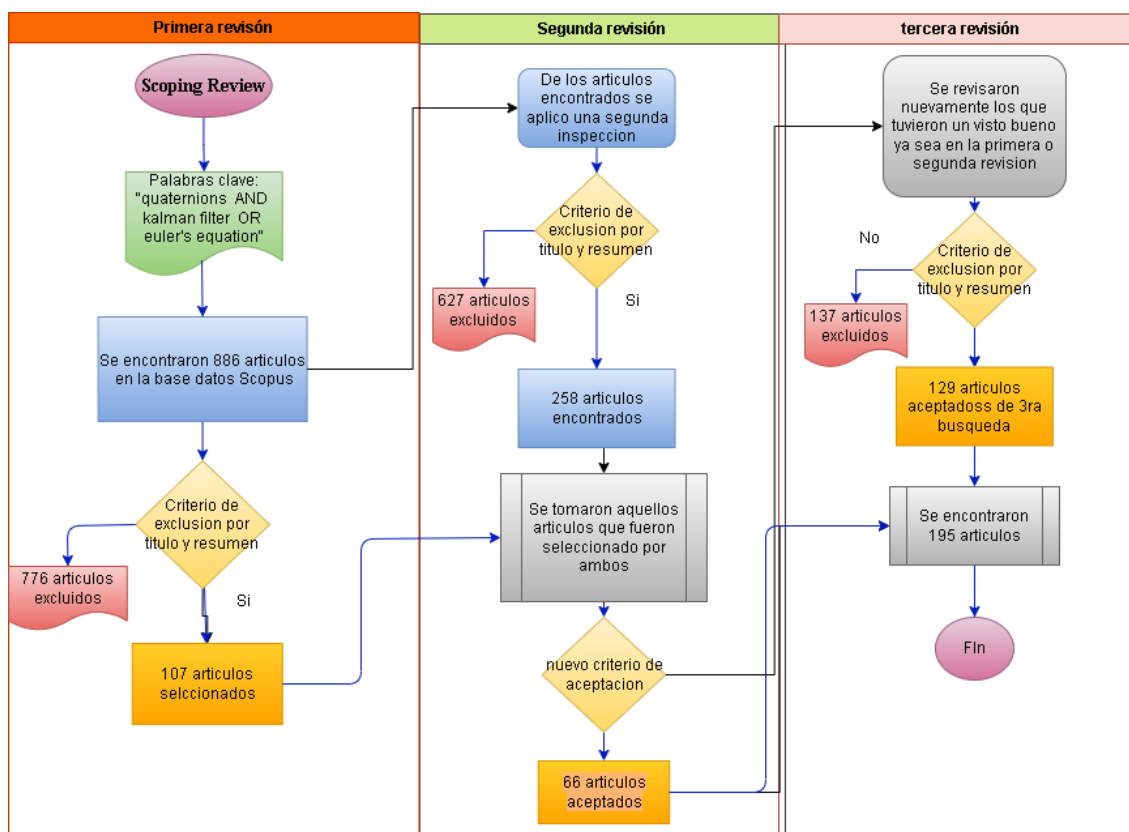


Figura 2-1 Diagrama de revisión.

A continuación, se muestra el Scoping Review que se realizó en la siguiente ilustración:

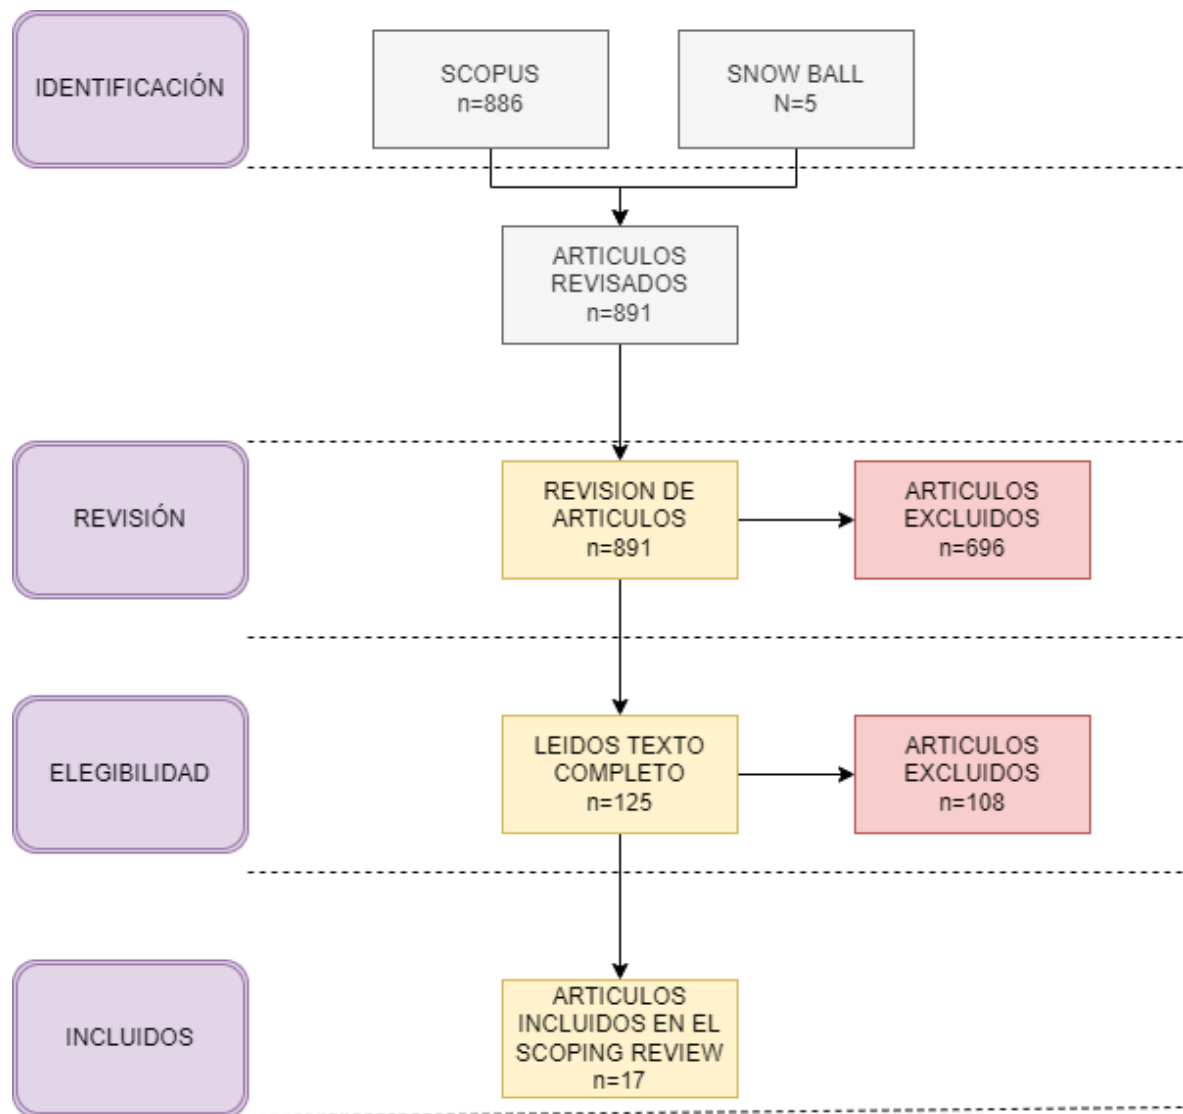


Figura 2-2 Scoping Review.

Así como los resultados obtenidos por la búsqueda bibliográfica:

Sensores empleados por los autores




Figura 2-3 Sensores utilizados en los artículos encontrados.

De los resultados obtenidos, se puede observar como el interés por el uso de IMU ha incrementado en este último periodo de tiempo al igual que algunos autores lo emplean en conjunto de un GPS[1][8] [9].

Además, el uso de Cuaterniones se ha mantenido, así como ha ido en aumento en el transcurso de los años; del mismo caso ha sido el filtro del Kalman. Así como el empleo de otras técnicas de IA y Python.

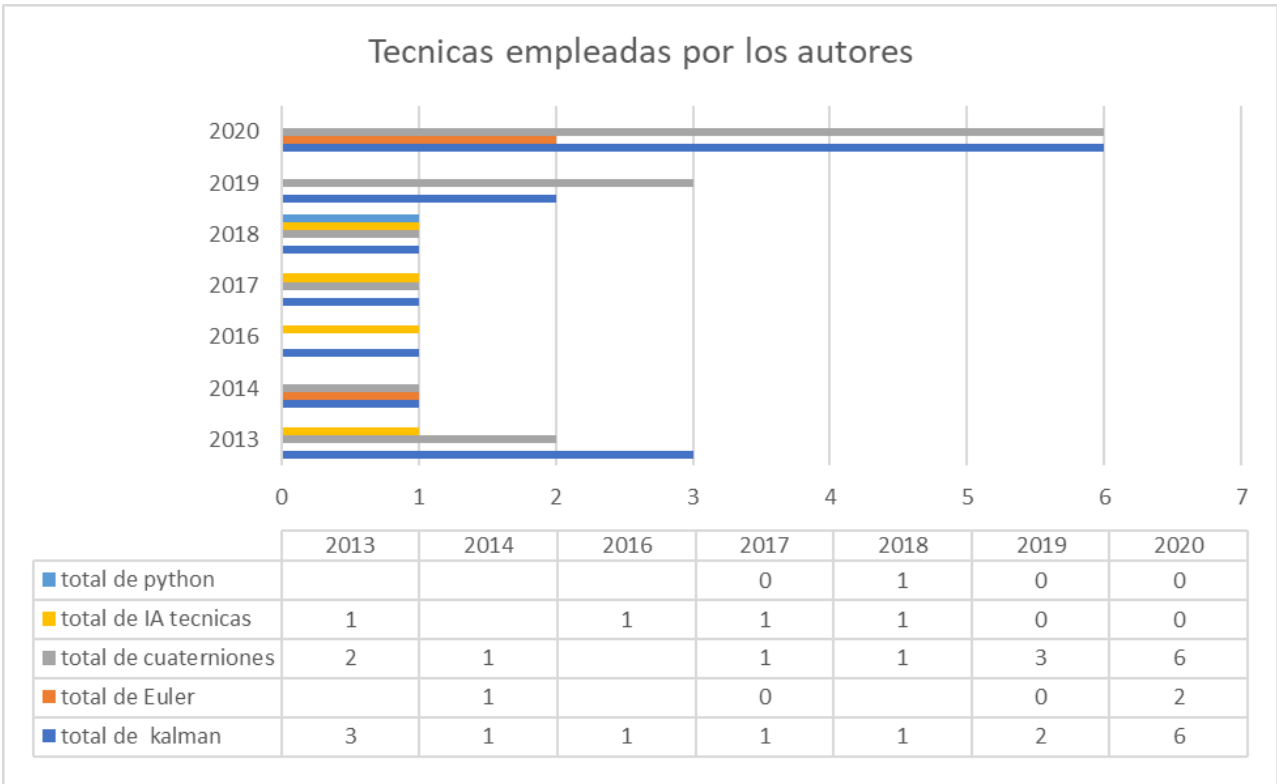


Figura 2-4 Técnicas utilizadas en los artículos encontrados.

Capítulo 3

3 Metodología

En este apartado se describirá de forma más detallada el proceso que se llevó a cabo en esta investigación. El cual consta de 4 experimentos. Así, como trabajo adicional utilizando un sensor MPU6050.

Durante el desarrollo de experimentación se utilizó una IMU 3 Space Mini Bluetooth de la marca YostLabs, con unas dimensiones 30mm x 30mm x 13mm y con comunicación bluetooth, el cual fue colocado en el centro de gravedad del prototipo de aeronave fabricada para el desarrollo de esta tesis.

Para el segundo experimento se utilizó un IMU de la marca Xsens, el modelo es MTw Awinda con dimensiones 47 x 30 x 13 mm. En ambos casos se utilizó el mismo modelo de avión y se ajustó el peso del mismo para que la aeronave se mantuviese estable.

Ambos experimentos se realizaron bajo las mismas condiciones dentro del túnel de viento, así como la configuración de los sensores. Es por ello que para poder desarrollarlo es necesario definir ciertos parámetros con el fin de poder replicarlos con otros dispositivos bajo las mismas condiciones. Por lo tanto, se deben establecer los periodos de tiempo y posición de la perilla de velocidad del túnel de viento.

A continuación, se muestran la metodología a seguir para ambos experimentos:

- Definir la sensibilidad del acelerómetro +/-16 g
- Definir la sensibilidad del giroscopio +/-2000 grad/s
- Identificar los ejes del sensor y ejes de referencia, y calibrarlos
- Montar el sensor dentro de la aeronave
- Montar la aeronave dentro del túnel de viento
- - Encender el túnel de viento y se dejarlo 30 seg en velocidad 0 m/s. (esto con el fin de poder observar los cambios de velocidad desde el inicio).

