


# CARACTERIZACIÓN AUTOMÁTICA DE TERRENOS PARA AGRICULTURA CON REDES NEURONALES CONVOLUCIONALES

JULIO SUAREZ FLECHAS  
DIEGO NARANJO INFANTE



**CPS**  
RESEARCH GROUP

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS  
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE  
TELECOMUNICACIONES  
INGENIERÍA ELECTRÓNICA  
BUCARAMANGA

2023

CARACTERIZACIÓN AUTOMÁTICA DE TERRENOS PARA  
AGRICULTURA CON REDES NEURONALES CONVOLUCIONALES

JULIO SUAREZ FLECHAS  
DIEGO NARANJO INFANTE

*Trabajo de grado presentado como requisito para optar al título de*  
Ingeniero Electrónico

Director  
Said Pertuz, PhD

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS  
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE  
TELECOMUNICACIONES  
INGENIERÍA ELECTRÓNICA  
BUCARAMANGA

2023

---

## CONTENIDO

---

	Pág.
<b>INTRODUCCIÓN</b>	<b>7</b>
<b>2 OBJETIVOS</b>	<b>9</b>
2.1. Objetivo general . . . . .	9
2.2. Objetivos específicos . . . . .	9
<b>3 CREACIÓN DE LA BASE DE DATOS DE IMÁGENES</b>	<b>10</b>
3.1. SELECCIÓN DE LAS BASES DE DATOS DE GOOGLE EARTH ENGINE	11
3.2. CREACIÓN Y POST PROCESAMIENTO DE LA BASE DE DATOS CREA- DA. . . . .	14
<b>4 DISEÑO DE LA ARQUITECTURA DE LA RED NEURONAL CONVOLU- CIONAL</b>	<b>17</b>
4.1. SEGMENTACIÓN SEMÁNTICA. . . . .	17
4.2. ARQUITECTURA PROPUESTA. . . . .	18
<b>5 ENTRENAMIENTO Y EVALUACIÓN DE LA RED NEURONAL CONVOLU- CIONAL</b>	<b>21</b>
5.1. PARÁMETROS DE IMPLEMENTACIÓN . . . . .	21
5.2. RESULTADOS OBTENIDOS . . . . .	21
<b>6 CONCLUSIONES</b>	<b>29</b>
<b>BIBLIOGRAFÍA</b>	<b>30</b>
<b>APÉNDICES</b>	<b>32</b>

---

## LISTA DE FIGURAS

---

	<b>Pág.</b>
Figura 1. Google Earth Engine. . . . .	10
Figura 2. Ejemplo de bases de datos de GEE: (A) Datos de temperatura de la superficie. (B) Datos del clima. Tomado de [4]. . . . .	11
Figura 3. Ejemplo de bases de datos de GEE: (A) Datos de tiempo. (B) Datos de Landsat. Tomado de [4]. . . . .	12
Figura 4. Ejemplo de bases de datos de GEE: (A) Datos de terreno. (B) Datos del NAIP. Tomado de [4]. . . . .	13
Figura 5. Base de datos Cropland. Tomado de [4]. . . . .	13
Figura 6. Ejemplo de imágenes generadas . . . . .	14
Figura 7. Exportación de las imágenes. . . . .	15
Figura 8. Imagen corregida . . . . .	15
Figura 9. Aumento y reducción espacial para segmentación semántica. Tomado de [11] . . . . .	18
Figura 10. Arquitectura de la red neuronal para realizar el proceso de down-sampling. . . . .	19
Figura 11. Arquitectura de la red neuronal para realizar el proceso de upsampling. . . . .	20
Figura 12. Resultados del primer entrenamiento con carpeta de imágenes de entrenamiento. . . . .	22
Figura 13. Comparación de la imagen etiquetada original con la imagen etiquetada generada. . . . .	23
Figura 14. Resultados del entrenamiento . . . . .	25
Figura 15. Comparación de la imagen etiquetada original con la imagen etiquetada generada. . . . .	26
Figura 16. Comparación de la imagen etiquetada original con la imagen etiquetada generada. . . . .	27
Figura 17. Caracterización de imágenes de terrenos Colombianos. . . . .	28

---

## RESUMEN

---

<b>TÍTULO:</b>	CARACTERIZACIÓN AUTOMÁTICA DE TERRENOS PARA AGRICULTURA CON REDES NEURONALES CONVOLUCIONALES *
<b>AUTORES:</b>	Diego Naranjo Infante ** Julio Suarez Flechas **
<b>PALABRAS CLAVE:</b>	Caracterización automática, Google Earth Engine, imágenes cropland, imágenes satelitales, Python, redes neuronales convolucionales.

