

# Base de Datos Abierta TRAM-FPV RACING. Secuencias completas de vuelo indoor para el estudio de drones de carreras.

J.M. Castiblanco, S. Garcia-Nieto, D. Ignatyev, X. Blasco

jocasqui@doctor.upv.es, sgnieto@isa.upv.es, D.Ignatyev@cranfield.ac.uk, xblasco@isa.upv.es

Universitat Politècnica de València, Camí de Vera, s/n, 46022 València, Valencia

Universidad de Cranfield, College Rd, Cranfield, Wharley End, Bedford MK43 0AL, Reino Unido.

## Resumen

*Este artículo presenta la base de datos abierta TRAM-FPV Racing, la cual ha sido generada a partir de un conjunto de vuelos indoor realizados con drones de carreras en la Universidad de Cranfield (UK), concretamente en el Flight Arena, uno de los campos de vuelo indoor más grandes del mundo con fines académicos y de investigación. La base de datos que se presenta, incorpora la información de posición y orientación en el espacio de cinco modelos de drones de carreras, empleando un sistema de medición óptico (OMS). Además, incluye las lecturas de los acelerómetros, giroscopios y ángulos de heading registrados por los sensores de las unidades inerciales (IMU). Estas bases de datos, frecuentemente, son empleadas para el desarrollo y el ajuste de los algoritmos de fusión sensorial que incorporan los drones para la estimación de su vector de estados actual. No obstante, su campo de aplicación es muy amplio, pudiendo ser empleadas, por ejemplo, para el desarrollo de los modelos matemáticos no lineales de los drones o para la generación de trayectorias.*

**Palabras clave:** Drones de carreras, Base de datos, Trayectorias, Guiado, Optimización, GPS, IMU, Navegación, Autónomo, Simulación.

## 1. Introducción

Existen múltiples bases de datos que incorporan datos experimentales procedentes de pruebas de vuelo de vehículos autónomos, generalmente denominados como *drones*. La tabla 1 muestra algunos ejemplos de bases de datos.

Tabla 1: Diferentes Bases de datos

Base de datos	BD1	BD2	BD3	BD4	BD5
Tipo de chasis	Quad SY130	Hexa SY300	Quad SY-MAV	Quad SY	Quad SY250
Cantidad de vehículos	1	1	1	1	1
Secuencias de vuelo	186	11	1	4	27
Interior/sensores	IMU/OMS	IMU/OMS	NO	NO	IMU/OMS
Exterior/sensores	GPS	NO	GPS/IMU	GPS/IMU	GPS/IMU
Captura vídeo/imagen	Sí	Sí	Sí	Sí	Sí
Área utilizada	11, 0x11, 0 m <sup>2</sup>	1, 5x1, 0 m <sup>2</sup>	Urbana	Exterior	3, 0x1,5 m <sup>2</sup>

En general, los datos experimentales disponibles se suelen emplear para desarrollar, ajustar y validar

algoritmos de estimación, control, guiado y navegación para este tipo de dispositivos. Las bases de datos citadas, presentan distintas características diferenciadoras, como, por ejemplo, la Blackbird (BD1) [2], la cual almacena información de aeronaves con velocidades de vuelo medias cercanas a los  $7,0 \frac{m}{s}$ . La base de datos EuRoC (BD2) [7] destaca por utilizar un sistema láser para el seguimiento de los vehículos con el objetivo de mejorar las medidas. La Urban Mav (BD3) [44] tiene como peculiaridad que sus datos proceden de vuelos en zonas urbanas, mientras que la base de datos KumarRobotics (BD4) [68] contiene un archivo de Matlab que alinea sus medidas de GPS con un sistema de odometría. Por último, la UZH-FPV (BD5) [15] se caracteriza por incluir la información de las cámaras FPV que incorporan los drones de carreras.

Las mediciones registradas en estas bases de datos suelen realizarse con un solo tipo de dron, principalmente registrando información de señales satelitales y lecturas de sensores inerciales y/o sistemas de medida externos al dron [8, 26, 30]. Asimismo, los drones empleados suelen ser de propósito general y no suelen estar particularizadas para una aplicación claramente definida.

Sin embargo, los drones de carreras han irrumpido con fuerza en el ámbito científico, pudiendo encontrar numerosos trabajos relacionados con su comportamiento dinámico [9, 41]. Estos estudios constatan la existencia de cuestiones abiertas en el ámbito de su diseño estructural, dinámica de vuelo y su control autónomo en ambientes con obstáculos estáticos o dinámicos. Por ello, han empezado a desarrollarse nuevas bases de datos con información de este tipo específico de drones, los cuales se caracterizan principalmente por su dinámica rápida y agresiva comparada con los drones tradicionales [58].

Este artículo presenta la base de datos abierta TRAM-FPV Racing, la cual ha sido creada para poder estudiar en detalle el comportamiento dinámico de drones de carreras. En la sección 2, se realiza una breve introducción al sistema de visión empleado para la sensorización del movimiento y orientación 3D. En la sección 3, se describe la ca-

libración y configuración del *Flight Arena*, donde se han realizado los experimentos, junto con los drones de carreras empleados y la descripción de los esquemas básicos de control que integran estos drones. La sección 4, detalla el procedimiento de vuelo, mientras que la sección 5 describe la estructura de la base de datos. Finalmente, la sección 6 presenta las conclusiones más relevantes del trabajo.

## 2. Sistemas de sensorización de posición y orientación 3D para drones.

Un sistema dotado de la capacidad para planificar su trayectoria de vuelo y posteriormente ejecutarla sin la intervención humana, según ciertos estándares de seguridad, es un vehículo aéreo autónomo [10]. Si, además, durante el recorrido de esas trayectorias autónomas, el vehículo aéreo detecta objetos, evita posibles colisiones y re-calcula su trayectoria realizando distintas maniobras de vuelo, entonces, el vehículo, se dice, que navega autónomamente [4]. Para conseguir que un vehículo aéreo se comporte de manera autónoma, es necesario combinar las medidas de distintos tipos de sensores, generalmente denominado fusión sensorial [21, 69]. Esta combinación de información es necesaria para la estimación de estados, el control y estabilización, la navegación y el guiado de la aeronave [34, 61].