- Girar la perilla hasta alcanzar una velocidad 5 *m/s* y mantener la posición durante 1 min. - Se induce una perturbación*
- Mantener en la misma posición durante un minuto para observar su comportamiento.
- Se gira la perilla hasta alcanzar una velocidad 11.5 *m/s* y se mantiene la posición durante 1 min
- Introducir una perturbación*
- Mantener en la misma posición durante un 1 min para observar su comportamiento.
- Girar la perilla hasta alcanzar una velocidad 19.5 *m/s* y se mantiene la posición durante 1 min.
- Introducir una perturbación*
- Mantener en la misma posición durante un 1 min para observar su comportamiento.
- Regresar la perrilla a su posición inicial (0 grados) y se deja durante 20 seg.

Cabe resaltar que para garantizar que las mediciones no sean afectadas por ninguna otra variable, se requiere que la habitación donde se encuentra el túnel de viento este aislada.

Sin embargo, es necesario que no haya ningún tipo de objeto frente al túnel de viento; a excepción cuando se induzcan las perturbaciones en el flujo de aire.

Este procedimiento se repitió para cada una de las pruebas, esto con el fin de comparar los diferentes resultados en condiciones similares.

Como tercer experimento se utilizan los datos recabados y se emplearon algunas de las técnicas de Inteligencia Artificial específicamente Machine Learning y Deep Learning. Comparando los valores medidos vs los predichos.

*La perturbación se induce al abrir el compartimiento de la ventana en la parte superior hasta obtener una abertura de 15cm durante 1 segundo y se cierra la ventana; se encuentra en la parte lateral del túnel de viento

Previo a realizar pruebas, es necesario calibrar el sensor. Para nuestro caso primero se determina nuestra referencia global la cual debe ser perpendicular al vector gravitacional de la tierra. Para ello es necesario una superficie plana y a partir de ahí se determina nuestro vector y plano de acción. Una vez que se determina nuestro offset se traslada la aeronave dentro del túnel de viento para poder realizar las pruebas, ajustándolo lo más posible a nuestra referencial global para poder iniciar las pruebas.

El modelo del túnel de viento utilizado es el AF100 túnel de viento subsónico.



Figura 3-1 Túnel de viento AF100 subsónico.




Figura 3-2 Configuración de la aeronave en túnel de viento.

El avión utilizado durante las pruebas, se realizó en una impresora 3D.

En cada prueba se utilizó el mismo modelo de la aeronave la cual fue modificada en el software SolidWorks para poder colocar el sensor de medición, este fue colocado en el centro de gravedad de la aeronave y también los orificios de sujeción en la parte lateral de la misma. Esto con el fin de limitar los grados de libertad del avión dentro del túnel de viento, para poder realizar las pruebas y capturar los datos.

Como se observa en la figura 3-3 y 3-4, el avión fue impreso en dos partes para facilitar el proceso de impresión.

En la Figura 3-4 se muestra la cavidad del sensor YostLabs.



Figura 3-3 Modelo de avión.




Figura 3-4 Avión Modificado.

En la Figura 3-5 se observa como el avión fue colocado dentro del túnel de viento haciendo uso de un soporte.




Figura 3-5 Configuración del avión en el túnel de viento.

3.1 Diagrama de trabajo

A continuación, se muestra el diagrama de trabajo propuesto. El cual consiste en determinar el ángulo de inclinación de una aeronave por distintas metodologías. Para ello se lleva a cabo en 3 fases, tales como, la metodología, experimentación y pruebas numéricas.



Figura 3-6 Diagrama de trabajo.

En la sección de modelado, se realizó toda la búsqueda relacionada con el modelo de avión a utilizar, así como los sensores que se emplearon.

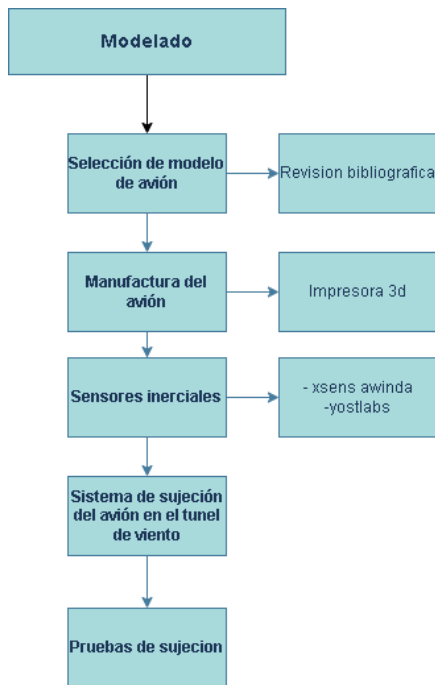


Figura 3-7 Desglose del modelado.

En la sección de experimentación, se realizó en 3 fases. Como se muestra a continuación:

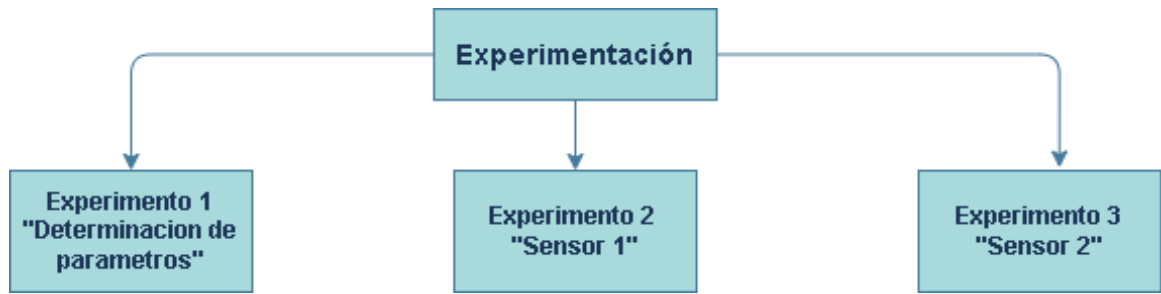


Figura 3-8 Fases d experimentación.

Cada fase de la experimentación se desarrolló en distintas pruebas desde determinar los rangos a evaluar hasta la evaluación de los 2 sensores propuestos por medio de Cuaterniones, y así poder determinar el ángulo de ataque de la aeronave.

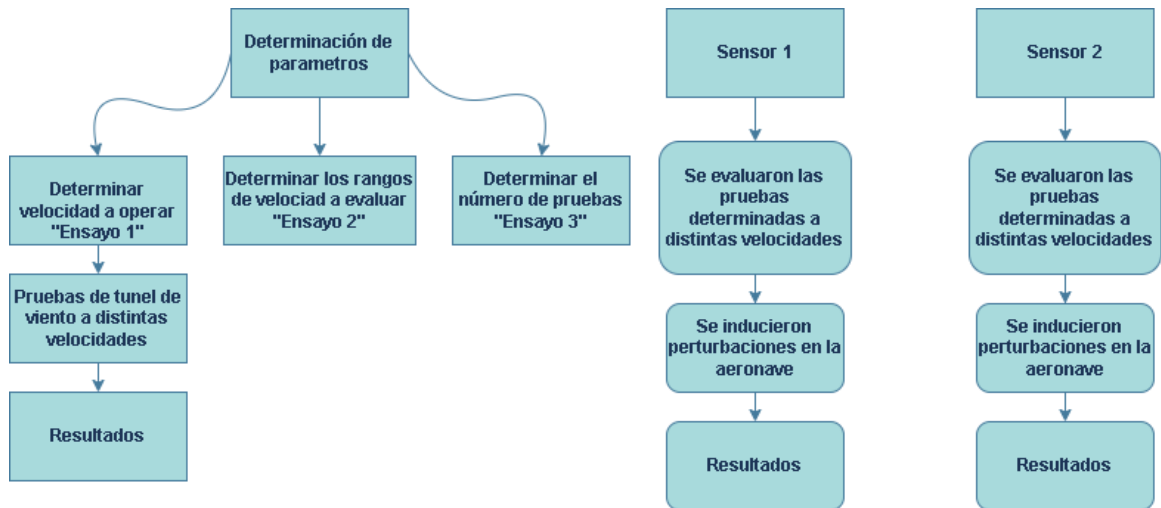


Figura 3-9 Desglose de experimentación.

Y para culminar, a partir de los resultados obtenidos por la experimentación. Se identificaron métodos de inteligencia artificial tales como Machine Learning y Deep Learning, tales que pudieran aplicarse a los mismos.

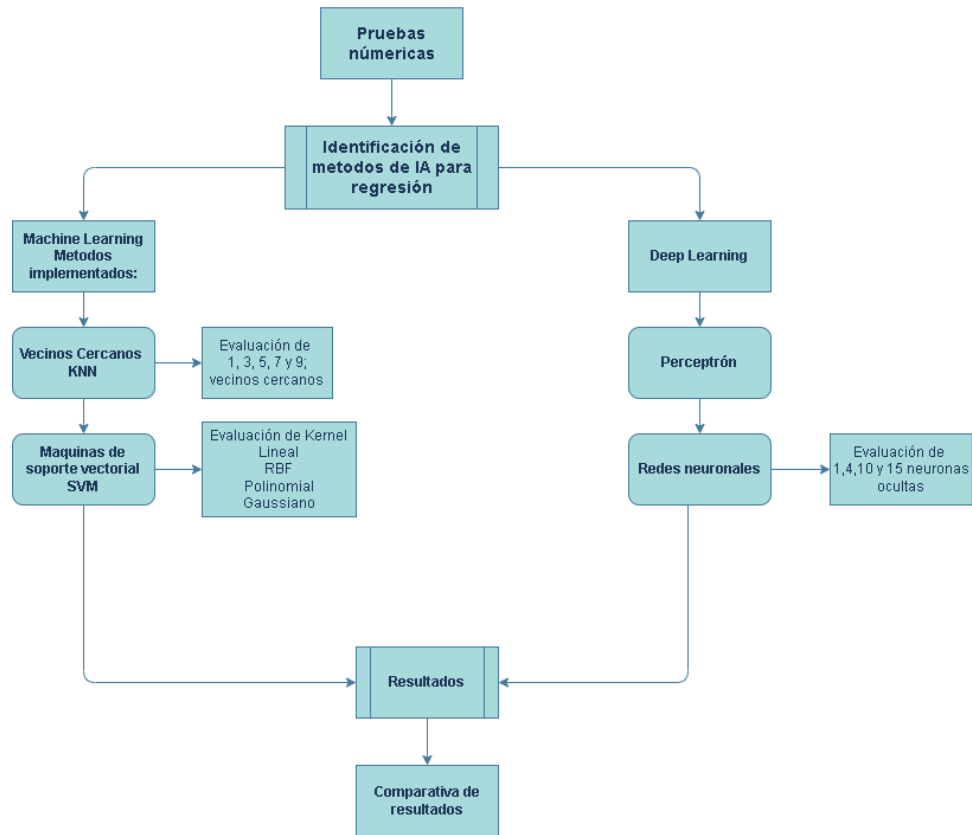


Figura 3-10 Desglose pruebas numéricas.

Y, por último, se analizan los resultados obtenidos en el capítulo 4.

3.2 Trabajo Adicional

Derivado de los resultados obtenidos de la búsqueda bibliográfica, en los cuales se encontró que algunos autores hacen uso del sensor MPU6050, se optó por el uso de éste, ya que cuenta con 9 ejes.

Se usó un microcontrolador Arduino que nos permitió hacer las lecturas del sensor MPU6050. Y para validar su funcionamiento el sensor y el microcontrolador se colocaron en un nivelador impreso en 3D como se observa en la Figura 3-12, 3-13 y 3-14. El sensor se comunica con el Arduino y manda los valores crudos del acelerómetro, giroscopio y magnetómetro; además de los Cuaterniones calculados.

A continuación, se muestra un diagrama de flujo de trabajo:




Figura 3-11 Diagrama de flujo de trabajo.

Como se menciona anteriormente, se utilizó una placa Arduino que además de extraer los datos del sensor MPU6050 hacia las conversiones a grados para una mejor interpretación. Esto lo hace tanto para los valores sin procesar de aceleración en tres ejes, del giroscopio y el magnetómetro, así como para los Cuaterniones y ángulos de Euler.

El nivelador contiene en su interior una batería, una pantalla LCD, un Arduino y sensor MPU6050.




Figura 3-12 Diseño de nivelador experimental.




Figura 3-13 Tapa del nivelador.

Teniendo la impresión lista, se realizó la primera prueba, donde se colocó el nivel sobre una superficie plana con el objetivo de comprobar la funcionalidad del sensor, esperando que las lecturas fuesen valores cercanos a los 0 grados.



Figura 3-14 Impresión y ensamble del nivelador.

Una vez realizada la primera prueba y corroborando que los datos eran cercanos a los 0 grados, se procedió a inclinar el nivel sobre su propia base perpendicular a la superficie, esperando que los valores arrojados por el sensor fueran cercanos a los 90 grados, para lo cual obtuvimos una medición de 92 grados. Estas pruebas se realizaron en 6 ocasiones más y los resultados fueron iguales en cada una de ellas. Cabe recalcar, que para este punto no se había aplicado ningún tipo de método como filtro de Kalman ni Cuaterniones, solo se calibraba el sensor dependiendo la ocasión y lugar.

```

Serial.print("a/g:\t");
Serial.print(ax); Serial.print("\t");
Serial.print(ay); Serial.print("\t");
Serial.print(az); Serial.print("\t");
Serial.print(gx); Serial.print("\t");
Serial.print(gy); Serial.print("\t");
Serial.println(gz);

// blink LED to indicate activity
blinkState = !blinkState;

```

Figura 3-15 Impresión de variables Arduino.




