

Detección del árbol de dzidzilché usando los descriptores de Halarick y redes neuronales artificiales

Juan Jose Negron-Granados

Universidad Autónoma de Yucatán, Facultad de Matemáticas, Mérida, Yucatán,
México
A08001373@alumnos.uady.mx

Resumen. La apicultura es una actividad pecuaria de gran importancia para la economía de México, siendo Yucatán uno de los principales estados productores, a pesar de ello, esta actividad ha sufrido grandes deterioros que han disminuido la productividad de miel en la entidad, lo cual es posible de detener si se aprovechan correctamente los recursos tecnológicos para el fortalecimiento de la producción de miel [6]. Una manera de mejorar el cultivo de miel es con la caracterización de los recursos poliníferos que se encuentran alrededor de una colonia de abejas, con dicha información se puede establecer centros de producción estratégica, disminuir la destrucción selvática o prevenir plagas y enfermedades. La caracterización de la cobertura terrestre suele realizarse con el análisis de información espectral en función de la luz reflejada por la superficie. En este trabajo se hace la propuesta de utilizar el dispositivo Sequoia Parrot como sensor espectral para la recolección de imágenes aéreas y el uso de los descriptores de Halarick para el entrenamiento de una red neuronal que permita detectar el árbol de dzidzilché, un árbol endémico de la Península de Yucatán de gran relevancia para la producción de productos poliníferos.

Palabras clave: redes neuronales, imágenes multiespectrales, descriptores de Halarick.

Detection of the Dzidzilché Tree Using the Halarick Descriptors and Artificial Neural Networks

Abstract. Beekeeping is a livestock activity of great importance for the economy of Mexico, being Yucatan one of the main states that produces more honey, in spite of this, this activity has suffered great deteriorations that have diminished the productivity of honey in the state, which is possible to stop if the technological resources for the strengthening of the production of honey are harnessed correctly [6]. One way to improve the cultivation of honey is with the characterization of polliniferous resources that are around a colony of bees, with this information can establish strategic production centers, reduction of jungle destruction or

prevention of pests and diseases. The characterization of the terrestrial cover is usually carried out with the analysis of spectral information as a function of the light reflected by the surface. In this paper, the proposal is made to use the Sequoia Parrot device as a spectral sensor for the collection of image areas and the use of Halarick descriptors for the training of a neural network that allows the detection of the dzidzilché tree, an endemic tree of the Yucatan Peninsula of great relevance for the production of polliferous products.

Keywords: neural networks, multispectral images, Halarick descriptors.

1. Introducción

La apicultura es una de las actividades agropecuarias de gran importancia económica y ambiental para México, pues los principales productores y exportadores de miel a nivel internacional son mexicanos [12]. La Península de Yucatán es una importante región productora de miel para México, ya que el 95 % de su producción se destina al mercado internacional [9]; sin embargo, la apicultura ha sufrido un grave deterioro en los últimos años ha presentado una disminución en la producción de miel que se ve reflejado en los porcentajes de exportaciones, los cuales se redujeron en un 40 % a nivel nacional y un 35 % en Yucatán. Uno de los principales factores de esta reciente declinación ha sido la disminución de los recursos néctar-polinívoros, lo que se ve reflejado en una baja producción melífera. Por lo anterior, existe la necesidad de mejorar los sistemas de comercialización y diversificación de la actividad así como actualizar las técnicas de producción y administración del proceso productivo por parte de los apicultores para obtener la cantidad de miel requerida por el mercado [9].

La caracterización del ambiente es la principal labor para comprender los procesos ecológicos y conservar la fauna [14], algunas de las aplicaciones de esta labor se han aplicado en la conservación de los humedales del norte de Argentina [18] y Chile [11], de igual forma es posible encontrar trabajos que apliquen la caracterización de plantas que sean de utilidad para los actividades pecuarias, como la ganadería [16] o para mejorar la producción de miel, por ejemplo, en Tabasco se utilizó este procedimiento para producción de mieles monoflorales y competir en el mercado internacional, pues dicho tipo de mieles son altamente apreciadas en Europa, a pesar de que Tabasco no destaca en producción de miel [4]. Por lo tanto, una manera de mejorar la producción y calidad de la miel es caracterizando la flora que se encuentra alrededor de una colmena, pues se espera que en 5km a la redonda de una colonia de abejas se encuentre abundante vegetación polinífera; la dieta de las abejas es muy específica y se espera que tengan al alcance algunas de las plantas que se encuentran en la Tabla 1.

