

Estimación de área foliar utilizando técnicas de procesamiento de imágenes

Una metodología simple, fiable y de bajo costo

M. Soledad Mieza¹, Federico D. Kovac¹ y Walter R. Cravero²

¹ Facultad de Ingeniería, UNLPam, General Pico. L.P. 6360, Argentina

² IFISUR, UNS y CONICET, Alem 1253, Bahía Blanca, Argentina
ageo@ing.unlpam.edu.ar

Abstract. En este trabajo se propone una metodología para estimar área foliar (**AF**), basada en técnicas de procesamiento digital de imágenes usualmente utilizadas en teledetección. La metodología se evaluó para hojas de girasol. El **AF** y el ampliamente difundido índice de área foliar (**IAF**), calculado a partir del anterior, se requieren para modelar, validar y predecir un número importante de variables de interés en distintas áreas del conocimiento. Se analizan en este trabajo todas las etapas, desde la adquisición de las imágenes a los métodos de procesamiento, así como la evaluación de la fiabilidad del método y, se diseñó, con especial detalle, una sección orientada a cuantificar adecuadamente la incertidumbre en la determinación del **AF**. El método propuesto es simple y robusto, las imágenes pueden adquirirse con cualquier cámara disponible y, para la estimación de superficie, pueden utilizarse una variedad de paquetes de software tanto comerciales como libres. La incerteza obtenida para la determinación del **AF** resultó inferior al 4% en la estimación de AF por planta. Cabe mencionar que todo el proceso se realiza a partir de las imágenes sin necesidad de datos del cultivo, climáticos, etc. Se proponen también alternativas semiautomáticas para la estimación de superficies que no presentan diferencias estadísticamente significativas con el diseño original.

Keywords: área foliar, clasificación digital, IAF, girasol, La Pampa

1 Introducción

El área foliar (**AF**) y, en particular, el índice de área foliar (**IAF**), una magnitud adimensional definida como la superficie total de hojas (**AF**) por unidad de superficie de suelo [1] son ampliamente utilizadas en modelos climáticos [2], ecológicos [3], así como para aplicaciones agronómicas. Una revisión detallada de estas últimas pueden encontrarse por ejemplo en [4].

Una clasificación de los métodos para obtener **AF** e **IAF** que puede realizarse es: métodos *in-situ*, mediante mediciones directas e indirectas, sobre la hojas propiamente dichas [5,6], o indirectamente mediante sensores remotos, como por ejemplo imágenes satelitales [7]. Ambos tipos de métodos presentan ventajas y desventajas; respecto de las mediciones locales éstas suelen ser más precisas y fiables pero puntuales y muy demandantes en términos de tiempo. En contraposición, los sensores remotos permiten realizar estimaciones regionales o a nivel de parcelas, son rápidos y no destructivos pero necesitan ser calibrados adecuadamente.

En este trabajo proponemos una metodología orientada a la estimación de **AF** para girasol *in-situ* basada en técnicas de procesamiento de imágenes.

Se seleccionó el cultivo de girasol (*Helianthus annuus L.*), dado que es una de las oleaginosas de mayor importancia en la zona de estudio, situada en La Pampa, así como en Argentina [8].

Algunos de los métodos propuestos en la bibliografía para la determinación de **AF** para girasol incluyen: ajustes mediante funciones polinómicas ([9],[10],[11]), instrumentos de medición local [12] y planímetros [5].

Se analizarán en este trabajo todas las etapas, desde la adquisición de las imágenes a los métodos de procesamiento, así como una evaluación de la fiabilidad del método, y la determinación de las incertezas en la determinación del **AF**. Se incluyen opciones que permiten simplificar la metodología para ser aplicada con fines operativos, y se comparan los resultados con ajustes de funciones polinómicas propuestas en la literatura [10].

2 Materiales y métodos

Se recolectaron ejemplares de girasol, en una parcela representativa, en la zona NE de La Pampa, en un establecimiento agrícola situado a 10 km al SE de General Pico. El muestreo se realizó en distintos estados fenológicos (R1, R4, R6, R7) a los efectos de contar con hojas de distintos tamaños y formas. Se realizó un muestreo al azar de dos ejemplares por fecha y por ambiente productivo (loma, media loma y bajo) [13, 14].

Las hojas se colocaron sobre una plancha de poliestireno expandido (telgopor) de 1m de lado, y se fotografiaron utilizando una cámara digital compacta. El tamaño resultante de los pixeles fue de 0.04 cm de lado.

