

Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes

Development of a convolutional neural network to recognize patterns in images

Adriana Cifuentes, Estefania Mendoza, Miguel Lizcano, Andrés Santrich, Silvia Moreno-Trillos

Universidad Simón Bolívar, Barranquilla-Colombia

Open Access

Publicado:
1 julio de 2019

Correspondencia:
smoreno12@unisimonbolivar.edu.co

Resumen

Este proyecto es sobre el reconocimiento por patrones de una imagen que se inicia con la implementación de redes neuronales convolucionales (CNN), con el objetivo de diferenciar entre imágenes de diferentes animales, utilizando un software de aprendizaje profundo (Deep Learning) con el fin de que el modelo pueda clasificar nuevas imágenes. El entrenamiento de la red será aplicarle diferentes condiciones como la resolución, iluminación, ente otros; permitiendo el mínimo error de clasificación en la CCN y posteriormente poder aplicarlo para analizar datos volumétricos en 3D.

Palabras claves: Aprendizaje Profundo, Clasificaciones de Imágenes, Inteligencia Artificial, Redes Neuronales Convolucionales (CNN, Convolutional Neural Networks), Reconocimiento de Patrones, Visión Artificial.

Abstract

This project is about the recognition of patterns in images that begins with the implementation of convolutional neural networks (CNN), with the objective of differentiating between images of different animals, using a deep learning software in order that the model can classify new images. The training of the network will apply different conditions such as resolution, lighting, among others; allowing the minimum classification error in CNN and later be able to apply it to analyze volumetric data in 3D.

Keywords: Deep Learning, Image Classification, Artificial Intelligence, Convolutional Neural Networks (CNN), Pattern Recognition, Artificial Vision.

Como citar (IEEE): A. Cifuentes, E. Mendoza, M. Lizcano, A. Santrich & S. Moreno-Trillos, "Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes", *Investigación y Desarrollo en TIC*, vol. 10, no. 2, pp. 7-17., 2019

Introducción

En los últimos años, las redes neuronales convolucionales han tenido una gran mejora en su desempeño, tanto así que han sido numerosos los trabajos que se realizan y publican cada año, por todo el mundo.

Su uso ha dejado de ser exclusivamente académico y objeto de estudio e investigación a estar totalmente implementada en nuestro día a día. Un ejemplo de ello son las nuevas aplicaciones que surgen sobre todas aquellas que se utilizan para reconocer objetos, cosas, personas, fauna o flora por medio de una imagen.

Aunque las empresas no han quedado atrás ya que empezaron a apostarle a la evolución de las redes neuronales lanzando al mercado productos nuevos tanto en software como hardware.

Este proyecto consiste en el reconocimiento por patrones de una imagen que se inicia con la implementación de redes neuronales convolucionales. El objetivo de este sistema será diferenciar entre imágenes de diferentes animales.

Para lograr este fin se utiliza un software de aprendizaje profundo (Deep Learning), con el cual se entrenará una red neuronal convolucional con una base de datos de imágenes de animales, y posteriormente se utilizará el modelo creado para clasificar nuevas imágenes.

La red neuronal será empleada en distintas condiciones como resolución, escala de grises, iluminación, entre otros factores, teniendo como referencia los estudios y posteriores resultados que con ellos se obtengan que permitirá la disminución del porcentaje de error al momento de clasificar las imágenes.

Con esta red se quiere llegar al punto donde se pueda clasificar claramente todo tipo de imágenes de animales sin ningún problema dado por los patrones o las capas de filtros de una o más dimensiones, y posteriormente aplicar este tipo de redes neuronales para analizar datos volumétricos en 3D.

Marco teórico

Visión Computacional

Es un asunto nuevo y conectado con el aprendizaje de las máquinas. Es un área de la ciencia donde se desarrolla teorías y métodos hacia la extracción automática de información útil contenida en imágenes, el objetivo de esta ciencia es crear y transmitir esa información a las máquinas de forma comprensible.

