

# Jornadas de Automática

## Arquitectura de fusión sensorial tolerante a fallos para la estimación de la actitud en UAVs

Rico, R.<sup>a</sup>, Gil-Martínez, M.<sup>a,\*</sup>, Rico-Azagra, J.<sup>a</sup>

<sup>a</sup>Grupo de Ingeniería de Control, Departamento de Ingeniería Eléctrica, Universidad de la Rioja,  
Edificio Departamental - C/San José de Calasanz, 31, 26004, Logroño, España.

**To cite this article:** Rico, R., Gil-Martínez, M., Rico-Azagra, J. 2024. Fault-tolerant sensor fusion architecture for UAV attitude estimation. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10941>

### Resumen

La redundancia de unidades de medida inercial (IMU) dota al sistema de navegación de mayor precisión, confiabilidad y robustez en el control del vehículo aéreo no tripulado (VANT). Así, se presenta una arquitectura de fusión sensorial tolerante a fallos. Las estimaciones de actitud realizadas con acelerómetros y giroscopios triaxiales de tres IMUs, más la obtenida con un modelo del VANT, se fusionan mediante un algoritmo de medias ponderadas. Sus pesos se asignan: (i) en virtud de un sistema de votación que penaliza las discrepancias entre las fuentes de información y (ii) en base a la confiabilidad de las fuentes. Para ello, se han caracterizado los errores estocásticos de estimadores y sensores IMU, incluyendo fenómenos no estacionarios identificados mediante la varianza de Allan. Mas allá de obtener la fusión más precisa, la arquitectura será capaz de eliminar las estimaciones con fallo. Los resultados verifican varios escenarios de fallo de IMU y se comparan las mejoras de fusión con otros algoritmos.

*Palabras clave:* Fusión sensorial, Detección y diagnóstico de fallos, Estimación y filtrado, Aviónica y equipos embarcados.

### Fault-tolerant sensor fusion architecture for UAV attitude estimation

#### Abstract

Redundancy of inertial measurement units (IMU) provides the navigation system with greater accuracy, reliability, and robustness in controlling the unmanned aerial vehicle (UAV). In this context, a fault-tolerant sensor fusion architecture is presented. Attitude estimates obtained with triaxial accelerometers and gyroscopes from three IMUs, as well as that obtained with a model of the UAV, are fused using a weighted averaging algorithm. Their weights are assigned (i) under a voting system that penalizes discrepancies between information sources and (ii) based on the reliability of the sources. Previously, the stochastic errors of IMU estimators and sensors were characterized, including non-stationary phenomena identified by the Allan variance. In addition to achieving the most accurate fusion, the architecture will be able to eliminate erroneous estimates. The results verify various IMU failure scenarios and compare the fusion improvements with other algorithms.

*Keywords:* Sensor data fusion, Fault detection and diagnosis, Estimation and filtering, Avionics and on-board equipments.

## 1. Introducción

El crecimiento exponencial de la industria de los UAVs (*Unmanned Aerial Vehicles*) y sus aplicaciones plantea el reto de incrementar su fiabilidad y seguridad incorporando la tolerancia a fallos (Fourlas and Karras, 2021; Puchalski and

Giernacki, 2022). La robustez y precisión son responsabilidad en último término de la controladora de vuelo del UAV, y en gran medida están condicionados por la confiabilidad de su sistema de navegación inercial (Farrell et al., 2022). En este se fusiona la información de diferentes tipos de sensores (Ye

\*Autor para correspondencia: montse.gil@unirioja.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

et al., 2023) para estimar los seis grados de libertad del movimiento. Y de entre ellos, son especialmente importantes los tres ángulos de orientación (Nazarahari and Rouhani, 2021), ya que estos condicionan el desplazamiento tridimensional.

Para resolver los problemas derivados del empleo de sensores micro-electromecánicos (MEM) de bajo coste en las unidades de medida inercial (IMU), se recurre a la redundancia de dispositivos (Patel and Faruque, 2022). Entonces, el aspecto crucial es la estrategia de combinación óptima de la información redundante para mejorar la robustez del sistema y la precisión en la estimación. Destacaremos, por su simplicidad, la fusión ponderada mediante pesos asignados a cada sensor. Su asignación no es un problema trivial (Gao et al., 2011), apoyándose muchas metodologías en la varianza de los sensores (Huang et al., 2023; Rivera Velazquez et al., 2022). Sin embargo, la diversidad de los procesos estocásticos no estacionarios (Farrell et al., 2022) que afectan a los sensores inerciales requieren su caracterización mediante la varianza de Allan (Jerath et al., 2018). Esta permitirá identificar los sensores más precisos y, por ende, aprovechar esta información en la fusión por ponderación (de Alteriis et al., 2023), que será aplicada en la arquitectura de fusión propuesta en este trabajo.