Usualmente, la caracterización de coberturas terrestres se realiza utilizando imágenes satelitales, pues los sensores que llevan a bordo son una herramienta adecuada para la caracterización del suelo [2]; no obstante, el tamaño del píxel en

Tabla 1. Especies de plantas más importantes para la producción de miel en Yucatán.

Nombre común	Nombre científico
Ts'its'ilche'	Gymnopodium floribundum
Taj	Viguiera dentata
Jaabin	Piscidia piscipula
Box katsim	Acacia gaumeri
Sac katsim	Mimosa bahamensis
Tsalam	Lysiloma latisiliquum
X-tabentún	Turbina corymbosa
Kitimché	Caesalpinia gaumeri
Enredaderas	Varias especies de la familia Convolvulaceae

imágenes satelitales puede llegar medir varios metros en cada lado, por ejemplo, el Landsat TM tiene una resolución de 30x30 metros por píxel en sus imágenes [3]. Sin embargo, es posible mejorar la resolución del espacio físico por píxel usando una cámara colocada en una aeronave no tripulada para la captura de imágenes aéreas, adicionalmente, si se utiliza una cámara espectral es posible obtener información de la corteza terrestre en función de la reflectancia de las ondas electromagnéticas. Para realizar el análisis de texturas suelen usarse métodos estadísticos como la matriz de co-ocurrencia o los descriptores de Halarick, por ejemplo, usando estas técnicas en imágenes espectrales es posible analizar la biodiversidad en las superficies de : volcanes [7], bosques [1], zonas urbanas [21] e incluso ríos [17].

Este trabajo tiene el objetivo de identificar el árbol de dzidzilché, una especie propia de la península yucateca y de alto valor para las actividades apícola. Para lograr el objetivo se utiliza el sensor multiespectral Sequoia Parrot, el cual cuenta con lentes que permite capturar la información espectral de la superficie terrestre con una resolución espacial de 3,7 y 18,6 centímetros por píxel para vuelos de 30 y 150 metros de altura, respectivamente. Así como también el uso de los descriptores de Halarick para el análisis de la textura, siendo estos parámetros el vector de entrada para el modelo de red neuronal que se propone. En el siguiente capítulo se describe el área de estudio y los elementos utilizados para cumplir el objetivo propuesto, como la cámara Parrot, los descriptores de Halarick y la red neuronal utilizada, de igual manera, se menciona la metodología usada. En el capítulo 3 se realiza un análisis del modelo a partir de los resultados obtenidos y finalmente, en el capítulo 4 se realizan las conclusiones.

2. Materiales y métodos

2.1. Área de muestreo

Debido a la actividad apícola de en Yucatán es posible encontrar vegetación polínifera en gran parte de la superficie del estado, una de estas zonas es el Campus de Ciencias Biológicas y Agropecuarias (CCBA) de la Universidad

Autónoma de Yucatán (UADY), que cuenta con el entorno adecuado para realizar sus investigaciones apícolas lo que hace del CCBA el lugar ideal para realizar la toma de fotos que se utilizará en este trabajo (Figura 1).