Figura 3-16 Nivelador puesto a 90 grados sobre superficie.

Cabe mencionar que con el paso del tiempo el sensor tendía a desfasarse y los valores respecto al tiempo cada vez eran más alejados de la realidad. Es por ello la razón de implementar otros métodos que corrigieran en gran medida ese sesgo de información. Posteriormente se hizo uso de los ángulos de Euler acorde a las ecuaciones establecidas de *pitch*, *roll* y *yaw*. Sin embargo, tienden a tener un sesgo cuando la posición llega a los 90 grados.

Además, el proceso se repitió de igual manera para el cálculo de Cuaterniones. Se extrae la información de los valores de i, j, k y q ; respectivamente y después se hace la conversión a grados para poder interpretarlos.

3.2.1 Segundo prototipo de nivelador digital

El diseño anterior del nivelador era demasiado grande para la aplicación deseada, por lo cual se realizó un nuevo diseño para poder hacer las pruebas de manera más simple. Para esto se hizo un nuevo modelo, pero con dimensiones más pequeñas en comparación del anterior con unas dimensiones de 4cm*2.5cm*3cm de largo, ancho y altura respectivamente.

El diseño se hizo en el software SolidWorks y se imprimió en una impresora 3d.



Figura 3-17 Nuevo modelo de pruebas.




Figura 3-18 Tapa del nuevo modelo.

Una vez impresa las piezas se montaron los dispositivos dentro de la caja. Las funciones que se integraron fueron un menú de opciones para calibración y configuración del sensor.




Figura 3-19 Impresión y ensamble del nuevo modelo.

Para poder validar las mediciones que arrojaba el sensor fue necesario compararlo con un nivelador digital comercial para verificar la precisión del mismo, es por ello que para este punto se colocaron ambos dispositivos en una superficie plana para poder compararlos y posteriormente se colocaron inclinados a 45 grados apoyándose sobre una escuadra.

En la superficie plana el sensor comercial daba una medición de 0.3 grados respecto a la superficie y el nuestro daba una medición de 1 grado respecto a la superficie, es decir, teníamos una diferencia de 0.7 grados.



Figura 3-20 Comparación del modelo propuesto vs sensor comercial.

Cuando el nivelador comercial se colocó sobre la escuadra proporcionó una medición de 44.55 grados y el nuestro 43 grado. Cabe mencionar, que nuestro prototipo fue diseñado para dar valores enteros y no de punto decimal.




Figura 3-21 Sensor comercial.



Figura 3-22 Modelo propuesto.

Al igual que en el caso del nivelador, en este punto no se había aplicado ningún tipo de técnica u algoritmo que atenuara el sesgo de información sino únicamente las lecturas directas del sensor y por tanto después de cierto tiempo tendía a descalibrarse y/o desfasarse.

3.3 Desarrollo de experimento 1:

3.3.1 Ensayo 1

Como parte del primer ensayo se realizaron 5 pruebas para validar el funcionamiento del avión, es decir, verificar que se mantuviese estable a ciertas velocidades para no exceder el punto crítico y la capa límite, y hacer pruebas por encima del mismo para observar cómo es su comportamiento de forma experimental.

3.3.2 Ensayo 2

Para este ensayo se realizaron 5 pruebas, para observar el comportamiento del avión y determinar los rangos de velocidad a evaluar. Además, se realizaron 2 pruebas adicionales por encima de la velocidad en su punto crítico para comparar el comportamiento evaluado en el ensayo. Para ello nos apoyamos en el uso de un anemómetro digital para poder medir la velocidad del túnel de viento.

3.3.3 Ensayo 3

Una vez definido el rango de velocidades, se repitió el ensayo anterior, pero con 3 velocidades. Una de 5 *m/s*, 11.5 *m/s* y 19.5 *m/s*, además de una velocidad adicional de 22 *m/s* por encima de la capa límite. De la misma forma que en el ensayo 2 se toman 5 muestras.

3.4 Desarrollo de experimento 2:

Acorde a la lista anterior para desarrollar la prueba, una vez que el sensor YostLabs se encuentra montado en la aeronave capturando los datos; estos son enviados por medio del bluetooth a la computadora por medio de su interfaz 3 Space Suit para dispositivos con sistema operativo Windows, para poder almacenarlos y posteriormente post procesarlos en un archivo de texto.

La información capturada son los datos del acelerómetro, giroscopio, ángulos de Euler y Cuaterniones. El tiempo de duración de cada prueba fue de 6 min 50 seg para cada una, con un total de 30 pruebas realizadas con el fin de obtener la repetibilidad y determinar si la aeronave era estable o no, con la ayuda del sensor. Considerando que el avión estaba sujeto de los laterales el ángulo pitch era el de nuestro interés.

3.5 Desarrollo de experimento 3:

En este experimento se tomaron en cuenta los mismos parámetros del anterior, es decir, la duración de cada experimento fue de 6 min 50 seg; y esto se realizó en 20 ocasiones de igual manera.

Sin embargo, para este caso se hizo uso de otro sensor llamado Xsens awinda y su interfaz Mt Manager para dispositivos con sistema operativo Windows. Los datos se transmitieron a un ordenador por medio de su transmisor y receptor; para realizar el post procesamiento. A diferencia del sensor anterior, este sensor proporcionaba directamente los valores de pitch sin necesidad de volver a calcularlos para los ángulos de Euler.

3.6 Desarrollo de experimento 4:

En el desarrollo de este experimento, se creó una base de datos con la información recabada de cada prueba con el fin de poder implementar algunos algoritmos del área de Inteligencia artificial tales como Machine Learning y Deep Learning.

Unas de las técnicas que se utilizaron fueron vecinos cercanos, redes neuronales y SVM; todas con algoritmos de regresión, ya que son las que más se adecuan a las pruebas realizadas. Se evaluaron 20 pruebas totales para realizar el entrenamiento con los datos recabados del sensor.

Se concatenan los resultados obtenidos de los sensores para 20 pruebas, y de esta manera poder tener un solo archivo con todos los datos necesarios. Dando un total de 402,000 datos para el entrenamiento y validación (80% entrenamiento y 20% validación). Sin embargo, para el caso de vecinos cercanos al tener que comparar dato por dato requiere de grandes cantidades de recursos computacionales, se propone realizar el entrenamiento y validación con particiones representativas de la población; y así mismo poder comparar los resultados a diferentes particiones.

3.6.1 Machine Learning

Vecinos cercanos

De los datos totales se tomaron el 80% para datos de entrenamiento y el 20% para pruebas. Se evalúan de 1 a 9 vecinos cercanos para cada una de las pruebas, únicamente evaluando aquellos vecinos impares. Este proceso se repitió para cada partición que se realizó posteriormente. Se usaron particiones del 100%, 80%, 60%, 40% y 10%, en cada una se tomó el 80% para datos de entrenamiento y 20% para validación correspondiente al tamaño de partición.

Evaluación prueba adicional

Para este caso se empleó una prueba nueva fuera de los datos de entrenamiento y test; la cual fue evaluada únicamente para una partición al 10%.

Support Vector Machine

Los kernel son hiperplanos que nos permiten separar datos por medio de vectores de soporte, y esto aplica para cualquier método. Los hiperplanos se obtienen por medio del entrenamiento de los datos.

Para la máquina de soporte vectorial se evaluaron 4 métodos los cuales son: Gaussian, Radial Basis Function (RBF), Polynomial y Linear; dentro de la plataforma de Matlab. Para cada método se evaluó con los mismos parámetros, variando el parámetro del “Box Constrain” para valores de $c = \{0.01, 0.1, 1, 5, 18.5, 24, 30\}$. Para todos los casos se usó el 100% del conjunto de datos totales.

Gaussian

Una vez cargados los archivos con los datos de las pruebas, se agregan los parámetros de “Box Constrain” o también conocido como parámetro “c”. Y al igual que para el caso de vecinos cercanos se tomó una partición del 80% para datos de entrenamiento y el restante 20% para validación.

RBF

De igual manera que en el caso anterior se evalúa el método con los mismos parámetros y la misma cantidad de datos.

Polynomial

Al igual que el caso anterior se evalúa el método con los mismos parámetros y la misma cantidad de datos.

Linear

Por último, este método no fue la excepción y para poder tener un punto de comparativa se evaluó bajo las mismas condiciones.

3.6.2 Deep Learning

Todas las pruebas se hicieron con el 100% del conjunto de datos. Pero para el caso de 10 y 15 neuronas ocultas se utilizó el toolbox de Matlab “neural net fitting”. Para el caso de una sola capa se desarrolló el algoritmo de forma manual.

Red Neuronal de una capa

Back Propagation

Otro de los métodos que se empleó fue una red neuronal artificial de una sola capa, donde al entrenar con los datos de entrada se obtiene una función representativa dada por los pesos finales. Pero para ello se define de manera previa el número máximo de épocas a realizar, así como el parámetro n que representa la tasa de aprendizaje.

Para el primer ejemplo se usó un número máximo de 20 épocas y un valor de $n=0.05$.

Redes neuronales artificiales con 4, 10 y 15 neuronas ocultas

Método Levenberg-Marquardt

El primer método que se utilizó consta de 10 neuronas ocultas definidas previamente. Pero para esta ocasión el número máximo fue de 1,000 épocas o hasta encontrar la solución más próxima.

Método Bayesiano regularización

Para este método se usaron los mismos parámetros del caso anterior.

Método Scaled conjugated gradient

Por último, se evaluó un método más con 15 neuronas y un máximo de 1,000 épocas.

Capítulo 4

4 Resultados de experimentación

4.1 Experimento 1:

4.1.1 Ensayo 1

En las primeras pruebas de valoración se realizaron 5 muestras a distintas velocidades. Los datos son exportados a un archivo de tipo texto los cuales contienen la información de Cuaterniones, ángulos de Euler, datos crudos del giroscopio y acelerómetro; por lo cual para poder visualizarlos de primera instancia se usó la herramienta Excel.

Tabla 1 Datos exportados del sensor.

(QX)	(QY)	(QZ)	(QW)	(OrientPitch)	(OrientYaw)	(OrientRoll)	(RawGyroX)	(RawGyroY)	(RawGyroZ)
0.0362442	0.0016735	0.000405	0.9993416	0.0725027	0.003383	0.0009333	0.0329858	-0.0305424	-0.0109953
0.0362508	0.001733	0.0003833	0.9993413	0.0725162	0.0035008	0.000894	0.0268773	-0.0329858	0
0.0362486	0.0016654	0.0003679	0.9993414	0.0725118	0.0033641	0.0008584	0.0293207	-0.0354291	-0.0134386
0.0362482	0.0016954	0.0003708	0.9993414	0.0725109	0.0034244	0.0008663	0.0317641	-0.0354291	-0.0183254
0.036272	0.0017196	0.0003797	0.9993405	0.0725584	0.0034737	0.0008859	0.0268773	-0.0354291	-0.0048868
0.0362885	0.001691	0.0004628	0.9993399	0.0725913	0.0034225	0.0010504	0.0305424	-0.0305424	-0.0122169
0.0363145	0.0016683	0.0005022	0.999339	0.0726432	0.0033797	0.0011279	0.0244339	-0.0342074	-0.0073302
0.0363222	0.0016844	0.0006517	0.9993385	0.072658	0.0034229	0.0014287	0.0317641	-0.0366508	-0.0195471

Pero al ser un gran volumen de información solo se podía visualizar una parte de ellos en representación gráfica.




Figura 4-1 Datos del giroscopio en sus 3 ejes.




Figura 4-2 Datos de Cuaterniones en sus componentes.

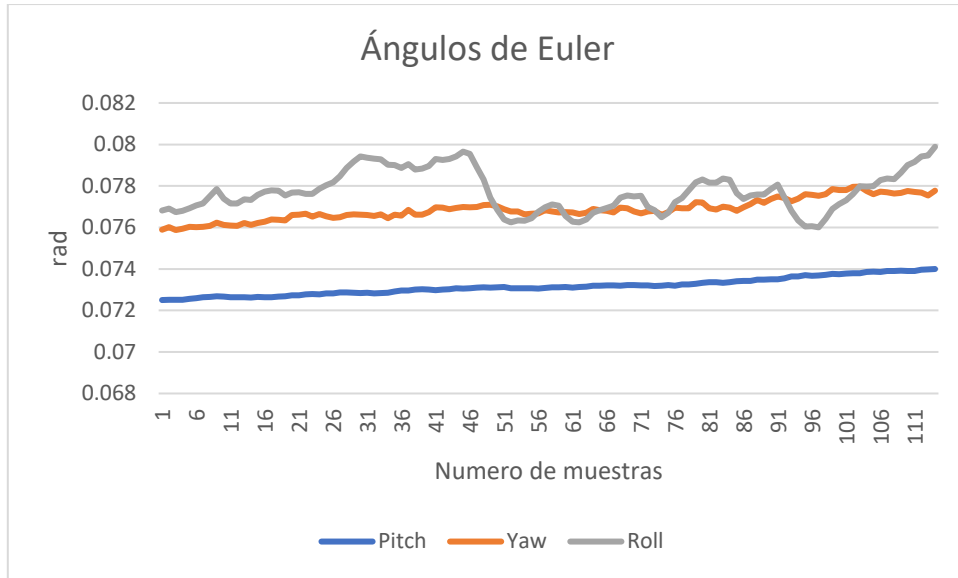


Figura 4-3 Datos de los ángulos de Euler dados en radianes.