En algunos casos debido al tamaño y cantidad de hojas debieron utilizarse dos planchas de telgopor por planta. Al conjunto de hojas perteneciente a cada planta la denominaremos *set*. Se fotografiaron 24 sets. Para ilustrar la metodología en este trabajo se seleccionaron 3 sets al azar que se presentan en la Fig. 1.




Fig. 1. Sets seleccionados para la estimación de IAF. Cada set comprende todas las hojas de una planta de girasol.

2.1 Estimación de AF mediante clasificación digital de imágenes.

Las correcciones de las distorsiones geométricas de las fotografías, como por ejemplo la forma ligeramente trapezoidal de las planchas de telgopor, que son cuadradas, y el ajuste en las dimensiones se realizó mediante el ajuste por puntos de control (GCP) [15]. Como GCP se utilizaron las esquinas de las planchas de telgopor. Para el remuestreo se seleccionó el método *vecino más cercano* dado que éste no modifica los valores radiométricos de los píxeles [16]. Para todas las etapas del procesamiento se utilizó el programa ERDAS Imagine 8.4 [17].

La clasificación es un proceso que permite asignar cada píxel de una imagen a una clase temática a partir de ciertos criterios preestablecidos [15]. Para analizar la separabilidad entre clases espectrales se realizó un análisis exploratorio de los datos mediante los histogramas de las fotos, y gráficos en el *espacio de características* (EC) [16]. Se utilizó la medida *transformed divergence* (TD) [18] para analizar cuantitativamente la separabilidad entre clases. La TD toma valores de 0 a 2000. Si $TD > 1900$ implica que las clases son completamente separables, para $1700 < TD < 1900$ la separabilidad es factible, y para $TD < 1700$ es probable exista confusión entre las clases espectrales [16].

Para la clasificación se utilizó una adaptación de un método híbrido propuesto por [19]. El método consta dos etapas: un método de agrupamiento no-supervisado mediante el algoritmo ISODATA (*The Iterative Self-Organizing Data Analysis Technique*) [20], para identificar y caracterizar estadísticamente las clases espectrales (valor medio ± 3 SE), y una clasificación supervisada para la asignación de los píxeles a las clases predefinidas. La clasificación supervisada se realizó en dos pasos: se aplicó el *método del paralelepípedo* [21], utilizando las firmas espectrales obtenidas en la etapa anterior, y el *método de máxima verosimilitud* [21], para aquellos píxeles cuyos DN se encontraran fuera de los límites de las clases definidas por el método del paralelepípedo.

Se obtuvo el mapa temático, resultado de la clasificación, donde cada píxel fue categorizado en dos clases, una clase perteneciente a las hojas y otra al fondo. Dado que

las dimensiones de los píxeles son conocidas, se calculó la superficie (**AF**) para la clase “hojas”.

2.2 Evaluación de la clasificación: fiabilidad e incerteza

Se evaluaron la fiabilidad de la clasificación, y la incerteza en la determinación del **AF**.

La fiabilidad da una medida del rendimiento de la clasificación. Se suele cuantificar mediante la proporción de píxeles correctamente asignados a las clases temáticas de interés. Se utilizó un muestreo aleatorio estratificado de 100 píxeles, y se calcularon las proporciones de los píxeles correctamente clasificados, en concordancia a las prácticas recomendadas [22].

Uno de los desafíos, de estimar superficies mediante clasificaciones digitales de imágenes, es obtener medidas de la incerteza de las estimaciones. En toda clasificación, incluso si las clases de interés son separables, y las firmas espectrales no presentan solapamiento, por el carácter intrínseco del tipo de archivo (raster), van a existir píxeles en los límites entre clases cuya respuesta espectral corresponda a una proporción de ambas (hojas y fondo en este caso), que no puedan asimilarse a las clases predefinidas. Estos píxeles suelen denominarse como *píxeles de borde* o *píxeles mixtos*. Por lo tanto, se propone como cota máxima para la incerteza ($I_{máx}$) (Ecuación 1), la relación entre la superficie de los píxeles fuera de los límites de las clases definidas por el método del paralelepípedo (**ASC**), en general coincidentes con los píxeles de borde, y el **AF** estimado mediante el método híbrido.

$$I_{máx}(\%) = \frac{ASC}{AF} * 100 \quad (1)$$

Donde:

ASC= área de los píxeles sin clasificar por el método del paralelepípedo

AF= área foliar (método híbrido)

2.3 Comparación con otros métodos

Se analizaron algoritmos semiautomáticos (clasificaciones no-supervisadas) que permitieran simplificar la metodología. Se probaron dos clasificadores ampliamente utilizados, ISODATA (*The Iterative Self-Organizing Data Analysis Technique*) [20] y *k-means* [23]. En este tipo de clasificador el software agrupa los píxeles en función de características espectrales similares que le son inherentes a la imagen [15].