Fig. 1. Ubicación del CCBA se puede notar que alrededor se conserva la flora nativa originaria del estado de Yucatán. (Fuente: maps.google.com)

2.2. Sensor multiespectral

Para la recolección de imágenes se ha utilizado el sensor espectral Sequoia Parrot (Figura 2), este dispositivo se define como espectral debido a que las imágenes están en función de diferentes frecuencias de luz, la información que se pueden obtener son las bandas: verde (530-570 nm), rojo (640-680 nm), borde rojo (730-740 nm) e infrarrojo cercano (770-810 nm); además de tomar fotos a color (imágenes RGB). El sensor se compone por dos módulos: el cuerpo (*body*) el cual tiene integrada los 4 lentes espectrales; y el sensor de luz, (*sunshine sensor*) que sirve para tener información más precisa de la reflectancia solar. Este sensor tiene mejor resolución espacial que las imágenes satelitales, además se evita influencias de gases en la atmósferas y nubes.

2.3. Corrección y alineación de las imágenes

Los sensores espectrales traen una distorsión de ojo de pescado y para corregirlo se debe obtener el punto proyectado del plano del mundo real en el plano de la imagen (ecuación 1), donde P y P' son puntos compuestos por (X, Y, Z) y (X', Y', Z') , respectivamente; R es la matriz de rotación con una dimensión de 3×3 y T el vector de traslación con dimensión 3, ambos están dados por el fabricante. A continuación se debe calcular el valor de un parámetro θ el cual se define en la ecuación 2, este valor se utiliza para calcular el coeficiente de distorsión ρ usando la ecuación 3; finalmente estos valores junto con la matriz afín (M) y el centro de la imagen es posible calcular la proyección del plano



Fig. 2. Cuerpo del sensor (Izquierda). Sensor de luz (Derecha).

del mundo real en el plano de la imagen (x_d, y_d) sin la distorsión de ojo de pescado (ecuación 4) [19]. Los componentes de la matriz M afín están definidos por C, D, E, F , valores que son dados por el fabricante al igual que el vector de desplazamiento (c_x, c_y) :

$$P' = R^T(P - T), \quad (1)$$

$$\theta = \frac{2}{\pi} \arctan\left(\frac{\sqrt{X'^2 + Y'^2}}{Z'}\right); \quad \theta \in [0, 1], \quad (2)$$

$$\rho = \theta + p_2\theta^2 + p_3\theta^3 + p_4\theta^4, \quad (3)$$

$$\begin{aligned} \begin{pmatrix} x_d \\ y_d \end{pmatrix} &= M \begin{pmatrix} \frac{\rho X'}{\sqrt{X'^2 + Y'^2}} \\ \frac{\rho Y'}{\sqrt{X'^2 + Y'^2}} \end{pmatrix} + \begin{pmatrix} c_x \\ c_y \end{pmatrix} \\ &= \begin{pmatrix} C & D \\ E & F \end{pmatrix} \begin{pmatrix} \frac{\rho X'}{\sqrt{X'^2 + Y'^2}} \\ \frac{\rho Y'}{\sqrt{X'^2 + Y'^2}} \end{pmatrix} + \begin{pmatrix} c_x \\ c_y \end{pmatrix}. \end{aligned} \quad (4)$$

2.4. Descriptores de Halarick

La matriz de co-ocurrencia del nivel de gris [22] una de las mejores herramientas para el análisis de las texturas, este método permite cuantificar las características presentes en una imagen y es ampliamente utilizado para la caracterización de diferentes tipos de terrenos en imágenes satelitales [20]. Esta matriz cuenta las parejas de píxeles vecinos en determinados ángulos ($0, 45, 90$ y 135°) y separados en una determinada distancia, usualmente 1, la misma que se usa para este trabajo (Figura 3).

Dada una matriz de co-ocurrencia es posible calcular los descriptores de Halarick, las cuales son variables que describen la textura en la imagen basados en la estadística y frecuencia de distribución [10]. Estos valores definen en un valor numérico la uniformidad, contraste, correlación entre los tonos de la imagen,

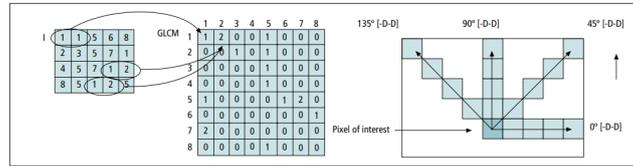


Fig. 3. Matriz de co-ocurrencia para una matriz con 8 escalas [20].