Se trabajo con Matlab como herramienta computacional. Los datos se importan al software para poder calcular los ángulos dados en rad y se hace una conversión a grados.

Las pruebas realizadas fueron continuas una tras otras por lo tanto el punto de partida siempre es distinto para cada una de ellas. Aun así, se puede observar cierta similitud en el comportamiento de las gráficas. Esta variación del punto de partida se deriva de no corregir la orientación de la aeronave dentro del túnel de viento.




Figura 4-4 Primera prueba preliminar.

Por lo tanto, se realizó un ajuste para que todas las pruebas empezaran en el ángulo 0 (esto solo se realizó para estas pruebas).




Figura 4-5 Corrección del punto de origen.

Al observar el comportamiento se aprecia ruido en la señal, por lo que es necesario un filtro que permitiera suavizar la señal de forma más óptima, utilizando las herramientas del software Matlab 2017, tales como movmean, movmedian, Gauss, Savitzky-Golay, entre

otros. A continuación, se muestran los datos filtrados, cabe mencionar que la selección de los filtros fue manera arbitraria para observar cual ofrece mejores resultados acorde al comportamiento de la aeronave.

Movmean




Figura 4-6 Filtro movmean.

Gauss




Figura 4-8 Filtro Gauss.

Golay




Figura 4-7 Filtro Golay.

Movmedian




Figura 4-9 Filtro Movmedian.

Rloess




Figura 4-10 Filtro Rloess.

Cabe mencionar que el comportamiento de la aeronave era errático, dado que el centro de gravedad estaba desfasado; por lo cual se realizó un ajuste en el peso de la aeronave antes de continuar con las siguientes pruebas.

Nuevamente se volvieron a realizar 2 pruebas más para corroborar el comportamiento de la aeronave, pero sin post procesamiento de datos. Además, para esta ocasión como prueba preliminar se trató de inducir un tipo de perturbación en el flujo de aire por medio un orificio de 2.5 cm de diámetro que se encuentra en la parte inferior del túnel de viento; por lo cual se fabricó un mecanismo que permite abrirlo y cerrarlo de forma controlada. Es por ello que se diseñó y fabricó el siguiente modelo en el software de SolidWorks:




Figura 4-11 Modelo propuesto para generar perturbaciones controladas en túnel de viento.

El diseño consta de una plataforma ovalada en la parte superior y con 2 sujeciones que permiten tanto elevarla como inclinarla; esto por medio de 2 servo motores. Una vez finalizado el diseño se mandó a imprimir para su valoración.

Adicional a ello se diseñó un soporte en SolidWorks para poder sostener el avión dentro del túnel de viento.




Figura 4-12 Soporte del avión.

Para la prueba de valoración el flujo de aire que entraba por el orificio de 2.5cm de diámetro no era lo suficiente como para observar algún cambio considerable en la aeronave. Por lo que se optó por abrir el compartimento de la ventana descrito en la metodología.

A continuación, se muestra la siguiente tabla con los datos obtenidos del sensor para las 2 nuevas pruebas:

Tabla 2 Exportación de datos capturados.

(QX)	(QY)	(QZ)	(QW)	(OrientPitch)	(OrientYaw)	(OrientRoll)	(RawGyroX)	(RawGyroY)	(RawGyroZ)
0.0011804	0.0001546	-0.0000292	0.9999993	0.0023609	0.0003091	-0.000058	0.0305424	-0.0354291	-0.0024434
0.0011695	0.0001564	0.0000732	0.9999994	0.0023389	0.000313	0.0001468	0.0317641	-0.0390942	-0.0146603
0.0011896	0.0001228	0.0001608	0.9999994	0.0023791	0.000246	0.0003218	0.0317641	-0.0403159	-0.0134386
0.0012048	0.0001212	0.0002162	0.9999993	0.0024095	0.000243	0.0004326	0.0317641	-0.0342074	-0.0207688
0.001179	0.0001294	0.0002914	0.9999993	0.0023579	0.0002596	0.000583	0.0256556	-0.0378725	-0.0109953
0.0011821	0.0001488	0.0004021	0.9999993	0.002364	0.0002985	0.0008046	0.0293207	-0.0329858	-0.0122169
0.0011761	0.0001636	0.0004775	0.9999993	0.002352	0.0003283	0.0009554	0.0268773	-0.0329858	-0.0048868
0.0011823	0.000205	0.0005265	0.9999992	0.0023645	0.0004113	0.0010536	0.0342074	-0.0366508	-0.015882

Una vez capturados los datos, estos son procesados en Matlab para poder visualizar el comportamiento de la aeronave por encima de los 26 m/s.




Figura 4-13 Primera prueba por encima de los 26 m/s.




Figura 4-14 Segunda prueba por encima de los 26 m/s.

Como se puede apreciar en las ilustraciones anteriores el avión ya no podía mantenerse estable y tendía a tener oscilaciones muy amplias y las señales ya se veían con mucho ruido. Por lo cual no es factible mantener velocidades por encima de los 26 m/s.

Durante este ensayo, se tomaron rangos de velocidad de forma arbitraria; teniendo en cuenta que el avión es a escala y retomando los resultados del ensayo anterior con velocidades mayores a 5 m/s y menores a 26 m/s. Por lo cual, podemos inferir que el avión perdía la capa limite y se desestabilizaba.

4.1.2 Ensayo 2

Para las primeras 5 pruebas con la velocidad por encima de los 22 m/s los datos tuvieron un comportamiento inusual, ya que el avión no podía mantenerse estable lo que ocasionaba oscilaciones con grandes amplitudes en el cabeceo. Además, a estos datos no se le indujo ningún tipo de perturbación sino únicamente los cambios de velocidad.




Figura 4-15 Ángulo de ataque vs no de pruebas.

Como se puede observar durante las 3 primeras secciones de velocidad el avión tendía a mantenerse alrededor de un solo grado de inclinación correspondiente al cabeceo del mismo, pero una vez que pasaba la transición de 19.5 m/s a 27.1 m/s el cambio era un poco drástico y ya no era capaz de mantenerse estable.




Figura 4-16 Ruido de la señal. Gráfico grados vs número de muestras.

Después de tener capturados los datos y seleccionar el filtro a utilizar “movmean”; este fue empleado en los datos dando lugar al siguiente grafico:




Figura 4-17 Ángulo de ataques número de muestras después del filtro.

Como se observa en la Figura anterior la señal fue atenuada sin llegar a suavizarla demasiado, manteniendo aún el comportamiento de la aeronave. Una vez concluida esa parte, se tomó una sección de datos de cada una de las pruebas con un total de 20,000 muestras,

para observar el rango en las cuales estas se mantenían; como se muestra en las ilustraciones 42-44.

A continuación, se muestran los datos de una prueba individual previa:




Figura 4-18 Prueba individual por secciones de velocidad.

Como se observa en la Figura anterior, se cuentan con 5 cambios de velocidad desde los 5 m/s hasta los 27.1 m/s.

4.1.3 Ensayo 3

Al observar los resultados del ensayo anterior, se seleccionaron los 3 primeros rangos de velocidad para proceder con la siguiente fase. Después de haber capturado los datos, se exportaron al software Matlab para poder graficarlos y hacer la conversión a grados de cada prueba.

A continuación, se muestran los datos capturados sin la aplicación de filtro:




Figura 4-19 Señal filtrada mediante movmean del ensayo No. 3.

Una vez que se estableció el rango de velocidades y filtro a emplear, se prosiguió a realizar más pruebas.




Figura 4-20 Filtrado de la señal.

Teniendo un total de 10 pruebas bajo las mismas condiciones. Se puede inferir que el comportamiento en todos los casos sigue el mismo patrón de comportamiento. Por ello, se procedió con el siguiente experimento.

4.2 Experimento 2

A partir de los resultados anteriores, se retomaron los 3 rangos de velocidad a evaluar, pero en este punto ya se les inducía una perturbación en el flujo de aire por medio de la ventanilla. Dando lugar a la siguiente Figura:




Figura 4-21 Primeras pruebas con sensor YostLabs.

Una vez que se observó la repetibilidad de las primeras 5 pruebas, entonces se procedió a evaluar más pruebas manteniendo las mismas condiciones.




Figura 4-22 Filtrando las 30 pruebas realizadas.

Se tomaron un total de 20 pruebas a todas se les indujo un cambio en el flujo de aire, lo cual desestabilizaba el avión en el mismo instante de tiempo. Esto con el fin de comparar cada una de las pruebas.




Figura 4-23 Sección de velocidad a comparar ángulo de ataque vs número de muestras.

Una vez finalizado el paso anterior, se analizó la misma sección de velocidad para todas las pruebas. Para poder asegurar que el análisis no se vea afectado por la perturbación

del viento, se optó por tomar una parte representativa de la población antes de llegar a ese punto, y de esta manera también poder compararlas con las pruebas del ensayo 3.




Figura 4-24 Sección de velocidad 1.

Además, se calculó la velocidad angular en cada prueba realizada como se muestra en la siguiente Figura.




Figura 4-25 Velocidad angular respecto al tiempo de una prueba.

Esto se repitió para 5 pruebas en total como se muestra a continuación:




Figura 4-26 Velocidad angular de un conjunto de 5 pruebas.

Y con esto se concluye el desarrollo del experimento 2, donde se hace uso del sensor YostLabs.

4.3 Experimento 3

Se utilizó el mismo modelo de avión que en el experimento 2, pero adecuándolo al sensor Xsens para poder realizar las nuevas mediciones. Se toman nuevamente 20 mediciones con este sensor considerando los mismo parámetros y condiciones que el caso anterior. Generando los nuevos gráficos como se ve en la siguiente Figura:




Figura 4-27 Primeras pruebas con sensor Xsens.

También se hizo un post procesamiento a los datos y poder atenuar un poco la señal tal y como se ve en la siguiente Figura:




Figura 4-28 Se agregaron 20 pruebas.

Así como en el experimento 2, se evaluó la misma sección de datos para poder realizar una comparativa bajo las mismas condiciones.




Figura 4-29 Sección de velocidad a evaluar.

Y a continuación, se muestran las 3 secciones de velocidad a evaluar del sensor Xsens:

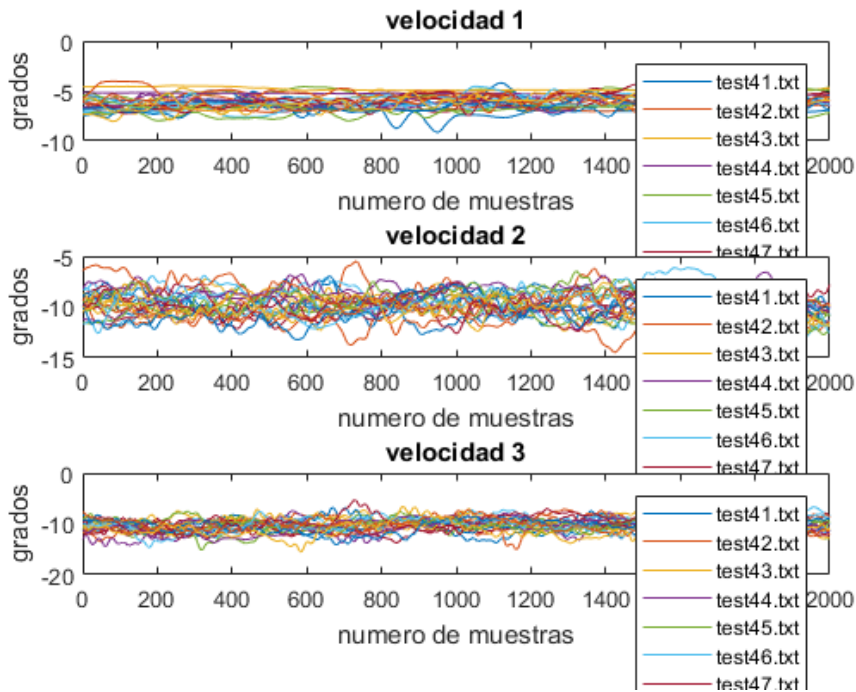


Figura 4-30 Comparativa de las velocidades por sección.