La información contenida en estas bases de datos suele contener datos de los sistemas de posicionamiento global (GNSS), cuando los vuelos se han realizado en espacios abiertos. Así como registros de los sensores del sistema de navegación inercial e, incluso, secuencias de vídeo para el guiado autónomo de la aeronave [17, 29, 49]. De igual forma, existen bases de datos que incorporan información de otro tipo de sensores, por ejemplo, sensores láser o ultrasónicos para detectar objetos o marcadores en el entorno de navegación [46]. A continuación, se detallan algunos de los sensores empleados para medir la posición y orientación de las aeronaves, tanto embarcados como externos a los vehículos:

- Sistemas de posicionamiento Global (GNSS). Están formados por satélites artificiales (constelación de satélites) que envían señales de radio (EMS) [45]. Estos sistemas calculan el tiempo que tarda en llegar la onda a un receptor para determinar la posición [42, 45, 72]. Sin embargo, la fiabilidad de los datos se ve afectada por distintos factores, incrementándose el ruido en la señal notablemente [27, 35, 52]. Entre estos sistemas se

encuentran el NAVSTAR-GPS, GLONASS, IRNSS, GALILEO y BEI-DUO.

- Información de los sistemas de navegación inerciales (INS). Estos sistemas están abordo del vehículo y utilizan unidades o sensores inerciales (IMU), están compuestos por acelerómetros, giroscopos y magnómetros [16, 53, 59]. Para determinar la posición y orientación, las medidas de estos sensores se combinan utilizando distintos algoritmos, como, por ejemplo, el filtro extendido de Kalman (EKF).
- Información de sistemas que procesan imágenes (IMS). Estos sistemas se encuentran abordo del vehículo y utilizan los distintos tipos de cámaras para estimar la posición y orientación del objeto. Los sensores de las cámaras capturan el desplazamiento mediante sucesiones de imágenes que son procesadas digitalmente y analizadas utilizando diferentes métodos o algoritmos [5, 28, 73], consecuentemente, el reconocimiento de imágenes en tiempo real requiere de una alta definición, además de cámaras de alta velocidad y resolución.
- Información de los sistemas acústicos (UMS). Estos sistemas determinan la localización del objeto mediante ondas ultrasónicas que viajan por el aire. Están compuestos de un transmisor de la señal que es fijado en un punto en el entorno de la navegación, mientras que el receptor se encuentra abordo del vehículo [19, 63].
- Información de los sistemas que combinan sensores ópticos y electrónicos (OMS). Estos sistemas están compuestos de un conjunto de cámaras y marcadores. Las cámaras se ubican en el entorno de la navegación, no están abordo del vehículo, y detectan la luz de un marcador que ha sido recubierto con material luminiscente y que se fija al vehículo. Para estimar la posición y la orientación del objeto es necesario un mínimo de dos cámaras, es decir, siempre que dos sensores (cámaras) detecten o reconozcan el marcador es posible reconstruir la posición del vehículo [20, 25]. La fiabilidad de los datos viene determinada por el número de cámaras, su ubicación y la intensidad de la luz en el ambiente [12, 31].

Cabe destacar que en situaciones de ausencia de medidas GNSS [1, 11, 40], o en contextos que demandan un alto rendimiento dinámico [14, 60, 67] con elevada precisión de posicionamiento y orientación, se emplean los sistemas OMS [3, 18, 24, 48].

Asimismo, debido a las dinámicas rápidas que presentan los drones de carreras, resulta imprescindible la utilización de sistemas OMS para poder estudiar con precisión su comportamiento [37, 50].

### 3. Configuración del sistema de experimentación para la base de datos TRAM-FPV RACING

Para realizar una secuencia de vuelo correctamente, es necesario la preparación de la arena de vuelo, los equipos de medición respectivos y los modelos de drones que se usarán para las pruebas de vuelo.

#### 3.1. Descripción y configuración de la arena de vuelo.

El emplazamiento donde se han realizado las pruebas es el *Flight Arena* de la Universidad de Cranfield en UK.

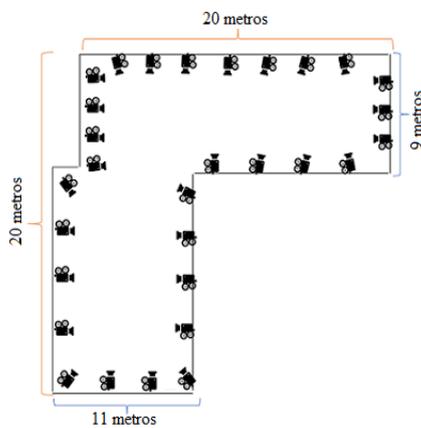


Figura 1: *Flight Arena* Universidad de Cranfield

Las dimensiones en planta de la arena se muestran en la figura 1, siendo la altura máxima de 10 m en todo el recinto. Por otro lado, el recinto está equipado con 30 cámaras Vicon [75]. Las cámaras están ubicadas a 10 m de altura y una separación de 1,5 m aproximadamente.



Figura 2: Cámaras Vicon. Vantage y Vero

La transmisión de datos se realiza mediante Ether-

net, empleando el protocolo de comunicación TCP/IP gestionado por el software *tracker* [74].

Las cámaras son del tipo Vicon Vantage y Vero (ver figura 2). Estas cámaras pueden capturar el movimiento entre 250 y 1070 FPS, siendo el campo de visión entre 40 y 57 grados. Por otra parte, la resolución oscila entre 1,3 y 5,0 megapíxeles, según la calibración del volumen, el área efectiva de vuelo y la cantidad de frames por segundo requeridos para el experimento.

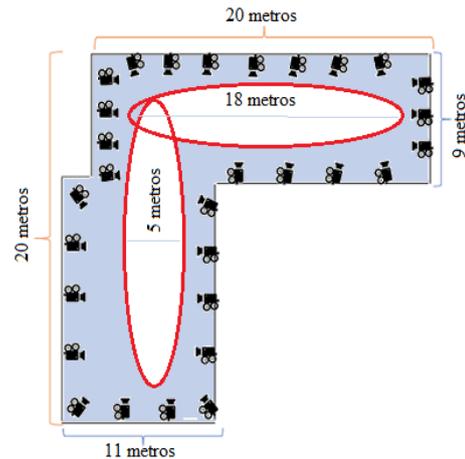


Figura 3: Arena efectiva de vuelo

La figura 3 muestra el área efectiva de medición después de las calibraciones realizadas. Se debe tener en cuenta que la norma ASTM E3064 relaciona la capacidad de las cámaras para procesar las imágenes sin filtrar ni post-procesar los datos. En concreto, cuando se trata de la concordancia entre el resultado de un ensayo y el valor de referencia aceptado, además de la concordancia entre resultados de ensayos independientes obtenidos en condiciones estipuladas (según *ISO3534 : 2014*), el software Vicon-tracker logra capturar 41993 fotogramas por segundo, con una precisión de 0,017 mm, según el método de pruebas estándares para evaluar el rendimiento de los sistemas de seguimiento óptico que miden seis grados de libertad de posición y orientación (ASTM E3064).