entropía, homogeneidad, valor medio del nivel de gris, desviación estándar del nivel de gris y el coeficiente de variación entre la desviación estándar y la media, para calcularlos se usan las ecuaciones 5-11 respectivamente, donde P es la matriz de co-ocurrencia de tamaño N y x cada píxel de una imagen de tamaño n .

$$\sum_{i,j=0}^{N-1} P_{i,j}^2, \tag{5}$$

$$\sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2, \tag{6}$$

$$\sum_{i,j=0}^{N-1} P_{i,j} \frac{(i-\mu_i)(j-\mu_j)}{\sqrt{\sigma_i\sigma_j}}, \tag{7}$$

$$\sum_{i,j=0}^{N-1} P_{i,j}(-LnP_{i,j}), \tag{8}$$

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i+j)^2}, \tag{9}$$

$$\frac{1}{n} \sum_{i=1}^n x_i n_i, \tag{10}$$

$$\frac{\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2 n_i^{-2}}}{\frac{1}{n} \sum_{i=1}^n x_i n_i}. \tag{11}$$

2.5. Red neuronal artificial

Las redes neuronales artificiales (RN) son algoritmos matemáticos basados en el funcionamiento del cerebro. Es un método de aprendizaje supervisado, es decir que tiene una fase de entrenamiento. Existe un gran número de arquitecturas de RN; la propuesta para este trabajo es una perceptrón multicapa con dos capas ocultas completamente conectadas, debido a que la más empleada en

percepción remota [8] por ser más eficiente que otros métodos para la clasificación de coberturas terrestres [15].

Lo primero a realizar es la alineación de las imágenes espectrales de la cámara, siguiendo la documentación del fabricante se encontró que la alineación entre las imágenes tienen un error entre 2 y 5 píxeles dependiendo de la banda, por lo que se ha recurrido la técnica de homografías para reducir dicho error. Se realizaron 100 fotos a un tablero ajedrez dando un total de 400 imágenes (100 por cada cámara espectral), luego se hallaron las homografías de las parejas verde-rojo, verde-borde rojo y verde-infrarrojo, tomando la banda verde como la imagen maestra, tal como se señala en la documentación del sensor, finalmente se calcularon las homografías promedio, de cada pareja, y su respectiva desviación estándar (Tabla 2). Realizada la alineación se procedió a entrenar la red neuronal en un periodo de mil épocas, tomando 500 muestras para entrenamiento, 250 para la validación y 250 para la etapa de prueba.

Tabla 2. Homografías promedio para la alineación entre bandas y su desviación estándar tomando como referencia la banda verde.

Banda.	Homografía promedio.	Desviación estándar.
Roja	$\begin{pmatrix} 1,0 & 0,0 & 53,5 \\ 0,0 & 1,0 & -9,3 \\ 0,0 & 0,0 & 1,0 \end{pmatrix}$	$\begin{pmatrix} 0,0 & 0,0 & 0,27 \\ 0,0 & 0,0 & 0,74 \\ 0,0 & 0,0 & 0,0 \end{pmatrix}$
Borde Rojo	$\begin{pmatrix} 1,0 & 0,0 & -9,9 \\ 0,0 & 1,0 & 27,2 \\ 0,0 & 0,0 & 1,0 \end{pmatrix}$	$\begin{pmatrix} 0,0 & 0,0 & 0,89 \\ 0,0 & 0,0 & 0,33 \\ 0,0 & 0,0 & 0,0 \end{pmatrix}$
Infrarrojo	$\begin{pmatrix} 1,0 & 0,0 & 41,8 \\ 0,0 & 1,0 & 15,7 \\ 0,0 & 0,0 & 1,0 \end{pmatrix}$	$\begin{pmatrix} 0,0 & 0,0 & 0,70 \\ 0,0 & 0,0 & 0,56 \\ 0,0 & 0,0 & 0,0 \end{pmatrix}$

