

Cálculo Predictivo de Trayectoria Aplicado a la Navegación Inercial Asistida por GNSS

Martin Escobar

Centro I+D Tecnologías Aeronáuticas
(CITeA) – Fuerza Aérea Argentina
Área Material Río Cuarto – Las
Higueras – Córdoba – Argentina

Grupo Sistemas de Tiempo Real
(GSTR) – Facultad de Ingeniería –
UNRC. Ruta Nacional N° 36 – Km. 601
– Las Higueras – Córdoba – Argentina.
Email: mescobar@ing.unrc.edu.ar.

Damián Primo

Centro I+D Tecnologías Aeronáuticas
(CITeA) – Fuerza Aérea Argentina
Área Material Río Cuarto – Las
Higueras – Córdoba – Argentina

Grupo Sistemas de Tiempo Real
(GSTR) – Facultad de Ingeniería –
UNRC. Ruta Nacional N° 36 – Km. 601
– Las Higueras – Córdoba – Argentina.
Email: dprimo@ing.unrc.edu.ar.

Dario Diaz

Centro I+D Tecnologías Aeronáuticas
(CITeA) – Fuerza Aérea Argentina
Área Material Río Cuarto – Las
Higueras – Córdoba – Argentina

Grupo Sistemas de Tiempo Real
(GSTR) – Facultad de Ingeniería –
UNRC. Ruta Nacional N° 36 – Km. 601
– Las Higueras – Córdoba – Argentina.
Email: ddiaz@ing.unrc.edu.ar.

Diego Badino

Centro I+D Tecnologías Aeronáuticas
(CITeA) – Fuerza Aérea Argentina
Área Material Río Cuarto – Las
Higueras – Córdoba – Argentina

Grupo Sistemas de Tiempo Real
(GSTR) – Facultad de Ingeniería –
UNRC. Ruta Nacional N° 36 – Km. 601
– Las Higueras – Córdoba – Argentina.
Email: dbadino@ing.unrc.edu.ar.

Resumen— El Sistema Global de Navegación Satelital (GNSS, por sus siglas en inglés de Global Navigation Satellite System) cuenta con la ayuda de algunos sistemas de radionavegación complementarios y Sistemas de Navegación Inercial (INS, por sus siglas en inglés de Inertial Navigation System) para obtener mayor precisión y robustez en la navegación y orientación espacial. Cuando las señales de GNSS no están disponibles, el INS puede llenar los vacíos para proporcionar soluciones de navegación continua (posición, velocidad y actitud). Una unidad de medición inercial (IMU, por sus siglas en inglés de Inertial Measurement Unit) generalmente contiene un conjunto de sensores inerciales, por ejemplo, giroscopios y acelerómetros, con el fin de proporcionar mediciones sin procesar que incluyen cambios de velocidad (Δv) y cambios de orientación ($\Delta\theta$) en las tres direcciones de su marco de coordenadas fijo en el cuerpo.

El GNSS y el INS son dos sistemas básicos de navegación. Debido a sus características complementarias en muchos aspectos, el sistema de navegación integrado GNSS / INS es más preciso y confiable que tener solo uno de ellos.

El objetivo de este trabajo es describir la implementación de métodos de integración de datos obtenidos de sensores del tipo COTS integrados en una placa de desarrollo propia utilizando sensores para registrar los parámetros de GNSS e INS para luego ser post-procesados mediante técnicas de Machine Learning.

Abstract—The Global Navigation Satellite System (GNSS) is assisted by some complementary radionavigation systems and Inertial Navigation System (INS) to obtain greater precision and robustness in navigation and spatial orientation. When GNSS signals are not available, INS can fill in the gaps to provide continuous navigation solutions (position, speed and attitude). An Inertial Measurement Unit (IMU) generally contains a set of inertial sensors, for example gyros and accelerometers, in order to provide raw measurements including velocity changes (Δv)

and orientation changes ($\Delta\theta$) in all three directions of its fixed coordinate frame on the body.

GNSS and INS are two basic navigation systems. Due to its complementary features in many respects, the integrated GNSS / INS navigation system is more accurate and reliable than having just one of them.

