

Detección de aeronaves en trayectoria de colisión de vuelo mediante optical flow

J.J. Cabrera^{a,*}, A. Gil^a, L. Payá^a, O. Reinoso^{a,b}, D. Rodríguez^c

^aInstituto de Investigación en Ingeniería de Elche (I3E), Universidad Miguel Hernández de Elche, Avda. de la Universidad s/n, 03202 Elche (Alicante), España.

^bValencian Graduate School and Research Network of Artificial Intelligence (valgrAI), Camí de Vera S/N, Edificio 3Q, 46022 Valencia, España.

^cAbionica Solutions S.L.P., Avda. Jean Claude Combaldieu, 03008 Alicante, España.

To cite this article: Cabrera, J.J., Gil, A., Payá, L., Reinoso, O., Rodríguez, D. 2023. Detección de aeronaves en trayectoria de colisión de vuelo mediante optical flow. XLIV Jornadas de Automática, 843-848.
<https://doi.org/10.17979/spudc.9788497498609.843>

Resumen

En este artículo se presenta un método que permite detectar UAVs mediante una única cámara instalada en una aeronave y, además, es capaz de predecir si existe riesgo de colisión. Se emplea la información del flujo óptico disperso presente en la imagen para: (1) modelar mediante una matriz de homografía el movimiento en la imagen debido al propio movimiento de la cámara, (2) compensar el movimiento en la imagen y (3) segmentar todo aquel flujo óptico cuyo movimiento es diferente al provocado por la cámara con objeto de detectar el UAV presente en el espacio aéreo. Además, se predice una posible colisión analizando la colinealidad existente entre el vector posición del UAV con su vector velocidad (salvo un factor de escala). Los resultados experimentales muestran que el método propuesto es efectivo en la detección, seguimiento y predicción de la colisión entre UAVs con independencia de su apariencia, tamaño y movimiento, lo que puede ser útil para aumentar la seguridad del espacio aéreo.

Palabras clave: Detección de UAVs, Predicción de la colisión, Flujo Óptico.

Detection of Aircrafts in flight collision path using optical flow

Abstract

This paper presents an approach to detect, track and predict the collision of UAVs by means of a single camera mounted on an aircraft. The method is based on the computation of a sparse optical flow in the image in order to: (1) model the image motion due to the camera's own movement using a homography matrix, (2) compensate the image motion and (3) segment the optical flow whose movement is different from that caused by the camera in order to detect the UAV. Additionally, collisions are predicted by analyzing the collinearity between the position vector of the UAV and its velocity vector, which are estimated up to a scale factor. Experimental results show that the proposed method is effective in detecting, tracking, and predicting collisions with UAVs regardless of their appearance, size, and relative movement, which can be useful for airspace security applications.

Keywords: UAV detection, collision prediction, optical flow

1. Introducción

Los vehículos aéreos no tripulados (UAVs), comúnmente conocidos como drones, se han hecho cada vez más populares en los últimos años, utilizándose en una amplia variedad de aplicaciones en ámbitos como vigilancia, defensa, rescate y reparto de productos. Sin embargo, hay una preocupación creciente sobre la seguridad en el ámbito de los UAVs: a medida que aumenta el número de aplicaciones con drones, es mayor

el riesgo de colisión con aeronaves tripuladas. Por ello, es de suma importancia disponer de un detector de objetos en vuelo para evitar posibles accidentes aéreos.

Diversos trabajos han abordado la detección y el seguimiento de UAVs utilizando una variedad de sensores, como LiDAR, radar, sensores acústicos y cámaras. Los sensores LiDAR pueden no ser eficaces para detectar UAVs pequeños a largas distancias (Benedek et al., 2021), debido, principalmente, a la baja resolución en sus medidas. Por otra parte, la utilización de los

*Autor para correspondencia: juan.cabreram@umh.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

sensores radar en aplicaciones civiles está, en la mayoría de países, legislada mediante una estricta normativa que limita las bandas de frecuencia y niveles de potencia con objeto de evitar las interferencias electromagnéticas con otros sistemas. Los sensores acústicos pueden utilizarse para detectar drones que no emiten ondas electromagnéticas. Sin embargo, la eficacia de estos sensores puede verse limitada por factores como el viento y el ruido de los motores y hélices (Christnacher et al., 2016), impidiendo su uso a bordo de los UAVs.

