

Clasificación de vegetación mediante Random Forest y datos espectrales RGB adquiridos con un vehículo aéreo no tripulado (VANT) en un bosque de *Juniperus*

Vegetation classification using Random Forest and RGB spectral data acquired with an unmanned aerial vehicle (UAV) in a *Juniperus* forest

Buendía-Rodríguez, Enrique ¹, Hernández-Ramos, Adrián², Casimiro Ordoñez-Prado³, Jonathan Hernández-Ramos⁴ y Julio César Ríos-Saucedo⁵

¹ Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP)-Campo Experimental Valle de México.

² INIFAP-Campo Experimental Saltillo.

³ INIFAP- Campo Experimental San Martinito.

⁴ INIFAP-Campo Experimental Bajío.

⁵ INIFAP-Campo Experimental Valle del Guadiana.

*Autor para correspondencia: j_riosaucedo@hotmail.com

RESUMEN

La utilización de imágenes de alta resolución espacial RGB tomadas con vehículo aéreo no tripulado (VANT) generan información precisa y actualizada de alta resolución espacial, que permite observar detalladamente las condiciones de la vegetación. Por lo que, el objetivo fue clasificar especies forestales en un bosque dominado por *Juniperus* sp. en imágenes RGB tomas con un VANT de bajo costo, utilizando el algoritmo de aprendizaje automático *Random Forest* (RF). El área de estudio se ubica en un bosque de *Juniperus* en el municipio de Atlangatepec, Tlaxcala. Las imágenes RGB de alta resolución fueron adquiridas con una cámara 4k RGB de 20 mp, con sensor CMOS de 1/2.3" montada en un DJI® Mavic 2 pro. Se generó un Ortomosaico con resolución espacial de 5 cm por pixel, éste fue separó en bandas de coloración RGB y se generaron los índices GLI, VARI y Vlgreen. Como resultado se logró clasificar la vegetación de un bosque de *Juniperus*, diferenciando adecuadamente la cobertura del suelo presente en la zona de estudio con una precisión global del 77.88 % y un índice Kappa de 0.7308, destacando potencial para discriminar arbolado de *Juniperus* vivo y muerto, con una exactitud de 84 % y 68.8 %, respectivamente. Con la utilización de imágenes de alta resolución RGB tomadas con un VANT y procesadas con *Random Forest* pueden ser utilizadas para determinar el tipo de cobertura vegetal que contiene un bosque natural del estado de Tlaxcala.

Palabras clave: Árboles muertos, dron, *Juniperus deppeana*, aprendizaje automático.

ABSTRACT

The use of high spatial resolution RGB images taken with an unmanned aerial vehicle (UAV) generates accurate and updated information of high spatial resolution, which allows detailed observation of vegetation conditions. Therefore, the objective was to classify forest species in a forest dominated by *Juniperus* sp. in RGB images taken with a low-cost UAV, using the Random Forest (RF) machine learning algorithm. The study area is located in a *Juniperus* forest in the municipality of Atlangatepec, Tlaxcala. High resolution RGB images were acquired with a 20 mp 4k RGB camera with 1/2.3" CMOS sensor mounted on a DJI® Mavic 2 pro. An Orthomosaic with spatial resolution of 5 cm per pixel was generated, this was separated into RGB coloration bands and GLI, VARI and Vlgreen indices were generated. As a result, it was possible to classify the vegetation of a *Juniperus* forest, adequately differentiating the ground cover present in the study area with an overall accuracy of 77.88 % and a Kappa index of 0.7308, highlighting the potential to discriminate living and dead *Juniperus* trees, with an accuracy of 84 % and 68.8 %, respectively. With the use of high resolution RGB images taken with a UAV and processed with Random Forest can be used to determine the type of vegetation cover that contains a forest. a natural forest in the state of Tlaxcala.

Key words: Dead trees, drone, *Juniperus deppeana*, machine learning.