Y, por último, se evalúan todas las pruebas realizadas correspondientes a cada sección de velocidad:

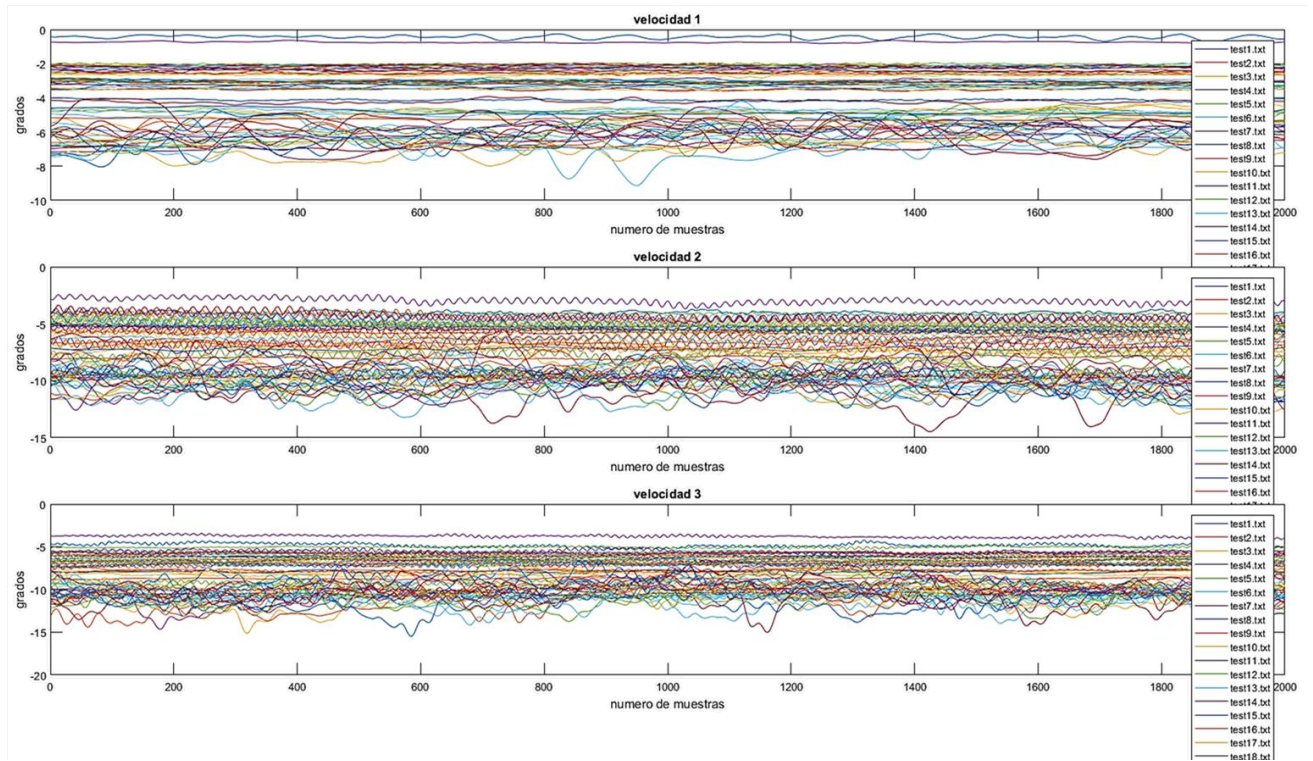


Figura 4-31 Comparativa total de las velocidades entre ambos sensores.

Capítulo 5

5 Análisis de Resultados

5.1 Experimento 1

5.1.1 Ensayo 1

Se compararon 3,800 datos entre prueba y prueba correspondientes a los datos antes de hacerle corrección del punto de partida.

Obteniendo una media de las desviación estándar agrupada de 1.59 grados, esto quiere decir, que se tiene una variación de +/- 1.59 grados entre prueba y prueba. Considerando que el avión se encuentra oscilando constantemente.

Nuevamente se calculó la desviación estándar, pero para aquellas pruebas donde ya se había hecho la corrección del punto de partida.

Tabla 3 Calculo de la desviación estándar.

Desviación estándar
0.43991878
0.426470225
0.412841786
0.410900797
0.405460251
0.409776585
0.414419036
0.39032934
0.397506827
0.395933251
0.411502181

Obteniendo una media de las desviaciones estándar agrupada es de 1.83, esto quiere decir, que se tiene una variación de +/- 1.83 grados entre prueba y prueba. Un factor importante a considerar es el comportamiento errático debido al centro de gravedad como se explicó en la metodología.

5.1.2 Ensayo 2

La desviación estándar y media ahora se calcularon en base a las secciones de velocidad teniendo una desviación estándar grupal con un mínimo de 0.8239 +/- grados entre las 5 pruebas tomadas. A continuación, se muestran las medias de cada prueba:

Tabla 4 Media de cada prueba de la velocidad 1, velocidad 2 y velocidad 3 respectivamente.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
1	-4.844119627	-9.480072802	-10.58889074
2	-4.940515736	-10.42952451	-10.85078612
3	-4.214208116	-9.745537336	-10.4965621
4	-3.349293508	-7.19434652	-7.896019682
5	-3.067819004	-7.959857127	-8.719526519

Tabla 5 Desviación estándar grupal.

	Velocidad 1	Velocidad 2	Velocidad 3
Media total	-4.083191198	-8.961867659	-9.710357032
Desv. Est. grupal	0.85158226	1.338361633	1.319477502

5.1.3 Ensayo 3

Para este ensayo se tomaron en cuenta las mediciones anteriores ya que se encontraban bajo las mismas condiciones de velocidad del viento. Dando un valor en conjunto de desviación estándar con un mínimo de 1.66.

Tabla 6 Media de cada prueba.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
1	-0.440890121	-4.029421058	-4.829078851
2	-2.112940436	-6.689608875	-6.962966283
3	-2.101115056	-7.275471312	-7.957815267
4	-0.743515745	-5.794985249	-6.832644588
5	-4.844119627	-9.480072802	-10.58889074
6	-4.940515736	-10.42952451	-10.85078612
7	-4.214208116	-9.745537336	-10.4965621
8	-3.349293508	-7.19434652	-7.896019682
9	-3.067819004	-7.959857127	-8.719526519
10	-4.713255922	-9.642602599	-9.823575334

Tabla 7 Desviación estándar.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
media total	-3.052767327	-7.824142739	-8.495786548
Desv. Est. grupal	1.663674667	2.028938799	1.970695068

Esto quiere decir que los rangos de velocidad arrondan alrededor de 2 grados respecto a la media de cada sección.

5.2 Experimento 2:

Para las primeras 20 pruebas iniciales se tiene un promedio de desviación estándar de 1.32 entre las 3 secciones de velocidad. A continuación, se muestra las medias de cada prueba, así como la desviación estándar.

Tabla 8 Desviación estándar grupal de las secciones de velocidades.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
1	-3.059095384	-6.709858772	-7.168035123
2	-3.111003529	-7.759552284	-9.280686819
3	-4.728727582	-9.728652767	-10.98486118
4	-2.121173057	-5.604433758	-6.665418873
5	-4.126024417	-9.293968721	-10.64605649
6	-2.596303477	-6.681697706	-7.773916182
7	-3.231033922	-5.816495101	-6.887010931
8	-3.22208554	-5.519446659	-6.486324803
9	-2.014913087	-4.117899549	-5.040897687
10	-2.945114206	-4.809337759	-5.988992054
11	-3.501823102	-9.629780866	-9.988267038
12	-3.057985673	-5.258608994	-6.229358556
13	-3.056603096	-7.093427797	-7.776012121
14	-3.503402114	-6.360477971	-7.216246342
15	-2.094885793	-5.183164838	-5.733936557
16	-2.149770446	-4.965311768	-5.667335607
17	-3.408564652	-6.293511812	-6.95619675
18	-2.43678289	-5.521200808	-6.14220229
19	-2.266170135	-5.279623726	-6.114578922
20	-3.06104087	-6.095826793	-6.920487454
media total	-2.980705662	-6.386113922	-7.283341089
Desv. Est. grupal	0.70185	1.6034	1.6815

Después de ello se evaluaron las 10 pruebas adicionales dando un total de 30 pruebas.

Tabla 9 Desviación estándar de pruebas adicionales.

No. pruebas	Desv. 1	Desv. 2	Desv. 3
21	0.697831742	1.571467608	1.652810337
22	0.698257104	1.699022364	1.781738558
23	0.686655242	1.680955619	1.746808425
24	0.688478994	1.683679365	1.736413176
25	0.686895368	1.689108391	1.721124823
26	0.674611049	1.661222681	1.686382737
27	0.66465626	1.655203788	1.668754761
28	0.653221205	1.635413329	1.644297499
29	0.646286812	1.629038165	1.635582969
30	0.638009097	1.603726446	1.607842762

Se evaluaron una a una para observar cómo variaba la desviación estándar conforme se agregaban más pruebas. Además, se agregaron las pruebas del ensayo 2 y 3 del experimento 1. Con un total de 40 pruebas analizadas.

A continuación, se muestra la variación de la desviación estándar de las 12 últimas pruebas.



Figura 5-1 Desviación estándar grupal velocidad 1.



Figura 5-2 Desviación estándar grupal velocidad 2.



Figura 5-3 Desviación estándar grupal velocidad 3.

Se puede inferir que no hay una variabilidad significativa al realizar más de 20 pruebas. Es por ello que se optó por realizar solamente 20 pruebas para el experimento 3.

5.3 Experimento 3:

Como resultado de las 20 pruebas que se hicieron de este sensor en conjunto de las pruebas pasadas, se obtuvo un valor mínimo de *RMSE* de 1.762, los valores de las medias realizadas de cada sección de velocidad se muestran en la siguiente tabla para la velocidad 1, velocidad 2 y velocidad 3 respectivamente:

Tabla 10 Media de las pruebas totales.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
1	-6.778016289	-9.341398862	-11.19548225
2	-6.853398995	-9.923404096	-10.47872889
3	-5.940004825	-10.08987418	-9.608278151
4	-6.080168626	-9.707372398	-10.6360596
5	-5.198751695	-9.785828349	-11.04935678
6	-6.216056659	-9.160014624	-9.577646353
7	-6.13895368	-9.771226036	-10.35256005
8	-6.091616232	-10.54906711	-9.993030167
9	-6.179477458	-10.77488249	-10.25306176
10	-4.820980422	-9.839790494	-10.70305348
11	-5.271468712	-9.571215973	-10.10243776
12	-7.065663166	-10.21439148	-10.09896848
13	-6.218120516	-9.895198149	-10.02520589
14	-5.974160954	-9.947741373	-10.9956324
15	-6.708745182	-9.80785473	-10.63077383
16	-5.499796283	-10.31305126	-10.00100559
17	-6.111703979	-10.23248792	-9.898195497
18	-6.084914865	-8.535955782	-10.55463478
19	-6.222897928	-9.391079976	-10.02294174
20	-5.890543647	-9.737865402	-10.37735718

Una vez determinada la velocidad media de cada una de las pruebas, se calcula la desviación estándar grupal, como se muestra a continuación:

Tabla 11 Desviación estándar de las medias.

No. pruebas	Velocidad 1	Velocidad 2	Velocidad 3
media total	-6.067272006	-9.829485034	-10.32772053
Desv. Est. grupal	0.55914933	0.497288421	0.4531503

Con esto se concluye las pruebas en el túnel de viento dando lugar al experimento 4 realizando pruebas numéricas con los resultados obtenidos de ambos experimentos.

5.4 Experimento 4:

En el diagrama de bloques que se muestra a continuación se muestra el proceso que se lleva a cabo para poder generar algunos de los modelos de aprendizaje obtenidos:

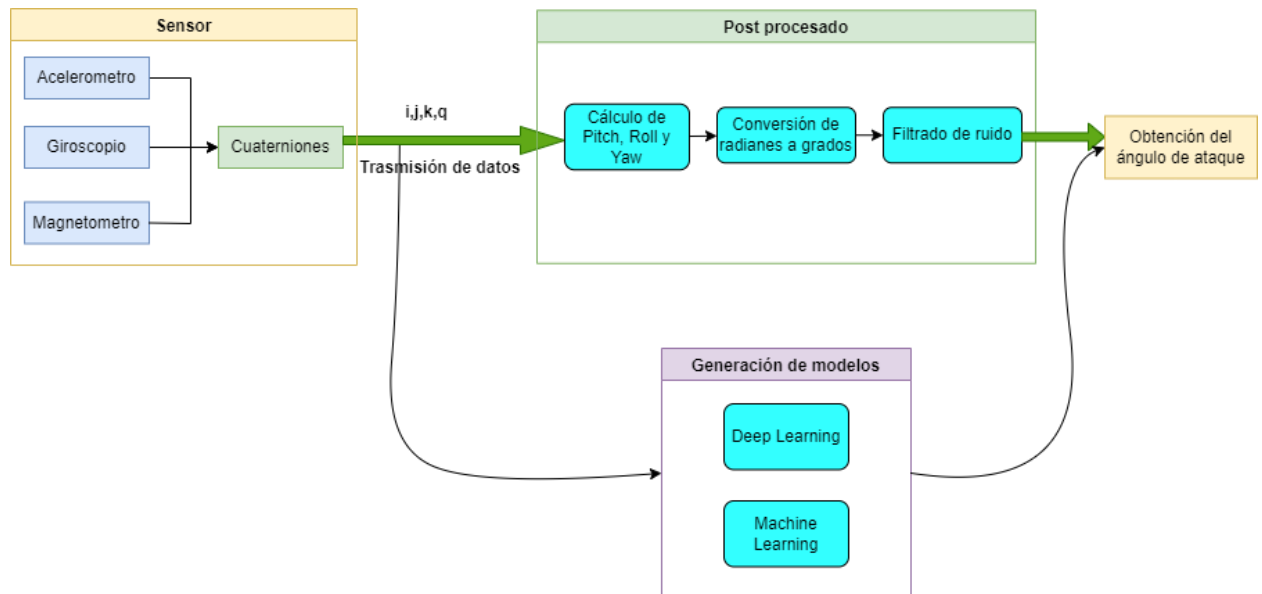


Figura 5-4 Diagrama de bloques del proceso de aprendizaje.