No obstante, el error relativo entre la posición de las cámaras y el origen del área efectiva de vuelo viene dado por el proceso de calibración junto a las condiciones ambientales de luz durante la pruebas. Por ello, teniendo en cuenta las condiciones en las que se realizaron los experimentos, se aceptó un rango promedio de 0,1 mm por cada uno de los ejes coordenados.

### 3.2. Descripción y configuración de los drones de carreras empleados.

En esta base de datos se ha tenido en consideración la estructura geométrica de 5 tipos de drones de carreras. Estos drones tienen comportamientos dinámicos distintos según su geometría (airframe) [9], las cuales se definen como simétricas (SY), no simétricas (NSY) o híbridas (HS).

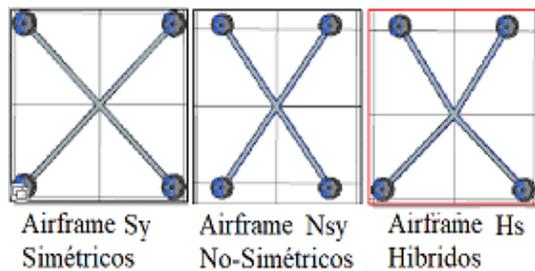


Figura 4: Geometría de drones de carreras

En la figura 4, las geometrías simétricas (SY) representan una distancia angular entre brazos superiores e inferiores igual a 90 grados y distancia entre ejes de motores igual a 210 y 250 milímetros (mm). La distancia angular de las estructuras no simétricas (NSY) está comprendida entre 80 y 65 grados y la distancia entre ejes de motores entre 210 y 230 mm. Los estructuras híbridas tienen una distancia angular entre brazos superiores igual a 80 grados y brazos inferiores de 90, mientras que la distancia entre ejes es 250 mm.

Tabla 2: Configuración de la plataforma de vuelo

Componentes	Descripción
Airframe	SY, NSY, HS
Variador ESC	55 Amperios - Tmotor
Controladora	F7 - Tmotor
Tarjeta de video	Viva FPV - Tbs
Receptor mando	R-XSR - FrSKY
Antenas	Emax lineales
Batería	6s - 4s
Hélices	5147 - Tmotor
Motores Tmotor	F60PRO 1950-2550 Kv
Firmware	Betaflight

Todos los drones de carreras fueron equipados con los mismos componentes electrónicos, grupo motor y la alimentación como se observa en la tabla 2. Además, algunos de los drones empleados para los experimentos se muestran en la figuras 5, 6 y 7.

Cabe destacar que los parámetros geométricos de estos modelos de drones de carreras fueron introducidos en el firmware de cada una de las 5 controladoras de vuelo. Las ayudas para la navegación y el control de estabilidad fueron configurados bajo las mismas condiciones para realizar los experimentos [9]. Además, los ajustes relacionados con el recorrido de las palancas del radio-control fueron fijadas a sus valores por defecto.



Figura 5: Modelo híbrido - HS.



Figura 6: Modelo simétrico - SY.



Figura 7: Modelo no simétrico - NSY.



Figura 8: Ubicación de los marcadores en el dron de carreras.

Con el objetivo de capturar las trayectorias de vuelo de la forma más precisa, sobre cada uno de los frames se ubicaron cinco marcadores esféricos y luminiscentes de 14 mm de diámetro como muestra la figura 8. Además, se ubicaron en posiciones no simétricas con una distancia mínima de 10 mm. Esto garantiza que el sistema OMS pueda reconstruir con mayor rapidez la posición de los marcadores durante el movimiento.

### 3.3. Esquema de control de los drones empleados

Las bases de datos como la TRAM-FPV Racing son integradas entre varios niveles de control para fusionarse con las diferentes lecturas de los sensores. Esto es para entrenar los movimientos de los drones de carreras autónomos o para validar sus comportamientos en espacios cerrados bajo ciertas condiciones de seguridad. [23, 32, 36].

La figura 9 muestra una esquema o arquitectura de control básica para dos drones de carreras en un entorno controlado. Muestra como la información de traslación y rotación obtenida de los sistemas ópticos (Cámaras Vicon), reemplazan la información que suele suministrar un sistema satelital más inercial para la navegación autónoma. Además, muestra las posibles interacciones de estos datos con los módulos de la arquitectura de control en un entorno para detectar, evadir o pasar a través de obstáculos de ellos y evitar colisiones.

En general, emplear los datos directos del sistema de visión suele ser un uso recurrente [51, 70, 71]. Esto permite la gestión de posibles obstáculos

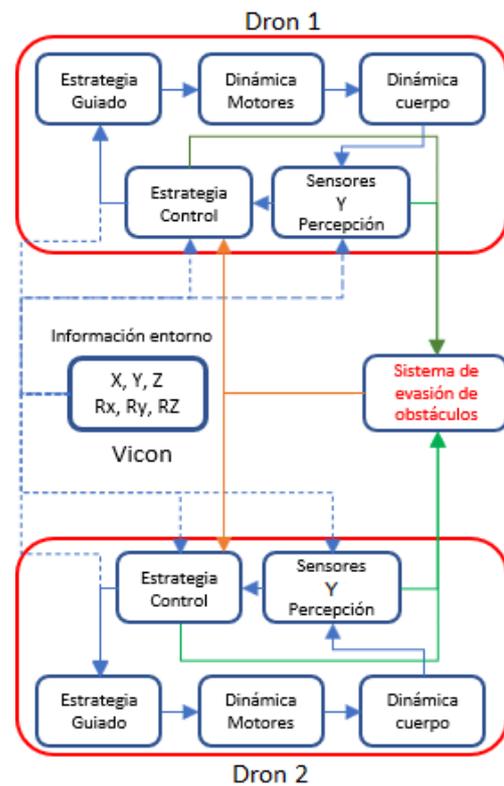


Figura 9: Alternativas Vicon

[39, 55, 56] bien sea para detectarlos y/o evadirlos durante una trayectoria de vuelo.

