




Clasificación Automática para Animales en Peligro de Extinción de Colombia Usando Redes Neuronales Convolucionales

An Automated Classification for Danger of Extinction Animals from Colombia Using Convolutional Neural Networks

^aAndrés Felipe Rivera-Carrillo, ^bDarwin Orlando Cardozo-Sarmiento, ^cSergio Martínez-Campo

 ^a, Ingeniero Electrónico, andresfeliper@ufps.edu.co, Universidad Francisco de Paula Santander, Cúcuta, Colombia
 ^b, MSc Ingeniería Electrónica, darwinorlandocs@ufps.edu.co, Universidad Francisco de Paula Santander, Cúcuta, Colombia
 ^c, MSc. Ingeniería Eléctrica, sergio.martinez@campusucc.edu.co, Universidad Cooperativa de Colombia, Barranquilla, Colombia

Recibido: Marzo 15 de 2021 **Aceptado:** Junio 20 de 2021

Forma de citar: A.F. Rivera-Carrillo, D.O. Cardozo-Sarmiento, S. Martínez-Campo. "Clasificación Automática para Animales en Peligro de Extinción de Colombia Usando Redes Neuronales Convolucionales", *Mundo Fesc*, vol. 11, no. 21, pp. 95-105, 2021

Resumen

La extinción de distintos tipos de animales es un problema que ha ido creciendo a lo largo de los años y que, en consecuencia, ha provocado problemas medioambientales, como el cambio climático. La diversidad genética (biodiversidad) es esencial para el desarrollo de todas las especies y los seres humanos dependen de ella en su vida cotidiana. Cuando la biodiversidad disminuye, la esperanza de vida del ser humano se reduce, no sólo desde el punto de vista ecológico, sino también desde el punto de vista de los recursos, incluso para poder tener especies adaptadas a un nicho ecológico. En esta investigación se expondrá una estrategia informática que a lo largo del tiempo ha logrado grandes resultados; las redes neuronales convolucionales es un proceso que ha facilitado el monitoreo de diferentes tipos de animales en los últimos años, esto, con el fin de facilitar el proceso de reconocimiento y conteo de animales, enfocado a la agricultura y la zoología. Para ello, se utilizará una arquitectura en el campo de las redes neuronales convolucionales (CNN), Alexnet, que tiene referencias con resultados muy elevados. Además, se utiliza el software de programación matemática Matlab para el desarrollo de la red neuronal. Obteniendo de esta forma un resultado de precisión de validación del 97,52%, con la utilización de un conjunto de datos con 3026 imágenes, en donde, el 80% se utilizan para el entrenamiento y el 20% para la validación.

Palabras clave: Animales, Extinción, Redes Neuronales Artificiales

Autor para correspondencia:

*Correo electrónico: darwinorlandocs@ufps.edu.co



Abstract

The extinction of different types of animals is a problem that has been growing over the years, and that, consequently, has caused environmental problems, such as climate change. Genetic diversity (biodiversity) is essential for the development of all species and human beings depend on it in their daily lives. When biodiversity decreases, human life expectancy is reduced, not only from an ecological point of view, but also from a resource point of view, even to be able to have species that are adapted to an ecological niche. This research will expose a computer strategy that over time has achieved great results; convolutional neural networks is a process that has facilitated the monitoring of different kinds of animals in recent years, this, in order to facilitate the process of recognition and counting of animals, focused on agriculture and zoology. For this, an architecture in the field of convolutional neural networks (CNN) will be used, Alexnet, which has references with very high results. In addition, the mathematical programming software Matlab is used for the development of the neural network. Getting of this way a result of accuracy of validation of 97,52%, with the use of a dataset with 3026 images, in where, 80% are used for training and 20% for validation.

Keywords: Animals, Extinction, Artificial Neural Networks.

Introducción

Las redes neuronales son un modelo inspirado en el funcionamiento del cerebro humano. Está formado por un conjunto de nodos conocidos como neuronas artificiales que están conectadas y transmiten señales entre sí. Estas señales se transmiten desde la entrada hasta generar una salida. Su objetivo es aprender modificándose automáticamente a si mismo de forma que puede llegar a realizar tareas complejas que no podrían ser realizadas mediante la clásica programación basada en reglas. De esta forma se pueden automatizar funciones que en un principio solo podrían ser realizadas por personas [1].