Donde los datos sin procesar de los Cuaterniones, son utilizados para generar la predicción mientras que los datos generados de la obtención del ángulo de ataque son utilizados como etiquetas de predicción. De esta manera, se generaron modelos capaces de realizar la predicción sin necesidad de realizar el proceso convencional de datos.

5.4.1 Machine Learning

Vecinos cercanos

Partición al 100%




Figura 5-5 Partición del 100% del conjunto de datos para 3 vecinos cercanos.

Para esta particion se obtuvo en promedio un valor de 1.5 para el *RMSE*. En las figuras donde se encuentran 2 graficos; el color azul representa el valor real obtenido en las pruebas y las de color rojo representa la estimacion del valor acorde a los vecinos cercanos para cada prueba.

A continuación, se muestran los resultados de los gráficos obtenidos correspondientes a las demás particiones. Para todos los gráficos siguientes el que se representa por color rojo es la prueba estimada mientras que el color azul representa el valor real.

Partición al 80%




Figura 5-6 Partición del 80% del conjunto de datos para 5 vecinos cercanos.

Partición al 60%




Figura 5-7 Partición del 60% del conjunto de datos para 3 vecinos cercanos.

Partición al 40%




Figura 5-8 Partición del 40% del conjunto de datos para 7 vecinos cercanos.

Partición al 10 %




Figura 5-9 Partición del 10% del conjunto de datos para 9 vecinos cercanos.

Evaluación prueba adicional

Y al igual que en las pruebas anteriores en promedio se obtuvo un RMSE aproximado de 1.4.




Figura 5-10 Prueba evaluada fuera del set de datos de entrenamiento y validación.

A continuación, se muestra la tabla con los resultados de cada una de los vecinos cercanos empleados, así como sus particiones correspondientes.

Tabla 12 Métrica de desempeño de k-NN.

Número de vecinos/tamaño partición	100		80		60		40		10		Prueba 1 fuera de test 10	
	R2a	RMSE	R2a	RMSE	R2a	RMSE	R2a	RMSE	R2a	RMSE	R2a	RMSE
1	0.92208	0.97564	0.89356	0.92024	0.88901	0.73912	0.73912	1.0186	0.94572	1.0454	0.73912	1.8087
3	0.94488	0.82058	0.83085	0.94423	0.82676	0.85208	0.85208	0.84951	0.9444	0.89059	0.85208	1.362
5	0.94881	0.79078	0.80105	0.94816	0.79633	0.89204	0.89204	0.8225	0.94289	0.85644	0.89204	1.1635
7	0.95025	0.77954	0.78894	0.94971	0.78721	0.90958	0.90958	0.81022	0.93824	0.84499	0.90958	1.0648
9	0.95065	0.77641	0.78592	0.9501	0.78282	0.91642	0.91642	0.8057	0.9149	0.83491	0.91642	1.0237




Figura 5-11 Grafico comparativo del RMSE para k-NN.

Todas las pruebas anteriores se realizaron con una computadora, la cual cuenta con un procesador Intel i7 a 2.6 GHz. Dando un tiempo de ejecución para cada vecino cercano evaluado, como se muestra en la siguiente tabla:

Tabla 13 Tiempo de ejecución CPU.

Tamaño de prueba	Tiempo de ejecución para cada vecino(minutos)
100	43
80	39
60	35
40	29
10	15

Como se puede observar en la tabla 14, el tiempo de ejecución para un solo vecino cercano es de 43 minutos con todo el set de datos 100%. Es decir, se requirieron 387 minutos para poder evaluar todos los vecinos cercanos propuestos. No obstante, al tener una muestra representativa del set con un 10% de los datos, se obtuvieron valores muy cercanos que, si se hubiese usado una partición del 100% pero con una gran diferencia de tiempo de ejecución, ya que de tardar 43 minutos pasan a ser 15 minutos. Por lo cual, acorde a los resultados

obtenidos para este ensayo se recomienda emplear una partición menor para trabajar con vecinos cercanos.

De igual manera se realizaron las pruebas anteriores, pero con ayuda de una tarjeta gráfica de rtx2070 con memoria de 6 GB. Mejorando aun los tiempos de ejecución de cada una de las pruebas.

Tabla 14 Tiempo de ejecución GPU.

Tamaño de prueba	Tiempo de ejecución para cada vecino(seg)
100	425
80	370
60	232
40	162
10	48

Retomando el caso de una particion del 10%, de tardarse 15 minutos por prueba ahora pasaron a ser 48 seg. Lo cual muestra un avance significativo.

Método Support Vector Machine

Gaussian

Es un modelo para datos no lineales, ajustándose a un promedio ponderado de los datos de entrenamiento. De esta manera se ajusta en mayor medida a nuestra salida. Obteniendo así, un valor de regresión superior a 0.90 lo cual es bastante favorable como se muestra a continuación:




Figura 5-12 Comparativo valor real (grafico color naranja) vs predicho (grafico color azul). Kernel Gaussiano.




Figura 5-13 Grafico de regresión para el Kernel Gaussiano.

Radial Basis Function (RBF)

Cuando los datos no son linealmente separables este kernel es de gran utilidad ya que crea combinaciones no lineales para elevarlas a un espacio superior. Lo cual da un valor de regresión arriba del 0.9.




Figura 5-14 Comparativo valor real (grafico color naranja) vs predicho (grafico color azul). Kernel RBF.




Figura 5-15 Grafico de regresión para el Kernel RBF.

Polynomial

El kernel polynomial traza hiperplanos con grado 2 o polinomios que permiten adaptarse más a los datos. Como se puede observar en la siguiente imagen los valores de regresión y predicción no son lo más exacto posible, por lo cual se puede inferir que este kernel no es el más adecuado de los métodos evaluados.




Figura 5-16 Comparativo valor real vs predicho. Kernel Polynomial.




Figura 5-17 Grafico de regresión para el Kernel Polynomial.

Lineal

El método lineal consiste en trazar hiperplanos lineales para separar los datos además de ser más rápido de entrenar en comparación de los anteriores.




Figura 5-18 Comparativo valor real vs predicho. Kernel Lineal.




Figura 5-19 Grafico de regresión para el Kernel Lineal.

Tabla 15 Métrica de desempeño SVM.

Box Constrain	Gaussian		RBF		Polynomial		Linear	
	R2a	RMSE	R2a	RMSE	R2a	RMSE	R2a	RMSE
0.1	0.8983	1.1139	0.8983	1.0021	0.9022	1.0899	0.8775	1.2234
1	0.9346	0.8896	0.9344	0.9574	0.1643	3.1865	0.8778	1.2221
18	0.9392	0.8615	0.9374	0.8566	-25.5705	17.9675	0.8745	1.2387
48	0.94	0.8556	0.9386	0.8619	-44.8882	23.6124	0.5862	2.2489
80	0.9384	0.8667	0.9381	0.8778	-7.1677	9.9618	0.6549	2.0538
150	0.9190	0.9839	0.9396	0.8868	-35.4413	21.0419	0.6653	2.0227

El método con menor *RMSE* fue el gaussiano con un parámetro de BoxConstrain de 24; dando un valor de *RMSE* de 0.9596 más bajo que los demás.

5.4.2 Deep Learning

Red Neuronal de una capa

Back Propagation

En esta etapa se inició con una red neuronal de una sola capa para observar el comportamiento, obteniendo valores de *RMSE* de 1.1670; considerando que se trata de un perceptrón de una sola capa se tiene una variación de +/- 1 grado de variación respecto al valor real del predicho.




Figura 5-20 Evaluación del conjunto de datos por una red neuronal.

Con un valor de regresión de 0.8930. Así mismo, se tiene en ambos casos 0.8833 para el coeficiente de determinación (R^2) y el coeficiente de determinación ajustado (R^2_a).




Figura 5-21 Grafico de regresión para una red neuronal.




Figura 5-22 Variación del RMSE.

En la gráfica anterior el color naranja representa el valor real, mientras que el grafico en color azul representa el valor predicho por la neurona.

Prueba 1

A partir de los resultados anteriores se decidió evaluar una prueba nueva, fuera de los datos de entrenamiento y validación. Obteniendo así, un valor de $RMSE$ de 1.1670, así como un R^2 y R^2A de 0.8883.




Figura 5-23 Evaluación de la neurona con una prueba nueva fuera del set de datos de entrenamiento y validación.




Figura 5-24 Grafico de regresión para la prueba nueva.

La tasa de aprendizaje “mu” para esta evaluación fue de 0.005 con la que se generó el modelo de aprendizaje.

Por lo tanto, se optó por un nuevo parámetro de “mu” o $\mu=0.001$; dando así el siguiente resultado




Figura 5-25 Evaluación del conjunto de datos por una red neuronal con $\mu=0.001$.

Para este caso el grafico del valor predicho versus el real fue un poco más semejante dando un valor de 0.92056 para el caso de regresión.




Figura 5-26 Grafico de regresión para la nueva neurona $\mu=0.001$.

Y un valor de $RMSE$ de 1.8 con un máximo de 20 épocas, y un $R2$ y $R2a$ de 0.89 en ambos casos.




Figura 5-27 Evaluación de la neurona con prueba 1 fuera del set de datos de entrenamiento y validación $\mu=0.001$.

Prueba 2

De igual manera se evaluó una prueba fuera de los datos de entrenamiento.




Figura 5-28 Evaluación de la neurona con prueba 1 fuera del set de datos de entrenamiento y validación $\mu=0.001$.

Para este caso también se obtuvo un valor de RMSE de 2.14 y la función siguiente:




Figura 5-29 Grafico de regresión para la prueba 2.

Como respuesta al modelo de entrenamiento se obtuvo la siguiente ecuación:

$$y = -8.4546 x_1 + 41.8187 x_2 + 1.4342 x_3 - 0.21577 x_4 - 2.7839 \quad (1)$$

Redes neuronales multicapa

Se evaluaron redes neuronales con 4, 10 y 15 capas ocultas. Todas las pruebas se hicieron con el 100% del dataset, con el 70% para datos de entrenamiento, 15% para pruebas y 15% para validación en todos los siguientes casos. En todos los casos se evaluaron los métodos Levenberg, bayesiano y scaled conjuged gradient.

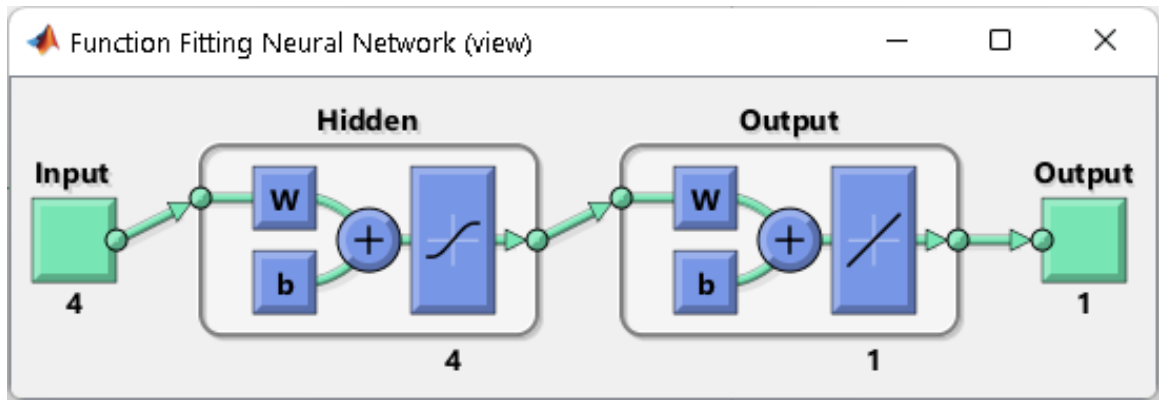


Figura 5-30 Modelo de la red neuronal con 4 entradas, 4 neuronas ocultas y una salida.

En todos los métodos se obtuvo el mismo esquema que se muestra en la Figura anterior.

Redes neuronales artificiales con 4 neuronas ocultas

En todos los 3 métodos evaluados se obtuvo un valor en promedio de 0.95 de regresión. La siguiente Figura muestra los resultados obtenidos del método Levenberg.