Algunos de los algoritmos relacionados con estas estrategias para la gestión de obstáculos son la localización precisa, localización simultánea con imágenes (SLAM), LiDAR, odometría entre otras que incluyen la clasificación y extracción de imágenes precargadas en bases de datos para el reconocimiento de entornos dinámicos.

## 4. Secuencias de vuelo

En primer lugar, antes de comenzar los vuelos, es necesario ajustar las frecuencias de muestreo de los sensores de las cámaras Vicon y los sensores inerciales (IMU) según el área efectiva de vuelo (ver figura 3), así como los errores relativos de medición.

En el caso de las cámaras Vicon, las secuencias de vuelo fueron capturadas a 250 FPS mientras que la captura de datos recogidos por los sensores inerciales (IMU) de la controladora embebida en el dron de carreras fue realizada a 500 Hz. Esta calibración se realizó cada 10 vuelos y fue admitido un error de calibración menor a 0,1%, además, estas secuencias de vuelo fueron sincronizadas con grabaciones de vídeo por cada una de las pruebas realizadas.

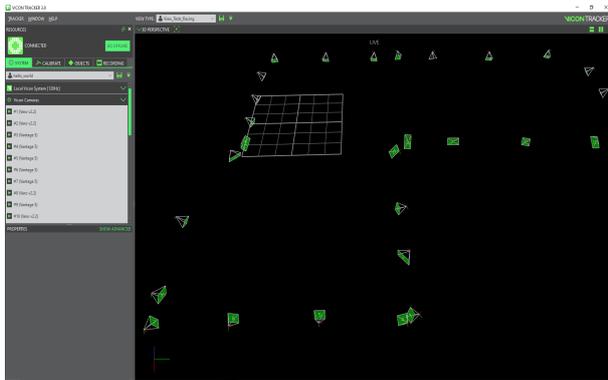


Figura 10: Entorno Vicron Tracker.

Cabe destacar que se empleó el software Tracker (ver figura 10) para que coincidieran el sistema de referencia del objeto con el sistema de referencia inercial del volumen de la arena, es decir, se ajustó el origen de coordenadas del objeto según coordenadas NED respecto al sistema de referencia de las cámaras.

La grabación de los datos puede comenzar después de calibrar el área efectiva de vuelo. El procedimiento de calibración depende de las condiciones de luz junto a los parámetros de las cámaras, y es efectiva cuando el software tracker registra los márgenes de errores admisibles. Posteriormente, el piloto activará los sensores de la IMU del dron para iniciar la prueba de vuelo.

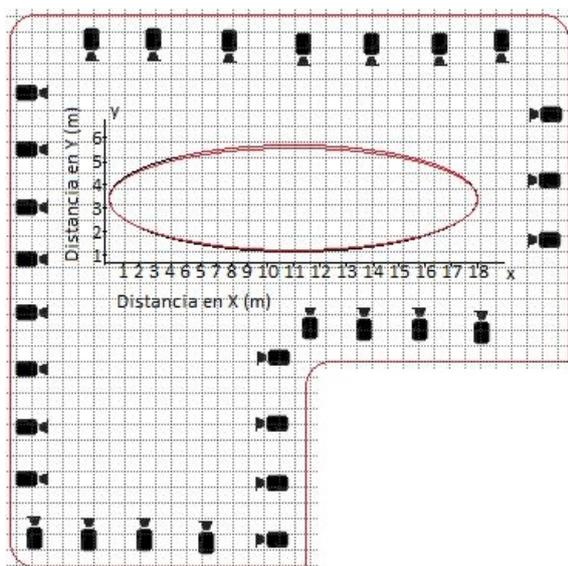


Figura 11: *Flight Arena* Universidad de Cranfield. Distancias y trayectorias realizadas.

Cada prueba tuvo una duración entre 2,5 y 3,0 minutos de vuelo aproximadamente. Se realizaron 30 pruebas por cada uno de los drones utilizados, para un total de 150 pruebas realizadas. Lo que

equivale a un rango entre 75 y 90 horas de vuelo efectivas por cada dron utilizado, almacenadas en la base de datos TRAM-FPV.

Todas las cámaras de la arena de vuelo (figura 11) fueron direccionadas hacia las trayectorias realizadas por el dron de carreras, de tal manera que al menos tres cámaras pudiesen detectar un marcador durante las rotaciones o los giros, al final de los 18 metros realizados y al inicio de la trayectoria.

### 5. Estructura de la base de datos TRAM-FPV.

Los datos de los experimentos fueron almacenados en una base de datos y esta se encuentra alojada en un repositorio para tal fin de la Universidad de Cranfield. Esta base de datos es abierta y está disponible en la referencia bibliográfica [76].

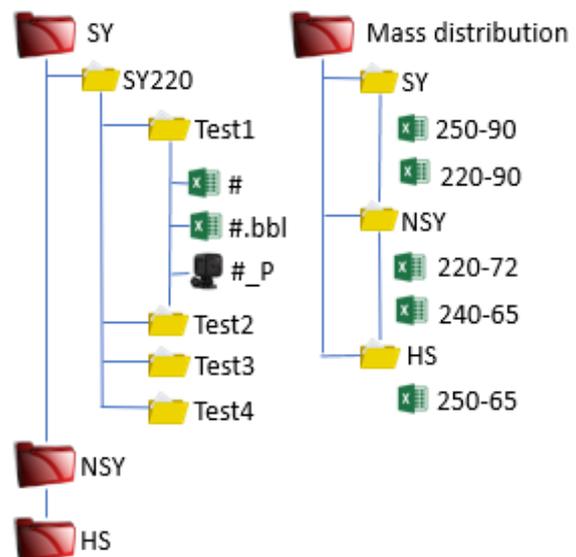


Figura 12: Arbol de carpetas de la base de datos TRAM-FPV Racing.

La base de datos TRAM-FPV Racing está compuesta por 3 carpetas según la geometría de los drones de carreras (SY, NSY y HS) y una carpeta adicional que relaciona las distribuciones de masa y distintos momentos de inercia de cada uno de los modelos utilizados, organizada igualmente en tres subcarpetas según las geometrías de los drones (Ver figura 12).

En el interior de las tres primeras carpetas SY, NSY y HS se encuentran otras 3 subcarpetas llamadas test1, test2, test3, salvo para el caso de la carpeta SY que está compuesta de 4 tests. Asimismo, en el interior de cada subcarpeta test, se encuentran 3 tipos de archivos: Un archivo de vídeo en formato WEBM y dos archivo de excel -

CSV. Los archivos CSV que arroja el software Vicon están llamados por el número de batería desde cero hasta el 9, y los archivos CSV que arroja la IMU están llamados por el número de batería igualmente y la sigla bbl.