Un tipo de red es la red neuronal convolucional (CNN), un algoritmo de Deep Learning que está diseñado para trabajar con imágenes, asignándole importancia a elementos en la imagen para diferenciar unos de otros. Este es uno de los principales algoritmos que ha contribuido en el desarrollo y perfeccionamiento del campo de Visión por computadora. Las redes convolucionales contienen varias hidden layers, donde las primeras puedan detectar líneas, curvas y así se van especializando hasta poder reconocer formas complejas como un rostro, siluetas, etc. Las tareas comunes de este tipo de redes son detección o categorización

de objetos, clasificación de escenas y clasificación de imágenes en general [2]-[7].

La incorporación de la informática en las ciencias de la biología ha estado progresando rápidamente con la finalidad de proporcionar metodologías que beneficien a esta misma o que a su vez les provee una solución a distintos problemas que posea esta misma, tales como, la extinción de algunas especies de animales. Actualmente, más de 1.200 especies endémicas de animales de Colombia se encuentran en peligro de extinción o en estado de vulnerabilidad, sin contar aquellas especies de las que no se han podido obtener datos. El cuidado y la conservación de los animales amenazados se hace cada vez más necesario para la sostenibilidad del planeta y por el bien de todos los seres vivos que en él habitan [8].

Con el fin de suministrar un método de clasificación de imágenes de animales en peligro de extinción, en este documento se desarrollará una investigación que usa una red neuronal convolucional para proporcionar un avance en el cuidado y bienestar animal, para usarse como motor de búsqueda de ejemplares en peligro de extinción para su vigilancia y protección. En la Sección 2, se establece los avances y principales resultados en investigaciones relacionadas con el tema; en la Sección 3, se establece el

entrenamiento de la red neuronal artificial; en la Sección 4, los resultados; finalmente, en la Sección 5 las respectivas conclusiones.

Avances en Clasificación de Imágenes

El avance de clasificación de imágenes usando redes neuronales es de gran interés, por esto se realiza una tabla (ver Tabla 1) comparando investigaciones relacionadas con la clasificación de imágenes, en cuanto a datos, entrenamiento y resultados. Por ejemplo, en [4] mediante un conjunto de datos de caras de ovejas que utiliza el aprendizaje por transferencia para realizar la clasificación de imágenes de caras de ovejas normales (sin dolor) y anormales (dolor), utilizando CNN; en [5], se busca el reconocimiento a la raza de ganado Pantaneira, utilizaron cámaras en los cercos para tomar 27.849 imágenes del ganado y utilizaron CNN con tres arquitecturas DenseNet-201, Resnet50 e Inception-Resnet-V; en [6], se proponen algoritmos de visión por computadora, aprendizaje automático y técnicas de aprendizaje profundo para el reconocimiento de cerdos mediante las distintas características físicas; en [7], desarrollan una aplicación móvil basada en la visión para clasificar especies de loros en peligro de extinción utilizando CNN; en [8], preparan un conjunto de datos especializado basado en Google Open Images y conjuntos de datos COCO, resultando en aproximadamente 20000 imágenes de animales de 10 clases y probaron las arquitecturas YOLOv3, RetinaNet R-50-FPN, Faster R-CNN R-50-FPN y Cascade RCNN R-50-FPN; en [9], se presentan métodos de clasificación para razas basado mediante CNN con aprendizaje por transferencia; en [10], se propone un método que combina un sistema integrado y aprendizaje profundo basado en MobileNetV2 y el aprendizaje por transferencia para clasificar las imágenes de animales marinos; en [11], determinan que

es aconsejable el uso de CNN para clasificar los animales con imágenes digitales; en [12], utilizan redes neuronales convolucionales profundas (D-CNN) y k Nearest Neighbors (kNN) para la clasificación de leopardo de las nieves, oveja Marco polo, oso del Himalaya y otros animales, utilizando D-CNN como AlexNet, ResNet-50, VGG-19 e inception v3 para extraer funciones; en [13], usan procesamiento de imágenes y aprendizaje profundo para estimar el puntaje de condición corporal de la vaca, usando 5470 imágenes de muestra y el método Faster RegionConvolutional Neural Networks (Faster R-CNN).

