



Uso de Redes Neuronales Artificiales y Computación en la Nube para clasificar la cobertura del suelo en territorio ecuatoriano

Use of Artificial Neural Networks and Cloud Computing to classify land cover in Ecuadorian territory

Uso de redes neurais artificiais e computação em nuvem para classificar a cobertura do solo no território equatoriano

Marco Javier Castelo-Cabay ^I
mcc563@inlumine.ual.es
<https://orcid.org/0000-0003-2400-3049>

Gustavo Iván Buñay-Gualoto ^{II}
mcarrillo2@uteq.edu.ec
<https://orcid.org/0000-0001-8000-8333>

Byron Geovanny Pillajo-Landa ^{III}
bpl853@inlumine.ual.es
<https://orcid.org/0000-0003-0121-4580>

Correspondencia: mcc563@inlumine.ual.es

Ciencias técnicas y aplicadas.
Artículo de investigación

***Recibido:** 16 de marzo de 2021 ***Aceptado:** 19 de abril de 2021 * **Publicado:** 03 de mayo de 2021

- I. Máster en Tecnologías de la Información y de la Comunicación Aplicadas a la Educación, Máster en Tecnologías y Aplicaciones en Ingeniería Informática, Ingeniero en Sistemas Informáticos, Estudiante de Doctorado en Universidad de Almería, España.
- II. Ingeniero en Sistemas Informáticos, Docente del Instituto Tecnológico Luis A. Martínez, Ambato, Ecuador.
- III. Máster en Tecnologías y Aplicaciones en Ingeniería Informática, Ingeniero en Sistemas Informáticos, Universidad de Almería, España.

Resumen

Los gobiernos locales, seccionales y nacionales utilizan mapas de cobertura del suelo en la toma de decisiones políticas, ambientales, seguridad alimentaria, entre otras; la siguiente investigación presentó una nueva alternativa para realizar estos mapas mediante herramientas de computación en la nube como: Google Earth Engine, Google Colaboratory, Google Cloud Storage y Redes Neuronales Artificiales. La clasificación se realizó en la zona centro del territorio ecuatoriano específicamente en la provincia de Chimborazo abarcando una extensión de 6500 km². Se creó una Red Neuronal Artificial usando Tensor Flow y Keras, se clasificaron cinco tipos de cobertura, vegetativo, no vegetativo, agua, nieve y árboles; la arquitectura de la red es de tipo profunda con una entrada de 1024 neuronas, varias capas intermedias de 512, 256, 128 neuronas con una función de activación relu y un dropout de 0.2 entre cada capa que evita el sobre ajuste; una función de salida para cinco clases con una función de activación softmax. La red neuronal fue entrenada durante 100 épocas, tras evaluar el modelo se obtuvo una precisión del 92% en las clasificaciones y una pérdida del 13%. La utilización de plataformas en la nube contribuye al procesamiento de grandes cantidades de datos con capacidad de almacenamiento y procesamiento para realizar la clasificación de amplias coberturas. Además de esto el utilizar redes neuronales artificiales en imágenes satelitales es un campo en expansión que está dando buenos resultados.

Palabras Clave: Redes Neuronales Artificiales; imágenes satelitales; clasificación de la cobertura.

Abstract

Local, sectional and national governments use land cover maps in making political, environmental, and food security decisions, among others; the following research presented a new alternative to make these maps using cloud computing tools such as: Google Earth Engine, Google Colaboratory, Google Cloud Storage and Artificial Neural Networks. The classification was carried out in the central zone of the Ecuadorian territory, specifically in the province of Chimborazo, covering an area of 6,500 km². An Artificial Neural Network was created using Tensor Flow and Keras, five types of coverage were classified, vegetative, non-vegetative, water, snow and trees; the network architecture is deep type with an input of 1024 neurons, several intermediate layers of 512, 256, 128 neurons with a relu activation function and the a dropout of 0.2 between each layer that avoids overfitting; an output function for five classes with a softmax trigger function. The neural network was trained for 100 epochs; After evaluating the model, a

precision of 92% was obtained in the classifications and a loss of 13%. The utilization of cloud platforms contributes to the processing of large amounts of data with storage and processing capacity to perform the classification of wide coverage. In addition to this, using artificial neural networks in satellite images is an expanding field, which is giving good results.

Keywords: Artificial Neural Networks; satellite images; coverage classification.