The objective of this work is to describe the implementation of data integration methods obtained from COTS-type sensors integrated into a proprietary development board using sensors to record GNSS and INS parameters to later be post-processed using Machine Learning techniques.

Keywords— *Embedded System, Machine Learning, COTS, IMU, GNSS, INS*

I. INTRODUCCIÓN

En los últimos años, la navegación y el control de vehículos son importantes y se utilizan ampliamente en aplicaciones civiles y militares. Uno de los sistemas de navegación más utilizados es el GNSS. El GNSS es un sistema de navegación por satélite que proporciona información precisa sobre la posición y la velocidad en todo el mundo. Sin embargo, la capacidad operativa del GNSS se degrada en entornos adversos como áreas urbanas y forestales, donde las señales de GNSS pueden estar parcial o completamente bloqueadas por edificios y follaje denso. Además, un receptor GNSS no proporciona datos de actitud y la frecuencia de actualización es lenta.

El INS es un sistema de sensores diseñado para medir la fuerza específica y las tasas angulares con respecto a un marco inercial para proporcionar velocidad, posición y actitud [1][2]. INS es un sistema autónomo, por lo que es independiente del entorno operativo. Sin embargo, la precisión de un INS disminuye con el tiempo por la acumulación de errores

sistémicos, como errores de alineación inercial y propias del sensor inercial [3].

La integración de GNSS con un INS mejora la calidad e integridad de cada sistema de navegación: el uso de GNSS permite la calibración de los sesgos de los instrumentos inerciales, y el INS puede utilizarse para mejorar el rendimiento de rastreo y readquisición del receptor GNSS.

Para lograr una integración de GNSS/INS, podría realizarse con las ecuaciones de cinemática, pero en este caso se utilizó técnicas de Machine Learning (ML)[6][7]. Los algoritmos de Machine Learning aprenden de los datos de forma iterativa y permiten que las computadoras encuentren diferentes tipos de información oculta sin estar programados explícitamente para hacerlo. En machine learning se trata de que los sistemas aprendan automáticamente. Entendemos esa acción de aprendizaje como la identificación de patrones complejos en millones de datos. Básicamente, la máquina es capaz de predecir comportamientos “aprendiendo” un algoritmo que revisa los datos.

La peculiaridad de sus métodos de predicción, basados en métodos algorítmicos donde la certeza del modelo teórico, deja paso a modelos aproximados basados en la probabilidad y la estadística [11]. Esta forma de modelar la realidad, en base a probabilidades, es la que nuestro cerebro sigue, apoyado por su gran capacidad de cómputo. La certeza absoluta no existe para nuestro cerebro, cada uno de nosotros interpreta la realidad y la ajusta según una determinada probabilidad, la necesaria en el momento.

El Machine Learning se divide en tres áreas principales: aprendizaje supervisado, aprendizaje por refuerzo y aprendizaje no supervisado. Uno de los usos más extendidos del aprendizaje supervisado consiste en hacer predicciones a futuro basadas en comportamientos o características que se han visto en los datos ya almacenados (el histórico de datos). El aprendizaje supervisado permite buscar patrones en datos históricos relacionando todos campos con un campo especial, llamado campo objetivo. [10]

Otro tipo de aprendizaje automático es el aprendizaje por refuerzo. En el aprendizaje por refuerzo, el objetivo es desarrollar un sistema (agente) que mejore su desempeño en función de las interacciones con el entorno. Dado que la información sobre el estado actual del entorno normalmente también incluye una llamada señal de recompensa, se puede pensar en el aprendizaje por refuerzo como un campo relacionado con el aprendizaje supervisado. Sin embargo, en el aprendizaje por refuerzo, esta retroalimentación no es la etiqueta o el valor de verdad fundamental correcto, sino una medida de qué tan bien se midió la acción mediante una función de recompensa. A través de la interacción con el entorno, un agente puede utilizar el aprendizaje por refuerzo para aprender una serie de acciones que maximizan esta recompensa mediante un enfoque exploratorio de prueba y error o una planificación deliberativa. [10]