### DESCRIPCIÓN

Este documento presenta el diseño de un sistema para caracterizar automáticamente terrenos para agricultura mediante redes neuronales convolucionales. El proyecto propone brindar estimaciones de superficie en cuanto a tierras de cultivo, permitiendo clasificar, caracterizar y describir terrenos georreferenciados. Por medio de aprendizaje automático se realiza una clasificación supervisada de imágenes satelitales, con la arquitectura de una red neuronal convolucional, la cual se entrena usando imágenes ya caracterizadas por el departamento de agricultura de Estados Unidos (USDA). En cada capítulo se presenta uno de los procesos que se llevaron a cabo en el desarrollo del algoritmo para caracterizar automáticamente terrenos para agricultura con redes neuronales convolucionales. El primer proceso consiste en la creación de la base de datos con la cual se realizará el entrenamiento de la red neuronal. El segundo corresponde al diseño e implementación de la arquitectura de la red neuronal convolucional para identificar como mínimo cuatro tipos de terrenos, a partir de imágenes satelitales. Finalmente, se propone utilizar la red previamente entrenada, para evaluar su funcionamiento con imágenes satelitales de terrenos Colombianos.

---

\*Trabajo de investigación.

\*\* Facultad de Ingenierías Fisicomecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: Said Pertuz, PhD.

---

## ABSTRACT

---

**TITLE:** Automatic terrain mapping for agriculture with convolutional neural networks. \*

**AUTHORS:** Diego Naranjo Infante \*\*  
Julio Suarez Flechas \*\*

**KEYWORDS:** Automatic characterization, Google Earth Engine, cropland imagery, satellite imagery, Python, convolutional neural networks.

### DESCRIPTION:

This paper presents the design of a system to automatically characterize agricultural land using convolutional neural networks. The project proposes to provide surface estimations in terms of arable land, allowing to classify, characterize and describe georeferenced land. By means of machine learning, a supervised classification of satellite images is performed, with the architecture of a convolutional neural network, which is trained using images already characterized by the United States Department of Agriculture (USDA). Each chapter presents one of the processes that were carried out in the development of the algorithm to automatically characterize land for agriculture with convolutional neural networks. The first process consists of the creation of the database with which the training of the neural network will be carried out. The second corresponds to the design and implementation of the architecture of the convolutional neural network to identify at least four types of terrain from satellite images. Finally, it is proposed to use the previously trained network to evaluate its performance with satellite images of Colombian terrains.

---

\*Bachelor Thesis

\*\* Facultad de Ingenierías Fisicomecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: Said Pertuz, PhD.

---

## INTRODUCCIÓN

---

En las últimas décadas la demanda mundial de alimentos ha crecido rápidamente. Parte de las actuales tierras de cultivo del mundo tienen rendimientos muy inferiores a su potencial, y la actual trayectoria mundial de expansión agrícola tiene graves consecuencias a largo plazo para el medio ambiente [13]. De esta manera, la forma como el ser humano logre adaptarse y generar transferencias de tecnologías al sector agrícola genera la posibilidad de obtener mejoras en la utilización de nutrientes, en la fertilidad del suelo y en una eventual disminución en la emisión de gases de efecto invernadero, proporcionando un camino hacia un ambiente agrícola más sostenible.

Generar herramientas tecnológicas con las cuales apoyar y mejorar la producción de alimentos se convierte en una oportunidad para ayudar a los campesinos Colombianos y una manera de empezar con esto es poder identificar distintas cubiertas que se presentan en la superficie de los terrenos, generando la posibilidad de clasificar distintas áreas como lo son sectores con agua, suelo árido, bosques, distintos tipos de cultivos y edificaciones, etc. Poder tener un proceso de clasificación de imágenes que permita la extracción de información presente en las imágenes satelitales y la generación de un complemento con técnicas cuantitativas permitirá una automatización para identificar las áreas de interés contenidas en el entorno.