Resumo

Os governos locais, seccionais e nacionais usam mapas de cobertura da terra na tomada de decisões políticas, ambientais e de segurança alimentar, entre outros; A pesquisa a seguir apresentou uma nova alternativa para fazer esses mapas utilizando ferramentas de computação em nuvem como: Google Earth Engine, Google Colaboratory, Google Cloud Storage e Redes Neurais Artificiais. A classificação foi realizada na zona central do território equatoriano, especificamente na província de Chimborazo, cobrindo uma área de 6.500 km². Uma Rede Neural Artificial foi criada usando Tensor Flow e Keras, cinco tipos de cobertura foram classificados, vegetativo, não vegetativo, água, neve e árvores; a arquitetura de rede é do tipo profundo com uma entrada de 1024 neurônios, várias camadas intermediárias de 512, 256, 128 neurônios com uma função de ativação relu e uma queda de 0,2 entre cada camada que evita overfitting; uma função de saída para cinco classes com uma função de gatilho softmax. A rede neural foi treinada 100 vezes, após avaliação do modelo, obteve-se acurácia de 92% nas classificações e perda de 13%. O uso de plataformas em nuvem contribui para o processamento de grandes quantidades de dados com capacidade de armazenamento e processamento para realizar a classificação de ampla cobertura. Além disso, o uso de redes neurais artificiais em imagens de satélite é um campo em expansão e com bons resultados.

Palavras-chave: Redes Neurais Artificiais; imagens de satélite; classificação de cobertura.

Introducción

La clasificación de la cobertura del suelo proporciona información importante para las distintas entidades gubernamentales en el Ecuador como: GADs(Gobiernos Autónomos Descentralizados), Gobiernos Provinciales, Ministerios; es útil para el ordenamiento territorial (Pinos, 2016), seguimiento del rendimiento de los cultivos (Sepúlveda et al., 2109), levantamiento de indicadores

ambientales (Escandón et al., 2018), inventarios forestales, (Sangurima y Cuasquer, 2019), entre otros; facilitando la toma de decisiones adecuadas que beneficien a la población y ayuden a la protección del medio ambiente. En el Ecuador se han realizado este tipo de clasificaciones usando métodos convencionales y paquetes de software tradicionales (Cartaya et al., 2014; Fernández et al., 2020), pero la necesidad de escalar a superficies amplias es un limitante para estos proyectos (Ma et al., 2015), la plataforma Google Earth Engine (GEE), nos permite hacerlo de una manera rápida, ahorrando recursos en vastas extensiones.

A nivel mundial se han realizado estudios acerca de la clasificación de la cobertura del suelo usando GEE ya que esta herramienta almacena colecciones de imágenes satelitales y permite su procesamiento de una manera rápida y eficiente.

Un estudio en Tailandia utilizó GEE con el objetivo de monitorear los cambios en los ecosistemas de los manglares con datos desde 1987 a 2017 con imágenes Landsat, mediante el algoritmo Random Forest, los resultados de la detección de cambios revelaron una disminución significativa en el área agrícola, mientras que hubo un aumento en el bosque de manglares, la granja de camarones, peces, y tierras baldías (Pimple et al., 2018).

En Malasia se evaluó la viabilidad de GEE como plataforma para estudiar los cambios de cobertura durante varios años mediante el uso de algoritmos de aprendizaje automático. Como resultado se obtuvo que la plataforma se desempeñó bastante bien en términos de tiempo y complejidad de procesamiento. (Wahap y Shafri, 2020)

En una investigación en áreas agrícolas de Canadá se realizó una clasificación de la cobertura del suelo en 10 provincias con un área aproximada de 2.803 millones de km², se utilizaron imágenes Sentinel-1 y Sentinel-2, adquiridas durante el año 2018, se realizó la clasificación basada en objetos con Redes Neuronales Artificiales, se demostró que el método propuesto de computación en la nube es eficiente en términos de costo, tiempo, computación y automatización. (Amani et al., 2020).

La plataforma GEE contiene varios algoritmos de aprendizaje automático predeterminados para realizar clasificaciones de cobertura del suelo: Árboles de Decisión, Máquinas de Soporte Vectorial, Random Forest, pueden ser utilizados por los usuarios de manera sencilla, pero el aprendizaje profundo y las Redes Neuronales Artificiales (RNA) están abriendo nuevas posibilidades para estas aplicaciones con buenos resultados, y ya se utilizan en varias áreas como:

agricultura (Berra, 2017), medicina (Avila et al., 2020), traducción de idiomas (Zhang y Zong, 2020), vehículos autónomos (Kebria et al., 2020), entre otras.

En Ecuador, se han realizado trabajos de la clasificación de la cobertura del suelo usando RNA (Jaramillo y Antunes, 2018; Tituaña, 2018), por medio de métodos y software convencional en pequeñas regiones.

El objetivo de la presente investigación es realizar la clasificación de cobertura vegetal utilizando RNA con la ayuda de Tensor Flow y Keras, herramientas de computación en la nube como: Google Colaboratory (Google Colab), Google Cloud Storage (GCS), GEE, en una zona del centro del Ecuador.