La redundancia *hardware* es crucial para la detección, diagnóstico y recuperación de fallos (Xu et al., 2023). Así, la técnica de duplicación-comparación se emplea a nivel de sensor (medidas en crudo) y a nivel del estimador (información de navegación), para detectar e identificar fallos *hardware* y *software* (Bader et al., 2017). Uno de los mecanismos de detección, que paralelamente realiza la fusión, consiste en el empleo de un sistema de votación. Este calcula las discrepancias entre las fuentes de información, que operan en paralelo, para asignarles los pesos de combinación. Frente al uso de un umbral duro para cuantificar la discrepancia como cero o uno, el empleo de umbrales blandos (zona difusa) arroja mejores prestaciones en la detección de errores (Latif-Shabgahi, 2004). Existe entonces una zona difusa de discrepancia donde el indicador de concordancia entrega valores entre cero y uno. Este sistema de votación, al que se añade la información del modelo y funcionalidades de diagnóstico y recuperación de errores, se aplica a un UAV en (Hamadi et al., 2022).

En este marco, el presente trabajo utiliza una controladora de vuelo con tres IMUs dispuestas de forma coaxial (Rico et al., 2022). La información de los acelerómetros y giroscopios de cada IMU se fusionan empleando estimadores, obteniéndose de forma redundante la actitud y la velocidad de rotación del UAV. Las tres estimaciones, junto a la que proviene de un modelo analítico del comportamiento del drone (Rico-Azagra et al., 2021), se derivan a una arquitectura de fusión tolerante a fallos. Su elemento central es el sistema de votación que utiliza una modificación de la estrategia propuesta en (Latif-Shabgahi, 2004). Como novedad, los parámetros que definen la zona de umbral blando se asignan en base a un estudio de la varianza de las estimaciones. De este modo, además de detectar errores, ajusta unos pesos de ponderación que premian la estimación/IMU menos ruidosa. No obstante, esta ponderación no será suficiente para que predomine claramente dicha estimación. Para ello, los pesos incorporarán la inversa de los parámetros estadísticos que caracterizan cada sensor. De este modo, resultará una fusión sensorial que de forma natural sobrevalora la estimación más precisa, y a la vez

será capaz de eliminar las estimaciones con fallo. Se prevén tres escenarios de fallo típicos (rotura, derivas y señales aleatorias en los datos IMU) a los que la arquitectura propuesta será capaz de sobreponerse. Todo ello mejorará la fiabilidad y la precisión del sistema de estimación de actitud a bordo de una controladora de vuelo.

La exposición del trabajo se estructura como sigue. La Sección 2 describe la controladora de vuelo, caracterizando los sensores IMU. La Sección 3 recoge la estimación redundante y detalla la arquitectura con los algoritmos de fusión y detección de fallos. La Sección 4 analiza los resultados de simulación frente a varios escenarios de fallo y realiza una comparativa de la fusión sensorial respecto a otros algoritmos.

## 2. Controladora de vuelo: sensores inerciales

Se emplea la controladora de vuelo en la Figura 1, que es de diseño propio (Rico et al., 2022) y presenta unas prestaciones similares a las existentes actualmente en el mercado para UAVs de uso profesional. En concreto, su microcontrolador STM32F767 puede trabajar hasta 216 MHz y presenta una arquitectura Cortex-M7 que incorpora una unidad de coma flotante de doble precisión. Esto es crucial para la implementación de los algoritmos de fusión sensorial con estimación del estado, y los relacionados con la tolerancia a fallos. Destacaremos la redundancia de su paquete de sensores: incorpora cuatro IMUs ( $2 \times$  ICM20689, ICM20602, MPU6000) de grado comercial y dispuestas coaxialmente, dos magnetómetros (IST8310) y dos barómetros (MS5611). La frecuencia de muestreo del sistema es de 1kHz, con la que se obtienen medidas de acelerómetros y giroscopios de las IMUs, mientras que la fusión sensorial tolerante a fallos entrega la estimación de ángulos con una frecuencia de 0,5 kHz y de velocidades con una frecuencia de 1 kHz.




Figura 1: Controladora de vuelo URpilot.

En este trabajo se emplean tres IMUs: IMU1 (ICM20689), IMU2 (ICM20602) e IMU3 (MPU6000). Cada una aporta un giroscopio y un acelerómetro, ambos tri-axiales, que miden velocidades angulares y aceleraciones lineales, respectivamente, referidas a tres ejes ortogonales solidarios al cuerpo. Las medidas son procesadas con filtros digitales paso-bajo con frecuencia de corte de 100 Hz para limitar el ruido estocástico asociado a los sensores MEM de bajo coste.

Para caracterizar y modelar los sensores se han realizado diferentes ensayos. Además de identificar errores deterministas (*bias* constante y desalineaciones), se añaden parámetros relacionados con procesos estocásticos no estacionarios (Farrell et al., 2022). Así, las diferentes fuentes de ruido para gi-

roskopios son: (i) un *bias* variable en el tiempo, descrito por el proceso de primer orden de Gauss-Markov, que se conoce como *bias instability* -  $B$  -; (ii) el *rate random walk* -  $K$  -, que representa inexactitudes en la aceleración angular debido al ruido blanco; y (iii) el *angle random walk* -  $N$  -, que representa inexactitudes en el ángulo debidas al ruido blanco. Unos parámetros similares se utilizan para caracterizar las fuentes de ruido de los acelerómetros, con la diferencia que  $N$  y  $K$  representan inexactitudes aleatorias en la velocidad y la aceleración, designadas como *velocity random walk* y *acceleration random walk*, respectivamente.