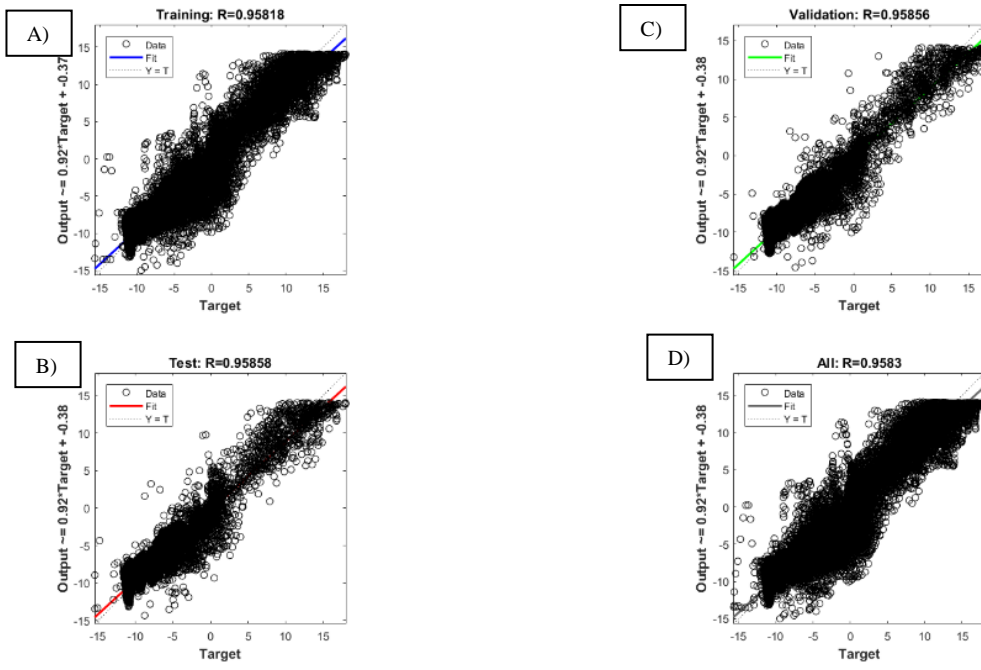


Figura 5-31 Grafico de regresión para una red neuronal de 4 neuronas ocultas.

Así como un valor de RMSE de 0.9923.




Figura 5-32 Variación del RMSE para el modelo de 4 neuronas ocultas.




Figura 5-33 Variación del gradiente, mu y validación respecto al número de épocas.

Como se puede apreciar en la figura anterior el gradiente muestra la tasa de cambio respecto al error mínimo permitido lo cual al llegar a la época 236 tenemos un valor de 0.0253 y una tasa de aprendizaje o “mu” de $1e-7$.

En la siguiente tabla se muestran los resultados de todos los métodos:

Tabla 16 Métrica de desempeño 4 neuronas.

Método/métricas	Regresión	R2	R2a	RMSE
Levenberg-Marquardt	0.9583	0.921	0.921	0.9932
bayesiano regularización	0.95928	0.9202	0.9202	0.97235
scaled conjuged gradient	0.95004	0.9026	0.9026	1.1963

Redes neuronales artificiales con 10 neuronas ocultas

Al igual que el caso anterior de 4 neuronas se evaluaron 10 neuronas ocultas. La media de regresión fue de 0.96. A continuación, se muestran algunos de los resultados obtenidos para el método bayesiano.

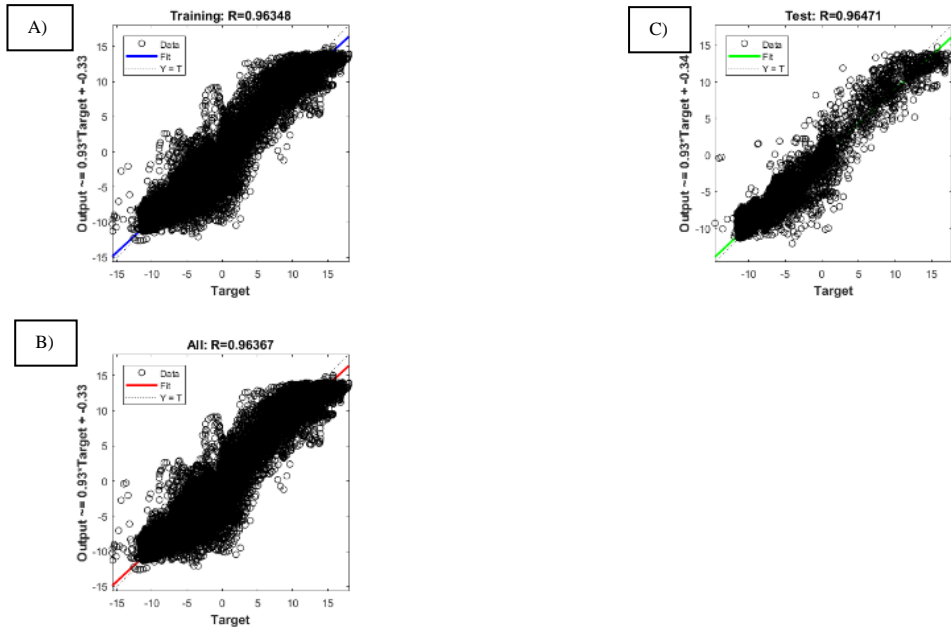


Figura 5-34 Grafico de regresión para una red neuronal de 10 neuronas ocultas.




Figura 5-35 Histograma para una red neuronal de 10 neuronas ocultas.




Figura 5-36 Variación del RMSE para el modelo de 10 neuronas ocultas.

En las figuras anteriores se muestra el histograma y como varia el RMSE respecto al número de épocas.

A continuación, se muestra la tabla con los resultados de todos los métodos evaluados:

Tabla 17 Métrica de desempeño 10 neuronas.

Método/ métrica	Regresión	R2	R2a	RMSE
Levenberg-Marquardt	0.9629	0.9272	0.9272	0.91414
bayesiano regularización	0.96367	0.9287	0.9287	0.87014
scaled conjuged gradient	0.94997	0.9024	0.9024	1.1483

Redes neuronales artificiales con 15 neuronas ocultas

Derivado de los resultados obtenidos de los 2 métodos anteriores, se optó por incrementar el número de neuronas ocultas esperando obtener un resultado más favorable.

A continuación, se muestran los resultados del método Levenberg obteniendo un valor de regresión de 0.96428.

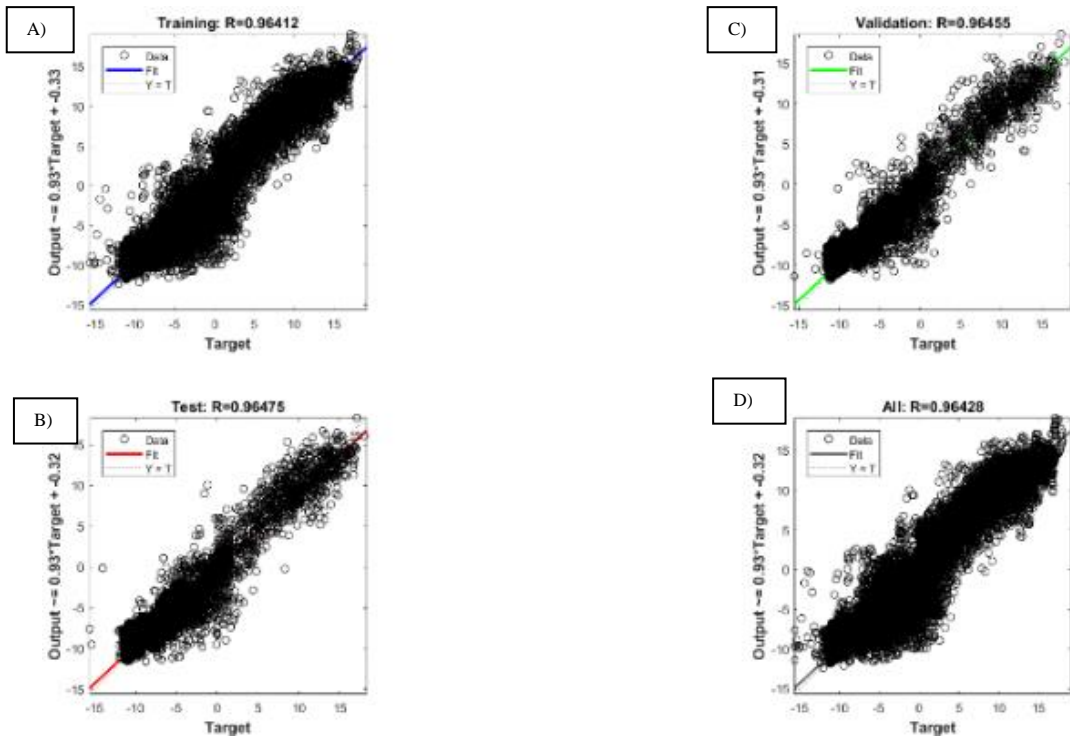


Figura 5-37 Grafico de regresión para una red neuronal de 15 neuronas ocultas.

Así como su histograma y RMSE:




Figura 5-38 Histograma para una red neuronal de 15 neuronas ocultas.




Figura 5-39 Variación del RMSE para el modelo de 15 neuronas ocultas.

También los parámetros de la taza de aprendizaje:




Figura 5-40 Variación del gradiente, mu y validación respecto al número de épocas.

En la siguiente tabla se muestran todos los métodos:

Tabla 18 Métrica de desempeño 15 neuronas.

Método/ métrica	Regresión	R2	R2a	RMSE
Levenberg-Marquardt	0.96428	0.9298	0.9298	0.85202
bayesiano regularización	0.96482	0.9309	0.9309	0.84059
scaled conjugated gradient	0.95261	0.9075	0.9075	1.1319

En la siguiente Figura se muestra el modelo de la red neuronal con 4 entradas y 15 neuronas ocultas.

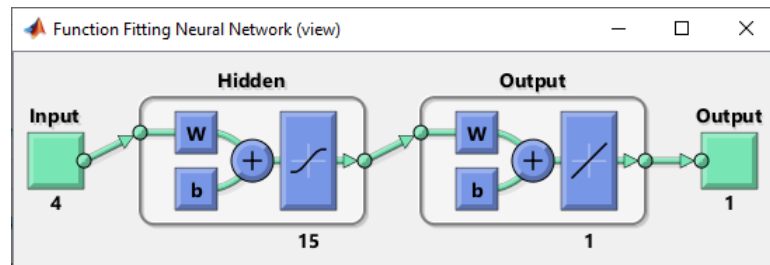


Figura 5-41 Modelo de la red neuronal con 4 entradas, 15 neuronas ocultas y una salida.

Y, por último, se muestra una tabla de los métodos con sus respectivas neuronas ocultas:

Tabla 19 Métrica de desempeño en conjunto de 4, 10 y 15 neuronas.

Método	Levenberg-Marquardt		Bayesiano regularización		Scaled conjugated gradient	
	R2a	RMSE	R2a	RMSE	R2a	RMSE
4	0.921	0.9932	0.9202	0.97235	0.9026	1.1963
10	0.9272	0.91414	0.9287	0.87014	0.9024	1.1483
15	0.9298	0.85202	0.9309	0.84059	0.9075	1.1319

5.5 Estabilidad longitudinal

Como se mencionó con anterioridad, se inducía una perturbación en el flujo de aire de tal manera que desestabilizara la aeronave, con el fin de poder observar el tiempo de recuperación de la misma y si ésta era capaz de hacerlo por sí misma.




Figura 5-42 Tiempo de recuperación de la aeronave.

En la Figura anterior, se observa la respuesta de la aeronave ante una perturbación y como varía respecto al tiempo, dado en segundos.

Para poder determinar la estabilidad de una aeronave, se puede realizar por medio de la ecuación de la cuartica de estabilidad dimensionales o adimensionales o también conocida como ecuación característica, tal que, determinan si es estable o no, como se comportaría ante perturbaciones y el tiempo de recuperación de la misma.

$$A\delta\lambda^4 + B\delta\lambda^3 + C\delta\lambda^2 + D\delta\lambda^1 + E\delta = 0 \quad (2)$$




Figura 5-43 Variación del ángulo de ataque respecto al tiempo por las ecuaciones de la cuartica de estabilidad.[19].

Como se puede observar en la figura anterior, por medio de dichas ecuaciones se puede observar el ángulo de ataque dado en grados, respecto al tiempo. Así como, la velocidad angular correspondiente. Además, de determinar el tiempo de la transición hasta su estado estable.

Sin embargo, para poder determinarlas se requiere de cálculos complejos para lo cual se obtienen resultados similares por medio de sistemas de predicción basados en IA haciendo uso de sensores inerciales.

Los resultados obtenidos tanto por las mediciones de Cuaterniones y la predicción de las técnicas de IA, son bastante semejantes a los resultados obtenidos utilizando la cuartica de estabilidad.




Figura 5-44 Predicción del modelo generado por técnicas de IA.

Se puede inferir en base a los resultados, que el tiempo de recuperación de la aeronave es en promedio de 6.85 segundos para una velocidad de 5 m/s y de 4.15 segundos para 11.5 m/s y 19.5 m/s.

Tabla 20 Tiempo de recuperación de la aeronave en segundos.