Este trabajo está organizado de la siguiente manera: se describen las herramientas utilizadas para la elaboración de la clasificación de la cobertura del suelo, se muestra la metodología utilizada para finalmente exponer los resultados obtenidos.

Datos y Métodos

Area de estudio

La presente investigación se realizó en la zona central del Ecuador, específicamente en la provincia de Chimborazo tal como se muestra en la figura 1, abarcando una extensión aproximada de 6500 km², posee una variedad de cobertura terrestre como nevados, lagunas, bosques, ciudades, haciéndolo un lugar atractivo para realizar la clasificación de cobertura del suelo.

Figura 1: Ubicación del área de estudio, Provincia de Chimborazo - Ecuador



Herramientas

Los dispositivos de teledetección recogen gran cantidad de datos cada año llegando a formar terabytes de información (Ma et al., 2015, p.171), que se encuentran en distintas plataformas gubernamentales de los Estados Unidos y la Agencia Espacial Europea, su procesamiento y almacenamiento para la elaboración de mapas en grandes extensiones requiere de una ingente cantidad de espacio y capacidad de cómputo, por lo que es necesario utilizar plataformas basadas en la nube.

Geewax (2018) describe la nube como “una colección de servicios que ayuda a los desarrolladores a centrarse en su proyecto en lugar de en la infraestructura que lo impulsa”

Google Earth Engine

Es una plataforma de escala planetaria que utiliza las grandes capacidades de procesamiento y almacenamiento de Google para procesar imágenes satelitales para poder abordar problemas sociales y ambientales como: la deforestación, monitoreo del clima, seguridad alimentaria (Gorelick et al., 2017, p.18)

Esta plataforma permite el análisis geoespacial en la nube sin la necesidad de ocupar la memoria y procesamiento de la computadora del usuario ya que utiliza recursos de Google conectándose a sus servidores, agilizando la velocidad de procesamiento y aumentando enormemente la capacidad de almacenamiento (Perilla y Mas, 2020).

Google Colaboratory

Desde el punto de vista de Sharma (2020) “Es un entorno gratuito de Jupyter Notebook en línea basado en la nube que nos permite entrenar nuestros modelos de aprendizaje automático y aprendizaje profundo en CPU, GPU, TPU”.

Google Cloud

Es una gama de productos y servicios que permite que las personas usen la infraestructura de Google, como máquinas virtuales bajo demanda, almacenamiento, entre otros a través de Google Compute Engine (Geewax, 2018).