Para identificar los citados parámetros ( $N, B, K$ ), se ha utilizado la varianza de Allan  $\sigma^2(\tau)$ , que analiza estadísticamente los datos en ventanas de tiempo  $\tau$  (seg.) diferentes (Jerath et al., 2018). Se realizaron experimentos estáticos de hasta 12h de duración con una frecuencia de almacenamiento de datos de 100Hz, para poder identificar derivas de muy baja frecuencia. La Figura 2 muestra la desviación de Allan  $\sigma(\tau)$  obtenida para cada sensor, pudiéndose comparar su grado de precisión.

Para cada curva de desviación de Allan se ajustan los coeficientes de las diferentes pendientes, relacionados con las fuentes de ruido  $N, B, K$ , de acuerdo a los estándares IEEE para giroscopios (IEEE Std 647-2006, 2006) y acelerómetros (IEEE Std 1293™-2018, 2018). Los parámetros identificados se muestran en la Tabla 1. Estos, además de perfeccionar la simulación de la estimación inercial, se utilizarán en los propios algoritmos de fusión para premiar los sensores más precisos.

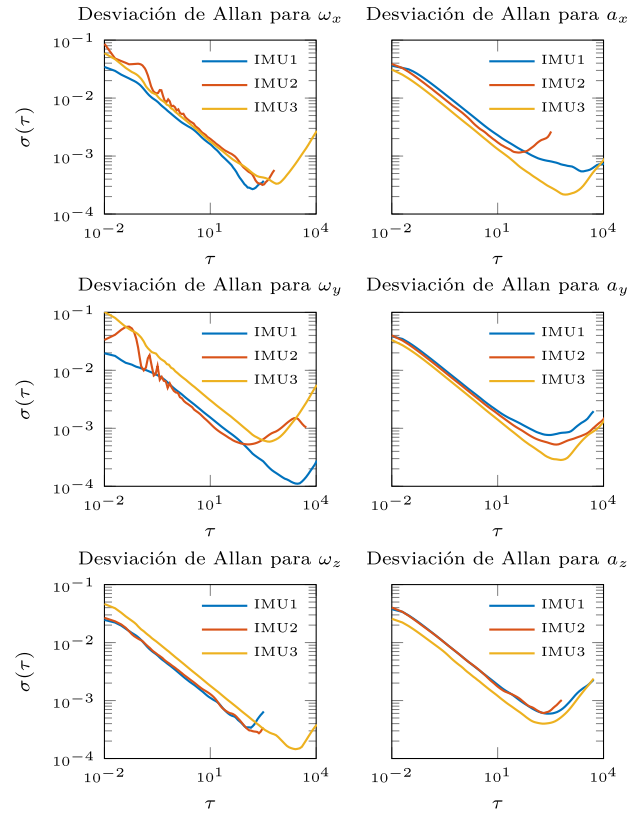


Figura 2: Desviación de Allan de giroscopios triaxiales (rad/s) -primera columna-, y acelerómetros triaxiales (m/s<sup>2</sup>) -segunda columna-.

### 3. Arquitectura de fusión sensorial tolerante a fallos

La Figura 3 muestra la arquitectura propuesta. Consta de tres estimadores independientes, uno por cada IMU, que fusionan las medidas de giroscopios y acelerómetros para estimar el ángulo y la velocidad de rotación del UAV. Estas medidas también son estimadas empleando un modelo dinámico del UAV. Por último, el elemento central del sistema es el *voter*, que recibe la información y fusiona los datos homólogos de forma convenientemente, haciendo que el sistema sea tolerante a fallos y reduzca el ruido en las estimaciones.

#### 3.1. Estimación de la actitud

Pese a la popularidad de los filtros de Kalman, el uso de otros filtros puede ofrecer una buena precisión para la estimación de la orientación con un considerable ahorro de costo computacional. Este resulta relevante en la arquitectura propuesta, donde operarán tres filtros de estimación en paralelo.

Cada filtro empleado es de tipo Madgwick (Madgwick et al., 2011) y opera como se indica en el bloque correspondiente, generando los tres ángulos de Euler ( $\phi, \theta, \psi$ ) y las velocidades de rotación ( $p, q, r$ ).

Se desea evitar el ruido estocástico asociado a los magnetómetros, con el fin de probar de manera más sencilla si la fusión propuesta reduce el ruido de cada estimador que combinará exclusivamente giroscopios y acelerómetros. Así, se estiman con precisión únicamente los ángulos de Euler *roll* ( $\phi$ ) y *pitch* ( $\theta$ ), y las velocidades de rotación ( $p$  y  $q$ ). Y se caracteriza el error estocástico (ruido) contenido en las variables estimadas; su varianza se muestra en la Tabla 2 (el Estimador # utiliza la IMU #).