En lo relativo al empleo de cámaras se plantea el reto de estimar la posición y velocidad del UAV en un espacio 3D utilizando únicamente la información presente en las imágenes. En este sentido, las cámaras binoculares con un baseline reducido no son de aplicación al problema, debido a la falta de sensibilidad a largas distancias. La utilización de sistemas binoculares con una línea base más amplia resulta difícil de instalar en drones pequeños. Por tanto, resulta atractivo el uso de sistemas monoculares para la detección de objetos en trayectoria de colisión, debido a su reducido coste y peso. La ausencia de información sobre la profundidad resulta, sin embargo, una dificultad añadida.

Para detectar y rastrear UAVs en imágenes obtenidas por una única cámara, se pueden usar diversas técnicas. Algunas investigaciones recientes se han centrado en el uso de algoritmos de aprendizaje profundo (Hu et al., 2019; Wu et al., 2019), como es el caso de las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN). Estas técnicas plantean el reconocimiento del dron en la imagen y la posterior estimación del movimiento. Sin embargo, estas técnicas se ven limitadas por el número de modelos de drones con la que se ha entrenado la red neuronal. De esta forma, la red neuronal no sería capaz de detectar nuevos tipos de aeronaves u otro tipo de objetos que pudieran ser peligrosos en vuelo. Por este motivo, en el presente trabajo se propone un método analítico para llevar a cabo una detección de objetos en vuelo basada en el movimiento aparente en la imagen cuyas principales ventajas son: (1) Se realiza una detección generalista de objetos en vuelo con independencia de su apariencia, forma, tamaño y movimiento. (2) Se obtiene una medida de posición del objeto en coordenadas de cámara (salvo un factor de escala). (3) Se efectúa una predicción sobre la colisión en vuelo, que podría ser utilizada para iniciar una maniobra de evasión. (4) No requiere ningún tipo de entrenamiento.

El resto del artículo se estructura como sigue: el apartado 2 realiza una revisión de la literatura relacionada. Después, en el apartado 3 se define el método propuesto. Seguidamente, en el apartado 4 se presenta la base de datos empleada y los resultados obtenidos para la detección de UAVs y la predicción de la colisión con estos. Finalmente, se presentan las principales conclusiones.

2. Estado del arte

La detección de objetos en vuelo se puede abordar mediante diferentes enfoques en función de la complejidad de la tarea a resolver. De la más fácil a la más difícil, podría clasificarse de la siguiente manera: (1) detección de un objeto en movimiento desde una cámara estática, (2) detección de un objeto estático

desde una cámara en movimiento y (3) detección de un objeto en movimiento desde una cámara en movimiento.

Por un lado, los métodos de “Background Subtraction” eliminan aquellos píxeles cuya intensidad permanece constante mediante la diferencia de imágenes consecutivas. De esta manera se destacan y detectan los objetos en movimiento. Este tipo de métodos funcionan bien únicamente cuando el fondo apenas se mueve (Piccardi, 2004), lo cual no es aplicable a la situación dada en el presente trabajo.

Otros métodos están basados en el cálculo del flujo óptico, que se define como el movimiento aparente de los píxeles causado por el movimiento relativo entre la cámara y la escena. Si se realiza el seguimiento de todos los píxeles que conforman la imagen, estamos ante un flujo óptico denso (Sepehr and Homa-youn, 2014; Agarwal et al., 2016). De otro modo, si únicamente se tienen en cuenta una serie de puntos característicos, se trataría de un flujo óptico disperso. Por ejemplo, Mori and Scherer (2013) hacen uso de descriptores SURF para obtener correspondencias entre imágenes con el fin de poder detectar objetos que se acerquen frontalmente (caso imperceptible mediante un flujo óptico denso). El método propuesto por estos autores se basa en el cambio de tamaño de los objetos a detectar, de manera que se descartan aquellos objetos cuyo tamaño permanezca invariante o disminuya y se obtienen los objetos cuya área aumenta. Además, proponen el cálculo de un tiempo hasta la colisión basado en el aumento de tamaño de la escala asociada al descriptor SURF. Otros autores emplean técnicas parecidas, empleando descriptores SURF y definiendo el área de los objetos mediante una envolvente convexa. De esta forma, se asume que ocurre una colisión cuando se detecta un cambio abrupto en el área del objeto en la imagen (Al-Kaff et al., 2017).