INTRODUCCIÓN

Los ecosistemas forestales cubren aproximadamente un tercio de la superficie terrestre de la Tierra (FAO, 2020) proporcionando innumerables y sustanciales servicios ambientales o ecosistémicos. Por lo tanto, existe un gran interés en obtener información sobre el estado de conservación y distribución de estos ecosistemas forestales. En México, el género *Juniperus* es el segundo de coníferas más diverso en el mundo después del género *Pinus*. Se conocen 16 especies, de las cuales *Juniperus deppeana* Steud. y *Juniperus flaccida* Schldtl. son las de mayor distribución (Farjon, 2005). El taxón *J. deppeana* forma bosques que se distribuyen en la Sierra Madre Occidental, el Eje Volcánico Transversal y una franja entre Perote, Veracruz y Apizaco, Tlaxcala que cubre importantes extensiones (Herrera y Nieto de Pascual, 2020).

En el estado de Tlaxcala se localizan bosques de *J. deppeana* distribuidas en poblaciones pequeñas y fragmentadas que enfrentan un alto riesgo de pertenecer al listado de especie en estatus de amenazada. En su área de distribución natural son constantemente asediadas por el clandestinaje, cambios de uso del suelo para la agricultura, perturbaciones naturales o antropogénicas, usos de la madera para elaboración de muebles, ornamental, medicinal, entre otros. Por lo que es necesario cuantificar su distribución para así poder determinar las pérdidas del arbolado, ocasionado por diferentes factores, que resulta difícil si no se cuenta con metodologías que minimicen el tiempo y el costo de su evaluación.

La eficiencia de la tecnología de teledetección transportada por pequeños sistemas aéreos pilotados remotamente (RPAS del inglés Remotely Piloted Aircraft System) o también denominados vehículos aéreos no tripulados (VANT), comúnmente llamados drones son una alternativa viable para obtener información geoespacial sobre la cobertura del suelo (Guevara-Bonilla et al., 2020). Por otro lado, los procesos fotogramétricos que utilizan imágenes de alta resolución espacial tomadas con drones generan información precisa y actualizada que permite observar detalladamente las condiciones de la vegetación (Tang & Shao,

2015; Fassnacht et al., 2016). Este tipo de información es fundamental para la planificación de los recursos forestales y su aplicación práctica (Cárdenas-Tristán et al., 2013).

La teledetección con VANT tiene un gran potencial para la detección de los diferentes tipos de vegetación en diferentes paisajes, incluyendo los ambientes urbanos complejos, gracias a las imágenes de muy alta resolución espacial adquiridas a baja altitud (Feng et al., 2015). Debido a las restricciones de capacidad de carga útil, las cámaras digitales disponibles en el mercado se utilizan ampliamente en vehículos aéreos no tripulados de tamaño mediano y pequeño. Una técnica que ha sido ampliamente utilizada, por lo menos en aplicaciones de teledetección por satélite es *Random Forest*, pero su uso en la clasificación de imágenes tomadas desde un VANT no está suficientemente documentado (Estrada et al., 2022).

Por lo que, con información de alta resolución espacial RGB obtenida mediante una VANT además de una técnica aprendizaje automático (*Random Forest*), contribuirá de manera significativamente a conocer la distribución geoespacial de las especies arbóreas en un bosque de *Juniperus*. Por lo que, en este estudio se planteó como objetivo clasificar especies forestales en un bosque dominado por *Juniperus* sp. en imágenes RGB tomas con un VANT de bajo costo, utilizando el algoritmo de aprendizaje automático *Random Forest* (RF).

MATERIALES Y MÉTODOS

Área de estudio: El estudio se llevó a cabo en San Pedro Ecatepec, municipio de Atlangatepec y se localiza al norte del estado colindando con el municipio de Tlaxco, del estado de Tlaxcala; Tiene una altitud promedio de 2,560 m; y se encuentra entre las coordenadas 19° 32' 50.95" latitud Norte y 98° 08' 22.45" longitud Oeste (Figura 1). El clima es templado subhúmedo con lluvias en verano entre 600 – 700 mm. La temperatura promedio máxima anual registrada es de 20.7 grados centígrados.