Tabla 2: Varianza  $\sigma_{i,j}^2$  de los datos de estimación

(i,j)=(fil,col)	$\sigma^2$ -Ángulo (deg) <sup>2</sup>		$\sigma^2$ -Velocidad (deg/s) <sup>2</sup>	
	$\phi$	$\theta$	$p$	$q$
Estimador 1	0,09	0,09	2,80	2,97
Estimador 2	0,10	0,08	4,11	2,34
Estimador 3	0,09	0,07	4,00	5,61

#### 3.2. Modelo del UAV

Este bloque contiene un modelo del sistema de propulsión y el del movimiento del sólido rígido (Rico-Azagra et al., 2021). El sistema de propulsión relaciona primero las acciones de control ( $u$ ) en los cuatro grados de libertad del movimiento (tres ángulos y altura) con las señales de actuación de los motores. Considerando el conjunto motor-hélice, su dinámica y la tensión de la batería ( $V_{bat}$ ), estas se convierten en velocidades de las hélices, pares de rotación y fuerzas de sustentación (Nájera et al., 2023). Después se plantea la dinámica de rotación utilizando el cuaternión velocidad en el sistema de referencia del cuerpo que, debidamente rotado a la tierra e integrado, genera los ángulos de Euler. Entonces, el modelo provee ángulos ( $\phi, \theta, \psi$ ), y velocidades ( $p, q, r$ ).

#### 3.3. Algoritmos de fusión y detección de fallos

El elemento central del sistema de fusión es el *voter*, que recibe la información (tres ángulos y tres velocidades de rotación, o sea un total de  $j = 1, \dots, 6$  variables) de forma redundante  $i = 1, \dots, 4$ : la que estiman los tres filtros Madgwick a partir de cada una de las tres IMUs y la que estima el modelo. Dicha información consiste en un vector :

$$\mathbf{x}_{i=1,\dots,4} = \{x_{i,j=1,\dots,6}\} = \{x_{i,1}, x_{i,2}, x_{i,3}, x_{i,4}, x_{i,5}, x_{i,6}\}. \quad (1)$$

Tabla 1: Caracterización de las fuentes de ruido no estacionarias en los sensores IMU

Coeficiente	$N$ ((rad/s)/√Hz)			$B$ (rad/s)			$K$ ((rad/s)·√Hz)		
	$\omega_x$	$\omega_y$	$\omega_z$	$\omega_x$	$\omega_y$	$\omega_z$	$\omega_x$	$\omega_y$	$\omega_z$
Giroscopio tri-axial									
IMU ICM20689	$4,7e-3$	$5,1e-3$	$3,4e-3$	$4,3e-4$	$1,6e-4$	$5,2e-4$	$3,5e-5$	$3,3e-6$	$4,9e-5$
IMU ICM20602	$7,0e-3$	$4,0e-3$	$3,7e-3$	$3,3e-4$	$7,9e-4$	$4,6e-4$	$3,1e-5$	$5,5e-5$	$3,2e-5$
IMU MPU6000	$5,7e-3$	$9,6e-3$	$5,7e-3$	$5,0e-4$	$8,9e-4$	$2,1e-4$	$1,9e-5$	$4,0e-5$	$4,4e-6$

Coeficiente	$N$ ((m/s <sup>2</sup> )/√Hz)			$B$ (m/s <sup>2</sup> )			$K$ ((m/s <sup>2</sup> )·√Hz)		
	$a_x$	$a_y$	$a_z$	$a_x$	$a_y$	$a_z$	$a_x$	$a_y$	$a_z$
Acelerómetro tri-axial									
IMU ICM20689	$6,8e-3$	$6,0e-3$	$5,9e-3$	$8,2e-4$	$1,2e-3$	$8,9e-4$	$1,2e-5$	$4,2e-5$	$5,3e-5$
IMU ICM20602	$5,4e-3$	$5,3e-3$	$5,6e-3$	$1,7e-3$	$7,9e-4$	$9,1e-4$	$2,5e-4$	$2,4e-5$	$6,6e-5$
IMU MPU6000	$4,1e-3$	$4,5e-3$	$3,7e-3$	$3,2e-4$	$4,4e-4$	$6,0e-4$	$1,0e-5$	$2,1e-5$	$3,5e-5$

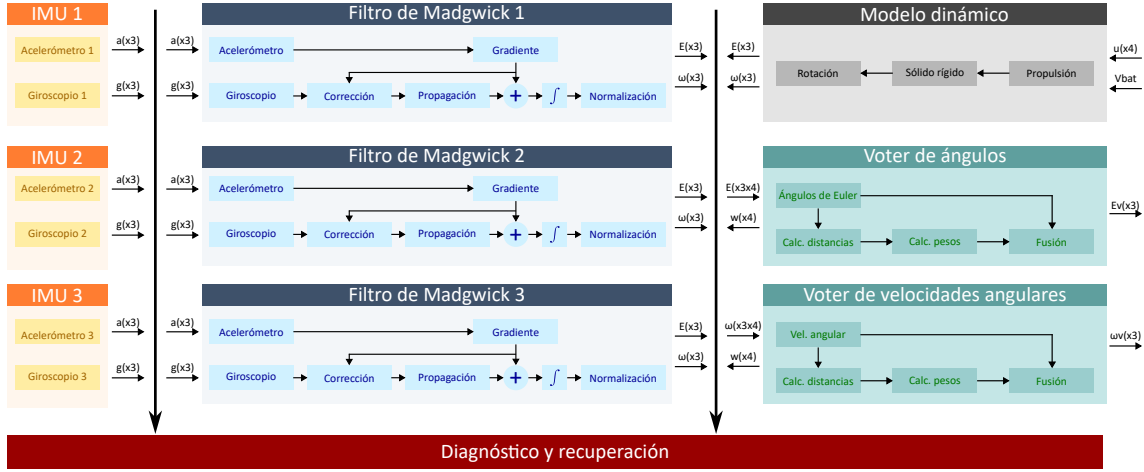


Figura 3: Arquitectura de fusión sensorial tolerante a fallos

Se realizará una fusión de datos homólogos  $j$  de estimación  $x_{\{i=1,\dots,4;j\}}$ , utilizando un sistema de votación de medias ponderadas que promueve las mejores estimaciones y activa las rutinas de detección de errores y de recuperación.