Sabemos que la visión humana trabaja con base en un análisis de la imagen que llega a la retina y es enviada a la corteza visual. Este tomará la imagen con otras imágenes ya clasificadas en el cerebro para definir el objetivo, la dimensión aproximada y qué hacer con ella. Un detalle importante es que esto ocurre en una pequeña fracción de segundos. La visión computacional es totalmente basada en la visión humana y trabaja con el proceso de modelado y réplica de esa visión usando software y hardware ultra avanzados [1].

Hay tareas que son aplicadas a la visión computacional con el fin de realizar la identificación total de las imágenes de forma amplia y sin ningún esfuerzo humano. Las principales tareas de automatización son: reconocimiento, identificación, detección, movimiento, reconstrucción de escena y restauración de imágenes.

En un inicio, dada la complejidad del sistema de visión humana se intentó abordar estos problemas de formas más directas a partir de tres enfoques [2]:

Comandado por las ideas: Azriel Rosenfeld, comenzó el desarrollo de técnicas empíricas basadas en criterios matemáticos que aproximaban estos problemas de estimación de bordes y líneas usando distintos criterios. Tuvo el inconveniente de no poder proponer métodos para la evaluación de los distintos algoritmos. Sin embargo, ha seguido su desarrollo con notable éxito en algunos casos.

En un segundo enfoque se profundiza el problema reduciendo su alcance a un mundo de bloques blancos mate iluminados sobre fondo negro. Los bloques podían tener cualquier forma, siempre que todas sus superficies fueran planas y todos sus bordes rectos.

Horn realizó trabajos pioneros sobre la formación de la imagen. Se establecen modelos de cálculo que expresan la formación de la imagen a través de ecuaciones diferenciales que relacionan los valores de intensidad de la imagen con la geometría, la reflectancia de la superficie y el punto de vista del observador actuaban de forma conjunta para crear los valores de intensidad medidos en la imagen. La idea era que debía existir un nivel adicional de comprensión en el que el carácter de las tareas de procesamiento de la información llevadas a cabo durante la percepción se analice y comprendan de modo independiente a los mecanismos y escrituras particulares que los implementa en nuestros cerebros.

Ahora bien, debemos considerar que la visión computacional y el procesamiento de imágenes son cuestiones diferentes. El procesamiento de imagen trata sobre cómo mejorar una imagen para su interpretación por una persona mientras que la visión computacional trata de interpretar las imágenes por la computadora.

La visión computacional se puede dividir en 3 grandes etapas [2]:

- Procesamiento de nivel bajo: Se extraen propiedades como orillas, gradiente, profundidad, textura, color, etc.
- Procesamiento de nivel intermedio: Agrupa elementos de nivel bajo para obtener contornos y regiones con el propósito de segmentar.
- Procesamiento de alto nivel: Consiste en la interpretación utilizando modelos y/o conocimiento del dominio del problema.

Red Neuronal Artificial

Las RNA son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. Consisten en un gran número de elementos simples de procesamiento llamados nodos o neuronas que están organizados en capas. Cada neurona está conectada con otras neuronas mediante enlaces de comunicación, cada uno de los cuales tiene asociado un peso. Los pesos representan la información que será usada por la red neuronal para resolver un problema determinado.

Así, las RNA son sistemas adaptativos que aprenden de la experiencia, esto es, aprenden a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos.

Mediante este entrenamiento o aprendizaje, las RNA crean su propia representación interna del problema, por tal motivo se dice que son auto organizadas. Posteriormente, pueden responder adecuadamente cuando se les presentan situaciones a las que no habían sido expuestas anteriormente, es decir, las RNA son capaces de generalizar de casos anteriores a casos nuevos.

Esta característica es fundamental ya que permite a la red responder correctamente no sólo ante informaciones novedosas, sino también ante informaciones distorsionadas o incompletas.