Figura 1. Localización geográfica del área de estudio

La vegetación correspondiente al área está compuesta principalmente por bosque de sabino, el cual en la mayoría de los casos se encuentra fuertemente perturbado o bien ha sido desplazado por la agricultura. La especie dominante es el sabino (*Juniperus deppena* Steud.) y cuando la densidad del arbolado es baja, se asocian otras especies de árboles, arbustos y hierbas como: pirul (*Schinus molle* L.), tepozán (*Buddleia cordata* Kunth.), uña de gato (*Mimosa biuncifera* Benth), chicalote blanco (*Argemone platyceras* Link & Otto), lengua de vaca (*Reseda luteola* L.), maguey pulquero (*Agave salmiana* Otto ex Salm-Dyck), varias especies de nopales (*Opuntia* spp.), gobernadora (*Brickelia veronicifolia* (Kunth) Gray), abrojo (*Adolphia infesta* (Kunth) Meisn) y capulín (*Prunus serótina* Ehrh.), así como zacate lobero (*Lycurus phleoides* Kunth). Es muy común encontrar este bosque asociado a elementos propios del matorral xerófito y bosque de encino. Además de algunas especies de pino que se han introducido como parte de las reforestaciones (INEGI, 2010; Atlangatepec, 2023).

Toma de datos RGB: La información fue recolectada con una cámara 4k RGB de 20 megapíxeles y 30 fps, con sensor CMOS de 1/2.3"

montada en un dron DJI® Mavic 2 pro. El plan de vuelo se realizó en el software Pix4Dcapture® a doble grid con una sobreposición del 75 % entre líneas de vuelo y entre fotografías, se definió una altura de vuelo de 100 m sobre la superficie del terreno. Con la información recolectada de 362 fotografías aéreas, se generó un ortomosaico que cubrió aproximadamente 34 ha del bosque de *Juniperus*. El proceso fotogramétrico se realizó en el software Pix4Dmapper®, se utilizó la información completa de las fotografías aéreas del dron y se estableció una resolución espacial de 5 cm para la salida del ortomosaico.

Análisis de la información: Tomando como base el ortomosaico, se ingresó la imagen digital del área de estudio en formato TIFF y esta fue descompuesta en las capas rojo, verde y azul (RGB por sus acrónimos en inglés), este procedimiento se llevó a cabo en el software R versión 4.3.1 (R Core Team, 2023) y su interfaz RStudio® versión 2023.06.0 Build 421 (Rstudio Core Team, 2023). Con las capas separadas se generaron los índices GLI (Green Leaf Index, por sus siglas en inglés; Ec. 1), VARI (Visible Atmospherically Resistant Indices Green, por sus siglas en inglés; Ec. 2) y VIgreen (Vegetation Identify Green, por sus siglas en inglés; Ec. 3) (Soon et al., 2019).

$$GLI = \frac{2\text{Green} - \text{Red} - \text{Blue}}{2\text{Green} + \text{Red} + \text{Blue}} \quad \text{Ec.1}$$

$$VARI = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red} - \text{Blue}} \quad \text{Ec. 2}$$

$$VIgreen = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red}} \quad \text{Ec. 3}$$

Para la clasificación de cobertura del suelo se generaron campos de entrenamiento de las siguientes clases de vegetación: agua [1], árbol muerto [2], *Juniperus* [3], pastizal [4], suelo desnudo 1 [5] y suelo desnudo 2 [6]. Estos campos de entrenamiento fueron utilizados para extraer la información del grupo ráster generado con las capas RGB y los índices de vegetación. Con la información de cada clase de cobertura del suelo se realizó una clasificación supervisada empleando el algoritmo de aprendizaje automático RF. Este proceso se realizó en el software R®, versión 4.3.1 (R Core Team, 2023), las rutinas generadas fueron creadas bajo el software R-Studio® 2023.06.0 Build

421 (RStudio Team, 2023) y la librería randomForest® (Liaw & Wiener, 2002).

El modelo RF que es una combinación de árboles predictores de tal modo que cada árbol depende de los valores de un vector aleatorio de la muestra de manera independiente y con la misma la distribución de todos los árboles en el bosque. Este algoritmo mejora la precisión en la clasificación mediante la incorporación de aleatoriedad en la construcción de cada clasificador individual. Esta aleatorización puede introducirse en la partición del espacio (construcción del árbol), así como en la muestra de entrenamiento (Breiman, 2001).