Primeramente, se comparan dos a dos, las estimaciones provenientes de fuentes diferentes. Para ello, se calcula la distancia entre los elementos de dos vectores de información

$$d_{ik} = |x_k - x_i| \quad \text{s.t.} \quad k \neq i. \quad (2)$$

Sus elementos  $d_{ik,j}$  reflejan la diferencia en la estimación de la variable homóloga  $j$  entre el estimador  $i$  y el  $k$ , evidenciando posibles discrepancias. Al existir cuatro estimaciones para la variable  $j$ , se calcularán tres distancias  $d_{ik,j}$  que se utilizarán para asignar un peso  $w_{ij}$  a cada estimación  $x_{i,j}$ , en un segundo paso del algoritmo.

Entonces, al estimador  $i$  se le asignará el vector de pesos

$$w_i = \{w_{i,j}\} = \{w_{i,1}, w_{i,2}, w_{i,3}, w_{i,4}, w_{i,5}, w_{i,6}\}, \quad (3)$$

tal que  $w_{i,j}$  ponderará la estimación de la variable  $j$  proveniente del estimador  $i$  en función de su concordancia con los valores estimados para dicha variable por los restantes estimadores  $k \neq i$ . En muchos sistemas de votación se usa un umbral duro para evaluar la discrepancia, tal que cuando  $d_{ik,j}$  supera dicho umbral el peso asignado  $w_{i,j}$  es cero. En (Latif-Shabgahi, 2004) se establece un umbral blando para cuantificar la discrepancia  $d_{ik,j}$  de acuerdo a

$$s_{ik,j} = \begin{cases} 1 & \text{si } d_{ik,j} \leq a_j \\ \left(\frac{n_j}{n_j-1}\right) \left(1 - \frac{d_{ik,j}}{n_j a_j}\right) & \text{si } a_j < d_{ik,j} < n_j a_j \\ 0 & \text{si } d_{ik,j} \geq n_j a_j \end{cases} \quad (4)$$

donde  $a_j$  sería el valor umbral duro clásico por debajo del cual la estimación es plenamente elegible y  $n_j$  es un segundo parámetro configurable, tal que  $n_j a_j$  fija un segundo umbral para tener en cuenta un porcentaje de la estimación o desestimarla totalmente y detectar un fallo. En nuestro caso se elige el valor  $a_j = 3 \min_{i=1}^3 \sigma_{i,j}$ , siendo  $\sigma_{i,j}$  la desviación estándar de la estimación de la variable  $j$  del estimador  $i$ , reflejada en la Tabla 2. De este modo se premia al estimador con menor varianza, y eligiendo tres veces su desviación estándar se asegura que el 99.7% de sus estimaciones sean plenamente consideradas. Sobre el valor de  $n_j$ , (Latif-Shabgahi, 2004) concluye que valores altos aumentan la probabilidad de detectar fallo cuando las discrepancias son pequeñas, mientras que valores pequeños favorecen la probabilidad de detectar fallo cuando las discrepancias son grandes. Aquí, considerando que el valor asignado a  $a_j$  esta relacionado con la estimación de varianza mínima,  $n_j$  debe tomar un valor  $\gg 1$  para garantizar que la medida estimada no quede en ningún caso supeditada solo a la información del modelo, sino que al menos las mediciones de una de las IMUs participen en la estimación. En concreto, se ha utilizado  $n_j = 5$  para las  $j = 1, \dots, 6$  variables estimadas.

Denominaremos a  $s_{ik,j}$  (4) el indicador de concordancia entre el estimador  $i$  y el estimador  $k$  de la variable  $j$ . Considerando las concordancias entre el estimador  $i$  y el resto de estimadores  $k \neq i$ , (Latif-Shabgahi, 2004) calcula el peso del estimador  $i$  tal que