Asimismo, en algunas investigaciones usan imágenes dimensionalmente pequeñas siempre y cuando se trabajen con modelos que se adecuen a sus características. También, se observa que INCEPTIONV3 es una arquitectura usada en varias investigaciones y con este tipo de red siempre se obtienen buenos resultados de validación, consiguiendo en todos sus casos un porcentaje superior al 90%.Entrenamiento de la red neuronal convolucional

Table I. Investigaciones sobre reconocimiento de imágenes de animales mediante el uso de redes neuronales convolucionales

Artículo de Investigación	Mejor Arquitectura Implementada	Cantidad de neuronas	Porcentaje datos Entrenamiento / Validación.	Precisión en Entrenamiento	Precisión en Validación
Automated sheep facial expression classification using deep transfer learning.	VGG16	2000	82,5% / 17,5%	100%	99,59%
Recognition of Pantaneira cattle breed using computer vision and convolutional neural networks.	DenseNet	27849	90% / 10%	99,74%	99,85%
An adaptive pig face recognition approach using Convolutional Neural Networks.	Haar Cascade / grad-CAM	2364	86.4% / 13.5%	N.A.	83.7%
The Real-Time Mobile Application for Classifying of Endangered Parrot Species Using the CNN Models Based on Transfer Learning.	NCEPTIONV3	3500	80% / 20%	97,25%	97%
Detection of Big Animals on Images with Road Scenes using Deep Learning	YOLOv3	19927	95% / 5%	N.A.	78%
Breakthrough Conventional Based Approach for Dog Breed Classification Using CNN with Transfer Learning	NASNET	188000	53% / 47%	98%	91%
Real-time Marine Animal Images Classification by Embedded System Based on Mobilenet and Transfer Learning.	MOBILENETV2	28747	94% / 6%	99,58%	92,89%
An Automated Vertebrate Animals Classification Using Deep Convolution Neural Networks.	ConvNet	12000	80% / 20%	99%	97,5%
Deep Learning and Computer Vision-based a Novel Framework for Himalayan Bear, Marco Polo Sheep and Snow Leopard Detection.	INCEPTIONV3 - KNN	1200	70% / 30%	99,1%	98,3%
Cow tail detection method for body condition score using Faster R-CNN.	Faster R-CNN	6017	91% / 9%	N.A.	71%

Entrenamiento de la red neuronal convolucional

Mediante el uso de Google Images, Yandex y Kaggle, se obtienen 3026 imágenes de 11 tipos de animales (ver Tabla 2), la iguana, la tortuga marina Laúd, el Condor de los andes, el armadillo, el puma, el jaguar, el titi cabeciblanco, el manatí del caribe, el tapir centroamericano, el mono araña y el

oso de anteojos.

El funcionamiento de la arquitectura Alexnet implementada se muestra en la Fig. 1. La arquitectura consta de ocho capas: cinco capas convolucionales y tres capas completamente conectadas. AlexNet permite el uso de procesadores gráficos (GPU) para el entrenamiento y utiliza unidades lineales rectificadas (ReLU) [19]. La combinación

de capas ayuda a reducir la dimensionalidad de las imágenes. Las capas de agrupación superpuestas funcionan de manera similar, excepto que el bloque de filtro adyacente sobre el que se realiza la operación de agrupación se superpone entre sí [20]. Dicha arquitectura se encuentra disponible en el software de programación Matlab; para su funcionamiento esta arquitectura exige que nuestra base de datos posea imágenes con dimensiones 227x227 y que se encuentren en formato RGB. Las imágenes de los animales en extinción se muestran en las Figuras 2 a 14.

Tabla II. Tamaño y Dimensiones promedio de la base de datos.

Animal	Tamaño promedio	Dimensiones promedio
Iguana	50 KB	600x400
Tortuga M. Laúd	160 KB	800x650
Condor de los andes	30KB	450x350
Armadillo	100KB	750x550
Puma	30KB	450x300
Jaguar	400KB	1000x800
Titi cabeciblanco	80KB	750x500
Manatí del caribe	58KB	600x400
Tapir C.	69KB	700x495
Mono araña	234KB	850x650
Oso de anteojos	42KB	460x350
Promedio	118KB	695x491




Figura 1. Ilustración de la Arquitectura Alexnet [21].