La clasificación del uso de suelo fue evaluado a través de la precisión global y del índice Kappa. Además, se estimaron los errores de comisión y de omisión para cada clase de cobertura. La contribución de cada capa en la mejora de la precisión del modelo fue evaluada mediante la disminución media del coeficiente de Gini. Este coeficiente es una medida de cómo cada variable contribuye a la homogeneidad de los nodos del bosque aleatorio resultante. Cuanto mayor sea el valor de la precisión de disminución media o la puntuación de Gini de disminución media, mayor será la importancia de la variable en el modelo. Finalmente, el modelo de predicción RF resultante fue transferido al área total de estudio, con lo que se generó un mapa de cobertura de la vegetación.

RESULTADOS Y DISCUSIÓN

La extracción de las bandas individuales RGB del Ortomosaico de las imágenes recopiladas con VANT se realizaron de forma correcta entre escalas de intensidad de 0 a 255 (Banda1= Red, Banda2= Green, y Banda3= Blue); de igual manera, se construyeron a partir de estas bandas tres índices de vegetación (Banda3= GLI, Banda4= VARI y Banda5= Vlgreen) (Figura 2).

Con estos datos espectrales y los seis tipos de coberturas determinadas se realizó la clasificación mediante la técnica de *Random Forest*, en la que se obtuvo que la clase con mayor porcentaje de precisión fue Agua con un 93.8 %, seguido de la clase de Juniperus con un 84 %. Además, las dos clases de suelo desnudo (1 y 2) tuvieron una precisión de 66.7 y 73.3 %, respectivamente. Mientras que, la clase de árbol muerto con 68.8 % y pastizal un 76.9 %. La exactitud global fue de 77.88 % e índice Kappa de 0.73 (Tabla 1). La clase que mayor confusión tuvo fue la de árboles muertos que se confunde con el suelo

desnudo y pastizal; y suelo desnudo 1 con Agua, Pastizal, Árbol Muerto, Suelo desnudo 2 (Figura 3).




Figura 2. Imagen de las Bandas RGB e índice trabajados. Donde: Banda1= Rojo, Banda2= Verde, Banda3= Azul, Banda4= Índice de verdor (GLI), Banda5= Índice De Resistencia Atmosféricamente Visible (VARI) y Banda6= Identificador de la Vegetación Verde (Vlgreen).

Tabla 1. Matriz de confusión resultado del entrenamiento del modelo Random Forest.

Clave	Clase	Agua	Árbol Muerto	Juniperus	Pastizal	Suelo Desnudo 1	Suelo Desnudo 2	Error (%)	Precisión (%)
1	Agua	15	0	0	0	1	0	6.3	93.8
2	Árbol Muerto	0	11	0	1	2	2	31.3	68.8
3	Juniperus	0	0	21	4	0	0	16.0	84.0
4	Pastizal	0	0	4	20	1	1	23.1	76.9
5	Suelo Desnudo 1	1	2	0	1	10	1	33.3	66.7
6	Suelo Desnudo 2	0	3	0	1	0	11	26.7	73.3
Error de estimación:		22.12%		Precisión general:		77.88 %		Índice Kappa: 0.73	




Figura 3. Errores de omisión y de comisión obtenidos mediante la matriz de confusión.

Con el modelo entrenado se realizó la predicción total del área de estudio generando así el mapa de clasificación de las siete clases de coberturas definidas en las 34 ha del bosque de *Juniperus* sobrevoladas (Figura 4). Con ello, se puede observar que las imágenes RGB de alta resolución espacial sirven para realizar una clasificación a detalle de la zona estudiada por lo que recomendaría para estudios de mayor detalla, por ejemplo, la determinación de aboles muertos o la cuantificación de cobertura del arbolado.




Figura 4. Imagen clasificada con la técnica de Random Forest. Donde: 1 es agua, 2 es Árbol muerto, 3 es *Juniperus*, 4 es pastizal, 5 es Suelo desnudo 1 y 6 es Suelo desnudo 2.

Las bandas que mayor contribuyen a la clasificación fueron la Banda4 (índice foliar de verdor, GVI) con un 30 %, seguido de la Banda3 (Azul) con un 26 %. En contraste, las bandas restantes contribuyen en menor medida (<24 %) (Figura 5a). Las de mayor aporte se graficaron mediante una gráfica de elipses, agrupando la clase de cobertura clasificada, donde se observa que la clase de *Juniperus* se separa adecuadamente de árboles muertos y los dos tipos de suelos, pero se encuentra traslapada la información con la clase de Pastizal, a pesar de ello, estas dos bandas separan los grupos (Figura 5b).