$$w_{i,j} = \frac{1}{3} \sum_{k=1, k \neq i}^4 s_{ik,j}. \quad (5)$$

Pese a los buenos resultados en caso de fallo, la ponderación (5) de las estimaciones obtendrá una media ponderada peor que la mejor de las estimaciones, pero mejor que la peor de las estimaciones. Por tanto, no es el mejor algoritmo de fusión si no hay fallo. Como solución, los pesos se asignarán no solo en función de las discrepancias  $d_{ik,j}$ , pensadas para detectar fallos, sino también considerando qué estimador es el más preciso. Puesto que los tres filtros Madgwick son idénticos, la precisión del estimador viene condicionada por la precisión de las IMUs, que se caracterizaron con los parámetros  $N, B, K$  de la Tabla 1. Así, de forma análoga a (de Alteriis et al., 2023), la inversa de dichos parámetros se tendrá en cuenta como peso de ponderación, con las debidas adaptaciones ya que estamos manejando las variables estimadas y no las variables IMU. De este modo, para la estimación de la velocidad de rotación triaxial ( $j = 4, 5, 6$ ) se propone usar para  $N_{i,j}, B_{i,j}$ , los coeficientes  $N$  y  $B$  de la Tabla 1 asignados a los giroscopios. Y para la estimación de los ángulos de Euler ( $j = 1, 2, 3$ ), como intervienen acelerómetros y giroscopios en el filtro Madgwick, se propone multiplicar los coeficientes homólogos  $N$  de giroscopo y acelerómetro de la Tabla 1, por un lado, y los coeficientes homólogos  $B$  de giroscopo y acelerómetro, por otro, para finalmente obtener los  $N_{i,j}, B_{i,j}$  correspondientes. Los efectos recogidos por el parámetro  $K$  no se consideran significativos para los intervalos de respuesta en la gestión de fallos. Todo lo anterior es aplicable para las tres IMUs, es decir,  $i = 1, 2, 3$ , de manera que se ponderará la estimación realizada con la más precisa utilizando la inversa de los coeficientes citados. Por otro lado, para la ponderación de las estimaciones del modelo ( $i = 4$ ) será preciso definir  $N_{4,j=1,\dots,6}, B_{4,j=1,\dots,6}$ . Estos coeficientes se calculan a partir de las  $N_{i,j}$  y  $B_{i,j}$  ya asignadas a las IMUs ( $i = 1, 2, 3$ ), considerando que el modelo es más preciso que la mejor de las IMUs. Así, calcularíamos  $N_{4,j} = 0,75 \min_{i=1,2,3} N_{i,j}$ , y  $B_{4,j} = 0,75 \min_{i=1,2,3} B_{i,j}$ . Teniendo en cuenta toda esta nueva ponderación, se proponen como pesos optimizados respecto a los pesos en (5), los siguientes:

$$w_{i,j}^o = \frac{\sum_{k=1, k \neq i}^4 s_{ik,j}}{3} \frac{1}{N_{i,j} B_{i,j}}. \quad (6)$$

Finalmente, la media ponderada de las estimaciones de la variable  $j$  será

$$\bar{x}_j = \frac{\sum_{i=1}^4 x_{i,j} w_{i,j}^o}{\sum_{i=1}^4 w_{i,j}^o}. \quad (7)$$

Aunando todas las variables estimadas, se obtiene el vector

$$\bar{\mathbf{x}} = \{\bar{x}_j\} = \{\bar{x}_1, \bar{x}_2, \bar{x}_3, \bar{x}_4, \bar{x}_5, \bar{x}_6\}. \quad (8)$$

Al fusionar cuatro estimaciones, el sistema será tolerante a un máximo de dos fallos simultáneos. Cuando se produce un fallo *hardware* de una IMU, o un fallo *software* en un filtro Madgwick, el valor tomado por el indicador de concordancia  $s_{ik,j}$  excluirá la información de esa fuente en el resultado (7). Así, el propio algoritmo ejecuta un mecanismo simple de recuperación. Funciones más complejas de diagnóstico y recuperación quedan fuera del alcance de este trabajo.

#### 4. Resultados

La arquitectura de navegación propuesta se simula con herramientas MATLAB-Simulink®, para verificar su desem-

peño. Se simula un control en el que  $\phi$  y  $\theta$  deben seguir cambios escalón de  $\pm 40^\circ$ . Se prueban tres escenarios de fallo de la IMU 1, todos entre los instantes  $t = 20s$  y  $t = 40s$ , periodo en el que el *voter* desestima las señales del estimador 1 en la fusión, y con el resto estima los ángulos,  $\phi$  y  $\theta$ , y velocidades,  $p$  y  $q$ , correctos, que permiten efectuar el control de ángulo esperado. Así, la Figura 4(a) muestra el Escenario 1 que simula la rotura total (valores cero en todos los sensores de la IMU1) en el periodo de fallo. La Figura 4(b) muestra el Escenario 2 con una deriva en el giroscopio  $p$  en el periodo de fallo. Y la Figura 4(c) muestra el Escenario 3 donde se simula un *random walk* (RW); en el intervalo de fallo, la fuente de ruido que integrada genera el RW tiene media cero y varianza  $5 \text{ (m/s}^2\text{)}^2$  para los acelerómetros y  $8000 \text{ (deg/s)}^2$  para los giroscopios.

En otro experimento y en ausencia de fallo, las estimaciones de fusión logradas con el algoritmo de media ponderada propuesto (A0), que utiliza los pesos (6), se comparan con otros dos algoritmos: un algoritmo de media aritmética (A1) con pesos  $w_i = 1/3$  sin modelo y que no emplea ningún sistema de votación; y el algoritmo de Latif-Hamadi (A2), que utiliza los pesos (5) acompañados de un sistema de votación. La Tabla 3 muestra la varianza de ángulos y velocidades estimadas, y la Figura 4(d) -subplot inferior- ilustra la fusión para la velocidad  $p$ . Puede concluirse que A2, siendo tolerante a fallos, realiza una fusión sensorial mejor que A1, gracias a la incorporación del modelo (Hamadi et al., 2022) que no presenta ruido. Sin modelo (Latif-Shabgahi, 2004), A2 sería peor que A1, quien, por contra, carece de la capacidad para detectar fallos, por lo que en cualquier caso un *voter* mejora las prestaciones. Por último, el algoritmo propuesto A0 mejora a los dos anteriores. El subplot superior de la Figura 4(d) detalla cómo el *voter* fusiona los estimadores, y entrega una medida más precisa que la estimada con cualquiera de las IMUs gracias al modelo; en ausencia de este, la salida igualaría a la mejor de las IMUs gracias a la ponderación mejorada (6). Por tanto, la arquitectura propuesta confiere la fusión sensorial más precisa y robusta, augurándose unos buenos resultados de cara a su implementación en la controladora de vuelo física.