Los archivos CSV-IMU contienen 11 columnas por 90000 filas aproximadamente y están organizadas como en la tabla 3. Esta tabla tiene la descripción de 3 rotaciones, 3 aceleraciones y 3 ángulos de heading según los ejes coordenados (X, Y Z). Por otro lado, se debe tener en consideración que las magnitudes de las aceleraciones y el ángulo de heading son valores crudos (RAW) según el recorrido de la palanca del mando, entonces, sus equivalencias son: 2048 unidades de aceleraciones es equivalente a una unidad de gravedad (1g). Además, los datos son suavizados mediante un filtro de paso bajo, donde una unidad de Heading es equivalente a 58,1 grados.

Tabla 3: Base de datos IMU

Columna	Descripción	Magnitud	Error (%)
1	loopIteration	< 1,284,656	
2	Time local	µs	
3	Rotación eje alabeo	deg/s	< 0,01
4	Rotación eje cabeceo	deg/s	< 0,01
5	Rotación eje guiñada	deg/s	< 0,01
6	Aceleración eje X	raw	< 0,1
7	Aceleración eje Y	raw	< 0,1
8	Aceleración eje Z	raw	< 0,1
9	Heading alabeo	raw	< 0,09
10	Heading cabeceo	raw	< 0,09
11	Heading guiñada	raw	< 0,09

Tabla 4: Base de datos OMS-Vicon

Columna	Descripción	Magnitud	Error (%)
1	Frames	fps	< 0,017
2	Subframes	0	NA
3	RX rotación eje X	rad	0,397 – 0,79
4	RY rotación eje Y	rad	0,397 – 0,79
5	RZ rotación eje Z	rad	0,397 – 0,79
6	TX Traslación eje X	mm	< 0,149
7	TY Traslación eje Y	mm	< 0,149
8	TZ Traslación eje Z	mm	< 0,149

Los archivos CSV-Vicon contienen 8 columnas con aproximadamente 50000 filas y están organizadas como muestra la tabla 4. Esta tabla contiene 3 rotaciones (RX, RY, RZ) y 3 traslaciones (TX, TY, TZ), además de la velocidad de captura de información o FPS. Notar que el orden de rotación es helicoidal, esto es que la rotación es relativa a la posición del marcador en los diferentes instantes de tiempo (roto-traslación) y puede ser transformada a cualquier otro tipo de rotación no instantánea como las de Euler o expresiones en cuaterniones. Los errores relacionados en la tabla son coeficientes porcentuales de variaciones arrojadas por el software tracker, para mediciones más precisas se debe consultar [48].

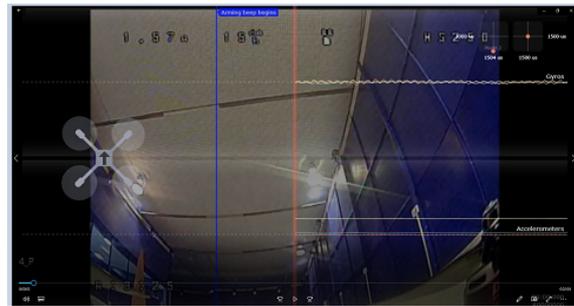


Figura 13: Lecturas IMU sincronizadas con vídeo.

En los archivos de vídeo WEBM (figura 13) es posible visualizar el comportamiento de los giroscopios en la parte superior y acelerómetros en la parte inferior mientras se realizaron las pruebas de vuelo. Estas secuencias de vídeo se han sincronizado con dichos comportamientos y de esta forma se pueden apreciar los cambios de las señales de los ángulos de manera sincronizada.

## 6. Conclusiones

Este trabajo presenta la base de datos TRAM-FPV que contiene información real de vuelo de 5 modelos de drones de carreras. La diversidad de datos relacionada con las distribuciones de masa junto a la información de posición y rotación la convierte en una de las fuentes de información más completa que se pueden encontrar en repositorios abiertos (Ver tabla 5). Además, dado que incorpora 30 secuencias de vuelo por cada uno de los modelos utilizados, para un total de 150 entre todos los modelos, garantiza la integridad y coherencia de los datos.

Tabla 5: Características de la Base de datos

Base de datos	TRAM-FPV Racing
Tipo de chasis	SY, NSY, HS
Cantidad de vehículos	5
Secuencias de vuelo	150
Interior/sensores	IMU/OMS
Exterior/sensores	NO
Captura vídeo/imagen	Sí
Área utilizada	20x20 metros

La incorporación de 5 modelos contribuye con una caracterización más precisa de los diferentes enfoques de diseño en los que la base de datos TRAM-FPV RACING pueda ser empleada. Enfoques basados en la geometría de sus estructuras para implementar algoritmos de control, permite la caracterización y el desarrollo de modelos aerodinámicos propios de drones de carreras.

Esta base de datos pretende continuar expandiendo el interés por el desarrollo de sensores para dro-

nes de carreras autónomos. Sensores que sean capaces de percibir las dinámicas típicas de un dron de carreras radio-controlado y que puedan ser implementados en drones de carreras autónomos.

Finalmente, el gran volumen de datos junto con la precisión que presentan, permite ser empleada para el diseño y ajuste de modelos, algoritmos de estimación, navegación y guiado.

### Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo del proyecto PID2020-119468RA-I00 financiado MCIN/AEI/10.13039/501100011033. Asimismo, agradecer al programa Erasmus prácticas por la ayuda económica suministrada a través de la Escuela de doctorado de la Universitat Politècnica de València y el programa para el intercambio internacional (OPII-UPV).

Especial agradecimiento a la Universidad de Cranfield en Reino Unido y al Centro de Sistemas Autónomos y Ciberfísicos de la Escuela Aeroespacial, transporte y Fabricación (SATM) por el soporte técnico recibido y facilitar el uso de sus instalaciones y equipos de medición Vicon de la arena de vuelo.