Figura 6. Contribución de las bandas e índices utilizados mediante el coeficiente Gini en el proceso de clasificación (a) y gráfica de elipses generadas a partir de las bandas con mayor importancia en la clasificación con el modelo *Random Forest* (b).

Al realizar un análisis de correlaciones entre las capas (Figura 6), se observó que las bandas con mayor incidencia para la definición de las categorías fueron las bandas 3, 4 y 5 que corresponden al Blue, GVI y VARI, respectivamente; lo que concuerda con el coeficiente Gini obtenido en el proceso de clasificación. Al utilizar la Banda4 y la Banda5 se observa que las clases de uso de suelo son identificables con un alto grado de correlación (<0.8), solo la clase de *Juniperus* con un 0.626. En cambio, la correlación entre las bandas 5 y 3, no representa mayor correlación entre coberturas, en general, tiene una correlación menor a 0.56, exceptuando el suelo desnudo 2 y el arbolado muerto (0.973 y 0.719, resp). La correlación entre la Banda3 y la Banda4 son superiores a 0.5, solo el Agua que tiene un valor muy bajo (0.150).




Figura 6. Análisis de correspondencia entre las bandas que mayor colaboran para la definición de clases (Banda3, Banda4 y Banda5).

En cuanto a las categorías de uso de suelo utilizadas, el Suelo desnudo 2, en todos los casos tiene una correlación >0.8 , y el arbolado muerto con un valor >0.59 , lo que se ve reflejado en una buena identificación en la clasificación. De modo contrario, la clase de agua tiene una correlación menor a 0.3 cuando se comparan las Banda3 con la Banda4 y la Banda5. El pastizal y el Juniperus se correlaciona de buena manera cuando se utiliza la Banda4 con la Banda5 y la Banda3 con valores por encima de 0.55 (Figura 6).

La Banda4 que representa el índice GLI resultaba ser la técnica más adecuada para resaltar la vegetación en zonas forestales, basándose en su sensibilidad para detectar las diferencias entre vegetación y no vegetación como lo comentan (Soon *et al.*, 2019). En general, la combinación de las tres bandas RGB y los tres índices incorporados como bandas proporcionan una buena clasificación de los diferentes tipos de vegetación presentes en el área de estudio.

Los resultados obtenidos son congruentes con los reportado por Zhou *et al.* (2021) quienes con imágenes RGB obtenidas con un dron similar y RF, clasifican la vegetación de humedales con una precisión general del 73.66 % y un índice Kappa de 0.70. Por otra parte, Furukawa *et al.* (2019) compararon las imágenes RGB y las multispectrales para clasificar material vegetativo vivo y muerto, si bien las preposiciones fueron mayores con multispectrales, también mencionan que las imágenes RGB tuvieron un mejor desempeño al utilizarse en condiciones de

nubosidad. Sus precisiones fueron del 49 % al 100 % para clases de vegetación materia muerta y vegetación. En su estudio indican que la mejor fecha para mapear la vegetación con RGB es en julio, por lo que es una variable que tomar en cuenta en futuros trabajos de investigación.

La incorporación de la técnica *Random Forest* de aprendizaje profundo en el procesamiento de imágenes RGB de alta resolución muestra un buen desempeño en la detección de cobertura de uso de suelo con un porcentaje mínimo de interpretaciones erróneas concordando con el estudio realizado por Feng *et al.* (2015). Además, con la adopción de *Random Forest* se puede reducir los inconvenientes de las cámaras digitales (RGB) disponibles en el mercado sin necesidad de utilizar una cámara o sensor multispectral.

CONCLUSIONES

Con la utilización de imágenes de alta resolución espacial RGB tomadas con un VANT, pueden ser utilizadas para determinar el tipo de cobertura vegetal que contiene un bosque natural del estado de Tlaxcala. Además, la incorporación de técnicas como *Random Forest* permitió mejorar la clasificación de vegetación de un bosque de juniperus, diferenciando adecuadamente los diferentes usos de suelo presentes en la zona de estudio con una precisión del 77.88 %, destacando que se puede identificar arbolado muerto, con un 68.8 % de exactitud.