Las neuronas biológicas se caracterizan por su capacidad de comunicarse. Las dendritas y el cuerpo celular de la neurona reciben señales de entradas excitatorias e inhibitorias de las neuronas vecinas; el cuerpo celular las combina e integra y emite señales de salida. El axón transporta esas señales a los terminales axónicos, que se encargan de distribuir información a un nuevo conjunto de neuronas. Por lo general, una neurona recibe información de miles de otras neuronas y, a su vez, envía información a miles de neuronas más.

Por su parte, la neurona artificial pretende mimetizar las características más importantes de la neurona biológica. En general, recibe las señales de entrada de las neuronas vecinas ponderadas por los pesos de las conexiones. La suma de estas señales ponderadas proporciona la entrada total o neta de la neurona y, mediante la aplicación de una función matemática —denominada función de salida—, sobre la entrada neta, se calcula un valor de salida, el cual es enviado a otras neuronas. Tanto los valores de entrada a la neurona como su salida pueden ser señales excitatorias (cuando el valor es positivo) o inhibitorias (cuando el valor es negativo [3]).

Deep Learning (Aprendizaje Profundo)

Es un algoritmo automático estructurado o jerárquico que emula el aprendizaje humano con el fin de obtener ciertos conocimientos.

El Deep Learning permite a modelos computacionales que están compuestos de múltiples capas de procesamiento aprender representaciones de datos con múltiples niveles de abstracción.

En realidad, lo que utilizamos en Deep Learning es algo llamado red neuronal artificial (ANN por sus siglas en inglés), que es una red inspirada en redes neuronales biológicas que se utilizan para estimar o aproximar funciones que pueden depender de una gran cantidad de entradas que generalmente son desconocidas.

A Continuación, algunas de las características que nos ofrece aplicar el Deep Learning [4]:

- Clasificación de imágenes a nivel casi humano.
- Reconocimiento de voz a nivel casi humano.
- Transcripción de escritura a mano a nivel humano.
- Mejora de la traducción automática.
- Mejora de la conversión de texto a voz.
- Asistentes digitales como Google Now o Amazon Alexa.
- Conducción autónoma a nivel humano.
- Mejora de la orientación de anuncios, tal como la utilizan Google, Baidu y Bing.
- Mejora de los resultados de búsqueda en la web.
- Responder preguntas de lenguaje natural.

Existen múltiples librerías de código abierto enfocadas a su uso para Deep Learning en lenguaje Python. Las más importantes son: TensorFlow, Theano, Keras, Caffe, Lasagne, DSSTNE, PrettyTensor, Torch, mxnet, DL4J, y Microsoft Cognitive Toolkit [5].

TensorFlow por su parte soporta Python y C++, además de Java y Go entre otros. Además, permite distribuir los cálculos en CPU, GPU de forma simultánea y escalado horizontal.

Keras es una API de redes neuronales de alto nivel, escrita en Python y capaz de ejecutarse sobre TensorFlow, CNTK o Theano. Fue desarrollado con un enfoque en permitir la experimentación rápida. Poder pasar de la idea al resultado con la menor demora posible es la clave para hacer una buena investigación [4].

Redes Neuronales por Convolución (CNN)

Es un tipo de Red Neuronal Artificial con aprendizaje supervisado que procesa sus capas imitando el cortex visual del ojo humano para identificar distintas características en la entrada que definitivamente hacen que puedan identificar objetos.

Las tareas principales que realizan las CNN son:

- Detección/categorización de objetos.
- Clasificación de escenas.
- Clasificación de imágenes en general.

Las capas convolucionales se entienden como un conjunto de filtros comúnmente llamados: campos receptivos, éstos se ajustan para la extracción de características de una señal. A diferencia de una red neuronal tradicional, en la que cada neurona de una capa se conecta a todas las neuronas de la otra, conocido como Fully Connected (FC), en las CNN se comparten las neuronas a través de filtros que permiten extraer información de las imágenes de entrada [6].