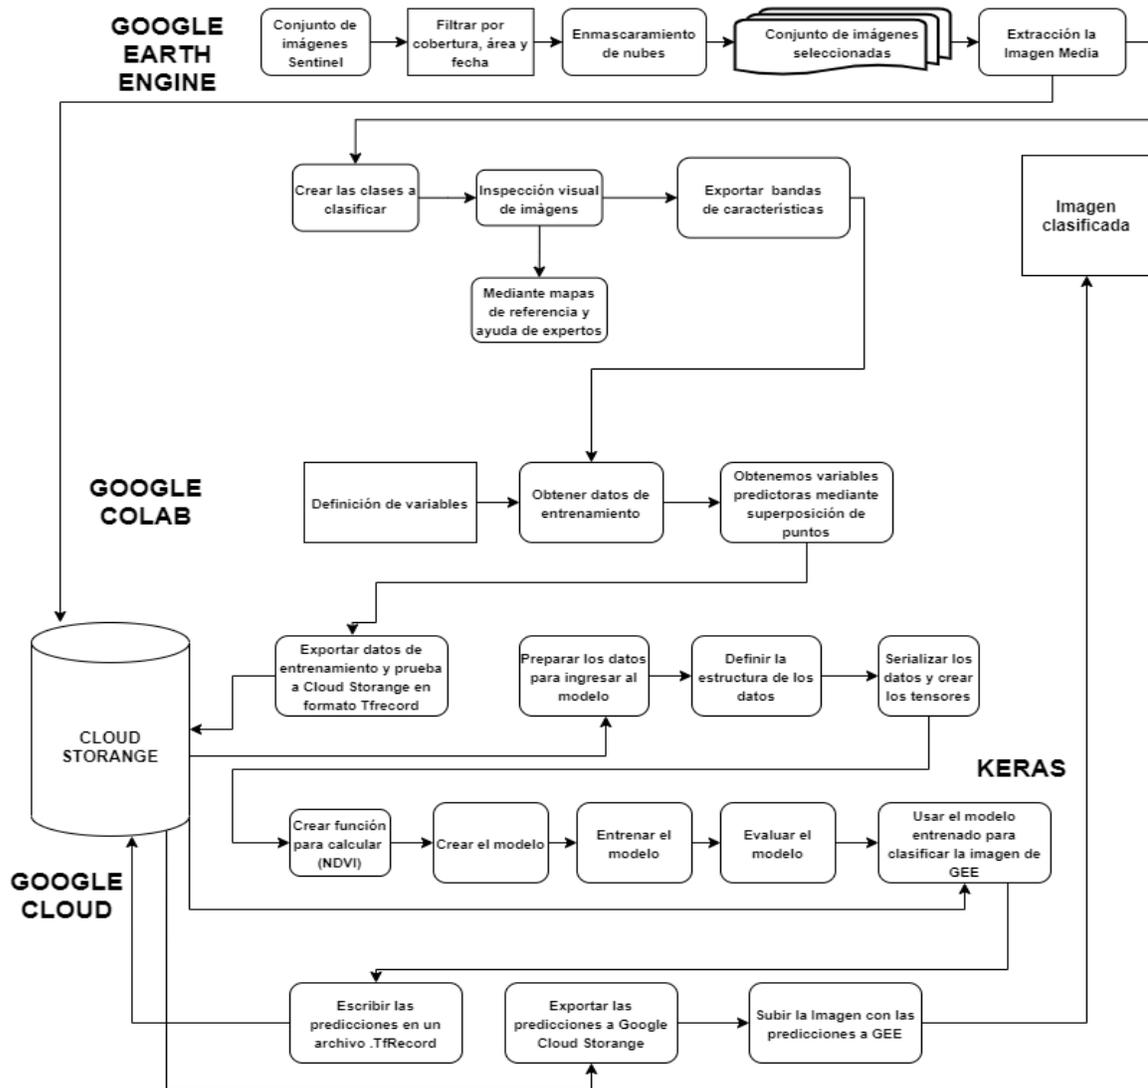
Keras

“Es un framework de alto nivel para el aprendizaje, escrito en Python y capaz de correr sobre los frameworks Tensor Flow, CNTK, o Theano. Fue desarrollado con el objeto de facilitar un proceso de experimentación rápida” (Burgal, 2018).

Metodología

En el siguiente diagrama de flujo de describe la metodología utilizada para la realización del proyecto.

Figura 2: Metodología utilizada para la clasificación de cobertura vegetal mediante redes neuronales y computación en la nube.

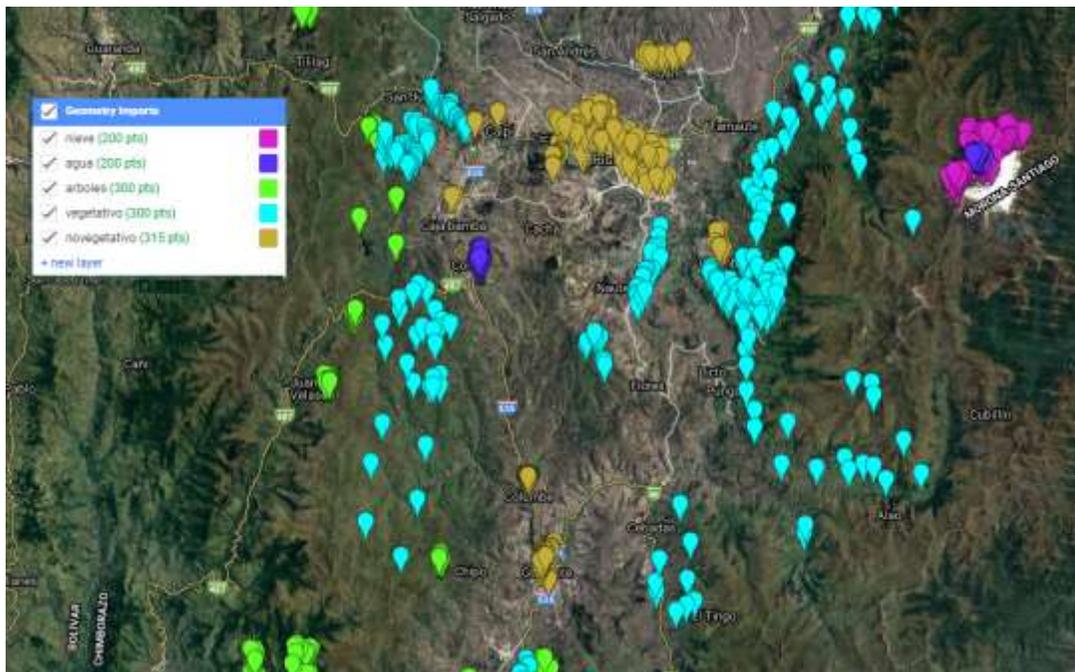


Se utilizó imágenes satelitales Sentinel-2 nivel 1C descargadas desde la plataforma GEE, se hace un filtrado del conjunto de imágenes por cobertura, área y fecha, en este caso en el rango de tiempo fue desde 01-01-2020 hasta el 31-12-2020, se obtuvo un mosaico de imágenes con estos atributos con un porcentaje de nubosidad del 10%, usando un enmascaramiento de cobertura de nubes que es calculado utilizando la banda QA60 que permite reconocer estos pixeles y eliminarlos de las imágenes, una vez obtenido el mosaico respectivo con estas características se extrae la media generando la imagen objetivo donde se realizó la clasificación.