Tabla 3: Comparativa de tres algoritmos

Algoritmo	$\sigma^2$ -Ángulo (deg) <sup>2</sup>		$\sigma^2$ -Vel. Ang. (deg/s) <sup>2</sup>	
	$\phi$	$\theta$	$p$	$q$
A0 (propuesto)	0,07	0,05	1,88	1,38
A1 (media arit.)	0,16	0,10	3,42	3,64
A2 (Latif-Hamadi)	0,10	0,08	2,83	1,97

#### Agradecimientos

Este trabajo ha sido realizado gracias a Ayuda a Grupos de Investigación REGI 22/40 de la Universidad de La Rioja.

#### Referencias

- Bader, K., Lussier, B., Schön, W., 2017. A fault tolerant architecture for data fusion: A real application of kalman filters for mobile robot localization. *Robotics and Autonomous Systems* 88, 11–23. DOI: 10.1016/j.robot.2016.11.015
- de Alteriis, G., Silvestri, A. T., Conte, C., Bottino, V., Caputo, E., Squillace, A., Accardo, D., Schiano Lo Moriello, R., 2023. Innovative fusion strategy for mems redundant-imu exploiting custom 3d components †. *Sensors* 23 (5). DOI: 10.3390/s23052508

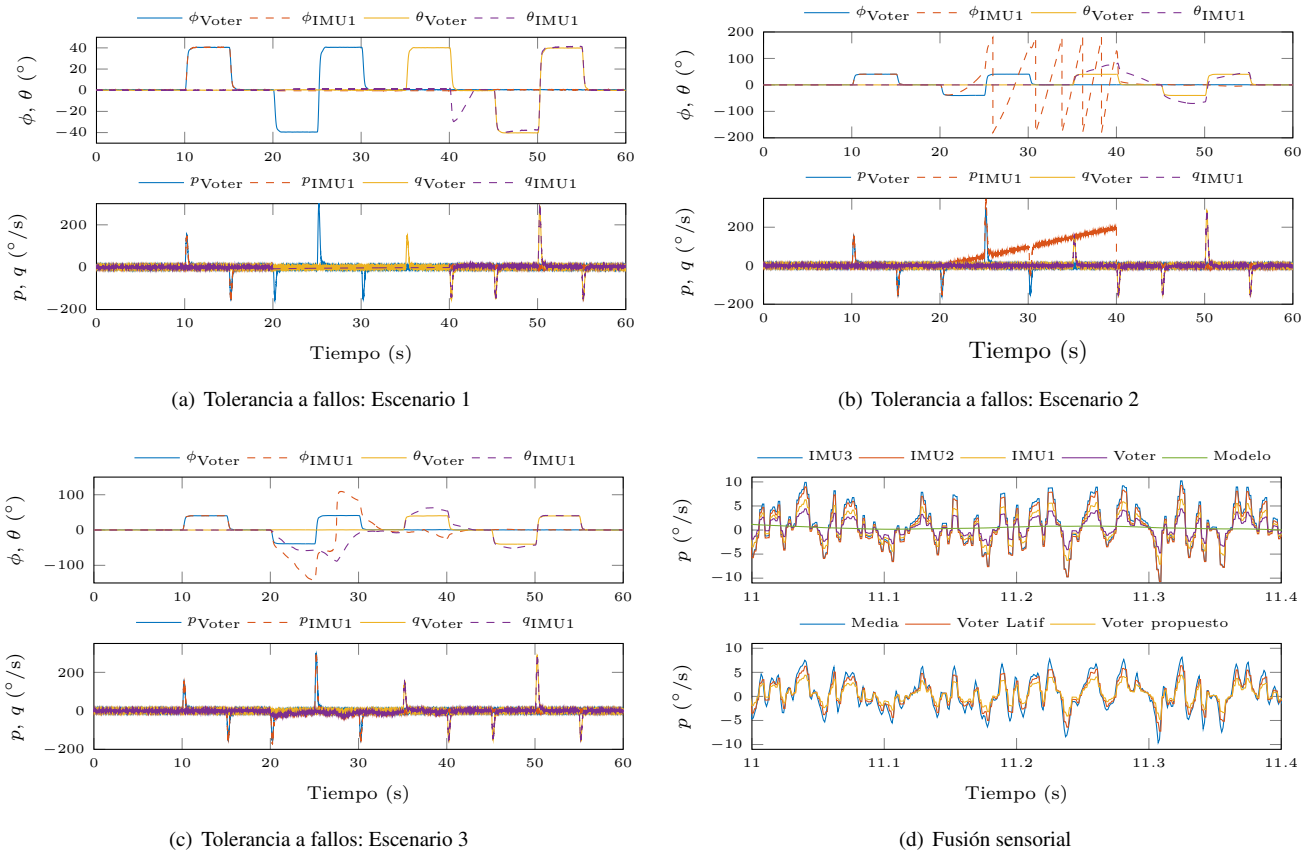


Figura 4: Resultados

Farrell, J. A., Silva, F. O., Rahman, F., Wendel, J., 2022. Inertial measurement unit error modeling tutorial: Inertial navigation system state estimation with real-time sensor calibration. *IEEE Control Systems* 42 (6), 40 – 66.  
DOI: 10.1109/MCS.2022.3209059