### English summary

**THE TRAM-FPV RACING Open Database. Sequences complete indoor flight sequences for the study of racing drones.**

### Abstract

*This paper presents the TRAM-FPV Racing open database, which has been generated from a set of indoor flights performed with racing drones at Cranfield University (UK), specifically at the Flight Arena, one of the largest indoor flight fields in the world for research purposes. The database incorporates the position and orientation information in space of five racing drone models, using an optical measurement system (OMS). It includes readings from accelerometers, gyroscopes, and heading angles recorded by inertial unit (IMU) sensors. These databases are frequently used for the development and adjustment of the sensor fusion algorithms incorporated in the drones to estimation of their current state vector. However, their field of application is*

*very wide, being able to be used, for example, for the development of the nonlinear mathematical models of the drones or for the generation of trajectories.*

**Keywords:** Racing drone, Database, Trajectories, Guidance, GPS-denied, IMU, Navigation, Autonomous, Simulation..

### Referencias

- [1] Abosekeen, A., Iqbal, U., Noureldin, A., and Korenberg, M. J. (2020). A novel multi-level integrated navigation system for challenging GNSS environments. *IEEE Transactions on Intelligent Transportation Systems*, 22(8), 4838-4852.
- [2] Antonini, A., Guerra, W., Murali, V., Sayre-McCord, T., and Karaman, S. (2018, November). The blackbird dataset: A large-scale dataset for uav perception in aggressive flight. In *International Symposium on Experimental Robotics* (pp. 130-139). Springer, Cham.
- [3] Aurand, A. M., Dufour, J. S., and Marras, W. S. (2017). Accuracy map of an optical motion capture system with 42 or 21 cameras in a large measurement volume. *Journal of biomechanics*, 58, 237-240.
- [4] Bagnell, J. A., Bradley, D., Silver, D., Sofman, B., and Stentz, A. (2010). Learning for autonomous navigation. *IEEE Robotics and Automation Magazine*, 17(2), 74-84.
- [5] Balcerek, J., Dabrowski, A., and Konieczka, A. (2013, September). Stereovision option for monitoring systems. A method based on perception control of depth. In *2013 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)* (pp. 226-230). IEEE.
- [6] Bigazzi, L., Basso, M., Boni, E., Innocenti, G., and Pieraccini, M. (2021). A Multilevel Architecture for Autonomous UAVs. *drones*, 5(3), 55.
- [7] Burri, M., Nikolic, J., Gohl, P., Schneider, T., Rehder, J., Omari, S., ... and Siegwart, R. (2016). The EuRoC micro aerial vehicle datasets. *The International Journal of Robotics Research*, 35(10), 1157-1163.
- [8] Caesar, H., Bankiti, V., Lang, A. H., Vora, S., Liong, V. E., Xu, Q., ... and Beijbom, O. (2020). nuscenes: A multimodal dataset for

- autonomous driving. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 11621-11631).
- [9] Castiblanco, J. M., Garcia-Nieto, S., Simarro, R., and Salcedo, J. V. (2021). Experimental study on the dynamic behaviour of drones designed for racing competitions. *International Journal of Micro Air Vehicles*, 13, 17568293211005757.
- [10] Chao, H., Cao, Y., and Chen, Y. (2010). Autopilots for small unmanned aerial vehicles: a survey. *International Journal of Control, Automation and Systems*, 8(1), 36-44.
- [11] Chen, C., Tian, Y., Lin, L., Chen, S., Li, H., Wang, Y., and Su, K. (2020). Obtaining world coordinate information of UAV in GNSS denied environments. *Sensors*, 20(8), 2241.
- [12] Chen, L., Takashima, K., Fujita, K., and Kitamura, Y. (2021, May). PinpointFly: An Egocentric Position-control Drone Interface using Mobile AR. In Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems (pp. 1-13).
- [13] Conte, C., de Alteriis, G., Schiano Lo Moriello, R., Accardo, D., and Rufino, G. (2021). Drone Trajectory Segmentation for Real-Time and Adaptive Time-Of-Flight Prediction. *Drones*, 5(3), 62.
- [14] Cyganek, B., and Wozniak, M. (2018). Virtual high dynamic range imaging for underwater drone navigation. In ICIAE2018 the 6th IIAE Int. Conf. Ind. Appl. Eng.
- [15] Delmerico, J., Cieslewski, T., Rebecq, H., Faessler, M., and Scaramuzza, D. (2019, May). Are we ready for autonomous drone racing? the UZH-FPV drone racing dataset. In 2019 International Conference on Robotics and Automation (ICRA) (pp. 6713-6719). IEEE.
- [16] de Figueiredo, R. P., Hansen, J. G., Fevre, J. L., Brandao, M., and Kayacan, E. (2021). On the advantages of multiple stereo vision camera designs for autonomous drone navigation. arXiv preprint arXiv:2105.12691.
- [17] Donati, C., Mammarella, M., Comba, L., Biglia, A., Gay, P., and Dabbene, F. (2022). 3D Distance Filter for the Autonomous Navigation of UAVs in Agricultural Scenarios. *Remote Sensing*, 14(6), 1374.
- [18] Eichelberger, P., Ferraro, M., Minder, U., Denton, T., Blasimann, A., Krause, F., and Baur, H. (2016). Analysis of accuracy in optical motion capture—A protocol for laboratory setup evaluation. *Journal of biomechanics*, 49(10), 2085-2088.
- [19] Famili, A., and Park, J. M. J. (2020, May). Rolatin: Robust localization and tracking for indoor navigation of drones. In 2020 IEEE Wireless Communications and Networking Conference (WCNC) (pp. 1-6). IEEE.
- [20] Farid, A., Veer, S., and Majumdar, A. (2022, January). Task-driven out-of-distribution detection with statistical guarantees for robot learning. In Conference on Robot Learning (pp. 970-980). PMLR.
- [21] Florea, A. G., and Buiu, C. (2019, May). Sensor fusion for autonomous drone waypoint navigation using ROS and numerical P systems: A critical analysis of its advantages and limitations. In 2019 22nd International Conference on Control Systems and Computer Science (CSCS) (pp. 112-117). IEEE.
- [22] Foehn, P., Romero, A., and Scaramuzza, D. (2021). Time-optimal planning for quadrotor waypoint flight. *Science Robotics*, 6(56), eabh1221.
- [23] Foroughi, F., Chen, Z., and Wang, J. (2021). A cnn-based system for mobile robot navigation in indoor environments via visual localization with a small dataset. *World Electric Vehicle Journal*, 12(3), 134.
- [24] Furtado, J. S., Liu, H. H., Lai, G., Lacheray, H., and Desouza-Coelho, J. (2019). Comparative analysis of optitrack motion capture systems. In *Advances in Motion Sensing and Control for Robotic Applications* (pp. 15-31). Springer, Cham.
- [25] Garcia, J. A. B., and Younes, A. B. (2021). Real-Time Navigation for Drogue-Type Autonomous Aerial Refueling Using Vision-Based Deep Learning Detection. *Transactions on Aerospace and Electronic Systems*, 57(4), 2225-2246. IEEE.
- [26] Geyer, J., Kassahun, Y., Mahmudi, M., Ricou, X., Durgesh, R., Chung, A. S., ... and Schuberth, P. (2020). A2d2: Audi autonomous driving dataset. arXiv preprint arXiv:2004.06320.
- [27] Hashim, H. A. (2021, May). Gps-denied navigation: Attitude, position, linear velocity, and gravity estimation with nonlinear stochastic observer. In 2021 American Control Conference (ACC) (pp. 1149-1154). IEEE.