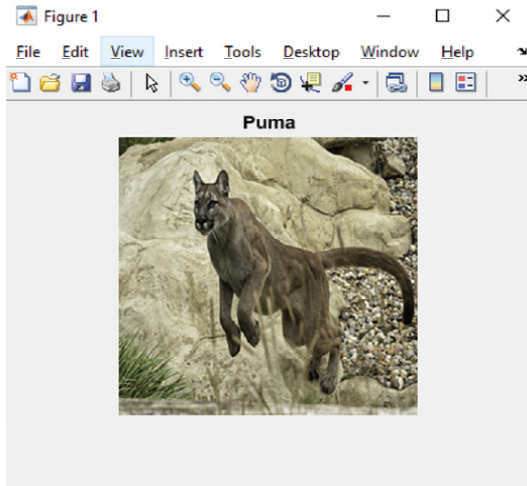


Figura 2. Puma.

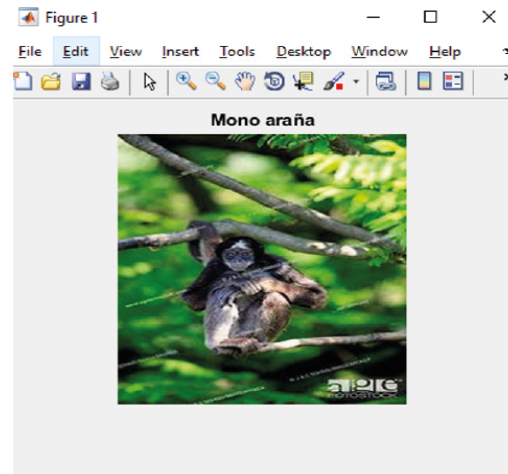


Figura 5. Mono araña

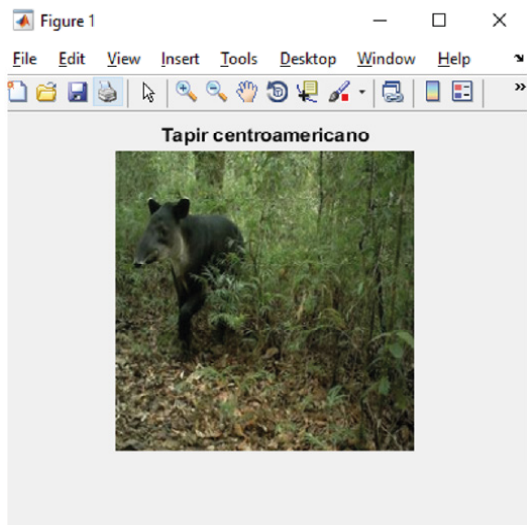


Figura 3. Tapir centroamericano.