Los métodos basados únicamente en flujo óptico presentan ciertas limitaciones, ya que un punto en movimiento no siempre genera movimiento aparente en el plano imagen (Figura 1). En cambio, un objeto alineado con el vector \vec{QT} podría producir flujo óptico debido al cambio del tamaño aparente. Por otro lado, es necesario lidiar con el flujo óptico generado por el propio desplazamiento de la cámara (Deniz et al., 2011). En este sentido, se puede emplear el flujo óptico para modelar y cancelar el movimiento introducido por la cámara. Esto permitiría detectar todo aquello que se mueva de forma diferente (por ejemplo otro UAV). La combinación del flujo óptico denso junto con la cancelación de movimiento permite la detección de objetos móviles desde una cámara en movimiento (Kurnianggoro et al., 2016). Aunque también se puede combinar el flujo óptico disperso con la cancelación de movimiento para la detección de objetos en movimiento, como es el caso de drones monoalas en secuencias en vuelo (Li et al., 2016).

En el presente trabajo proponemos un método que combina un flujo óptico disperso y la cancelación del movimiento en la imagen debido a la cámara. Para ello, se hace uso de la matriz de homografía y un flujo óptico disperso. La calidad de las correspondencias para la generación de los vectores de flujo óptico resultará crucial para el buen desempeño del algoritmo. De esta manera presentamos un método analítico robusto para la detección de UAVs en vuelo mediante un sistema monocular.

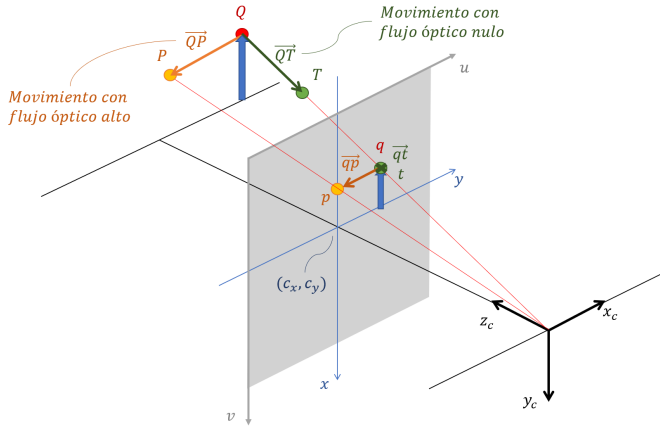


Figura 1: Esta figura muestra el modelo de cámara pinhole con el fin de demostrar que un movimiento en el espacio no siempre genera movimiento aparente en el plano imagen.

3. Descripción del método propuesto

En el presente trabajo proponemos un método que permite llevar a cabo una detección y seguimiento de objetos aéreos y que, además, realiza una predicción sobre la posible colisión entre los UAVs. En el apartado 3.1 se describe el método de detección y en el apartado 3.2 el método de predicción de la colisión.

3.1. Método para la detección de UAVs

El método desarrollado se compone principalmente de 5 pasos, definidos a continuación:

1. Cálculo de un flujo óptico disperso en imágenes consecutivas.
2. Modelado del movimiento de los puntos anteriores mediante una matriz de homografía.
3. Predicción del movimiento de la siguiente imagen y compensación del movimiento de la imagen.
4. Filtrado espacial y temporal de los objetos detectados.
5. Segmentación de contornos cerrados.

Primero, dadas unas imágenes consecutivas I_t e I_{t+1} se calcula un flujo óptico disperso sobre una serie de puntos característicos obtenidos con el algoritmo de Shi-Tomasi. Seguidamente, sobre estos puntos, se calcula un flujo óptico disperso usando el método Kanade-Lucas. De esta manera, se cuenta con un conjunto de correspondencias entre los puntos p_t (sobre la imagen I_t) y p_{t+1} (sobre la imagen I_{t+1}). A continuación, modelamos el movimiento de la escena a través de una matriz de homografía H , puesto que:

$$\vec{p}_{t+1} = H \cdot \vec{p}_t \quad (1)$$

lo que nos permite estimar H a partir de una serie de correspondencias, asumiendo que los puntos se encuentran sobre un plano (en la aplicación presentada, se asume que existe un plano en la escena). El conocimiento de H nos permite predecir la siguiente imagen \hat{I}_{t+1} usando una reproyección de perspectiva.