Se realizó un ajuste mediante una función cuadrática del AF en función del ancho de las hojas (x) y se comparó con la propuesta por [10] mediante una prueba t apareada.

3 Resultados

A los efectos de presentar las distintas etapas de la metodología propuesta se utilizará el Set 1 de la Fig. 1.

En la Fig 2.a, se presenta la foto con la corrección geométrica aplicada. El RMSE obtenido para todos los sets de fotos fue inferior a medio pixel, que se condice con lo usualmente aceptado [16]

Del análisis exploratorio de los datos, los histogramas para cada banda en el espacio RGB, en la Fig 2.b, muestran que, para todas las bandas, existe una clara distribución bimodal, lo cual implica la presencia de dos clases espectrales potencialmente separables. Dado que las imágenes están codificadas en 8 bits, la primera moda estará asociada a las hojas, y la segunda al fondo blanco.

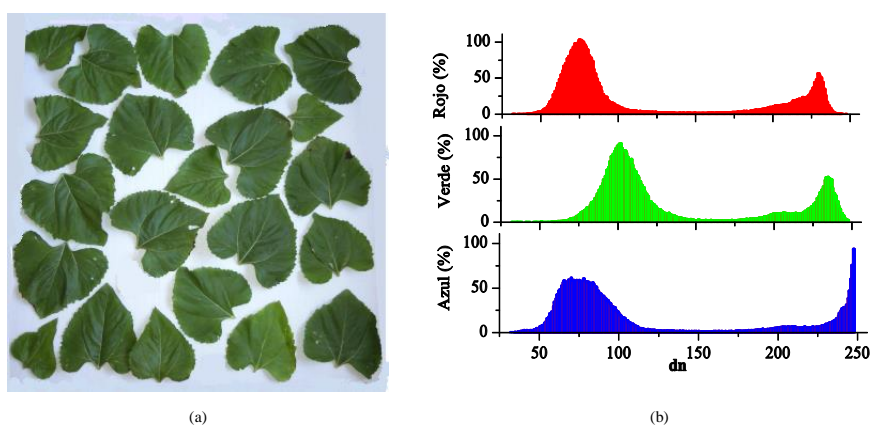


Fig. 2. (a) Foto con corrección geométrica aplicada (Set 1) y (b) Histograma para cada banda RGB

En la Fig. 3, se presentan en el EC, $G=f(R)$ en (a), $B=f(R)$ en (b) y $B=f(G)$ en (c). Los colores indican la abundancia de pixeles. En todos los gráficos pueden observarse dos zonas con agrupamientos naturales de pixeles[15] que podrán relacionarse *a-posteriori* con clases de interés.




Fig. 3. Representación en el espacio de características, sub-espacio RG (a), RB (b) y GB (c).

La separabilidad fue confirmada por la medida de TD ($TD = 2000$).

En la Tabla 1 se presentan las estadísticas para cada agrupamiento natural (clase).

Tabla 1. Descripción estadística de los agrupamientos naturales para cada set de hojas

Clase	Banda	Set 1		Set 2		Set 3	
		Media [DN]	SE	Media [DN]	SE	Media [DN]	SE
hojas	R	72	15	49	16	65	15
	G	100	17	72	18	75	15
	B	55	19	31	17	39	15
fondo	R	208	21	177	17	207	15
	G	221	21	192	18	207	15
	B	230	28	211	24	213	21

En las imágenes de la Fig. 3 se incluyen las elipses asociadas a la definición de cada clase a partir de la Tabla 1 (valor medio \pm 3 SE).

En la Fig. 4 se presenta el mapa temático resultante de la clasificación híbrida aplicada, donde se observan los píxeles (en gris) asignados a la clase que corresponde a las hojas, y en color blanco los del fondo.




Fig. 4. Mapa temático resultante de la clasificación híbrida.