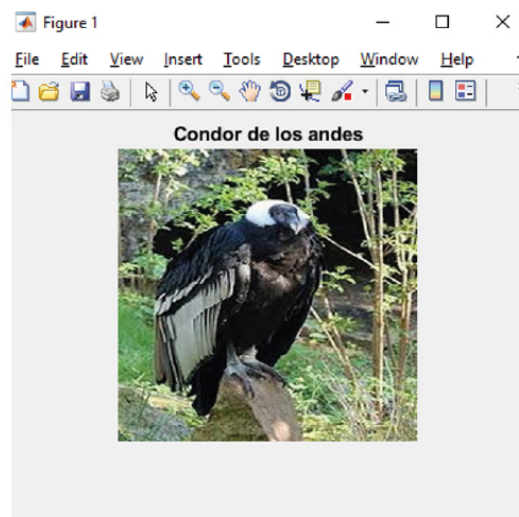


Figura 6. Condor de los Andes

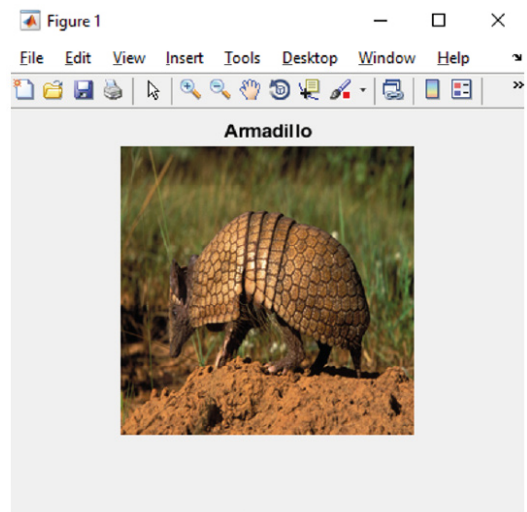


Figura 4. Armadillo.

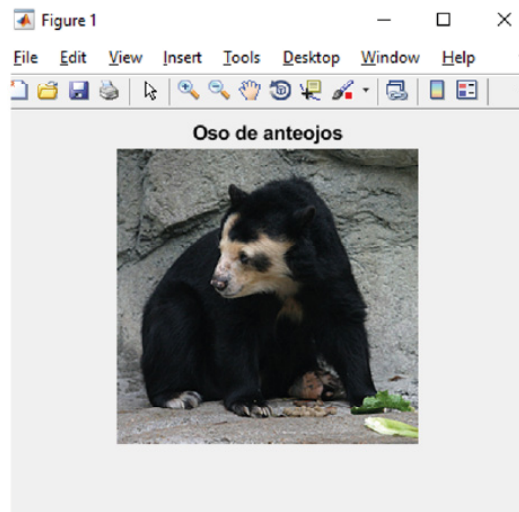


Figura 7. Oso de anteojos

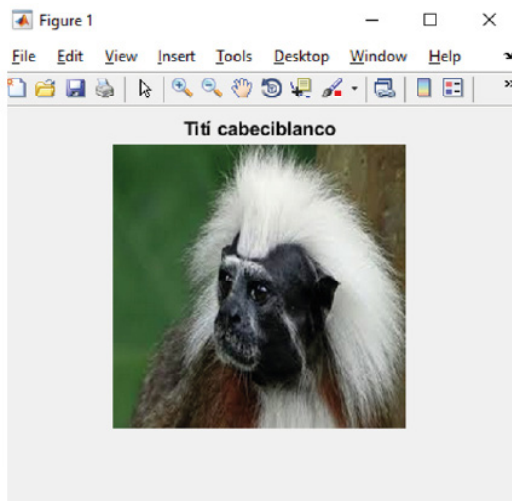


Figura 8. Tití cabeciblanco

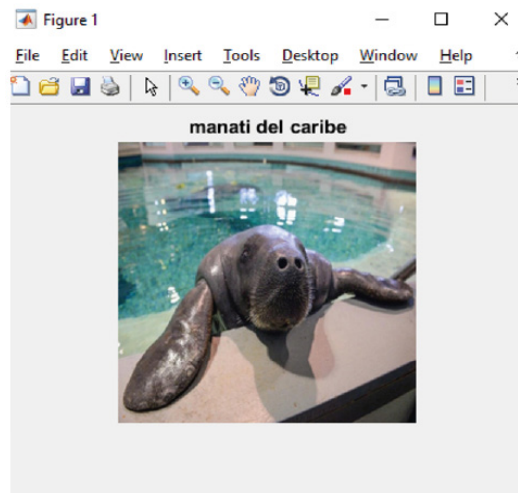


Figura 11. Manatí del caribe

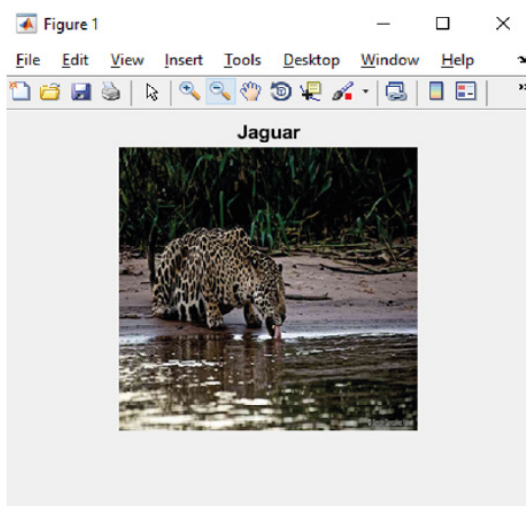


Figura 9. Jaguar.