En el aprendizaje supervisado, se sabe la respuesta correcta de antemano cuando se entrena el modelo, y en el aprendizaje por refuerzo, se define una medida de recompensa por acciones particulares del agente. En el aprendizaje no supervisado, sin embargo, se está tratando con datos sin etiquetar o con datos de estructura desconocida. Utilizando técnicas de aprendizaje no supervisadas, se puede explorar la estructura de los datos para extraer información significativa

sin la guía de una variable de resultado conocida o una función de recompensa. [10]

La técnica de ML aplicada en este caso es de aprendizaje supervisado de series temporales por lo que se usa una red neuronal recurrente (RNN) [9]. El entrenamiento de una red neuronal recurrente debe prolongarse para cada paso temporal, lo que es muy costoso en tiempo de proceso y memoria RAM. Esto se simplifica “desenrollando” la red en tantas capas como pasos temporales o de datos se dispone en la secuencia temporal de entrenamiento, como si fuese una red no recurrente (feed-forward) [10]. Cada capa desenrollada tiene los mismos pesos para acelerar el proceso. Como cuanto más larga sea la secuencia temporal a analizar, mayor será el número de capas debe desenrollar, puede aparecer el problema de desvanecimiento de gradiente (vanishing gradient). Esto se soluciona incorporando capas de tipo LSTM (memoria a largo plazo) que permiten el Backpropagation Through Time (Retropropagación a través del Tiempo) conectando eventos que aparezcan muy alejados en los datos de entrada, sin que su peso se diluya entre las capas.

A. *Sistemas Involucrados:*

1) *Sistema Global de Navegación Satelital - GNSS*

Es un sistema de posicionamiento global basado en tecnología satelital. La técnica fundamental del mismo es medir los rangos entre el receptor y algunos satélites observados simultáneamente. Las posiciones de los satélites se pronostican y transmiten junto con la señal GNSS al usuario. A través de varias posiciones conocidas (de los satélites) y las distancias medidas por el receptor debido a la información enviada por los satélites, se puede determinar la posición del propio receptor. El cambio de posición, que también se puede determinar, se traduce como la velocidad del receptor.

Las aplicaciones más importantes del GNSS son el posicionamiento y la navegación [5]. Aunque el GNSS es un sistema de alta tecnología, todavía existen errores por seis causas principales (sin incluir el error de disponibilidad selectiva): efemérides de satélite, reloj satelital, retardo del grupo ionosférico, retardo del grupo troposférico, errores de medición del receptor y de trayectos múltiples [6].

2) *Sistema de navegación inercial - INS*

El funcionamiento de un sistema de navegación inercial depende de las leyes de la mecánica clásica formuladas por Newton. Con la capacidad de medir la fuerza específica usando un acelerómetro, es posible calcular un cambio en la velocidad y la posición realizando una integración sucesiva de la aceleración con respecto al tiempo [3].

Un sistema INS a menudo consta de tres acelerómetros y tres giroscopios para medir las aceleraciones en tres dimensiones y las tasas de rotación alrededor de tres ejes. El desarrollo de la tecnología MEMS (Micro Sistemas Microelectromecánicos) ha sido un estímulo para ampliar el área de aplicación del INS. Hoy en día, una IMU incluso incluye un giroscopio de tres grados de libertad y un acelerómetro de tres grados de libertad [1][6]. Hay dos tipos de INS: Gimbals INS y strapdown INS.

El sistema strapdown, en el que los sensores se montan directamente en el vehículo y la transformación del sensor al marco de referencia inercial es por computadora en lugar de mecanizada.

En comparación, un sistema de navegación strapdown con respecto a un sistema de navegación gimbals, reduce significativamente el costo y el tamaño del sistema resultante, y no requiere ninguna entrada o dispositivo externo. Sin embargo, debido a errores en la fabricación y los errores de propagación en los cálculos a bordo, un sistema strapdown puede tener un error significativo, especialmente en sistemas de bajo costo.