En un reciente trabajo realizado en Colombia [12], se presenta un método de aprendizaje automático basado en redes neuronales convolucionales para la clasificación automática de coberturas del suelo a partir de imágenes Landsat 5 TM. La red neuronal convolucional fue entrenada a partir de las anotaciones manuales por medio de interpretación visual sobre las imágenes satelitales con las que los expertos generaron el mapa de cobertura del parque nacional el Tuparro, de los Parques Nacionales Naturales de Colombia. Los resultados obtenidos de la diagonal de la matriz de confusión de la exactitud promedio fue de 83.27 % en entrenamiento y 91.02 % en validación; para la clasificación en parches entre Bosques y áreas con

vegetación herbácea.

Otros trabajos plantean la incursión directa de la clasificación de varias clases de coberturas terrestres. El trabajo en [3] presenta un método regularizado de extracción de características profundas para la clasificación de imágenes hiperespectrales utilizando una red neuronal convolucional. El enfoque propuesto emplea varias capas convolucionales y de agrupación para extraer características profundas de las imágenes hiperespectrales. Además, para abordar el problema común del desequilibrio entre la alta dimensionalidad y la disponibilidad limitada de muestras de entrenamiento para la clasificación de imágenes hiperespectrales, se aplicaron distintas técnicas de duplicación de información, esto con el fin de agregar copias ligeramente modificadas de los datos ya existentes, asegurando que se evitara el sobre ajuste en el modelado de datos de cada clase y de esta forma se lograra tener un equilibrio en la base de datos con la que se realizara el entrenamiento.

Este proyecto tiene como objetivo diseñar un sistema para caracterizar mínimo 4 diferentes tipos de cultivos de forma automática mediante redes neuronales convolucionales. El proyecto propone brindar estimaciones de superficie en cuanto a tierras de cultivo, permitiendo clasificar, caracterizar y describir terrenos georreferenciados. En este proceso se utilizará la arquitectura Unet [10], la cual es una arquitectura de red neuronal convolucional utilizada en la detección de cáncer de seno, siendo usada en la segmentación semántica de las imágenes y la cual se puede migrar a diferentes áreas de aplicación.

---

## 2. OBJETIVOS

---

### 2.1 Objetivo general

- Diseñar un sistema para caracterizar automáticamente terrenos para agricultura mediante redes neuronales convolucionales.

### 2.2 Objetivos específicos

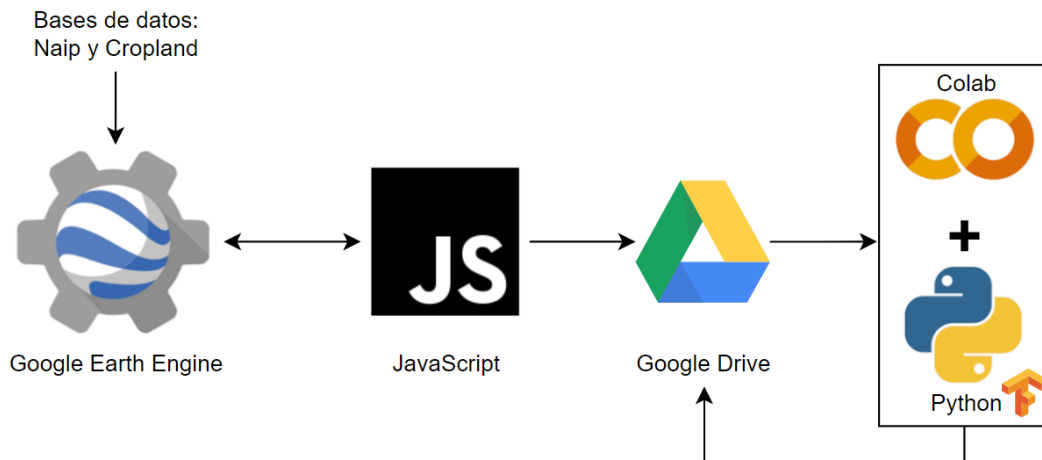
- Crear una base de datos, de mínimo cuatro clases de terrenos, a partir de imágenes de diferentes zonas de Estados Unidos, utilizando las bases de datos CDL (Cropland Data Layer)[8] y NAIP (National Agriculture Imagery Program)[7].
- Diseñar e implementar la arquitectura de la red neuronal convolucional para identificar como mínimo cuatro tipos de terrenos, a partir de imágenes satelitales.
- Utilizar la red previamente entrenada, para evaluar su funcionamiento con imágenes satelitales de terrenos Colombianos.