El uso de redes neuronales es muy efectivo para estimar modelos de aprendizaje supervisado de datos complejos no lineales [23]. El perceptrón multicapa completamente conectado es una de las arquitecturas más utilizadas, se compone por una capa de entrada, capas ocultas de neuronas ordenadas conectadas a una capa anterior y posterior, capas de normalización de los datos y una capa de salida donde se encuentra el valor de la clasificación [5]. Un perceptrón multicapa completamente conectado con una capa oculta es conocido como aproximador universal, sin embargo es posible mejorar los resultados agregando más capas ocultas [13]. Se le denomina completamente conectada debido a que cada neurona de la capa de entrada y de las ocultas tienen sus salidas conectadas a cada neurona de la siguiente capa. La red que se compone esta compuesta por una capa de entrada de dimensión 52, que representan los descriptores de Haralick calculados, posteriormente se encuentra una capa oculta de 500 neuronas, seguido de una capa de normalización, seguido de 5 capas ocultas de dimensiones: 250, 140, 70, 35 y 7; posteriormente una segunda capa de

normalización, finalmente una capa de salida de una sola neurona la cual indica si la imagen corresponde al árbol de dzidzilché o no (Figura 4).

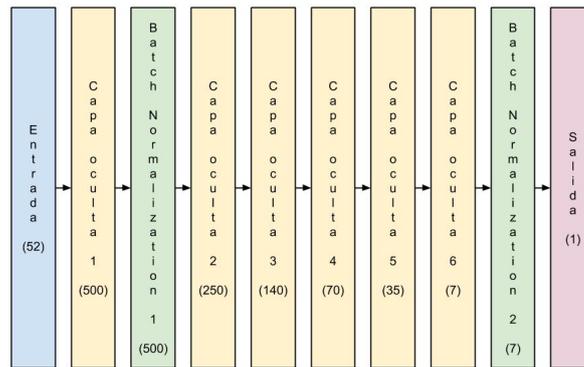


Fig. 4. Estructura de la neurona artificial completamente conectada propuesta. En la parte inferior de cada capa se encuentra el número de neuronas que se componen.

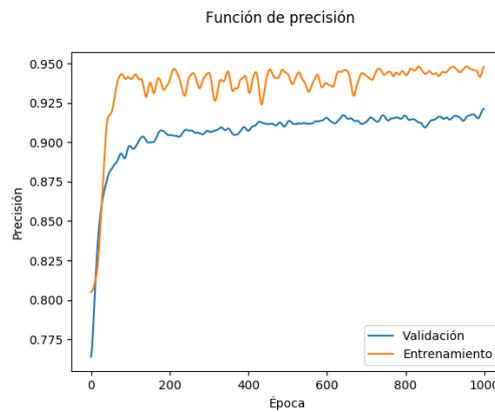


Fig. 5. Función de exactitud por época.

3. Resultados

La red se entrenó durante 1000 épocas con una tasa de aprendizaje de 0,01, el cuál logró alcanzar, al final de la etapa de entrenamiento, una precisión promedio del 94 % y 91 % para los conjuntos de entrenamiento y validación,

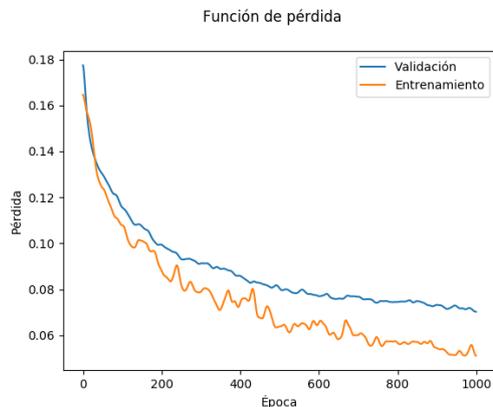


Fig. 6. Función de pérdida por época.

respectivamente (Figura 5); adicionalmente es posible observar que la función de pérdida respalda la robustez del modelo propuesto (Figura 6), pues se alcanza errores menores a 0,1.