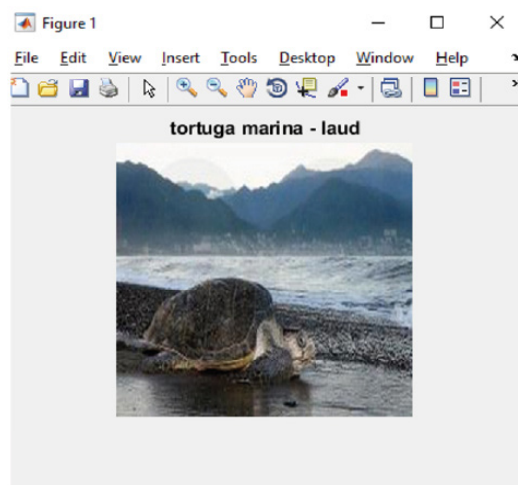


Figura 12. Tortuga marina Laud.

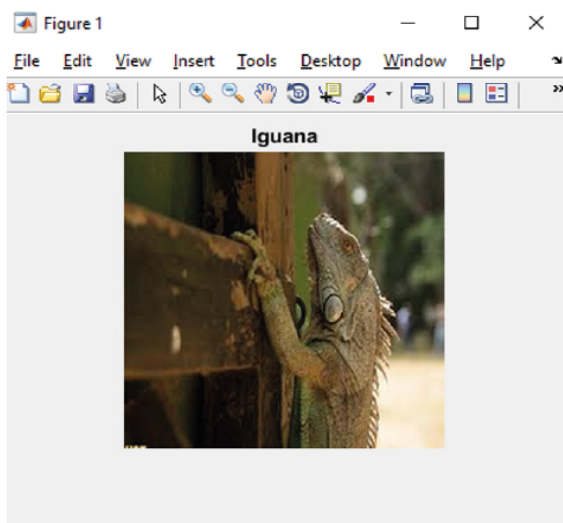


Figura 10. Iguana.

Resultados y discusiónx

Considerando la cantidad de imágenes, se utiliza el 80% del dataset para entrenamiento, y el 20% para validación. También, se establece un máximo de 15 épocas, una tasa de aprendizaje inicial de 0.001 y se utiliza la metodología de entrenamiento mostrada en la Figura 13 y los resultados se muestran en la Tabla III. Luego, se realiza el proceso de validación, usando como base la red entrenada y las imágenes establecidas para validación (ver Figura 14) previamente cargadas, logrando un porcentaje de validación igual a 97,52%.

Tabla III. Resultados del entrenamiento de la red neuronal convolucional.

Épocas	Interacciones	Porcentaje
1	50	87,50%
2	150	88,38%
3	200	90,72%
4	300	91,43%
5	350	92,88%
6	450	93,75%
7	500	94,25%
8	600	95,31%
9	650	95,97%
10	750	96,11%
11	800	96,87%
12	900	97,26%
13	950	97,99%
14	1050	97,17%
15	1125	98,82%