El análisis de fiabilidad mostró que el 100% de los píxeles de la muestra estaban correctamente clasificados.

En la Tabla 2, se presentan los resultados de la estimación del **AF** para cada set de hojas, la superficie correspondiente a los píxeles sin clasificar por el método del paralelepípedo (**ASC**), y la incerteza máxima según Ecuación 1.

Tabla 2. **AF**, área sin clasificar por el método del paralelepípedo (**ASC**) e incerteza máxima (**I_{máx}**) en la estimación del **AF**

Set	AF cm²	ASC cm²	I_{máx} %
1	6960	276	3.9
2	3909	116	2.9
3	9760	135	1.4

En la Fig. 5, se muestran, para dos zonas, los píxeles sin clasificar asociados a la incerteza. Como era esperable, existen píxeles mixtos en los bordes de las hojas (imagen a la derecha), y se observan también algunos asociados a las nervaduras. En la imagen de la izquierda se observan píxeles sin clasificar debido a la presencia de sombras en la imagen original.



Fig. 5. Pixeles asociados a la incerteza en la determinación del área, pixeles de borde (a la derecha), e incorrectamente clasificados por efecto sombra (a la izquierda).

Los resultados de la comparación del método híbrido con los métodos de clasificación no supervisada (ISODATA y *k-means*) se presentan en la Tabla 3.

Tabla 3. Diferencias porcentuales (en valor absoluto) de la estimación de **AF** mediante los algoritmos ISODATA y *k-means* respecto del método híbrido.

Set	Δ AF (%)	
	ISODATA	k-means
1	0.5	0.2
2	0.6	0.15
3	0.2	0.08

En ambos casos el error porcentual es aproximadamente un orden de magnitud menor que la incerteza esperada en la estimación del **AF**. Entre ambos, se observa un leve mejor desempeño del algoritmo *k-means*.

Se ajustaron los datos de **AF** con el ancho máximo de las hojas (**x**) mediante una función cuadrática (Ecuación 2):

$$y = 0.47x^2 + 5.7x - 23.4 \quad (2)$$

La función de la Ecuación 2, las propuestas por [10] y los datos, se presentan en la Fig. 6.




Fig. 6. AF para cada hoja en función del ancho máximo. Gráficos de la función de ajuste cuadrática con los datos obtenidos en este trabajo y las propuestas por [10].

La prueba t apareada mostró que existen diferencias estadísticamente significativas para cuando $x > 21$ cm, no así para $x < 21$ cm.

4 Discusión

Respecto de la adquisición de fotografías, podrían utilizarse otros tipos de cámaras, desde profesionales a cámaras de teléfonos móviles. Se recomienda procurar ubicar la cámara en forma perpendicular a la superficie en la que se coloquen las hojas, para evitar deformaciones geométricas que pueden resultar complejas de corregir, así como proveer iluminación uniforme para minimizar la presencia de sombras que puedan generar confusión de las firmas espectrales.

La incerteza en la determinación de superficies estará dada, como se mostró en el trabajo, por las características intrínsecas de las imágenes raster, que son inevitables, y que estará relacionada mayoritariamente al tamaño de pixel de las fotos, y con la forma y dimensiones de las hojas. Como regla general, dado que los pixeles mixtos son mayoritariamente aquellos localizados en los bordes, la incertidumbre en la determinación estará dada por la relación perímetro/área de las hojas en consideración.

En la Fig. 7 se presenta la relación perímetro/área en función del área para las hojas del Set 1. Como era esperable, la relación disminuye a medida que aumenta la superficie de las hojas, por lo tanto la incerteza para hojas individuales, en general, será mayor para

las hojas más pequeñas. Se presenta también la comparación de la relación perímetro/superficie con la de un círculo de igual superficie. De las figuras geométricas el círculo es la que presenta la menor relación perímetro/superficie.




Fig. 7. Relación perímetro/área en función del área para las hojas del Set 1 y para un círculo de igual superficie.

Para analizar el efecto de la forma de las hojas, en la incerteza en la determinación de áreas, se compararon dos figuras ideales (un círculo de área A y perímetro P_c , y una figura irregular de igual área (A), y perímetro $P_i=1.5 P_c$) con una hoja del Set 1 (ubicada en la esquina superior derecha de la plancha de telgopor) de igual superficie A , y perímetro P_g (Fig. 8). Si se considera que la incerteza en la determinación se debe solo un pixel de espesor en todo el perímetro de cada figura, entonces las incertezas en la estimación de áreas de la figura irregular (I_i), y de la hoja (I_g), estarán relacionadas por el mismo factor que los perímetros cuando se las compara con la del círculo (I_c). En general, la incerteza en la determinación de áreas será mayor cuanto más compleja sea la forma de las hojas.