Finalmente, en la etapa de prueba se obtuvo una precisión del 93 % con un valor de pérdida de 0,05, adicionalmente, se calcularon las tablas de contingencia con los valores absolutos (Tabla 3), y con valores relativos (Tabla 4); además se calculó la curva característica operativa del receptor (roc) así como el área bajo dicha curva (auc) (Figura 7) como parámetros adicionales para evaluar el modelo, cuyo resultado fue bastante bueno, pues en el valor del área auc (0.98) está muy próximo a 1, por lo cual se puede considerar un modelo excelente que cumpla el objetivo de detectar el árbol de dzidzilché.

Tabla 3. Tabla de contingencia con los valores absolutos.

		Valor real		Total
		Positivo	Negativo	
Predicción	Positivo	111	11	122
	Negativo	5	123	128
Total		116	134	250

4. Conclusiones

Con la realización de este trabajo hemos demostrado que utilizar los descriptores de Halarick en imágenes áreas capturadas con el sensor Sequoia Parrot proporcionan la información adecuada para que una red neuronal pueda discriminar una planta polinífera en específico, el árbol de dzidzilché. Sin embargo, es

Tabla 4. Tabla de contingencia con los valores relativos.

		Valor real		Total
		Positivo	Negativo	
Predicción	Positivo	44,4 %	4,4 %	48,8 %
	Negativo	2 %	49,2 %	51,2 %
Total		46,4 %	53,6 %	100 %

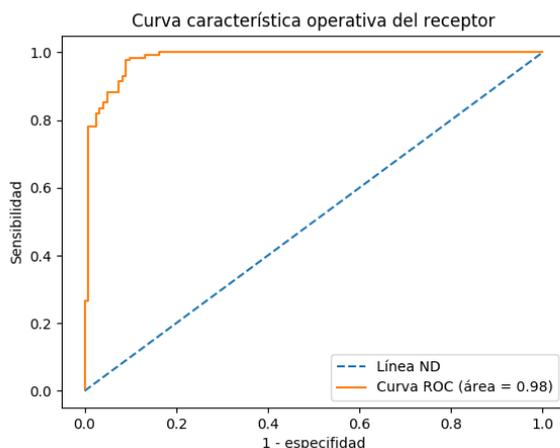


Fig. 7. Función de exactitud por época.

posible utilizar la información espectral colectada para evaluar y comparar con otros modelos, por ejemplo una red neuronal convolucional o un autoencoder y de tal manera aumentar la complejidad de la caracterización de las diferentes texturas que puedan encontrarse en las regiones políníferas.

Finalmente, el modelo planteado cumple el objetivo de clasificación propuesto, lo cual permitiría cuantificar el espacio de crecimiento del árbol de dzidzilché, valor que es de utilidad para mejorar la producción de miel del estado de Yucatán.

Referencias

1. Anaya, A., Jesus, A., Duque, L., Rosa, A., Valencia, H., German, M.: Texture analysis of satellite imagery in the field of biodiversity and forest structure of the colombian andes; analisis de textura en imagenes de satelite en el ambito de la biodiversidad y la estructura en un bosque de los andes colombianos (2008)
2. Atkinson, P.M., Lewis, P.: Geostatistical classification for remote sensing: an introduction. *Computers & Geosciences* 26(4), 361–371 (2000)
3. Centro Nacional de Información y Comunicación Educativa: Resolución de las imágenes satélite (2006), http://concurso.cnice.mec.es/cnice2006/material121/unidad1/i_resolucion.htm, último acceso: 2019/05/11