Es importante destacar que la estimación de la matriz de homografía H es uno de los elementos más importantes del método propuesto, ya que condicionará el buen funcionamiento del

algoritmo. Para llevar a cabo el cálculo de dicha matriz se requiere disponer de, al menos, 4 puntos característicos no alineados pertenecientes a un plano en la escena que defina nuestro propio movimiento. Sin embargo, no todos los puntos calculados en el flujo óptico pertenecen a dicho plano y se requiere de un filtrado que desestime aquellos puntos que no se corresponden con el movimiento general de la escena. Para este filtrado se hace uso del algoritmo RANSAC, que de forma iterativa, estima la matriz de homografía H eliminando los datos con valores atípicos (outliers).

Una vez se ha modelado el movimiento de la escena mediante una matriz de homografía y se ha realizado la predicción de la siguiente imagen, se compensa el movimiento de la cámara de mediante el cálculo de la imagen de diferencias:

$$\Delta I_{t+1} = \hat{I}_{t+1} - I_{t+1} \quad (2)$$

Este último paso se explica en detalle en la Figura 2. Una vez se ha obtenido la imagen de diferencias ΔI_{t+1} , se aplica a la misma un filtrado espacial compuesto de un filtrado gaussiano acompañado de un proceso de dilatación y una erosión. De esta manera se filtran pequeñas regiones de la imagen que podrían dar lugar a falsos positivos y se realiza el objeto de interés. Seguidamente, se introduce un filtrado temporal en el cual se lleva a cabo la media de N imágenes de diferencias $\Delta \bar{I}_{t+1}$ con el propósito de filtrar aquellas zonas de la imagen donde aparece ruido de forma esporádica:

$$\Delta \bar{I}_{t+1} = \frac{1}{N} \sum_{t=1,2,3,\dots,N} \Delta I_{t+1} \quad (3)$$

Por último, la imagen de diferencias media ($\Delta \bar{I}_{t+1}$), resultante de aplicar el filtro temporal, es procesada por un detector de contornos con el objetivo de detectar regiones cerradas. Se obtiene como resultado la posición del UAV en el espacio imagen y una escala estimada del objeto (área del rectángulo que engloba al contorno). Los diferentes pasos que conforman el método propuesto están ilustrados en la Figura 2.

3.2. Predicción de la colisión

El problema de predicción de colisión está altamente acoplado con la detección, ya que es necesario conocer la posición y velocidad en el espacio tridimensional. Ambos, posición y velocidad están definidos en el sistema de coordenadas de cámara. Se trata, pues, de la estimación de la posición y velocidad relativas. La predicción de la colisión se divide en los siguientes pasos:

1. Cálculo del área del UAV proyectada en la imagen.
2. Cálculo de la posición del objeto en coordenadas de cámara.
3. Cálculo de la velocidad relativa.
4. Cálculo del ángulo relativo.

Conocida su posición y su área en la imagen, se puede reproyectar la posición del objeto a un espacio 3D si consideramos conocido su tamaño real en la escena:

$$z_h = f_x \frac{h}{b_h} \quad z_w = f_y \frac{w}{b_w} \quad z_c = \frac{z_w + z_h}{2} \quad (4)$$