Fourlas, G. K., Karras, G. C., 2021. A survey on fault diagnosis and fault-tolerant control methods for unmanned aerial vehicles †. *Machines* 9 (9).  
DOI: 10.3390/machines9090197

Gao, S., Zhong, Y., Li, W., 2011. Random weighting method for multisensor data fusion. *IEEE Sensors Journal* 11 (9), 1955 – 1961.  
DOI: 10.1109/JSEN.2011.2107896

Hamadi, H., Lussier, B., Fantoni, I., Francis, C., 2022. Data fusion fault tolerant strategy for a quadrotor uav under sensors and software faults. *ISA Transactions* 129, 520–539.  
DOI: 10.1016/j.isatra.2022.01.007

Huang, H., Zhang, H., Jiang, L., 2023. An optimal fusion method of multiple inertial measurement units based on measurement noise variance estimation. *IEEE Sensors Journal* 23 (3), 2693 – 2706.  
DOI: 10.1109/JSEN.2022.3229475

IEEE Std 1293™-2018, 2018. IEEE Standard Specification Format Guide and Test Procedure for Linear Single-Axis, Nongyroscopic Accelerometers.

IEEE Std 647-2006, 2006. IEEE Standard Specification Format Guide and Test Procedure for Single-Axis Ring Laser Gyros.

Jerath, K., Brennan, S., Lagoa, C., 2018. Bridging the gap between sensor noise modeling and sensor characterization. *Measurement: Journal of the International Measurement Confederation* 116, 350 – 366.  
DOI: 10.1016/j.measurement.2017.09.012

Latif-Shabgahi, G., 2004. A novel algorithm for weighted average voting used in fault tolerant computing systems. *Microprocessors and Microsystems* 28 (7), 357 – 361.  
DOI: 10.1016/j.micpro.2004.02.006

Madgwick, S. O. H., Harrison, A. J. L., Vaidyanathan, R., 2011. Estimation of IMU and MARG orientation using a gradient descent algorithm. In: 2011 IEEE International Conference on Rehabilitation Robotics. pp. 1–7.  
DOI: 10.1109/ICORR.2011.5975346

Nájera, S., Zambrano, F., Rico, R., Rico-Azagra, J., Gil-Martínez, M., 2023. Improved gyroscopic platform for control engineering labs. In: *Actas de las XLIV Jornadas de Automática*. pp. 259–264.  
DOI: 10.17979/spudc.9788497498609.259

Nazarahari, M., Rouhani, H., 2021. 40 years of sensor fusion for orientation tracking via magnetic and inertial measurement units: Methods, lessons learned, and future challenges. *Information Fusion* 68, 67–84.  
DOI: 10.1016/j.inf.fus.2020.10.018

Patel, U. N., Faruque, I. A., 2022. Multi-imu based alternate navigation frameworks: Performance comparison for uas. *IEEE Access* 10, 17565–17577.  
DOI: 10.1109/ACCESS.2022.3144687

Puchalski, R., Giernacki, W., 2022. Uav fault detection methods, state-of-the-art. *Drones* 6 (11).  
DOI: 10.3390/drones6110330

Rico, R., Rico-Azagra, J., Gil-Martínez, M., 2022. Hardware and rtos design of a flight controller for professional applications. *IEEE Access* 10, 134870 – 134883.  
DOI: 10.1109/ACCESS.2022.3232749

Rico-Azagra, J., Gil-Martínez, M., Rico, R., Nájera, S., Elvira, C., 2021. A benchmark for orientation control of a multirotor in a three degrees-of-freedom rotation structure. *RIAI - Revista Iberoamericana de Automática e Informática Industrial* 18 (3), 265–276.  
DOI: 10.4995/riai.2021.14356

Rivera Velazquez, J. M., Latorre, L., Mailly, F., Nouet, P., 2022. A new algorithm for fault tolerance in redundant sensor systems based on real-time variance estimation. *IEEE Sensors Journal* 22 (15), 15410 – 15418.  
DOI: 10.1109/JSEN.2022.3186636

Xu, B., Wen, Z., Zhang, G., Li, P., 2023. A novel fault detection and isolation technology for redundant inertial measurement unit. *IEEE Transactions on Instrumentation and Measurement* 72, 1–11.  
DOI: 10.1109/TIM.2023.3284054

Ye, X., Song, F., Zhang, Z., Zeng, Q., 2023. A review of small uav navigation system based on multisource sensor fusion. *IEEE Sensors Journal* 23 (17), 18926–18948.  
DOI: 10.1109/JSEN.2023.3292427