4. Córdova-Córdova, C.I., Ramírez-Arriaga, E., Martínez-Hernández, E., Zaldívar-Cruz, J.M.: Caracterización botánica de miel de abeja (*apis mellifera* l.) de cuatro regiones del estado de tabasco, méxico, mediante técnicas melisopalinológicas. *Universidad y ciencia* 29(2), 163–178 (2013)
5. Daumé III, H.: *A course in machine learning*. Publisher, ciml. info 5, 69 (2012)
6. Echazarreta González, C.: Apicultura y producción de miel, <https://www.cicy.mx/documentos/CICY/Sitios/Biodiversidad/pdfs/Cap2/18%20Apicultura%20y%20produccion.pdf>, último acceso: 2019/05/11
7. Fernández, L., Álvarez, G., Salinas, R.: Methods for analyzing surface texture effects of volcanoes with plinian and subplinian eruptions types: Cases of study lascar (23° 22's) and chaiten (42° 50's), chile (2018)
8. Foody, G.M.: Thematic mapping from remotely sensed data with neural networks: Mlp, rbf and pnn based approaches. *Journal of Geographical Systems* 3(3), 217–232 (2001)
9. Güemes Ricalde, F.J., Echazarreta González, C., Villanueva, R., Pat Fernández, J.M., Gómez Alvarez, R.: La apicultura en la península de yucatán. actividad de subsistencia en un entorno globalizado. *Revista Mexicana del Caribe* 8(16) (2003)
10. Haralick, R.M., Shanmugam, K., et al.: Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics* (6), 610–621 (1973)
11. Hauenstein, E., González, M., Peña-Cortés, F., Muñoz-Pedreras, A.: Clasificación y caracterización de la flora y vegetación de los humedales de la costa de toltén (ix región, chile). *Gayana. Botánica* 59(2), 87–100 (2002)
12. Instituto Nacional de Economía Social: Historia e importancia de la apicultura (2018), <https://www.gob.mx/inaes/articulos/historia-e-importancia-de-la-apicultura?idiom=es>, último acceso: 2019/05/11
13. Lab, L.: *Deep Learning Tutorial*. University of Montreal, Canada (2015)
14. Leopold, A.: *Game management* charles scribner's sons. New York 481 (1933)
15. Lizarazo, I.: Clasificación de la cobertura y del uso del suelo urbano usando imágenes de satélite y algoritmos supervisados de inteligencia artificial. *UD y la geomática* (2), 4–18 (2008)
16. Machado, R., Roche, R., Toral, O., García, E.G.: Metodología para la colecta, conservación y caracterización de especies herbáceas, arbóreas y arbustivas útiles para la ganadería. *Pastos y Forrajes* 22(3), 181–204 (1999)
17. Maldonado, F., Quignard, I., Zamboni, L., Rodriguez, E., Sione, W.: Uso de imágenes landsat tm para la delimitacion de unidades de muestreo ambiental en el delta del río paraná
18. Perotti, M.G., Diéguez, M.C., Jara, F.G.: Estado del conocimiento de humedales del norte patagónico (argentina): aspectos relevantes e importancia para la conservación de la biodiversidad regional. *Revista chilena de historia natural* 78(4), 723–737 (2005)
19. Pix4D: <https://support.pix4d.com/hc/en-us/articles/202559089-How-are-the-Internal-and-External-Camera-Parameters-defined>, último acceso: 2019/05/11
20. Ríos-Díaz, J., Martínez-Payá, J.J., del Baño Aledo, M.E.: El análisis textural mediante las matrices de co-ocurrencia (glcm) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración.(textural analysis by means of a grey level co-occurrence matrix method on patellar tendon ultrasonography is useful for the detection of histological changes after whole-body vibration training). *CCD. Cultura.Ciencia.Deporte*. doi: 10.12800/ccd 4(11), 91–102 (2009)

Juan Jose Negron-Granados

21. Rodríguez-Cruz, M., Moctezuma-Flores, M.: Análisis bayesiano y fusión de datos para la clasificación de escenas urbanas del distrito federal. *Ingeniería, investigación y tecnología* 7(1), 17–28 (2006)
22. Tahir, M.A., Bouridane, A., Kurugollu, F.: An fpga based coprocessor for glcm and haralick texture features and their application in prostate cancer classification. *Analog Integrated Circuits and Signal Processing* 43(2), 205–215 (2005)
23. Wali, A.: *Clojure for Machine Learning*. Packt Publishing (2014)