Cada capa de la CNN es un bloque con tres principales variables: entrada, pesos y salida. en estas capas se presenta una característica fundamental como donde la salida de una capa se convierte en la entrada de la próxima. Este proceso es secuencial y puede ser no lineal, en cada capa se realiza una función específica. Las CNN tiene como principal tarea extraer patrones, en este caso sobre imágenes, debido a ello utilizan un entrenamiento no supervisado [7].

Estado del arte

J. Pérez Carrasco, M. Serrano Gotarredona, B. Ancha Piñero et al.; en el 2011 desarrollaron una red convolucional (ConvNet) bioinspirada compuesta por seis capas basada en eventos y no en fotogramas para el reconocimiento de dígitos numéricos escritos a mano en tiempo real. Entrenaron la red con el algoritmo de retropropagación utilizando imágenes 32x32 de la base de datos MNIST (Modified National Institute of Standards and Technology), codificando 10000 imágenes en eventos separados 50 ns para probar el sistema ConvNet no basado en cuadros. Obtuvieron resultados con una tasa de reconocimiento del 93% utilizando la red neuronal junto con el protocolo AER (representación de eventos mediante direcciones, address event representation) la cual permite 195 conexiones y 1700 parámetros entregables [8].

En la actualidad diferentes empresas como Apple y Google están apostando por la evolución de las redes neuronales. Apple introdujo en el 2016 CoreML [9], incorporo machine learning directamente en sus dispositivos sin depender de servidores externos para el reconocimiento, clasificación, visión y lenguaje natural. El año pasado, Apple actualizo la librería de CoreML que ha definido un software propio para la creación de red neuronal basado en imágenes con solo arrastrar una carpeta. Esto quiere decir que sigue apostando por el aprendizaje automático y que están proporcionando las herramientas suficientes a los programadores para que esto sea posible.

Por otro lado, en el 2018 Google lo ha introducido con MLKit [10]. Con estas dos empresas se puede ver que la inteligencia artificial cada día está más cerca de nosotros y quieren hacernos vía más fácil con la ayuda de esta tecnología.

Machine learning y Deep learning son dos subcategorías de la Inteligencia Artificial se consideran por poder aprender según los entrenes con un conjunto de datos con el final de construir una red neuronal capas de predecir como un humano.

En el 2018 Cristian Espinosa, realizó un proyecto que utilizaba la técnica de Deep Learning para la clasificación de imágenes de flores. La red neuronal convolucional se entrenó con diferentes conjuntos de imágenes, con un total de 2.600.000 imágenes. Con el fin de crear una aplicación móvil que permita la fácil identificación de las especies de flores. Se puede obtener un resultado aceptable para los usuarios sin conocimientos con las herramientas de Keras y realizando un Transfer Learning de la red[11].

Alejando Reátegui Pezo y Manuel Velasco Meléndez, realizó un aplicativo tecnológico usando la técnica de redes neuronales convolucionales, que permita el reconocimiento de plantas de Camu Camu a partir de sus hojas, teniendo en cuenta un banco de 2800 imágenes para los procesos de entrenamiento, validación y prueba de uso, las cuales constaron de 1400 imágenes de Camu Camu y 1400 imágenes de diferentes al Camu Camu. El software tiene la capacidad de reconocer en un 100% a las imágenes que efectivamente corresponden a la hoja de la especie Camu Camu y a la vez indica en un 97% que es otra especie [12].