3) Sistema de integración INS / GNSS

La navegación inercial se basa en principios de la cinemática, a partir de un punto de posición inicial logra calcular posiciones futuras en todo momento, con el conocimiento de la velocidad, orientación y aceleración.

Su funcionamiento continuo brinda la solución de navegación en dispositivos que no poseen datos continuos de GNSS por diferentes causas. Con la adquisición de datos brutos de altitud, rotación, aceleración que permite el cálculo continuo mediante la estimación de la posición y velocidad basado en las mediciones iniciales [3].

Por otro lado, la adquisición de datos de GNSS permite corregir los eventuales errores de deriva que se producen en el INS.

Un sistema es complemento del otro sistema al realizar correcciones y brindar información debido a las causas ya presentadas como falencias de dichos sistemas presentados individualmente [13].

II. METODOLOGIA

El Dispositivo Adquisición de parámetros de vuelo (DAPV) utilizado para la recolección de datos es un desarrollo propio realizado con componentes tipo COTS.

El DAPV está compuesto por un microcontrolador, una IMU Boch de 9 grados de libertad, y un módulo GNSS Quectel. (Fig. 1).



Fig. 1. Dispositivo de Adquisición de parámetros de vuelo (DAPV)

La misma ha permitido realizar numerosos ensayos de diferentes modos de desplazamiento, comenzando con caminatas, vehículos, hasta conseguir ensayar el sistema registrador con aeronaves, bajo la modalidad de Strapdown.

El objetivo principal de esta implementación es acoplar los sistemas de GNSS e IMU para lograr, luego de su post-procesamiento de los datos adquiridos, la de conocer su posición, en los momentos en que, por diferentes motivos, el sistema GNSS no logra contar con la suficiente cantidad de satélites que permita geolocalizarse.

III. DESARROLLO

Para el desarrollo del presente trabajo, se logró contar con un sistema registrador de parámetros, tanto de GNSS como de INS, en el que, procesada la información que individualmente provee cada dispositivo, se almacena para luego extraerse y

realizar un post-procesamiento necesarios para aplicar, identificar y realizar el procedimiento que se va a describir con el objetivo de conocer la ubicación del sistema en la totalidad de su traslación.



Fig. 2. Diagrama del sistema de post-procesamiento de datos.

El diagrama de la Fig. 2 indica el funcionamiento del sistema que se implementa, primero con la adquisición y almacenamiento de los datos adquiridos por el registrador desarrollado, y luego el post-procesamiento de la información almacenada por el registrador.

El sistema de post-procesamiento implementa el cálculo de estimar la posición durante toda la trayectoria analizando, tanto los datos del INS como del GNSS.

El mismo se produce analizando, si existen datos válidos de GNSS, genera nuevo set de datos para actualizar la red neuronal entrenada, pero se toman como referencia los datos válidos de GNSS y en caso de no contar con ellos analiza los datos de INS adquiridos en el mismo instante con la etapa para realizar un cálculo predictivo de posición.

Para entrenar la RNN se necesitó seleccionar un set de datos de entrenamiento y de referencia. Como se necesita predecir los datos de posición espacial (Latitud, Longitud y Altitud) cuando el DAPV pierde estos datos debido a maniobras de la aeronave en la cual el receptor GNSS no logra recibir señal de los satélites; se necesitó datos de posición de referencia YTrain confiables y verdaderos; para ello se realizó un ensayo en una aeronave que tiene un registrador de vuelo propio con una computadora de vuelo que no pierde datos de navegación independientemente de la maniobra que esté efectuando. Entonces se tomaron los datos de posición espacial de la aeronave para generar el YTrain de la RNN.

Para los datos de XTrain se utilizaron los datos de DAPV como: Aceleración y Vector Gravedad en los ejes X, Y, Z, Roll , Pitch y Yaw; con estos datos describe el comportamiento de la aeronave en el espacio y se entrenó la RNN para poder predecir la posición en el espacio (Latitud, Longitud y Altitud).

Teniendo el set de datos, se normalizaron y se configuró la RNN con nueve variables de entrada y tres variables de salida; para luego realizar el proceso de entrenamiento de la misma.