A continuación, se definieron las cinco coberturas a clasificar que son las siguientes: agua, nieve, árboles, vegetativo y no vegetativo. Por vegetativos se entiende: arbustos pequeños, pastizales, páramo, áreas de cultivo, y por no vegetativo: suelo desnudo, calles, carreteras, edificaciones.

Las muestras se obtuvieron por interpretación visual con la ayuda de expertos que conocen la geografía del lugar y mapas de referencia, siendo 200 para nieve, 200 para agua, 300 para árboles, 300 para vegetativo, 315 para no vegetativo, estos datos se los etiqueta de acuerdo con la cobertura que representan, como lo muestra la figura 3.

Figura 3: Muestras obtenidas por interpretación visual de los tipos de cobertura de suelo a clasificar.



Posteriormente los datos etiquetados se los se exportó como un conjunto de características a la base de datos de activos de GEE para que sea leído desde Tensor Flow mediante el API de Python.

Creación de la red neuronal Artificial

Se debe conectar el entorno de GEE y CCS desde Google Colab mediante autenticación con una cuenta de Google que debe ser la misma para todos los entornos. Una vez establecida la conexión se declaran las variables globales que serán utilizadas en todo momento, luego se importa los datos de muestra de las distintas clases etiquetadas que están almacenadas en la base de datos de activos de GEE como se lo describió anteriormente, se superpone los puntos en las imágenes para obtener variables predictoras junto con las etiquetas que son almacenados en un diccionario de características.

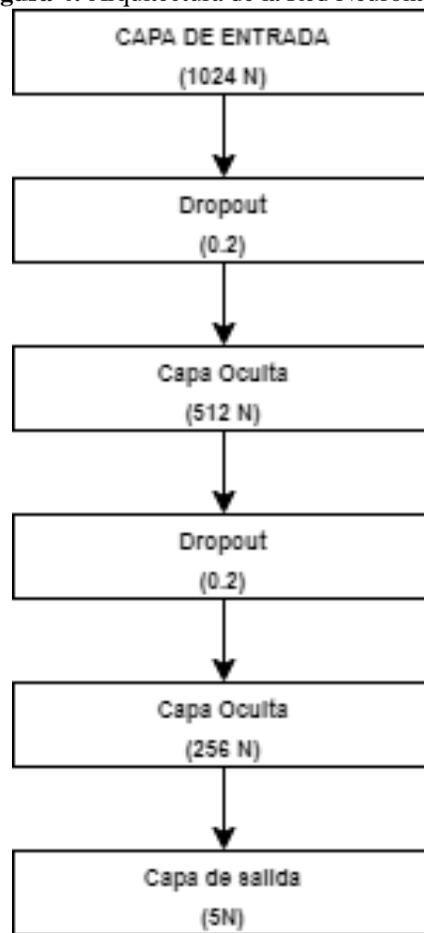
Se dividen los datos en entrenamiento y de prueba con un 70% y 30% respectivamente del conjunto total para almacenarlos en un depósito de GCS hay que transformarlos en un formato tfrecord (Liu, 2020) para que el modelo de Tensor Flow pueda tener acceso a ellos, de igual manera la imagen a clasificar también se la almacena en este depósito usando este formato.

Se procede con la preparación y preprocesamiento de datos definiendo su estructura para que Tensor Flow pueda leer los archivos tfrecords desde GCS en tensores, se crea una función para el análisis de estos datos y tengan la forma de entrada correcta al modelo que será creado en Keras. Se agregaron nuevas características como NDVI (Normalized Difference Vegetation Index), índice de vegetación calculado a partir de la reflectancia en dos bandas espectrales utilizado para la clasificación de la cobertura del suelo que son adheridas a las variables predictoras. La fórmula utilizada para el cálculo de este índice es el siguiente.

$$NDVI = \frac{B8 - B4}{B8 + B4}$$

Con Keras se creó el modelo de Red Neuronal Profunda (RNP) que consta de una entrada de 1024 neuronas, varias capas intermedias de 512, 256, 128 neuronas respectivamente, con una función de activación relu, un dropout de 0.2 entre cada capa para evitar el sobreajuste, una función de salida softmax para que discrimine las cinco características para cada una de las coberturas, como función de pérdida se utilizó la entropía cruzada categórica como se muestra en la figura 4.

Figura 4: Arquitectura de la Red Neuronal.