Fig. 8. Comparación de la incerteza en la estimación de superficies para un círculo, una superficie irregular ideal y una hoja de igual superficie (A). Se indican los perímetros (P) e Incertezas en la estimación de áreas (I). Subíndices: c (círculo), i (figura irregular), g (hoja girasol)

La otra fuente de incerteza, en este trabajo, se debió a la presencia de sombras en las fotos originales, efecto que podrá minimizarse con la iluminación adecuada.

Esta metodología no está limitada al cultivo de girasol, podrá utilizarse sobre otros tipos de hojas, y solo depende del análisis y procesamiento de las imágenes digitales, lo que la hace independiente de condiciones del cultivo, ambientales, densidades de siembra entre otras.

Respecto del procesamiento de las fotos, pueden utilizarse para todas las etapas programas libres, en particular aquellos orientados al procesamiento de imágenes satelitales, como por ejemplo QGIS [24] ó SoPI [25].

Para la clasificación, como se demuestra en el trabajo, pueden utilizarse clasificadores del tipo no-supervisados que simplifican notoriamente la metodología, que se limitaría en ese caso a: corrección geométrica→clasificación no-supervisada→cálculo de área.

Los datos recopilados en este trabajo también permitieron ajustar una curva local de **AF** en función al ancho máximo de las hojas (Fig. 6), pero aún resta analizar la validez de esta curva para otras condiciones locales.

Una desventaja, que se puede mencionar, de esta metodología es su carácter destructivo; una opción no destructiva consistiría en adquirir las fotografías sobre una lámina graduada in-situ (Fig. 9).




Fig. 9. Opción no destructiva para la adquisición de fotografías.

5 Conclusiones

En este trabajo se propone una metodología para estimar **AF**, en particular para girasol, basada en técnicas de procesamiento digital de imágenes.

El método propuesto es simple y robusto, las imágenes pueden adquirirse con cualquier cámara disponible, y la estimación de superficies realizarse con una variedad de paquetes de software tanto comerciales como libres. Un aspecto a destacar es la inclusión de una etapa para determinar la incerteza en la estimación del **AF** que se realiza a

partir de las mismas imágenes sin requerir datos particulares de las condiciones del cultivo. La incerteza obtenida para la determinación del **AF** en todos los casos resultó inferior al 4% por planta, y podría reducirse aún más corrigiendo factores como la iluminación al momento de la adquisición de las imágenes.

Se proponen también alternativas para simplificar la etapa de clasificación, utilizando clasificaciones no-supervisadas, cuyo rendimiento fue similar a la propuesta original. Las diferencia en la estimación del **AF** entre los diversos métodos fue inferior al **0.2 %**, muy por debajo de la incerteza estimada.

Agradecimientos

Agradecemos al Ing. Agr. Daniel E. Martínez (*in memoriam*) y al Ing. Agr. Agustín Picardi, asesores técnicos del establecimiento agropecuario donde realizamos el trabajo de campo por sus invaluable aportes y sugerencias, así también como al propietario del mismo.

Este trabajo fue financiado por la Facultad de Ingeniería, UNLPam.