De todo el vuelo solo se tomó una fracción del mismo para realizar el entrenamiento, test y validación; se utilizó 566 puntos de todo el vuelo, cada punto es registrado cada 500ms. El 70% se utilizó para entrenar la RNN, el 15% para test y el 15% para validar. Luego se tomaron otros 433 puntos para realizar una simulación de la RNN y se comparó con el resultado del vuelo real.

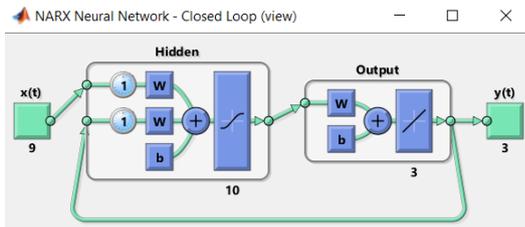


Fig. 3. Red Neuronal Recurrente de una serie temporal multivariable

IV. RESULTADOS

Los resultados que se muestran en el presente trabajo, han sido ensayados en una Aeronave en la que, debido a variaciones en la actitud ante virajes ha conseguido que el sistema registrador montado en la aeronave, pierda datos de GNSS.

En la siguiente gráfica (Figura 4) se puede observar en línea de trazo continua clara (color azul) la trayectoria real de la Aeronave y la línea de trazo continua oscura (color rojo) es la trayectoria que se obtiene de los datos solamente del GNSS.

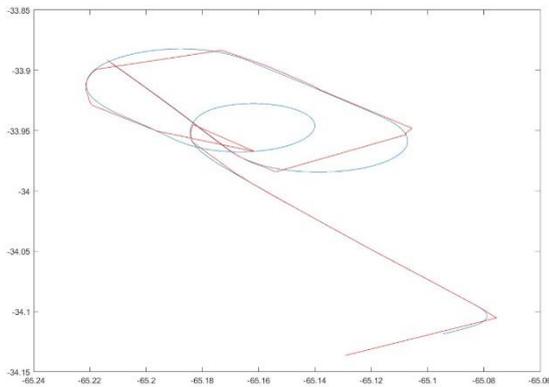


Fig. 4. Trayectoria Real y GNSS

En la Fig. 4, se observa la comparación entre la trayectoria calculada con INS en referencia con la trayectoria real. Para este caso, solo se tuvo en cuenta sólo la posición inicial GNSS para poder marcar el punto de inicio de la trayectoria calculada con el INS.

Puede observarse que la precisión es mejor debido a que dicho sistema no pierde datos en ningún momento, se puede visualizar un error que se produce en la trayectoria entre la trayectoria real y la estimada en los puntos en donde se perdió la señal de GNSS.

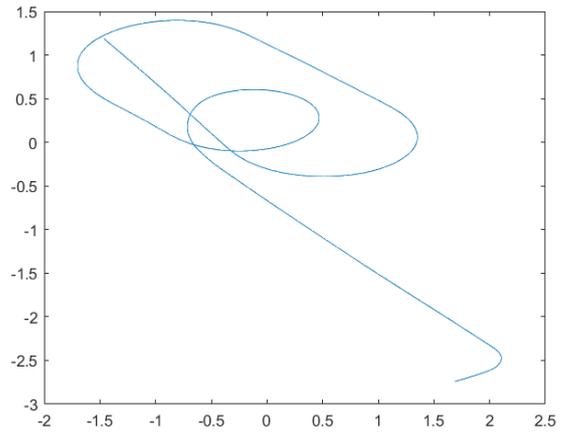


Fig. 5. Trayectoria Real e INS

Uniendo y procesando tanto los datos obtenidos con el sistema GNSS y el INS, se pueden lograr mejores aproximaciones y predicciones de la RNN de la trayectoria real debido a la retroalimentación que poseen un sistema con respecto al otro.