No. prueba	1	2	3
1	12	4	4
2	7	4	4
3	9	5	3
4	6	4	4
5	7	6	6
6	4	5	4
7	8	4	4
8	7	4	6
9	14	5	7
10	6	4	3
11	5	4	4
12	5	3	3
13	7	7	6
14	4	4	4
15	4	3	5
16	6	3	3
17	6	5	4
18	6	4	3
19	8	3	2
20	6	3	3
Tiempo promedio	6.85	4.2	4.1

En la figura anterior, se muestran los resultados del tiempo de estabilización de la aeronave para cada sección de velocidad y el número de prueba realizada.

A continuación, se muestra la tabla general de los métodos empleados y su representación gráfica correspondiente, así como la métrica de desempeño para cada una:

Tabla 21 Resultados generales de los métodos evaluados.

Método	Regresión	R2a	RMSE
Back propagation 1 (mu=0.005)	0.893	0.8833	1.167
Back propagation-prueba fuera de test (mu=0.005)	0.73755	0.8883	1.167
Back propagation 1 (mu=0.001)	0.92056	0.89	1.8
back propagation-prueba fuera de test (mu=0.001)	0.89893	0.899	2.14
Levenberg-Marquardt-4	0.9583	0.921	0.9932
Bayesiano regularización-4	0.95928	0.9202	0.97235
scaled conjuged gradient-4	0.95004	0.9026	1.1963
Levenberg-Marquardt-10	0.9629	0.9272	0.91414
Bayesiano regularización-10	0.96367	0.9287	0.87014
Scaled conjuged gradient-10	0.94997	0.9024	1.1483
Levenberg-Marquardt-15	0.96428	0.9298	0.85202
Bayesiano regularización-15	0.96482	0.9309	0.84059
Scaled conjuged gradient-15	0.95261	0.9075	1.1319
Gaussian c=0.1	0.95942	0.8983	1.1139
Gaussian c=1	0.94374	0.9346	0.8896
Gaussian c=18	0.95261	0.9392	0.8615
Gaussian c=48	0.95968	0.94	0.8556
Gaussian c=80	0.94996	0.9384	0.8667
Gaussian c=150	0.94967	0.9190	0.9839
RBF c=0.1	0.94857	0.8983	1.0021
RBF c=1	0.96669	0.9344	0.9574
RBF c=18	0.96829	0.9374	0.8566
RBF c=48	0.96889	0.9386	0.8619
RBF c=80	0.96864	0.9381	0.8778
RBF c=150	0.96948	0.9396	0.8868
Linear c=0.1	0.93802	0.8775	1.2234
Linear c=1	0.93808	0.8778	1.2221
Linear c=18	0.93586	0.8745	1.2387
Linear c=48	0.88674	0.5862	2.2489
Linear c=80	0.92597	0.6549	2.0538
Linear c=150	0.89682	0.6653	2.0227
Polynomial c=0.1	0.95015	0.9022	1.0899

Polynomial c=1	0.86778	0.1643	3.1865
Polynomial c=18	0.06496	-25.5705	17.9675
Polynomial c=48	0.067046	-44.8882	23.6124
Polynomial c=80	-0.10882	-7.1677	9.9618
Polynomial c=150	-0.028303	-35.4413	21.0419
k1 100	0.9735	0.92208	0.97564
k3 100	0.97644	0.94488	0.82058
k5 100	0.97127	0.94881	0.79078
k7 100	0.97318	0.95025	0.77954
k9 100	0.97418	0.95065	0.77641
k1 80	0.97667	0.95356	0.92024
k3 80	0.96579	0.83085	0.94423
k5 80	0.97443	0.80105	0.94816
k7 80	0.96871	0.78894	0.94971
k9 80	0.96722	0.78592	0.9501
k1 60	0.97118	0.88901	0.73912
k3 60	0.97051	0.82676	0.85208
k5 60	0.96945	0.79633	0.89204
k7 60	0.96662	0.78721	0.90958
k9 60	0.97741	0.78282	0.91642
k1 40	0.95957	0.73912	1.0186
k3 40	0.96398	0.85208	0.84951
k5 40	0.95656	0.89204	0.8225
k7 40	0.95991	0.90958	0.81022
k9 40	0.95643	0.91642	0.8057
k1 10	0.95328	0.94572	1.0454
k3 10	0.96593	0.9444	0.89059
k5 10	0.96822	0.94289	0.85644
k7 10	0.96954	0.93824	0.84499
k9 10	0.96694	0.9149	0.83491
k1 test	0.90239	0.73912	1.8087
k3 test	0.89447	0.85208	1.362
k5 test	0.91901	0.89204	1.1635
k7 test	0.88978	0.90958	1.0648
k9 test	0.91022	0.91642	1.0237

Los métodos resaltados son aquellos que tienen mejor desempeño respecto a los demás en cada una de las métricas evaluadas.

Capítulo 6

6 Conclusiones

6.1 Contribuciones

En base a los resultados obtenidos, por medio de sensores inerciales es posible determinar el ángulo de cabeceo de una aeronave y así mismo, describir el comportamiento en comparación de las ecuaciones de la cuartica de estabilidad. Además, la información recabada nos permite dar respuesta a las preguntas de investigación:

- P1. ¿Cuál es el método más eficaz para orientar objetos en el espacio 3D?

Los resultados obtenidos con el método de Cuaterniones presentan una mejor precisión en comparación de los ángulos de Euler debido al bloque cardán. Siempre y cuando se utilicen bajo circunstancias similares. Además de aplicar un post procesamiento a los datos con el fin de atenuar el ruido de la señal.

- P2. ¿Es posible que, mediante el uso de algún algoritmo de IA, se pueda inferir al ángulo de ataque de una aeronave, utilizando los datos de los Cuaterniones de un IMU?

De acuerdo a los resultados obtenidos, se demuestra que es posible determinar el ángulo de ataque de una aeronave empleando técnicas de IA. No obstante, deben tener en cuenta ciertos criterios acorde al método a utilizar bajo condiciones similares a las propuestas en este estudio.

- P3. ¿Cuál es la precisión para detectar la orientación asociado con factores externos?

En la mayoría de los casos se obtuvieron valores de regresión alrededor de 0.90, y con un RMSE aproximado a 1. Al igual que el coeficiente de determinación ajustado arriba del 90%. Sin mencionar que los métodos empleados atenuaban el error producido por las vibraciones de la aeronave.

En base a los resultados obtenidos, algunos métodos ofrecen un coeficiente de determinación ajustado arriba del 90%, así como un porcentaje de efectividad o regresión de

igual manera. Sin embargo, si requieren utilizar vecinos cercanos (k-NN), se recomienda utilizar una partición menor representativa de la población ya que ofrece resultados similares al 100% del set de entrenamiento, pero con un menor tiempo de ejecución y recursos computacionales. No obstante, si lo que requieren es una respuesta rápida lo recomendable es generar un modelo de redes neuronales para evaluarlo de forma instantánea.

6.2 Limitaciones del estudio

Una de las limitaciones del estudio, fue el evaluar solo el cambio del ángulo de cabeceo de la aeronave, debido al sistema de sujeción que limitaban los grados de libertad de la misma. Además, de que no se exploraron más técnicas existentes tales como arboles de decisión para modelos de regresión. Y la exploración de técnicas que permitieran optimizar y mejorar el RMSE, así como la precisión.

6.3 Trabajo futuro

El uso en conjunto de las lecturas del acelerómetro, giroscopio, magnetómetro y Cuaterniones, en valores crudos para evaluar la precisión de modelos basados en IA. Y así poder observar si existe algún cambio respecto a tener solo un conjunto de datos de entrenamiento de Cuaterniones. Así como, evaluar otras técnicas de atenuación de ruido que permitan tener mejores resultados.

También, el desarrollo de un dispositivo que permita obtener las lecturas y post procesamiento de datos de forma integrada y así poder implementarlo en tiempo real dentro de una aeronave.

Bibliografía

- [1] W. Giernacki, “A Nonlinear Filter for Efficient Attitude Estimation of Unmanned Aerial Vehicle (UAV),” 2018.
- [2] M. Mirzaei, I. Hosseini, and H. Makarem, “Attitude determination improvement in accelerated motions for maneuvering underwater vehicles,” *Appl. Ocean Res.*, vol. 104, no. September, p. 102355, 2020, doi: 10.1016/j.apor.2020.102355.
- [3] M. H. Choi, R. Porter, and B. Shirinzadeh, “Comparison of attitude determination methodologies for implementation with 9DOF, low cost inertial measurement unit for autonomous aerial vehicles,” *Int. J. Intell. Mechatronics Robot.*, vol. 3, no. 2, pp. 1–15, 2013, doi: 10.4018/ijimr.2013040101.
- [4] Ammar Assad, W. Khalaf, and I. Chouaib, “Novel Adaptive Fuzzy Extended Kalman Filter for Attitude Estimation in Gps-Denied Environment,” *Gyroscope Navig.*, vol. 10, no. 3, pp. 131–146, 2019, doi: 10.1134/S2075108719030027.
- [5] Y. L. Hsu, J. S. Wang, and C. W. Chang, “A wearable inertial pedestrian navigation system with quaternion-based extended kalman filter for pedestrian localization,” *IEEE Sens. J.*, vol. 17, no. 10, pp. 3193–3206, 2017, doi: 10.1109/JSEN.2017.2679138.
- [6] K. Wen, K. Yu, Y. Li, S. Zhang, and W. Zhang, “A New Quaternion Kalman Filter Based Foot-Mounted IMU and UWB Tightly-Coupled Method for Indoor Pedestrian Navigation,” *IEEE Trans. Veh. Technol.*, vol. 69, no. 4, pp. 4340–4352, 2020, doi: 10.1109/TVT.2020.2974667.
- [7] H. E. Soken and S. ichiro Sakai, “Attitude estimation and magnetometer calibration using reconfigurable TRIAD+filtering approach,” *Aerosp. Sci. Technol.*, vol. 99, p. 105754, 2020, doi: 10.1016/j.ast.2020.105754.
- [8] R. Roubache, M. Benyettou, A. M. Si Mohammed, A. Boudjemai, and A. Bellar, “Impact of the orbital eccentricity on the attitude performance before and after the deorbiting phase for Alsat-1,” *Adv. Sp. Res.*, vol. 53, no. 3, pp. 474–489, 2014, doi: 10.1016/j.asr.2013.11.030.
- [9] B. Xu, L. Wang, S. Li, and J. Zhang, “A Novel Calibration Method of SINS/DVL Integration Navigation System Based on Quaternion,” *IEEE Sens. J.*, vol. 20, no. 16, pp. 9567–9580, 2020, doi: 10.1109/JSEN.2020.2988500.
- [10] C. Jiang, S. Chen, Y. Chen, B. Zhang, Z. Feng, and H. Zhou, “A MEMS IMU De-Noiseing Method Using Long Short Term Memory Recurrent Neural Networks (LSTM-RNN),” 2018, doi: 10.3390/s18103470.
- [11] D. E. C. P. M. Hmcl, “HMC5883L,” 2016.
- [12] Y. S. Suh, “Simple-Structured Quaternion Estimator Separating Inertial and Magnetic Sensor Effects,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 55, no. 6, pp. 2698–2706, 2019, doi: 10.1109/TAES.2019.2901559.
- [13] J. H. Zhang, P. Li, C. C. Jin, W. A. Zhang, and S. Liu, “A novel adaptive kalman filtering approach to human motion tracking with magnetic-inertial sensors,” *IEEE Trans. Ind. Electron.*, vol. 67, no. 10, pp. 8659–8669, 2020, doi: 10.1109/TIE.2019.2946557.
- [14] B. Central, D. E. C. Rica, M. Die-, N. T. Nota, C. J. Del, and S. Ram, “El filtro de kalman,” 2003, [Online]. Available: https://activos.bccr.fi.cr/sitios/bccr/investigacioneseconomicas/DocMetodosCuantitativos/Filtro_de_Kalman.pdf
- [15] K. Saadeddin, M. F. Abdel-hafez, and M. A. Jaradat, “Performance enhancement of low-cost , high-accuracy , state estimation for vehicle collision prevention system using ANFIS,” *Mech. Syst. Signal Process.*, vol. 41, no. 1–2, pp. 239–253, 2013, doi: 10.1016/j.ymsp.2013.06.013.

- [16] H. Ghanbarpourasl, "A new robust quaternion-based initial alignment algorithm for stationary strapdown inertial navigation systems," *Proc. Inst. Mech. Eng. Part G J. Aerosp. Eng.*, vol. 234, no. 12, pp. 1913–1925, 2020, doi: 10.1177/0954410020920473.
- [17] D. Giral, "Implementation of algorithms based on support vector machine (SVM) for electric systems topic review," *Tecnura*, vol. 20, no. 48, pp. 149–170, 2016, doi: 10.14483/udistrital.jour.tecnura.2016.2.a11.
- [18] J. Reed, M. Phillips, A. S. Van Epps, and D. Zwicky, "An Early Look at a Scoping Review of Systematic Review Methodologies in Engineering," *Proc. - Front. Educ. Conf. FIE*, vol. 2020-October, no. 3, 2020, doi: 10.1109/FIE44824.2020.9274232.
- [19] "performance, stability, dynamics and control of airplanes.pdf."