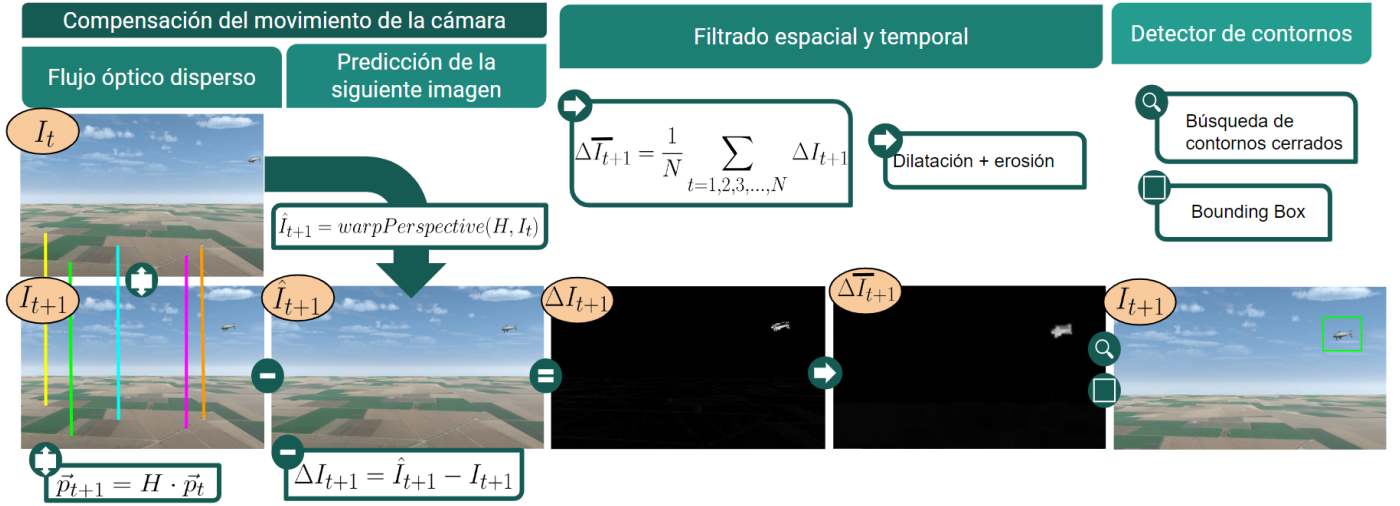


Figura 2: Pasos del método propuesto para la detección de UAVs.

$$x_c = \frac{u - c_x}{f_x} z_c \quad y_c = \frac{v - c_y}{f_y} z_c \quad (5)$$

donde h y w son la altura y anchura arbitrarias del objeto (m), b_h y b_w definen la altura y la anchura del “bounding box” del objeto detectado en la imagen. Esto nos permite obtener una estimación de la distancia del objeto a la cámara z_c (salvo un factor de escala). Además, u y v son las coordenadas en píxeles donde se detecta el objeto y f_x , f_y , c_x y c_y son los parámetros intrínsecos de la cámara. Finalmente, la posición del objeto en el instante t en coordenadas de cámara se escribe: $\vec{P}_t = (x_c, y_c, z_c)_t$.

Una vez conocida la posición del UAV \vec{P}_t respecto de la cámara en cada instante de tiempo, podemos calcular su velocidad \vec{V}_t como:

$$\vec{V}_t = \vec{P}_t - \vec{P}_{t-1} \quad (6)$$

Se trata de la velocidad relativa entre el UAV y la cámara, o lo que es lo mismo, la dirección del UAV respecto de la cámara. A continuación, para determinar si el UAV detectado está en una trayectoria de colisión, calculamos el producto escalar:

$$\vec{V}_t \cdot \vec{P}_t = |\vec{V}_t| |\vec{P}_t| \cos \theta \quad (7)$$

Cuando el vector de velocidad del UAV y su vector de posición son colineales, es posible una colisión en el aire. Por lo tanto, esta es la primera condición para detectar que el UAV colisionará con la cámara:

$$\vec{V}_t \cdot \vec{P}_t = |\vec{V}_t| |\vec{P}_t| \cos \theta = \cos \theta \approx -1 \quad (8)$$

ya que en este paso \vec{V}_t y \vec{P}_t se han normalizado, por lo tanto, $\theta \approx \pi$. Sin embargo, se espera una cantidad significativa de ruido en \vec{P}_t y, por lo tanto, en \vec{V}_t . Como resultado, como primera condición, solo comprobamos que $|\cos \theta| \approx 1$. A continuación,

la segunda condición considera una tendencia filtrada en el área del objeto a lo largo de varias imágenes. De esta manera, cuando el objeto se acerca, el “bounding box” debería crecer y viceversa. Para ello, se aproxima una función lineal de primer orden utilizando la escala estimada del objeto en cada imagen t . Como resultado, la segunda condición para predecir una colisión considera un valor positivo en la pendiente de la función.

4. Resultados

En este apartado se define la base de datos empleada para la comprobación del método propuesto y se presentan resultados en relación con la capacidad del método propuesto para la detección y seguimiento de objetos aéreos así como la predicción de la colisión con dichos objetos. A modo demostrativo, se incluye un ejemplo de detección y predicción de la colisión en el vídeo ¹.