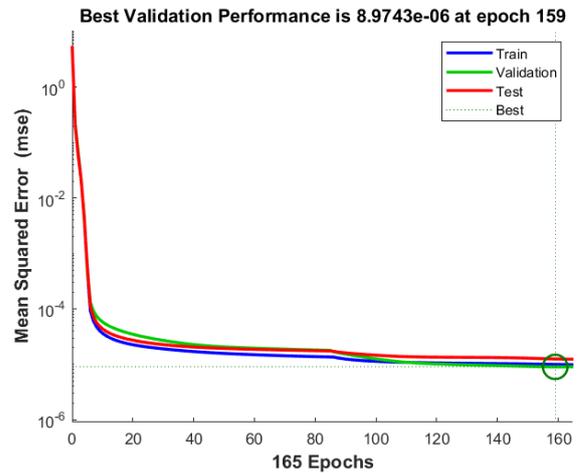


Fig. 6. Performance de la RNN

En la Fig. 6 se puede ver el proceso de performance de la RNN, llegando a un epoch de 159 con un error cuadrático medio de $1.0753e-05$.

En la Fig. 7 se muestra el comportamiento de la RNN, con su salida esperada y el error en cada punto, obteniendo como valor máximo de error ± 0.012 .

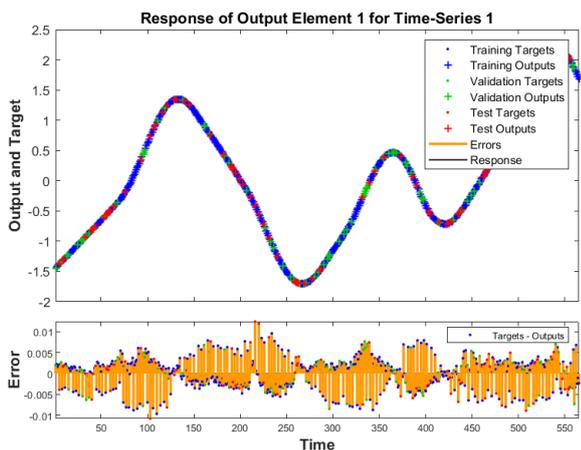


Fig. 7. Respuesta de la Salida y error

En la Fig. 8 se puede ver el Histograma de Error distribuido en formato de campana de Gauss, cuyo Error Medio es -0.00024.

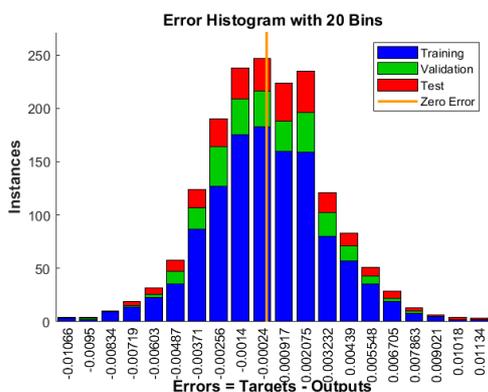


Fig. 8. Error en Entrenamiento, validación y test

Se procedió a realizar una simulación y predicción de 433 puntos a futuro con los datos de la RNN para analizar y comprobar qué tan bien realizaba las estimaciones con respecto a una predicción espacial, en la Fig. 9 se visualiza parte del recorrido inicial en la cual se usó para entrenar la red neuronal (trazo rojo) junto con los puntos predichos por la red (trazo azul).

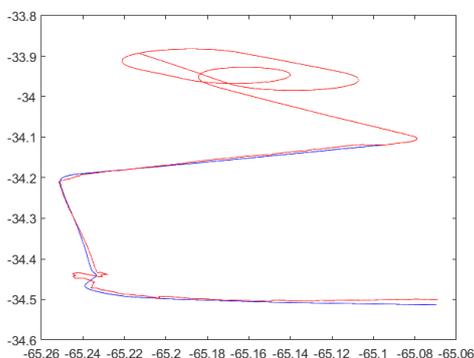


Fig. 9. Recorrido simulado por la RNN

CONCLUSIONES

En este documento, se proporciona una configuración del sistema integrado INS / GNSS para compensar la limitación de usar cada sistema de navegación por separado.

Por medio del dispositivo desarrollado y utilizado en el ensayo, es posible navegar con una precisión relativamente alta cuando se presenta la señal de GNSS y seguir manteniendo un buen seguimiento incluso cuando se pierde la señal de GNSS.