Fuente: Elaboración propia.

Una vez entrenado el modelo se lo evalúa mediante los datos de prueba, estos deben ser preparados para darles un formato adecuado e ingresarlos al modelo siguiendo el mismo procedimiento que con los datos de entrenamiento.

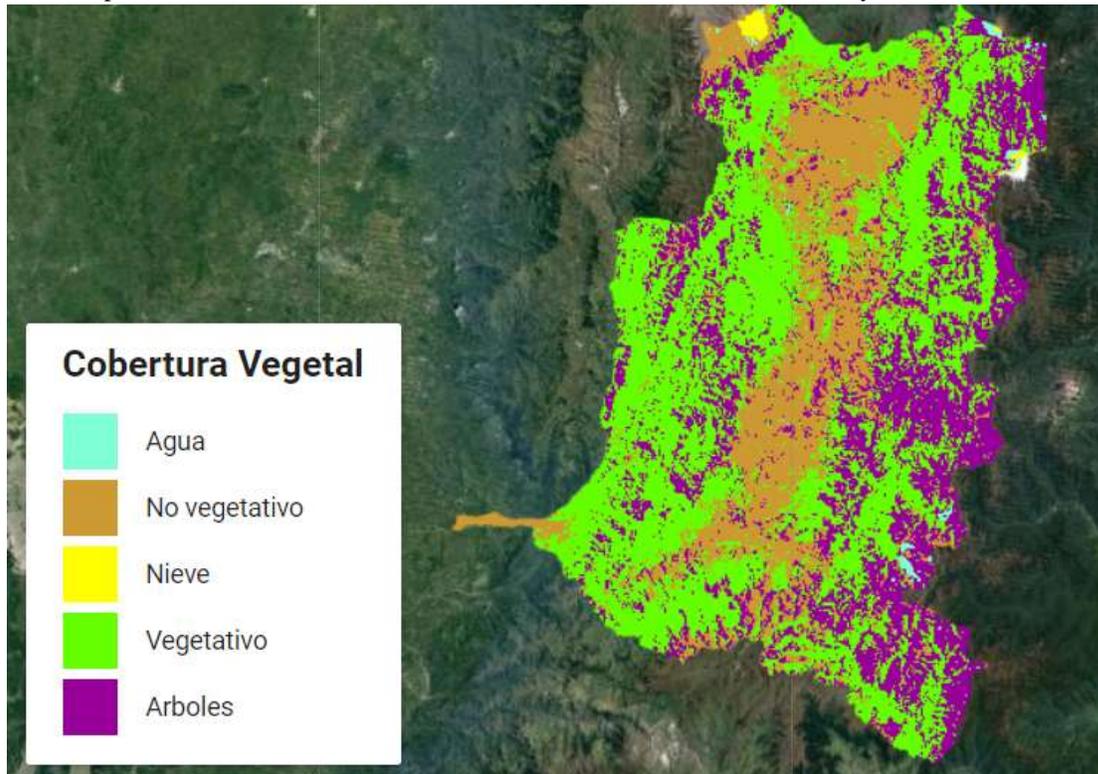
Cuando el modelo ha sido refinado se procede a realizar la clasificación de la imagen, si esta es demasiado grande se divide en varios archivos tfrecord para ser almacenada en el repositorio de GCS.

Los datos con la imagen clasificada en formato tfrecord se los exporta a GEE, donde se coloca una leyenda con una paleta de colores mostrando los resultados de la clasificación de la cobertura del suelo requerida.

Resultados y Discusión

En la figura 5 se muestran los resultados de la clasificación con la respectiva leyenda que identifica a cada una de las coberturas clasificadas mediante la RNP.

Figura 5: Mapa de la clasificación de la cobertura del suelo obtenida mediante GEE y Redes Neuronales Profundas.



En esta investigación se realizó la clasificación de la cobertura del suelo en el territorio ecuatoriano usando computación en la nube y RNA en la provincia de Chimborazo abarcando una superficie aproximada de 6500km² utilizando la plataforma GEE con imágenes Sentinel-2 adquiridas durante el año 2020, se clasificaron cinco tipos de cobertura que son: agua, no vegetativo, vegetativo, nieve y árboles. Se preparó al modelo usando los datos de entrenamiento con 100 épocas mediante el ensayo error hasta tener el resultado con una tasa de aciertos (accuracy) del 92% y una pérdida (loss) de 31%.

Se ha optimizado hardware mediante el uso de un computador local para conectarse a la nube que fue el lugar donde se almacenaron imágenes satelitales, se realizaron los respectivos procesos computacionales hasta obtener el producto final evitando utilizar infraestructura costosa en almacenamiento y capacidad de procesamiento.