4.1. Base de datos

La base de datos empleada consta de un total de 40 secuencias de vuelo obtenidas en el simulador Unity². Estas secuencias han sido diseñadas específicamente para recrear diferentes situaciones que se pueden dar en condiciones habituales de vuelo con el fin de abordar el problema de detección y predicción de la colisión con UAVs de la forma más robusta posible. En todas ellas una aeronave transporta una cámara monocular y coincide en el espacio aéreo con otro tipo de UAV. En 16 secuencias ambas aeronaves colisionan y en 24 de estas secuencias no se produce la colisión.

Con el objetivo de probar las limitaciones de la solución propuesta se generaron 20 simulaciones donde la aeronave vuela sobre terrenos de cultivo a gran altura (estas secuencias se denominan “crop plains”). Además, se generaron otras 20 simulaciones en un entorno de montaña donde la aeronave realiza un vuelo rasante (secuencia denominada “rocky mountains”). En

¹<https://youtu.be/K3qm2EL1xSM>

²<https://unity.com>




Figura 3: Ejemplos de diferentes secuencias del UAV modelo Camcopter© y Cessna© en los dos entornos de simulación (“crop plains” y “rocky mountains”).

este último entorno, el flujo óptico generado por los elementos del suelo resulta errático, por lo que constituye un desafío mayor en términos de la estimación del movimiento de la cámara y la detección del UAV en trayectoria de colisión. Por otro lado, se han simulado dos clases de UAV, un helicóptero Camcopter³ y una avioneta monohélice Cessna⁴.

Por último, se dispone de un “ground truth” en el que se conoce la posición del UAV en el espacio 3D y su proyección al espacio imagen con el fin de evaluar los resultados de detección y predicción de la colisión. A modo de ejemplo, en la Figura 3 se muestran algunas instantáneas extraídas de diferentes secuencias de simulación.

4.2. Resultados del método de detección

En este apartado se evalúa la bondad del algoritmo propuesto para desempeñar la tarea de detección y seguimiento descrita en el apartado 3.1. Para ello, se han calculado resultados en términos de “precision” y “recall” para las 20 secuencias de vuelo que conforman la base de datos (véase la Tabla 1). Con el objetivo de obtener dichas medidas, se han considerado los verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos de cada uno de las imágenes que conforman las diferentes secuencias.

En la Tabla 1 se puede apreciar que los resultados obtenidos para el entorno de terrenos de cultivo resultan muy correctos, obteniéndose valores de “precision” y “recall” cercanos a 1. Si se analizan en detalle los resultados obtenidos para el entorno de montaña, el número de falsos positivos aumenta, decreciendo así la precisión en la detección. Cabe remarcar que, en muchos casos, los falsos positivos son debidos a la detección de árboles y superficies rocosas cercanas a la cámara y cuya detección podría considerarse correcta, pues constituyen un peligro alto para la navegación de la aeronave.

Por otro lado, en todas las secuencias se observan valores altos de “recall”, con lo que podemos concluir que el algoritmo propuesto no produce falsos negativos. Es importante mencionar que los falsos negativos son altamente indeseables en un sistema de detección de UAVs en vuelo.

4.3. Resultados obtenidos en la predicción de colisiones

Seguidamente, se evalúa de forma cuantitativa el método propuesto para llevar a cabo la predicción de la colisión (apar-

tado 3.2). Para ello, se ha calculado la ratio entre el número de imágenes en las que se predice la colisión y el número total de imágenes que conforman una secuencia. Este factor se denomina “ratio de predicción global”, R_G . Esta ratio se debe comparar, en cada caso, con el resultado esperado (1: si existe colisión en la secuencia, 0: no existe colisión en la secuencia). Por otra parte, se observa en el conjunto de secuencias que, generalmente, el tamaño del objeto a detectar es muy pequeño en las primeras imágenes de la secuencia. Esto justifica la definición de una ratio de predicción que considere únicamente los últimos instantes antes de la posible colisión. Por tanto, se calcula la “ratio de predicción de 8 s”, R_8 , también, en los últimos 8 segundos de cada secuencia.