- [28] Hayat, S., Jung, R., Hellwagner, H., Bettstetter, C., Emini, D., and Schnieders, D. (2021). Edge computing in 5G for drone navigation: What to offload?. *IEEE Robotics and Automation Letters*, 6(2), 2571-2578.
- [29] He, D., Qiao, Y., Chan, S., and Guizani, N. (2018). Flight security and safety of drones in airborne fog computing systems. *IEEE Communications Magazine*, 56(5), 66-71.
- [30] Huang, X., Cheng, X., Geng, Q., Cao, B., Zhou, D., Wang, P., ... and Yang, R. (2018). The apolloscape dataset for autonomous driving. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 954-960).
- [31] Huppert, F., Hoelzl, G., and Kranz, M. (2021, May). GuideCopter-A precise drone-based haptic guidance interface for blind or visually impaired people. In *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems* (pp. 1-14).
- [32] Jiang, P., Osteen, P., Wigness, M., and Sari-palli, S. (2021, May). Rellis-3d dataset: Data, benchmarks and analysis. In *2021 IEEE international conference on robotics and automation (ICRA)* (pp. 1110-1116). IEEE.
- [33] Johansen, T. A., Fossen, T. I., and Berge, S. P. (2004). Constrained nonlinear control allocation with singularity avoidance using sequential quadratic programming. *IEEE Transactions on Control Systems Technology*, 12(1), 211-216.
- [34] Jung, S., Hwang, S., Shin, H., and Shim, D. H. (2018). Perception, guidance, and navigation for indoor autonomous drone racing using deep learning. *IEEE Robotics and Automation Letters*, 3(3), 2539-2544.
- [35] Karetnikov, V., Milyakov, D., Prokhorenkov, A., and Ol'khovik, E. (2021). Prospects of application of mass-produced GNSS modules for solving high-precision navigation tasks. In *E3S Web of Conferences* (Vol. 244, p. 08006). EDP Sciences.
- [36] Karnan, H., Nair, A., Xiao, X., Warnell, G., Pirk, S., Toshev, A., ... and Stone, P. (2022). Socially Compliant Navigation Dataset (SCAND): A Large-Scale Dataset of Demonstrations for Social Navigation. *arXiv preprint arXiv:2203.15041*.
- [37] Kaufmann, E., Gehrig, M., Foehn, P., Ranftl, R., Dosovitskiy, A., Koltun, V., and Scaramuzza, D. (2019, May). Beauty and the beast: Optimal methods meet learning for drone racing. In *2019 International Conference on Robotics and Automation (ICRA)* (pp. 690-696). IEEE.
- [38] Kaufmann, E., Loquercio, A., Ranftl, R., Dosovitskiy, A., Koltun, V., and Scaramuzza, D. (2018, October). Deep drone racing: Learning agile flight in dynamic environments. In *Conference on Robot Learning* (pp. 133-145). PMLR.
- [39] Kazim, M., Zaidi, A., Ali, S., Raza, M. T., Abbas, G., Ullah, N., and Al-Ahmadi, A. A. (2022). Perception Action Aware-Based Autonomous Drone Race in a Photorealistic Environment. *IEEE Access*, 10, 42566-42576.
- [40] Kim, J., and Sukkarieh, S. (2005). 6DoF SLAM aided GNSS/INS navigation in GNSS denied and unknown environments. *Positioning*, 1(09).
- [41] Loquercio, A., Kaufmann, E., Ranftl, R., Dosovitskiy, A., Koltun, V., and Scaramuzza, D. (2019). Deep drone racing: From simulation to reality with domain randomization. *IEEE Transactions on Robotics*, 36(1), 1-14.
- [42] Lin, X., Guo, J., Li, X., Tang, C., Shao, R., Pan, J., ... and Li, Z. (2022). Applications and Prospects for Autonomous Navigation Technology in a Satellite Navigation System. In *China Satellite Navigation Conference (CSNC 2022) Proceedings: Volume II* (p. 332). Springer Nature.
- [43] Madridano, A., Al-Kaff, A., Flores, P., Martin, D., and de la Escalera, A. (2021). Software architecture for autonomous and coordinated navigation of uav swarms in forest and urban firefighting. *Applied Sciences*, 11(3), (pp1258).
- [44] Majdik, A. L., Till, C., and Scaramuzza, D. (2017). The Zurich urban micro aerial vehicle dataset. *The International Journal of Robotics Research*, 36(3), 269-273.
- [45] Mangialardo, M., Jurado, M. M., Hagan, D., Giordano, P., and Ventura-Traveset, J. (2021, September). The full Potential of an Autonomous GNSS Signalbased Navigation System for Moon Missions. In *Proceedings of the 34th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2021)* (pp. 1039-1052).
- [46] McGuire, K., De Croon, G., De Wagter, C., Tuyls, K., and Kappen, H. (2017). Efficient