---

### 3. CREACIÓN DE LA BASE DE DATOS DE IMÁGENES

---

En esta primera sección se describe la estrategia adoptada para la creación de una base de datos que permitiera entrenar la red neuronal para la caracterización automática de terrenos para agricultura. Google Earth Engine es una plataforma de geomática basada en la nube que permite a los usuarios visualizar y analizar imágenes de satélite de nuestro planeta, permitiendo llevar a cabo estudios de teledetección remota, predecir brotes de enfermedades, gestionar recursos naturales, etc, basándose en la arquitectura propuesta en la Figura 1. De este modo, se convierte en una opción interesante para poder examinar grandes bases de datos con imágenes satelitales [9]. Sin embargo, es importante tener en cuenta que al trabajar con imágenes de satélites que se encuentran en constante movimiento y a distancias considerables respecto a la corteza terrestre se deberán realizar ajustes rotación o traslación para lograr obtener imágenes sin ningún tipo de inclinación, creando la necesidad de acudir a diferentes técnicas para realizar el pre-procesamiento de las imágenes [5].



**Figura 1:** Google Earth Engine.

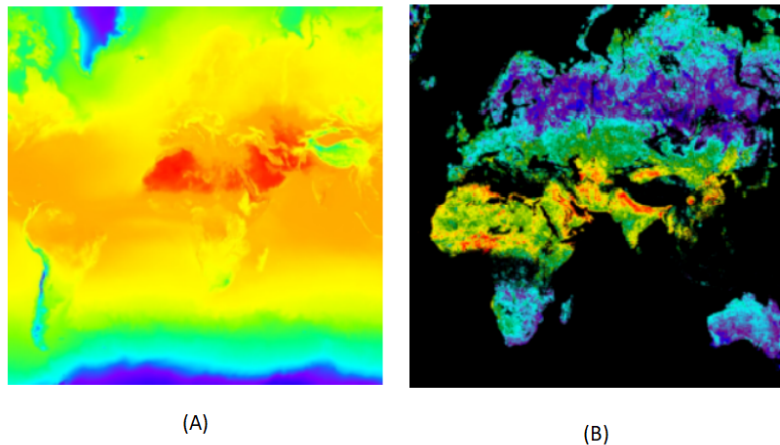
En la Figura 1 se puede observar el proceso completo que se llevara a cabo para realizar la exportación de imágenes hacia Google Drive y su posterior procesamiento en Colab. Para la creación de la base de datos es necesario el desarrollo del

código en la API de JavaScript brindada por Google Earth Engine. Este código se encargará de lanzar el proceso de exportación de las imágenes de las bases de datos de Google Earth Engine.

### 3.1 SELECCIÓN DE LAS BASES DE DATOS DE GOOGLE EARTH ENGINE


Las bases de datos de Google Earth Engine se actualizan a medida que se toman nuevas imágenes y se pueden consultar a través de diferentes criterios (calidad, localización, fechas, etc)[9]. A continuación se encuentra una lista con los datasets disponibles en Google Earth Engine:

- **Temperatura de la superficie:** Los sensores térmicos de los satélites pueden proporcionar información sobre la temperatura y la emisividad de la superficie (Figura 2-A).
- **Clima:** Los modelos climáticos generan tanto predicciones climáticas a largo plazo como interpolaciones históricas de las variables de superficie (Figura 2-B).



**Figura 2:** Ejemplo de bases de datos de GEE: (A) Datos de temperatura de la superficie. (B) Datos del clima. Tomado de [4].

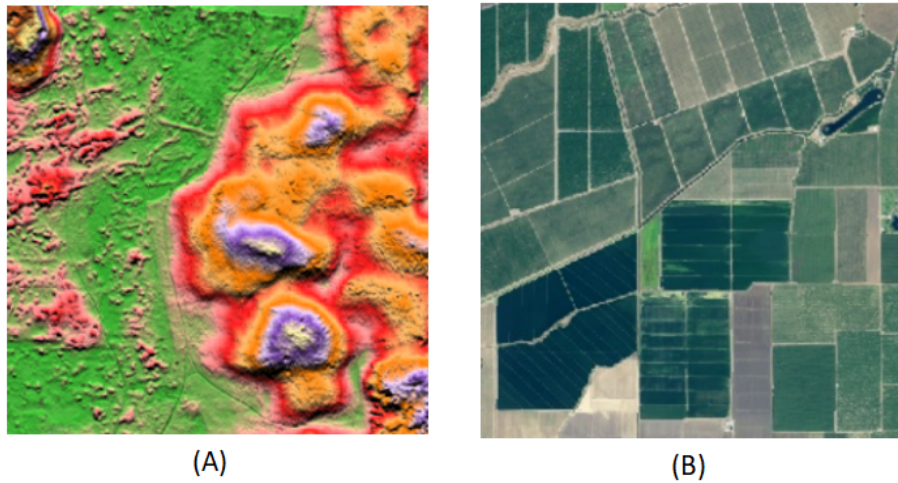
- **Tiempo:** Los conjuntos de datos meteorológicos describen las condiciones pronosticadas y medidas durante cortos periodos de tiempo, incluidas las precipitaciones, la temperatura, la humedad y el viento, así como otras variables (Figura 3-A).