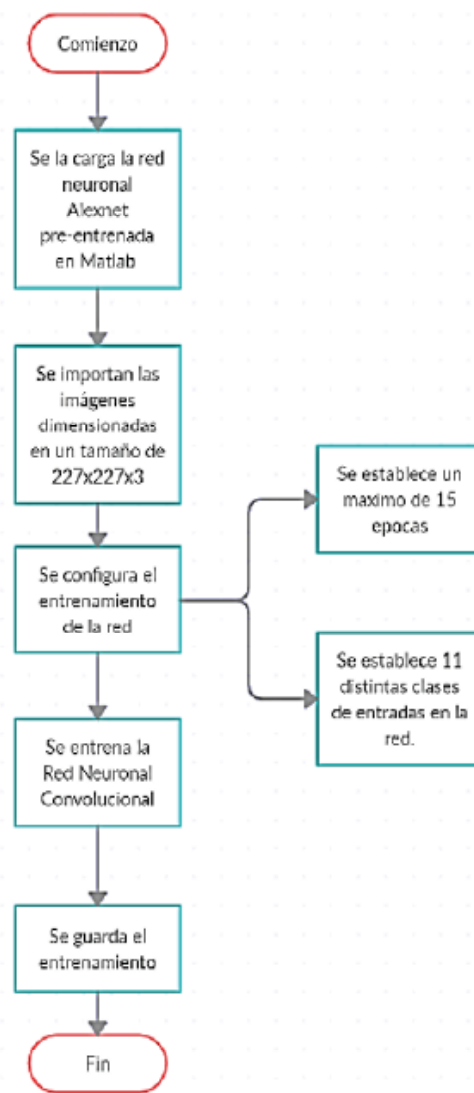


Figura 13. Programación para el entrenamiento de la CNN.




Figura 14. Programación establecida para la validación de la red neuronal convolucional

Conclusiones

En esta investigación se emplea la técnica de redes de neuronas artificiales convolucionales para desarrollar un sistema de clasificación de imágenes para animales en extinción. Se utilizan 3026 imágenes distribuidas en 80% para entrenamiento y 20% para validación.

En el entrenamiento del sistema de clasificación se obtiene un 98,82% de acierto en la clasificación de las imágenes. Asimismo, al realizar pruebas en la validación con imágenes que no se usaron en el entrenamiento del sistema, se obtiene un 97,52% de acierto en la clasificación de imágenes. Esto permite establecer que el sistema tanto en el entrenamiento como en la validación tiene gran precisión para la clasificación de las imágenes de 11 tipos de animales en extinción, la iguana, la tortuga M. Laúd, el Condor de los andes, el armadillo, el puma, el jaguar, el titi cabeciblanco, el

manatí del caribe, el tapir centroamericano, el mono araña y el oso de anteojos.

Referencias

- [1] “Que son las redes neuronales y sus funciones,” 22 Oct 2019 . [En línea]. Disponible en: <https://www.atriainnovation.com/que-son-las-redes-neuronales-y-sus-funciones/#:~:text=Las%20redes%20neuronales%20artificiales%20son,entrada%20hasta%20generar%20una%20salida>
- [2] S. Silva and E. Freire “Intro a las redes neuronales convolucionales”, 23 Nov 2019. [En línea]. Disponible en: <https://bootcampai.medium.com/redes-neuronales-convolucionales-5e0ce960caf8>
- [3] G. Li, L. Bai, C. Zhu, E. Wu and R. Ma, "A Novel Method of Synthetic CT

- Generation from MR Images Based on Convolutional Neural Networks", *11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, pp. 1-5, 2018. doi: 10.1109/CISP-BMEI.2018.8633142
- [4] K. Singh, A. Seth, H. S. Sandhu and K. Samdani, "A Comprehensive Review of Convolutional Neural Network based Image Enhancement Techniques", *IEEE International Conference on System, Computation, Automation and Networking (ICSCAN)*, pp. 1-6, 2019. doi: 10.1109/ICSCAN.2019.8878706
- [5] B. Chen, J. Li, B. Ma and G. Wei, "Convolutionalsparsecodingclassification model for image classification", *IEEE International Conference on Image Processing (ICIP)*, pp. 1918-1922, 2016. doi: 10.1109/ICIP.2016.7532692
- [6] Z. Gong, C. Sun, W. Guo, W. Tan, W. Zhou and G. Zhang, "Automated Thalamus Segmentation in MR Images Using Convolutional Networks", *IEEE 3rd International Conference of Safe Production and Informatization (IICSPI)*, pp. 158-161, 2020. doi: 10.1109/IICSPI51290.2020.9332452
- [7] C. Jia, X. Zhang, J. Zhang, S. Wang and S. Ma, "Deep convolutional network based image quality enhancement for low bit rate image compression", *Visual Communications and Image Processing (VCIP)*, pp. 1-4, 2016. doi: 10.1109/VCIP.2016.7805504
- [8] N. Manjón "16 animales en peligro de extinción en Colombia", 10 Agosto 2020. [En línea]. Disponible en: <https://www.ecologiaverde.com/16-animales-en-peligro-de-extincion-en-colombia-1909.html>
- [9] A. Noor, Y. Q. Zhao, A. Koubaa, L. W. Wu, R. Khan and F. Y. O. Abdalla, "Automated sheep facial expression classification using deep transfer learning", *COMPUTERS AND ELECTRONICS IN AGRICULTURE*. [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.do?product=WOS&search_cheurlFromRightClick=no
- [10] F. de Lima, de Moraes V. Aparecida, Menezes, G. Vilharva, "Recognition of Pantaneira cattle breed using computer vision and convolutional neural networks", *COMPUTERS AND ELECTRONICS IN AGRICULTURE*. [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.oc=4&cacheurlFromRightClick=no
- [11] M. Mathieu, M. Jiangqiang, S. Xiaocai, "An adaptive pig face recognition approach using Convolutional Neural Networks" *COMPUTERS AND ELECTRONICS IN AGRICULTURE* [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.do?product=WOS&search_oc=11&cacheurlFromRightClick=no
- [12] C. Daegy, C. Eunjeong, K. Dong Keun, "The Real-Time Mobile Application for Classifying of Endangered Parrot Species Using the CNN Models Based on Transfer Learning" *MOBILE INFORMATION SYSTEMS*. [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.do?product=WOS&search_c=24&cacheurlFromRightClick=no
- [13] Y. Dmitry; S. Anton; K. Andrey, "Detection of Big Animals on Images with Road Scenes using Deep Learning" *Conferencia: International Conference*