- optical flow and stereo vision for velocity estimation and obstacle avoidance on an autonomous pocket drone. *IEEE Robotics and Automation Letters*, 2(2), 1070-1076.
- [47] Mellinger, D., and Kumar, V. (2011, May). Minimum snap trajectory generation and control for quadrotors. In *2011 IEEE international conference on robotics and automation* (pp. 2520-2525). IEEE.
- [48] Merriaux, P., Dupuis, Y., Boutteau, R., Vas-seur, P., and Savatier, X. (2017). A study of vicon system positioning performance. *Sensors*, 17(7), 1591.
- [49] Miranda, V. R., Rezende, A., Rocha, T. L., Azpúrua, H., Pimenta, L. C., and Freitas, G. M. (2022). Autonomous navigation system for a delivery drone. *Journal of Control, Automation and Electrical Systems*, 33(1), 141-155.
- [50] Moon, H., Martinez-Carranza, J., Cieslewski, T., Faessler, M., Falanga, D., Simovic, A., ... and Kim, S. J. (2019). Challenges and implemented technologies used in autonomous drone racing. *Intelligent Service Robotics*, 12(2), 137-148.
- [51] Minoda, K., Schilling, F., Wüest, V., Floreano, D., and Yairi, T. (2021). Viode: A simulated dataset to address the challenges of visual-inertial odometry in dynamic environments. *IEEE Robotics and Automation Letters*, 6(2), 1343-1350.
- [52] Nezhadshahbodaghi, M., Mosavi, M. R., and Hajjalinajar, M. T. (2021). Fusing denoised stereo visual odometry, INS and GPS measurements for autonomous navigation in a tightly coupled approach. *Gps Solutions*, 25(2), 1-18.
- [53] Petritoli, E., Leccese, F., and Spagnolo, G. S. (2020, June). Inertial Navigation Systems (INS) for Drones: Position Errors Model. In *2020 IEEE 7th International Workshop on Metrology for AeroSpace (MetroAeroSpace)* (pp. 500-504). IEEE.
- [54] Patoliya, J., Mewada, H., Hassaballah, M., Khan, M. A., and Kadry, S. (2022). A robust autonomous navigation and mapping system based on GPS and LiDAR data for unconstrained environment. *Earth Science Informatics*, 1-13.
- [55] Pfeiffer, C., Wengeler, S., Loquercio, A., and Scaramuzza, D. (2022). Visual attention prediction improves performance of autonomous drone racing agents. *Plos one*, 17(3), e0264471.
- [56] Pham, H. X., Ugurlu, H. I., Le Fevre, J., Bardakci, D., and Kayacan, E. (2022). Deep learning for vision-based navigation in autonomous drone racing. In *Deep Learning for Robot Perception and Cognition* (pp. 371-406). Academic Press.
- [57] Reyes-Munoz, J. A., and Flores-Abad, A. (2021, August). A MAV Platform for Indoors and Outdoors Autonomous Navigation in GPS-denied Environments. In *2021 IEEE 17th International Conference on Automation Science and Engineering (CASE)* (pp. 1708-1713). IEEE.
- [58] Rojas-Perez, L. O., and Martínez-Carranza, J. (2021). On-board processing for autonomous drone racing: an overview. *Integration*, 80, 46-59.
- [59] Sani, M. F., and Karimian, G. (2017, November). Automatic navigation and landing of an indoor AR. drone quadrotor using ArUco marker and inertial sensors. In *2017 international conference on computer and drone applications (IConDA)* (pp. 102-107). IEEE.
- [60] Shafiee, M., Zhou, Z., Mei, L., Dinmohammadi, F., Karama, J., and Flynn, D. (2021). Unmanned aerial drones for inspection of offshore wind turbines: A mission-critical failure analysis. *Robotics*, 10(1), 26.
- [61] Song, Y., Steinweg, M., Kaufmann, E., and Scaramuzza, D. (2021, January). Autonomous drone racing with deep reinforcement learning. In *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 1205-1212). IEEE.
- [62] Song, Y., Steinweg, M., Kaufmann, E., and Scaramuzza, D. (2021, January). Autonomous drone racing with deep reinforcement learning. In *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 1205-1212). IEEE.
- [63] Šoštarić, D., and Mester, G. (2020). Drone localization using ultrasonic TDOA and RSS signal: Integration of the inverse method of a particle filter. *FME Transactions*, 48(1), 21-30.
- [64] Spedicato, S., Notarstefano, G., Bühlhoff, H. H., and Franchi, A. (2016). Aggressive maneuver regulation of a quadrotor UAV. In *Robotics Research* (pp. 95-112). Springer, Cham.

- [65] Spedicato, S., and Notarstefano, G. (2017). Minimum-time trajectory generation for quadrotors in constrained environments. *IEEE Transactions on Control Systems Technology*, 26(4), 1335-1344.
- [66] Srigrarom, S., Chew, K. H., Da Lee, D. M., and Ratsamee, P. (2020, September). Drone versus bird flights: Classification by trajectories characterization. In 2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE) (pp. 343-348). IEEE.
- [67] Stepanyan, V., Krishnakumar, K. S., and Bencomo, A. (2016). Identification and reconfigurable control of impaired multi-rotor drones. In AIAA Guidance, Navigation, and Control Conference (p. 1384).
- [68] Sun, K., Mohta, K., Pfrommer, B., Watterson, M., Liu, S., Mulgaonkar, Y., ... and Kumar, V. (2018). Robust stereo visual inertial odometry for fast autonomous flight. *IEEE Robotics and Automation Letters*, 3(2), 965-972.
- [69] Vanhie-Van Gerwen, J., Geebelen, K., Wan, J., Joseph, W., Hoebeke, J., and De Poorter, E. (2021). Indoor Drone Positioning: Accuracy and Cost Trade-Off for Sensor Fusion. *IEEE Transactions on Vehicular Technology*, 71(1), 961-974.
- [70] Wang, C., Wang, Y., Xu, M., and Crandall, D. J. (2022). Stepwise goal-driven networks for trajectory prediction. *IEEE Robotics and Automation Letters*, 7(2), 2716-2723.
- [71] Yao, Y., Atkins, E., Johnson-Roberson, M., Vasudevan, R., and Du, X. (2021). Bitrap: Bi-directional pedestrian trajectory prediction with multi-modal goal estimation. *IEEE Robotics and Automation Letters*, 6(2), 1463-1470.
- [72] Yayla, G., Van Baelen, S., Peeters, G., Afzal, M. R., Singh, Y., and Slaets, P. (2021). Accuracy benchmark of Galileo and EGNOS for Inland Waterways. In Proceedings of the International Ship Control Systems Symposium (iSCSS) (pp. 1-10). Zenodo.
- [73] Yue, Z. (2018). Dynamic Network Reconstruction in Systems Biology: Methods and Algorithms (Doctoral dissertation, University of Luxembourg, Luxembourg).
- [74] Vicon Company. Tracker system - User guide. (2019, December). Software. From URL: <https://www.vicon.com/cms/wp-content/uploads/2019/08/tracker-3-11042017-55587.pdf>
- [75] Vicon Company. Cameras - Technical specifications. (2020, June). Hardware. From URL: <https://www.vicon.com/hardware/cameras/>
- [76] Castiblanco, J.M., García-Nieto, S., Ignatyev, D., Blasco, X., (2022, Mayo 27) From URL: <http://figshare.com/s/24642072abc29b8f1535>



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).