El método utilizado fue más factible en términos de costo, tiempo, con resultados confiables, lo que facilitará futuras clasificaciones en extensiones más amplias y en distintas coberturas del territorio ecuatoriano, ahorrando dinero y tiempo a entidades gubernamentales o particulares que necesitan de este tipo de estudios.

El uso de redes neuronales artificiales combinado con la plataforma GEE para la clasificación de cobertura se está promulgando recientemente alcanzando resultados efectivos para cambios de cobertura del suelo (Sun et al., 2019; Murthy et al., 2003; Kumar et al., 2016; Seydi et al., 2020), siendo una novedosa alternativa para realizar la cobertura de cualquier tipo de suelos o hacerlo en territorios extensos.

Además de usar computación en la nube se abre la posibilidad de realizar investigaciones que no solo incluyan métodos de clasificación de aprendizaje automático tradicionales, sino también el aprendizaje profundo, explorar distintas arquitecturas o métodos de redes neuronales para seguir mejorando la precisión en la clasificación de la variada cobertura terrestre del territorio ecuatoriano.

En la presente investigación se han tomado solamente cuatro tipos de cobertura, ya que el objetivo no era obtener una clasificación detallada, sino más bien mostrar las bondades de usar computación en la nube, Redes Neuronales Artificiales, además de describir una metodología para usar estas herramientas que resultan ser novedosas y permiten optimizar tiempo y recursos.

Referencias

1. Aldás Andrade, A. P. (2019, April 29). Análisis de la dinámica temporal del índice de vegetación de diferencia normalizada (NDVI) para los años 1986, 2001 y 2017 en la Reserva Ecológica Cotacachi Cayapas, Imbabura, mediante el uso de google Earth Engine [Tesis de Grado, Universidad Católica del Ecuador]. <http://repositorio.puce.edu.ec/handle/22000/16619>.
2. Amani , M., Kakooei, M., Armin, M. 3, Ghorbanian , A., Ranjgar , B., Mahdavi , S., ... Mohammadzadeh, A. (2020). Application of Google Earth Engine Cloud Computing Platform, Sentinel Imagery, and Neural Networks for Crop Mapping in Canada. *Remote Sensing*,12(21).
<https://doi.org/10.3390/rs12213561>

3. Avila Tomás, J. F., Mayer Pujadas, M. A., y Quesada Varela, V. J. (2020). La inteligencia artificial y sus aplicaciones en medicina I: introducciones antecedentes a la IA y robótica. *Atención Primaria*, 52(10), 778–784. <https://doi.org/DOI:10.1016/j.aprim.2020.04.013>
4. Berra, E. (2017). Eficiencia de las redes neuronales para la toma de decisiones en el sector agrícola análisis exploratorio. *Reaxion*, (2).
5. Burgal, J. (20 de junio de 2018). Deep Learning básico con Keras (Parte 1). En *Mi Local Funciona*. <https://enmilocalfunciona.io/deep-learning-basico-con-keras-parte-1/>.
6. Cartaya Ríos, S., Zurita Alfaro, S., Rodríguez Ríos, E., y Montalvo Párraga, V. (2014). Comparación de técnicas para determinar cobertura vegetal y usos de la tierra en áreas de interés ecológico, Manabí, Ecuador. *REVISTA UD Y LA GEOMÁTICA*, (9), 5–17. <https://doi.org/10.14483/23448407.7883>
7. Escandón, J., Ordóñez, J. A., Nieto de Pascual, M. C. del C., y Ordóñez, M. de J. (2018). Cambio en la cobertura vegetal y uso del suelo del 2000 al 2009 en Morelos, México. *Revista Mexicana De Ciencias Forestales*, 9(46). <https://doi.org/10.29298/rmcf.v9i46.135>
8. Fernández Fierro, A. A., Rosero Erazo, C. R., Beltrán Dávalos, A. A., y Echeverría-Guadalupe, M. M. (2020). Caracterización y dinámica de la cobertura de suelo mediante teledetección: Caso de estudio volcán Tungurahua, Ecuador. *Dominio De Las Ciencias*, 6(2), 906–938. <http://dx.doi.org/10.23857/dc.v6i2.1201>
9. Geewax, J. J. (agosto de 2018). *Google Cloud Platform in Action*. Manning Publications. <https://www.manning.com/books/google-cloud-platform-in-action>.
10. Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202(2017), 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
11. Jaramillo, L. V., y Antunes, A. F. (2018). Detección de cambios en la cobertura vegetal mediante interpretación de imágenes Landsat por redes neuronales artificiales (RNA). Caso de estudio: Región Amazónica Ecuatoriana. *REVISTA DE TELEDETECCIÓN*, 51, 33–46. <https://doi.org/10.4995/raet.2018.8995>