En la 6th Conferencia de Ingeniería, Ciencia y Tecnología; Carlos Quintero, Fernando Marchan, Aydeé Cornejo y Javier Sánchez presentaron un proyecto que tenía como objetivo desarrollar un sistema capaz de reconocer dos familias de macroinvertebrado mediante el uso de imágenes. El sistema está basado en el uso de algoritmos de redes neuronales profundas, con el que pudieron lograr el aprendizaje de patrones, a partir de un conjunto de imágenes publicas provenientes de internet y de biomonitoreos realizados en campo, aplicaron el entrenamiento de una red neuronal convolucional implementado en Tensorflow y Keras. Para esta prueba preliminar se reportaron porcentajes de confiabilidad con valores por encima del 95% y con un error de clasificación del 6% [13].

En la 10ª Conferencia Internacional de Comunicaciones inalámbricas y Procesamiento de señales (WCSP, por sus siglas en inglés) Yoe Shang y Li Jianlong, presentaron un trabajo que se centra en las comparaciones de rendimiento de clasificación de tres características diferentes con cuatro métodos diferentes, con el fin de encontrar la combinación característica-método óptima de doce tipos de combinaciones. Primero, se introduce un modelo de simulación modificado para generar ecos de peces de diferentes especies de peces. Luego se emplean tres tipos de conjuntos de características comunes que incluyen formas de onda de eco, espectros de eco y espectrogramas de eco para las comparaciones de rendimiento de clasificación. Cada conjunto de características es utilizado por cuatro tipos de métodos de clasificación típicos, incluido el árbol de decisión, el refuerzo adaptativo (AdaBoost), Redes neuronales artificiales (ANN) y redes neuronales convolucionales (CNN). Los resultados de la simulación muestran que la CNN alcanza la tasa de clasificación más alta con espectrogramas de eco como entrada, lo que se verifica mediante el experimento del tanque posterior[14].

Schneiderm, Taylor y Kremer, propusieron dos clasificadores de detección de objetos con aprendizaje profundo, Faster R-CNN y YOLO v2.0, para identificar, cuantificar y localizar especies de animales dentro de las trampas de cámara utilizando la trampa de cámara Reconyx y la etiqueta autoadhesiva. Los métodos de reconocimiento de objetos demostraron ser exitosos, ya que se

entrenaron con grandes conjuntos de datos etiquetados. Demostraron su uso, en el contexto de conjuntos de datos ecológicos de tamaño realista, comprobando si los métodos de detección de objetos son aplicables para escenarios de investigación ecológica cuando se utiliza el aprendizaje por transferencia. El R-CNN más rápido superó a YOLO v2.0 con una precisión promedio de 93.0% y 76.7% en los dos conjuntos de datos, respectivamente. Sus hallazgos muestran pasos prometedores hacia la automatización de la laboriosa tarea de etiquetar imágenes de trampas de cámara, que se puede utilizar para mejorar la comprensión de la dinámica poblacional de los ecosistemas en todo el planeta [15].

Hayat Shaukat, Kun Ella, Tengtao Zou et al.; presentaron una investigación aplicando el aprendizaje profundo al reconocimiento de objetos de múltiples clases y exploraron la red neuronal convolucional (CNN). La red neuronal convolucional la crearon con la inicialización estándar normalizada y entrenada con un conjunto de entrenamiento de imágenes de muestra de 9 categorías de objetos diferentes más imágenes de pruebas de muestra utilizando un conjunto de datos muy variado. Los resultados lo implementaron en el marco de tensorflow de Python; examinaron y comprobaron los resultados de CNN con los vectores de características finales extraídos de los enfoques de variante de BOW basado en el clasificador L2-SVM lineal. Basados en esto, suficientes experimentos verifican la efectividad y robustez del modelo CNN con una tasa de 90.12% de precisión[16].

Materiales y métodos

Para la creación de la red neuronal convolucional (CNN), se utilizaron las librerías TensorFlow y Keras los cuales permite trabajar bajo el lenguaje de Python. Para la arquitectura de la red se trabajó con una basada en la VGG net [17].