Referencias

1. WATSON, D.J.: Comparative Physiological Studies on the Growth of Field Crops. I. Variation in Net Assimilation Rate and Leaf Area between Species and Varieties and between Year. *Ann. Bot.* 11, 41–76 (1947). <https://doi.org/10.1093/oxfordjournals.aob.a083148>.
2. Gobron, N.: LEAF AREA INDEX (LAI). In: *Terrestrial Essential Climate Variables*. p. 2. FAO (2008).
3. Fang, H., Liang, S.: Leaf Area Index Models. In: Jørgensen, S.E. and Fath, B.D.B.T.-E. of E. (eds.) *Reference Module in Earth Systems and Environmental Sciences*. pp. 2139–2148. Academic Press, Oxford (2008). <https://doi.org/https://doi.org/10.1016/B978-008045405-4.00190-7>.
4. Gebbers, R., Ehlert, D., Adamek, R.: Rapid mapping of the leaf area index in agricultural crops. *Agron. J.* 103, 1532–1541 (2011). <https://doi.org/10.2134/agronj2011.0201>.
5. Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M., Baret, F.: Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. *Agric. For. Meteorol.* 121, 19–35 (2004). <https://doi.org/10.1016/j.agrformet.2003.08.027>.
6. Bréda, N.J.J.: Ground-based measurements of leaf area index: A review of methods, instruments and current controversies. *J. Exp. Bot.* 54, 2403–2417 (2003). <https://doi.org/10.1093/jxb/erg263>.
7. Fang, H., Lopez-sanchez, J.M.: Remote Sensing of Leaf Area Index (LAI) and Other Vegetation Parameters. (2019). <https://doi.org/10.3390/books978-3-03921-240-8>.
8. I.N.D.E.C: Anuario Estadístico de la República Argentina 2017. INDEC, Ciudad Autónoma de Buenos Aires (2018).

9. Roupael, Y., Colla, G., Fanasca, S., Karam, F.: Leaf area estimation of sunflower leaves from simple linear measurements. *Photosynthetica*. 45, 306–308 (2007). <https://doi.org/10.1007/s11099-007-0051-z>.
10. Aguirrezabal, L., Orioli, G., Hernández, L., Pereyra, V., Miravé, J.P.: Girasol: Aspectos fisiológicos que determinan el rendimiento. (2001).
11. Tsialtas, J.T., Maslaris, N.: Evaluation of a leaf area prediction model proposed for sunflower. *Photosynthetica*. 46, 294–297 (2008). <https://doi.org/10.1007/s11099-008-0052-6>.
12. Pepó, P., Novák, A.: Correlation between photosynthetic traits and yield in sunflower. *Plant, Soil Environ.* 62, 335–340 (2016). <https://doi.org/10.17221/202/2016-PSE>.
13. Mieza, M.S., Cravero, W.R., Kovac, F.D., Bargiano, P.G.: Delineation of site-specific management units for operational applications using the topographic position index in La Pampa, Argentina. *Comput. Electron. Agric.* 127, 158–167 (2016). <https://doi.org/10.1016/j.compag.2016.06.005>.
14. Mieza, M.S., Kovac, F.D., Martínez, D.E.: Agricultura de Precisión: experiencias y potencial de aplicación en La Pampa. In: Di Liscia, M.S. (ed.) *Resultados Finales: Proyectos de Investigación Científica y Tecnológica Orientados al Desarrollo Productivo Provincial*. p. 193. EdUNLPam (2014).
15. ERDAS: ERDAS Field Guide™ - Tutorial. 810 (2009).
16. Jensen, J.R.: *Introductory Digital Image Processing: A Remote Sensing Perspective*. Prentice Hall (2005).
17. Hexagon's Geospatial Division: ERDAS IMAGINE, <https://www.hexagongeospatial.com/>.
18. Swain, P.H., Davis, S.M.: *Remote Sensing: The Quantitative Approach*. McGraw-Hill International Book Company (1978).
19. Richards, J.A.: *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin Heidelberg (2013).
20. Sydow, A.: Tou, J. T./Gonzalez, R. C., *Pattern Recognition Principles*, London-Amsterdam-Dom Mills, Ontario-Sydney-Tokyo. Addison-Wesley Publishing Company. 1974. 378 S., \$ 19,50 . *ZAMM - J. Appl. Math. Mech. / Zeitschrift für Angew. Math. und Mech.* 57, 353–354 (1977). <https://doi.org/10.1002/zamm.19770570626>.
21. Campbell, J.B.: *INTRO REMOTE SENSING 2ND/ED PB*. Taylor & Francis (1996).
22. Foody, G.M.: Status of land cover classification accuracy assessment, <http://www.sciencedirect.com/science/article/pii/S0034425701002954>, (2002). [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4).
23. Hartigan, J.A., Wong, M.A.: Algorithm AS 136: A K-Means Clustering Algorithm. *J. R. Stat. Soc. Ser. C (Applied Stat.* 28, 100–108 (1979). <https://doi.org/10.2307/2346830>.
24. QGIS Development Team: *QGIS Geographic Information System*, <http://qgis.osgeo.org>, (2020).
25. CONAE: SoPI, <https://www.argentina.gob.ar/ciencia/conae/unidad-educacion/software/sopi>, (2020).