LITERATURA CITADA

- Atlangatepec. (2023). Atlangatepec. Consultado 10 de enero 2023. <https://www.atlangatepec.gob.mx/tu-municipio/medio-fisico>.
- Breiman L. (2001). Random Forests. Machine Learning, 45: 5-32.
- Cárdenas Tristán, A., Treviño Garza, E.J., Aguirre Calderón, O.A., Jiménez Pérez, J., González Tagle, M.A., & Némiga, X.A. (2013). Uso de tecnologías espaciales para evaluar la calidad de muestras vectoriales de la producción de cartografía. Investigaciones Geográficas, 0(80), 111-128
- Estrada Z., A.V.; J. Cárdenas R.; J. V. Bejar S.; J. Ñaupari V. 2022. Estimación de la biomasa de una comunidad vegetal altoandina utilizando imágenes

- multiespectrales adquiridas con sensores remotos UAV y modelos de Regresión Lineal Múltiple, Máquina de Vectores Soporte y Bosques Aleatorios. *Scientia Agropecuaria* 13(3): 301-310.
- FAO. (2020). Global Forest Resources Assessment 2020 – Key findings, Rome. <https://doi.org/10.4060/ca8753en>.
- Farjon, A. (2005). A monograph of Cupressaceae and Sciadopitys. Ed. Royal Botanical Gardens, Kew. Richmond, Surrey, UK. 643 p.
- Fassnacht, F.E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L.T., Straub, C., Ghosh, A., 2016. Review of studies on tree species classification from remotely sensed data. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2016.08.013>.
- Feng, Q, J. Liu & J. Gong. (2015). UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. *Remote Sensing*, 7, 1074-1094; doi:10.3390/rs70101074
- Guevara-Bonilla, M., Meza-Leandro, A.S., Esquivel-Segura, E.A., Arias-Aguilar, D., Tapia-Arenas, A., & Masís-Meléndez, F. (2020). Uso de vehículos aéreos no tripulados (VANTs) para el monitoreo y manejo de los recursos naturales: una síntesis. *Revista Tecnología en Marcha*, 33 (4).
- Herrera M., L.G. y Nieto de Pascual C. C. (2020). Características estructurales y demográficas de *Juniperus deppeana* Steud. En dos localidades del estado de Tlaxcala. *Rev. Mexicana de Ciencias Forestales* 11(61). México. pp 124-151.
- INEGI. (2010). Compendio de información geográfica municipal 2010 Atlangatepec, Tlaxcala. Consultado 10 de enero 2023. https://www.inegi.org.mx/contenidos/app/mexicocifras/datos_geograficos/29/29003.pdf
- Liaw, A. & M. Wiener. (2002). Classification and Regression by randomForest. *R News* 2(3), 18–22.
- R Core Team. 2023. R: A language and environmental for statistical computing (version 4.3.1). Vienna, Austria. R Foundation for Statistical Computing. <http://www.R-project.org/> (29 de Septiembre de 2023).
- RStudio Team, 2023. RStudio: Integrated Development Environment for R (version 2023.06.0 Build 421), Boston, MA. <http://www.rstudio.com/>. (29 de September de 2023).
- Soon E., L., R. Ismail, W. Hashim, A. Baharum. (2019). The use of VARI, GLI, and VIgreen formulas in detecting vegetation in aerial images. *International Journal of Technology* 10(7): 1385-1394.
- Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forest Research*, 26, 791-797
- Zhou, R., Yang, C., Li, E., Cai, X., Yang, J., & Xia, Y. (2021). Object-based wetland vegetation classification using multi-feature selection of unoccupied aerial vehicle RGB imagery. *Remote Sensing*, 13(23), 4910. <https://doi.org/10.3390/rs13234910>
- Furukawa, F., Laneng, L. A., Ando, H., Yoshimura, N., Kaneko, M., & Morimoto, J. (2021). Comparison of RGB and multispectral unmanned aerial vehicle for monitoring vegetation coverage changes on a landslide area. *Drones*, 5(3), 97. <https://doi.org/10.3390/drones5030097>.