La red se entrenó con 1500 imágenes obtenidas de internet, organizadas en carpetas por categorías y en formato JPG. Después del entrenamiento proseguimos a probar la red con nuevas imágenes de animales y analizando los resultados de esta. Para evaluar el desempeño de la red esta se evaluó las 30 nuevas imágenes, en las cuales 10 eran de elefantes, 10 de leones y 10 de pandas.

Para evaluar los resultados de la red utilizamos la matriz de confusión, que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado [18, 19,20,21,22,23, 24]. Se manejan las siguientes métricas de la matriz:

$$Accuracy (ACC) = \frac{(TP+TN)}{(TP+FP+TN+FN)}$$

$$Specificity (TNR) = \frac{TN}{TN + FP}$$

$$Sensitivity (TPR) = \frac{TP}{TP + FN}$$

$$Precision (PPV) = \frac{TP}{TP + FP}$$

Resultados

Los datos obtenidos fueron los siguientes:

ACC = 0,933333333

TNR = 0,96

TPR= 0,933333333

PPV = 1

Tabla 1. Matriz de confusión

	Predicción		
Real	Elefante	León	Pandas
Elefante	10	0	0
León	2	8	0
Pandas	0	0	10

El software como resultado clasificó las imágenes etiquetándolas y prediciendo con un porcentaje el acierto de estas.

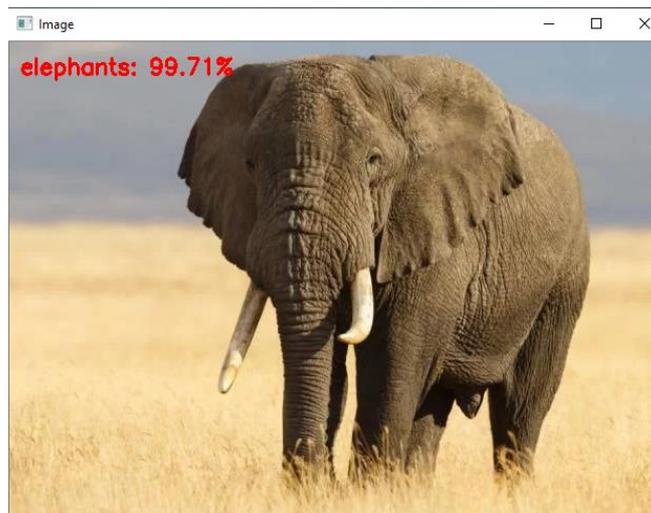


Figura 1. Muestra de resultado – imagen elefante

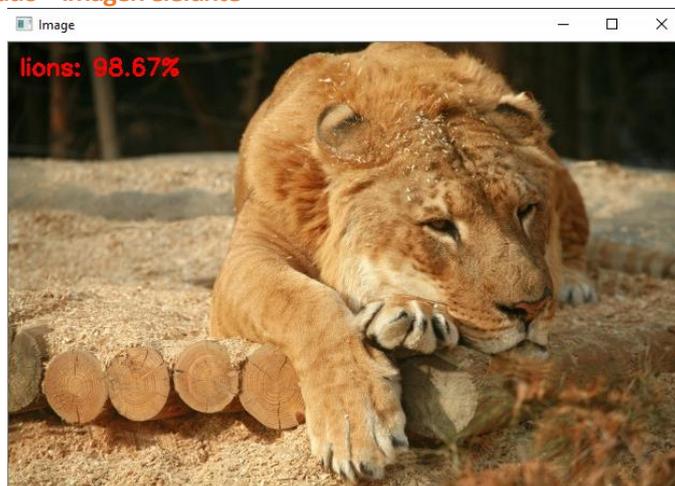


Figura 2. Muestra de resultado – imagen león



Figura 3. Muestra de resultado – imagen panda.

Conclusiones

La red neuronal convolucional cuenta con la habilidad para clasificar con una variedad bastante amplia en cuanto a identificación de imágenes se refiere, teniendo así la capacidad de llegar a aplicaciones mucho más complejas.