Se puede observar la eficiencia de la RNN para realizar una predicción a futuro teniendo los datos actitud de la aeronave.

Se destaca que los gráficos mostrados anteriormente solo muestran las curvas en el plano horizontal, aunque en altura fue parte de los resultados obtenidos en la generación de las salidas; no se visualizaron para no complejizar los gráficos.

Dado que los sensores de la IMU son algo ruidosos, genera un error acumulativo en las aceleraciones; por lo que se prevé a futuro realizar un pre-procesamiento sobre los datos adquiridos de la IMU, para mejorar los datos que son ingresados a la RNN, de esta manera se podría disminuir el error cuadrático medio en regiones en donde se pierde señal de GNSS y se empieza a utilizar los datos de INS solamente

En el trabajo futuro, esta configuración podría usarse para implementar en un Sistema Embebido con la finalidad de crear un sistema de navegación que realice los procesamientos indicados en este trabajo en tiempo real. Para esto último se requiere un microprocesador con mayores capacidades de cálculo, lo cual forma parte de futuros desarrollos.

REFERENCES

- [1] T. D. Tan, P. Fortier, and H. T. Huynh, "Design, simulation, and performance analysis of an INS/GPS system using parallel kalman filters structure" *REV Journal on Electronics and Communications*, vol. 1, no. 2, 2011.
- [2] D. Titterton, J. Wseton, *Strapdown Inertial Navigation Technology*, 2nd edition IEE Radar, Sonar and Navigation series 17, London, 2004, ch 2, pp. 17-26.
- [3] D. Kubrak, *Etude de l'hybridation d'un récepteur GPS avec des capteurs bas couts pour la navigation personnelle en milieu urbain*, Ph.D. Thesis report, ENST, 2007.
- [4] BNO055 Intelligent 9-axis absolute orientation sensor Disponible en: https://cdnhop.adafruit.com/datasheets/BST_BNO055_DS000_12.pdf
- [5] Daniel G. Maino, Lucas C. Uzal, and Pablo M. Granitto, *Predicción de Sistemas Dinámicos con Redes Neuronales Profundas*, 15th Argentine Symposium on Artificial Intelligence, ASAI 2014
- [6] Besay Montesdeoca Santana, *Estudios de predicción en series temporales de datos meteorológicos utilizando redes neuronales recurrentes*, Tesis de grado; Universidad de las palmas de la Gran Canaria, Escuela de Ingeniería Informática.
- [7] Juan Antonio Perez Ortiz, *Modelo Predictivo basados en redes neuronales recurrentes de tiempo discreto*, Tesis Doctoral, Universidad de Alicante 2002.
- [8] Cuenca L., León J., *Implementación de un sistema de navegación inercial, para mejorar la precisión de posicionamiento de un prototipo gps en una trayectoria dentro de la ESPOCH*, Tesis de Ingeniería, Escuela de Ingeniería en Electrónica, Telecomunicaciones y Redes, Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador, Tech. Report., 2017. p.85.
- [9] Peter Goos, David Meintrup., *Statistics with JMP: Hypothesis Tests, ANOVA and Regression*, *John Wiley*, 2016.
- [10] Sebastian Raschka, *Python Machine Learning*. Birmingham: Packt Publishing Ltd, 2015.
- [11] Steven M. Kay, *Fundamentals of Statistical Signal Processing Estimation Theory*, Signal Processing Series, Volume I, 1st Edition, PTR Prentice Hall, 1993.

- [12] Manar Abu Talib, Sohaib Majzoub, Qassim Nasir, Dina Jamal, A systematic literature review on hardware implementation of artificial intelligence algorithms, *The Journal of Supercomputing*, vol. 77, pp. 1897, 2021.
- [13] Sokolovic, Vlada, Goran Dikic, and Rade Stancic. "Integration of INS, GPS, Magnetometer and Barometer for Improving Accuracy Navigation of the Vehicle." *Defence Science Journal* 63.5 (2013): 451–455. Web.