En la Tabla 2 se muestran los resultados para cada una de las secuencias que conforman la base de datos utilizada. Observando los resultados, se puede apreciar que, de forma general, la predicción de la colisión es satisfactoria en todas las secuencias. Cabe destacar el buen desempeño del algoritmo para ambos entornos, y en concreto, para los últimos 8 segundos de simulación antes de la posible colisión. Este tiempo se considera suficiente para que el UAV inicie alguna maniobra de evasión.

5. Conclusiones y trabajos futuros

En este artículo se ha presentado una técnica para detectar UAVs en vuelo mediante una única cámara y predecir si existe riesgo de colisión. El método está basado en el cálculo de un flujo óptico disperso que permite calcular una matriz de homografía y compensar el movimiento de la cámara. Finalmente, se predice una posible colisión analizando la colinealidad existente entre el vector posición del UAV con su vector velocidad. Se han presentado resultados en simulación en términos de detección, seguimiento y predicción de la colisión entre UAVs. Los resultados obtenidos han sido altamente satisfactorios, puesto que en la gran mayoría de los casos se detecta y se predice la colisión con el UAV con la suficiente antelación como para esquivarlo en caso de que se encuentre en trayectoria de colisión.

Al evaluar el método de detección, se ha encontrado una tendencia a predecir un mayor número de falsos positivos que de falsos negativos. Este hecho se considera beneficioso, pues se considera que un falso negativo tiene una repercusión muy grave en relación con la seguridad de vuelo de estas aeronaves.

³<https://schiebel.net/products/camcopter-s-100/>

⁴<https://cessna.txtav.com>

El número de falsos positivos se ha visto incrementado especialmente en el entorno montañoso, donde la aeronave vuela a baja altura. En este caso, no sólo se detectaba el UAV, sino también aquellos elementos de la escena más cercanos que pueden suponer un peligro en la navegación.

En relación con el método de predicción de la colisión, cabe destacar que, aunque no se conozca la profundidad a la que se encuentra al UAV, sí que se puede estimar con precisión su dirección. De esta forma es posible estimar de forma fiable si el dron se encuentra en trayectoria de colisión. Por otro lado, la capacidad de predecir si el UAV está en trayectoria de colisión no implica que seamos capaces de conocer cuándo se producirá ese impacto. Esta capacidad se plantea como una extensión futura del presente trabajo que implicaría el reconocimiento del objeto y de su tamaño real en la escena. En los resultados mostrados, se obtiene que, en todas las secuencias en trayectoria de colisión el algoritmo ha sido capaz de emitir una alerta con una antelación de 8 segundos, tiempo suficiente para realizar un procedimiento de evasión.

En cuanto a trabajos futuros, la información obtenida por el método propuesto resulta de interés para integrarla en sistemas de “sense and avoid”. Para ello, habría que incorporar un método de planificación de trayectorias con el fin de eludir la colisión.

Agradecimientos

Este trabajo ha sido financiado por la empresa Abionica Solutions S.L.P. al amparo del contrato: “Empleo de algoritmos para conciencia situacional en vuelo mediante visión artificial”, ABIONICA1.21T. Además, esta publicación forma parte del proyecto TED2021-130901B-I00, financiado por MCI-N/AEI/10.13039/501100011033 y por la Unión Europea “Next-GenerationE”/PRTR” y del proyecto PROMETEO/2021/075 financiado por la Generalitat Valenciana.

Tabla 1: Resultados de “precision” y “recall” (en tanto por uno) para cada una de las secuencias que conforman el conjunto de datos (véase el apartado 4.1).

Detección de UAVs					
Modelo de UAV		Cessna		Camcopter	
Entorno	Sec.	Precision	Recall	Precision	Recall
Crop plains	1	0.99	1.00	1.00	1.00
	2	0.99	1.00	1.00	1.00
	3	1.00	1.00	1.00	1.00
	4	1.00	1.00	1.00	0.77
	5	1.00	1.00	1.00	0.77
	6	1.00	0.99	1.00	1.00
	7	1.00	0.96	1.00	0.68
	8	1.00	1.00	1.00	0.92
	9	1.00	1.00	1.00	1.00
	10	1.00	1.00	1.00	1.00
Rocky mountains	1	0.78	1.00	0.82	1.00
	2	0.84	1.00	0.83	1.00
	3	0.76	1.00	0.76	1.00
	4	0.84	1.00	0.83	1.00
	5	0.87	1.00	0.84	1.00
	6	0.94	1.00	0.86	1.00
	7	0.93	1.00	0.90	1.00
	8	0.89	1.00	0.72	1.00
	9	0.27	1.00	0.65	1.00
	10	0.71	1.00	0.70	1.00

Tabla 2: Resultados de predicción de la colisión (sobre 1). Esta evaluación se ha realizado teniendo en consideración las diferentes secuencias de manera completa y en los últimos 8 segundos. Resultado esperado: “0” si no colisiona y “1” si colisiona).