Otro punto para destacar es la rapidez con que la red es entrenada y probada, tardando mucho menos tiempo en realizar el proceso completo sin tener una capacidad de cómputo muy elevada.

Por consiguiente, en este trabajo se construyó una CNN capaz de diferenciar entre tres tipos diferentes de animales. Se puede decir que se obtuvo un resultado positivo sobre el reconocimiento de diferentes animales e identificación de estos mismos, dándole solución a nuestros objetivos llevados a cabo con la ayuda del CNN.

Sin embargo, se pudo observar a través de las pruebas realizadas que el software obtiene algunas confusiones en cuanto la imagen sea de un león con la boca abierta, ya que predice que es un elefante.

Se espera que este proyecto tenga mayor alcance en cuestión de imágenes en 3D para darle buen uso y ayudar a la sociedad en reconocimientos de animales u otras cosas.

En términos generales las redes neuronales convolucionales son una teoría relativamente nueva y como tal presenta algunas limitaciones, pero su facilidad de implementación y la calidad del resultado que ofrece impulsa a que su desarrollo y estudio continúen.

Referencias bibliográficas

1. N. Nagel, "Visión Computacional," 2017. [Online]. Available: <https://blogmexico.comstor.com/que-es-la-vision-computacional>. [Accessed: 01-Mar-2019].

2. A.L. Loyo P., “Visión Computacional.” [Online]. Available: <http://www.ana2lp.mx/inteligencia-artificial/vision-computacional-donde-comenzar/>. [Accessed: 01-Mar-2019].
3. Palmar Pol and J. . Montaña Moreno, “Redes Neuronales Artificiales.” [Online]. Available: <http://disi.unal.edu.co/~lctorress/RedNeu/LiRna001.pdf>. [Accessed: 01-Mar-2019].
4. F. Vázquez, “Deep learning,” 2018. [Online]. Available: <https://planetachatbot.com/deep-learning-fácil-con-deepcognition-9af43b2319ba>. [Accessed: 01-Mar-2019].
5. E. Blanco and F. Ramírez, “Introducción a TensorFlow,” 2018. [Online]. Available: <https://data-speaks.luca-d3.com/2018/05/deep-learning-con-python-introduccion.html>. [Accessed: 01-Mar-2019].
6. Ó. Picazo Montoya, “Redes Neuronales Convolucionales Profundas Para El Reconocimiento De Emociones En Imágenes,” Universidad Politécnica de Madrid, 2018.
7. J. A. Luna González, S. Paris, M. NakanoMiyatake, and D. Robles Camarillo, “Redes Neuronales Convoluciones,” 2016. [Online]. Available: https://www.researchgate.net/publication/309455781_Comparacion_de_Arquitecturas_de_Red_Neuronales_Convolucionales_para_la_Clasificacion_de_Imagenes_de_Ojos. [Accessed: 01-Mar-2019].
8. J. A. Pérez Carrasco, M. del C. Serrano Gotarredona, B. Acha Piñero, M. T. Serrano Gotarredona, and B. Linares Barranco, “Red neuronal convolucional rápida sin fotograma para el reconocimeinto de dígitos,” XXVI Simposio de la URSI, no. 1, pp. 1–4, Sep-2011.
9. “CoreML official website developed by Apple.” [Online]. Available: <https://developer.apple.com/machine-learning/>. [Accessed: 18-Mar-2019].
10. “Machine learning for mobile developers by Google.” [Online]. Available: <https://developers.google.com/ml-kit/>. [Accessed: 18-Mar-2019].
11. A. Espinosa Ruiz, “Clasificación de especies de flores usando técnicas de deep learning,” Barcelona, pp. 1–10, Jul-2018.
12. A. Reátequi Pezo and M. A. Velasco Meléndez, “Aplicación informática para reconocimiento especie camu camu (Myrciaria Dubai) a través de redes neuronales convolucionales, en Iguitos Perú, durante el año 2017,” Universidad Nacional de la Amazonía Peruana, 2018.
13. A. Quintero, F. Merchán, A. Cornejo, and J. S. Galán, “Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo,” KnE Eng., vol. 3, no. 1, p. 585, 2018.
14. S. Yoe and L. Jianlong, “Study on Echo features and Classification Methods of Fish Species.” Institute of Electrical and Electronics Engineers Inc., 2018.
15. S. Schneider, G. W. Taylor, and S. Kremer, “Deep Learning object detection methods for ecological camera trap date.” Institute of Electrical and Electronics Engineers Inc., pp. 321–328, 2018.
16. H. Shaukat, K. She, T. Zou, Y. Yue, T. Tianyi, and D. Yantong, “A Deep Learning Framework Using Convolutional Neural Network for Multi-Class Object Recognition.” Institute of Electrical and Electronics Engineers Inc., Chongqing, pp. 194–198, 2018.