12. Kebria, P. M., Nahavandi, S., Salaken, S. M., y Khosravi, A. (2020). Deep imitation learning for autonomous vehicles based on convolutional neural networks. *EEE/CAA Journal of Automatica Sinica*, 7(1), 82–95. <https://doi.org/10.1109/JAS.2019.1911825>.
13. Kumar, P., Prasad, R., Mishra, V. N., Gupta, D. K., y Singh, S. K. (2016). Artificial neural network for crop classification using C-band RISAT-1 satellite datasets. *Russian Agricultural Sciences*, 42, 281–284. <https://doi.org/10.3103/S1068367416030137>
14. Liu, Y. (18 de febrero de 2020). What is TFRecord and why it's useful for image classification? Medium. <https://lyleaf.medium.com/what-is-tfrecord-and-why-its-useful-for-image-classification-7cb3b25299b6>.
15. Ma, Y., Wang, L., Liu, P., y Ranjan, R. (2015). Towards building a data-intensive index for big data computing – A case study of Remote Sensing data processing. *Information Sciences*, 319,171-188. <https://doi:10.1016/j.ins.2014.10.006>
16. Murthy, C. S., Raju, P. V., y Badrinath, K. V. S. (2003). Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks. *International Journal of Remote Sensing*, 24(23), 4871–4890. <https://doi.org/10.1080/0143116031000070490>
17. Perilla, G. A., y Mas, J. F. (2020). Google Earth Engine (GEE): una poderosa herramienta que vincula el potencial de los datos masivos y la eficacia del procesamiento en la nube. *Investigaciones Geográficas*, 101. <https://doi.org/10.14350/rig.59929>
18. Pimple, U., Simonett, D., Sitth, A., Pungkul, S., Leadprathom, K., Skupek, H., ... Towprayoon, S. (2018). Google Earth Engine Based Three Decadal Landsat Imagery Analysis for Mapping of Mangrove Forests and Its Surroundings in the Trat Province of Thailand. *Journal of Computer and Communications*, 6, 247–264.
19. Pinos, N. (2016). Prospectiva del uso de suelo y cobertura vegetal en el ordenamiento territorial - Caso cantón Cuenca, 5(9).
20. Sangurima Tito, A. C., y Cuasquer Enríquez, F. B. (2019). Análisis multitemporal de la cobertura vegetal y uso del suelo en la reserva ecológica El Ángel, periodo 1990-2017, Carchi-Ecuador [Tesis de Grado, Universidad Técnica del Norte]. <http://repositorio.utn.edu.ec/bitstream/123456789/9408/2/03%20RNR%20321%20TRABAJO%20GRADO.pdf>

21. Sepúlveda Varas, A., Saavedra Briones, P., y Esse, C. (2109). Análisis de cambio de cobertura y uso de suelo en una subcuenca preandina chilena. Herramienta para la sustentabilidad productiva de un territorio. *Revista De Geografía Norte Grande*, 72. <http://dx.doi.org/10.4067/S0718-34022019000100009>
22. Seydi, S. T., Hasanlou, M., y Amani, M. (2020). A New End-to-End Multi-Dimensional CNN Framework for Land Cover/Land Use Change Detection in Multi-Source Remote Sensing Datasets. *Remote Sensing*, 12(12), 2010. <https://doi.org/10.3390/rs12122010>
23. Sharma, A. (29 de diciembre de 2020). Use Google Colab for Deep Learning and Machine Learning Models. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2020/03/google-colab-machine-learning-deep-learning/#1>.
24. Sun , C., Bian , Y., Zhou, T., y Pan, J. (2019). Using of Multi-Source and Multi-Temporal Remote Sensing Data Improves Crop-Type Mapping in the Subtropical Agriculture Region. *Sensors*, 19(10), 2401. <https://doi.org/10.3390/s19102401>
25. Tensorflow. (9 de agosto de 2020) TFRecord and tf.train.Example : TensorFlow Core. TensorFlow. https://www.tensorflow.org/tutorials/load_data/tfrecord.
26. Tituaña Jami, J. C. (25 ed octubre de 2018). Desarrollo de un método para la clasificación automatizada de imágenes Landsat 8 mediante Redes Neuronales Artificiales. EPN. <https://bibdigital.epn.edu.ec/handle/15000/19806?mode=full>.
27. Wahap, N. A., y Shafri, H. Z. M. (2020). Utilization of Google Earth Engine (GEE) for land cover monitoring over Klang Valley, Malaysia. *IOP Conference Series: Earth and Environmental Science*, 540, 012003. <https://doi.org/10.1088/1755-1315/540/1/012003>
28. Zhang, J. J., y Zong, C. Q. (2020). Neural machine translation: Challenges, progress and future. *Sci China Tech Sci*, 63(10), 2028–2050. <https://doi.org/10.1007/s11431-020-1632-x>