Predicción de la colisión						
UAV		Cessna		Camcopter		Res. esperado
Entorno	Sec.	R_G	R_8	R_G	R_8	
Crop plains	1	0.28	0.11	0.24	0.06	0
	2	0.45	0.41	0.34	0.30	0
	3	0.80	0.81	0.96	0.96	1
	4	0.80	0.80	0.71	0.93	1
	5	0.88	0.89	0.68	0.88	1
	6	0.03	0.05	0.12	0.00	0
	7	0.12	0.08	0.09	0.00	0
	8	0.52	0.53	0.84	1.00	1
	9	0.00	0.00	0.37	0.37	0
	10	0.40	0.40	0.03	0.03	0
Rocky mountains	1	0.00	0.00	0.00	0.00	0
	2	0.45	0.42	0.02	0.02	0
	3	0.96	0.97	0.79	0.79	1
	4	0.55	0.55	0.70	0.70	1
	5	0.78	0.79	0.67	0.67	1
	6	0.13	0.07	0.10	0.15	0
	7	0.08	0.00	0.09	0.00	0
	8	0.44	0.51	0.51	0.59	1
	9	0.29	0.29	0.54	0.54	0
	10	0.49	0.49	0.09	0.09	0

Referencias

Agarwal, A., Gupta, S., Singh, D. K., 2016. Review of optical flow technique for moving object detection. In: 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I). pp. 409–413.

Al-Kaff, A., García, F., Martín, D., De La Escalera, A., Armingol, J. M., 2017. Obstacle detection and avoidance system based on monocular camera and size expansion algorithm for UAVs. *Sensors* 17 (5).

Benedek, C., Majdik, A., Nagy, B., Rozsa, Z., Sziranyi, T., 2021. Positioning and perception in lidar point clouds. *Digital Signal Processing* 119, 103193.

Christnacher, F., Hengy, S., Laurenzis, M., Matwyschuk, A., Naz, P., Schertzer, S., Schmitt, G., 2016. Optical and acoustical uav detection. In: *Security + Defence*.

Deniz, O., Bueno, G., Bermejo, E., Sukthankar, R., 2011. Fast and accurate global motion compensation. *Pattern Recognition* 44 (12), 2887–2901.

Hu, Y., Wu, X., Zheng, G., Liu, X., 2019. Object detection of uav for anti-uav based on improved yolo v3. In: 2019 Chinese Control Conference (CCC). pp. 8386–8390.

Kurnianggoro, L., Shahbaz, A., Jo, K.-H., 2016. Dense optical flow in stabilized scenes for moving object detection from a moving camera. In: 2016 16th International Conference on Control, Automation and Systems (ICCAS). pp. 704–708.

Li, J., Ye, D. H., Chung, T., Kolsch, M., Wachs, J., Bouman, C., 2016. Multi-target detection and tracking from a single camera in Unmanned Aerial Vehicles (UAVs). In: 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). pp. 4992–4997.

Mori, T., Scherer, S., 2013. First results in detecting and avoiding frontal obstacles from a monocular camera for micro unmanned aerial vehicles. In: 2013 IEEE International Conference on Robotics and Automation. pp. 1750–1757.

Piccardi, M., 2004. Background subtraction techniques: a review. In: 2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583). Vol. 4. pp. 3099–3104 vol.4.

Sepehr, A., Homayoun, M. N., 2014. Optical flow based moving object detection and tracking for traffic surveillance. In: *International Conference on E-Business and E-Government*.

Wu, Z., Suresh, K., Narayanan, P., Xu, H., Kwon, H., Wang, Z., October 2019. Delving into robust object detection from unmanned aerial vehicles: A deep nuisance disentanglement approach. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*.