17. J. Utrera Burgal, "Deep Learning básico con Keras (Parte 3): VGG," 2018. [Online]. Available: <https://enmilocalfunciona.io/deep-learning-basico-con-keras-parte-3-vgg/>. [Accessed: 15-Oct-2019].
18. "Matriz de confusión." [Online]. Available: [https://es.wikipedia.org/wiki/Matriz de confusi3n](https://es.wikipedia.org/wiki/Matriz_de_confusi3n).
19. A. Jiménez Coronado, "Estrategia de competitividad y emprendimiento, una revisión de la literatura", *Investigacion e Innovación en Ingenierias*, vol. 4, no. 2, p. 104, 2016. DOI: <https://doi.org/10.17081/invinno.4.2.2492>
20. C. Villamizar, A. Orjuela and M. Adarme, "Análisis Forense En Un Sistema De Información En El Marco Normativo Colombiano", *Investigación e Innovación en Ingenierías*, vol. 3, no. 1, 2015. DOI: <https://doi.org/10.17081/invinno.3.1.2036>
21. A. Viloría and W. Quintero, "Gestión de información sat río Manzanares", *Investigación e Innovación en Ingenierías*, vol. 4, no. 2, p. 128, 2016. DOI: <https://doi.org/10.17081/invinno.4.2.2493>
22. C.A. Gutiérrez, R. Almeida., y W. Romero, "Diseño de un modelo de migración a cloud computing para entidades públicas de salud", *Investigación e Innovación en Ingenierías*, vol. 6, n°. 1, pp. 10 - 26., 2018. DOI: <https://doi.org/10.17081/invinno.6.1.2772>
23. A. Contreras, "Gestión de la motivación en escenarios organizacionales" *Investigación e Innovación en Ingenierías*, vol. 6, n°. 1, pp. 84 - 92., 2018. DOI: <https://doi.org/10.17081/invinno.6.1.2777>
24. J. Guillot and A. Viloría, "Estudio Sobre el Abastecimiento Constante de Energía Eólica", *Investigacion e Innovación en Ingenierias*, vol. 3, no. 2, 2015. DOI: <https://doi.org/10.17081/invinno.3.2.2028>
25. P. Sanchez y J. Garcia, «A New Methodology for Neural Network Training Ensures Error Reduction in Time Series Forecasting.» *Journal of Computer Sciences*, vol. 13, nº 7, pp. 211-217, 2017.
26. J. Garcia y P. Sanchez, «Autoregressive Moving Average Recurrent Neural Networks Applied to the Modelling of Colombian Exchange Rate,» *International Journal Of Artificial Intelligence*, vol. 16, nº 2, pp. 194-207, 2018.
27. A.Cruzado, R. Bruges, J. Dávila, Y. Mendoza., y P. Sánchez Sánchez, "Objeto virtual de aprendizaje para el estudio de algoritmos de búsquedas de agentes", *Investigación y Desarrollo en TIC*, vol. 6, nº.1., 2015.