- on *Artificial Intelligence - Applications and Innovations (IC-AIAI)*. [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.do?product=WOS&search_oc=76&cacheurlFromRightClick=no
- [14] B. Arnginn, P. Thongkanchorn, K. Kanchanapreechakorn, “Breakthrough Conventional Based Approach for Dog Breed Classification Using CNN with Transfer Learning”, *Conferencia: 11th International Conference on Information Technology and Electrical Engineering (ICITEE)*. [Online]. Available: http://apps.webofknowledge.com.bdbiblioteca.ufps.edu.co:2048/full_record.do?product=WOS&search_oc=79&cacheurlFromRightClick=no
- [15] X. Liu, Z. Jia, X. Hou, M. Fu, L. Ma, Q. Sun, “Real-time Marine Animal Images Classification by Embedded System Based on Mobilenet and Transfer Learning”, *OCEANS*. 2019. [Online]. Available: <https://ieeexplore-ieee-org.bdbiblioteca.ufps.edu.co/document/8867190/>
- [16] N. K. El Abbadi, E. Mohammed Thabit A. Alsaadi, “An Automated Vertebrate Animals Classification Using Deep Convolution Neural Networks”, *International Conference on Computer Science and Software Engineering (CSASE)*, 2020. [Online]. Available: <https://ieeexplore-ieee-org.bdbiblioteca.ufps.edu.co/document/9142070/>
- [17] S. Jamil, Fawad, M. S. Abbas, F. Habib, M. Umair, M. J. Khan, “Deep Learning and Computer Vision-based a Novel Framework for Himalayan Bear, Marco Polo Sheep and Snow Leopard Detection”, *International Conference on Information Science and Communication Technology (ICISCT)*. 2020. [Online]. Available: <https://ieeexplore-ieee-org.bdbiblioteca.ufps.edu.co/document/9080021/>
- [18] X. Huang, X. Li, Z. Hu, “Cow tail detection method for body condition score using Faster R-CNN”, *IEEE International Conference on Unmanned Systems and Artificial Intelligence (ICUSAI)*, 2019. [Online]. Available: <https://ieeexplore-ieee-org.bdbiblioteca.ufps.edu.co/document/9124743/>
- [19] J. Wei, “AlexNet: The Architecture that Challenged CNNs”, 2019. [Online]. Available: <https://towardsdatascience.com/alexnet-the-architecture-that-challenged-cnns-e406d5297951>
- [20] D. Jain y A. Dong, “Funcionamiento de una red neuronal convolucional (CNN) y la arquitectura AlexNet”, 2020. [En línea]. Disponible en: <https://ichi.pro/es/funcionamiento-de-una-red-neuronal-convolucional-cnn-y-la-arquitectura-alexnet-233779119045871>
- [21] A. Krizhevsky, I. Sutskever and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, 2012. [Online]. Available: <https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>