**Figura 3:** Ejemplo de bases de datos de GEE: (A) Datos de tiempo. (B) Datos de Landsat. Tomado de [4].

- **Landsat:** En la actualidad, los satélites Landsat toman imágenes de toda la superficie terrestre con una resolución de 30 metros cada dos semanas aproximadamente, incluyendo datos multiespectrales y térmicos (Figura 3-B).
- **Terreno:** Los modelos digitales de elevación (MDE) describen la forma del terreno de la Tierra (Figura 4-A).
- **NAIP(Programa Nacional de Imágenes Agrícolas):** Adquiere imágenes aéreas durante las temporadas de cultivo en el territorio continental de EE.UU. Los proyectos del NAIP se contratan cada año en función de la financiación disponible y del ciclo de adquisición de imágenes (Figura 4-B).
- **Cropland:** Los datos sobre las tierras de cultivo son fundamentales para comprender el consumo de agua y la producción agrícola a nivel mundial. Earth Engine incluye una serie de productos de datos de tierras de cultivo, como las capas de datos de tierras de cultivo del USDA NASS, así como capas de los Datos de análisis de apoyo a la seguridad alimentaria mundial (GFSAD) que incluyen la extensión de las tierras de cultivo, el predominio de los cultivos y las fuentes de riego.

Para este proyecto las bases de datos seleccionadas de Google Earth Engine fueron: USDA NASS Cropland Data Layer, el cual cuenta con una base de datos de



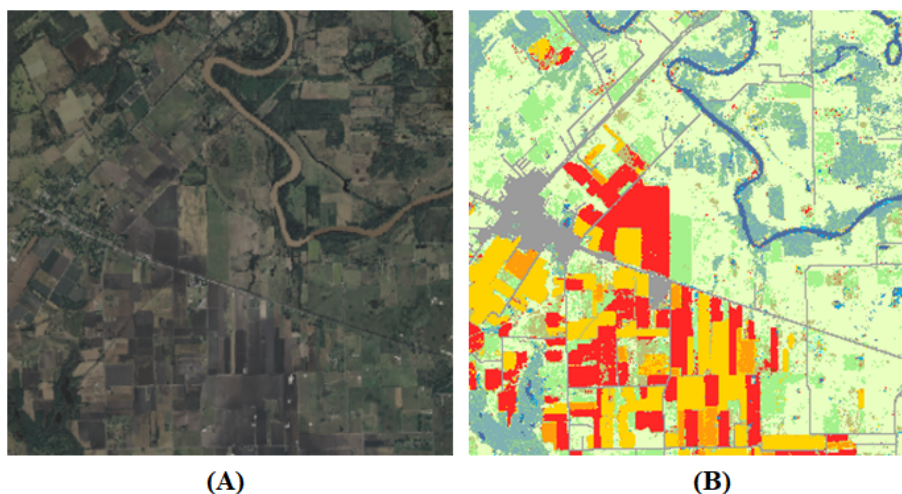
**Figura 4:** Ejemplo de bases de datos de GEE: (A) Datos de terreno. (B) Datos del NAIP. Tomado de [4].



**Figura 5:** Base de datos Cropland. Tomado de [4].

cobertura del suelo específica de los cultivos, creada anualmente para el territorio continental de los Estados Unidos utilizando imágenes de satélite de resolución moderada y una amplia variedad agrícola sobre el terreno [8], y el NAIP (National Agriculture Imagery Program), el cual cuenta con una base de datos de imágenes aéreas adquiridas durante las temporadas de crecimiento agrícola en el territorio continental de Estados Unidos [2].

En la Figura 6 se pueden observar dos imágenes generadas del mismo territorio, cada una desde las bases de datos seleccionada.



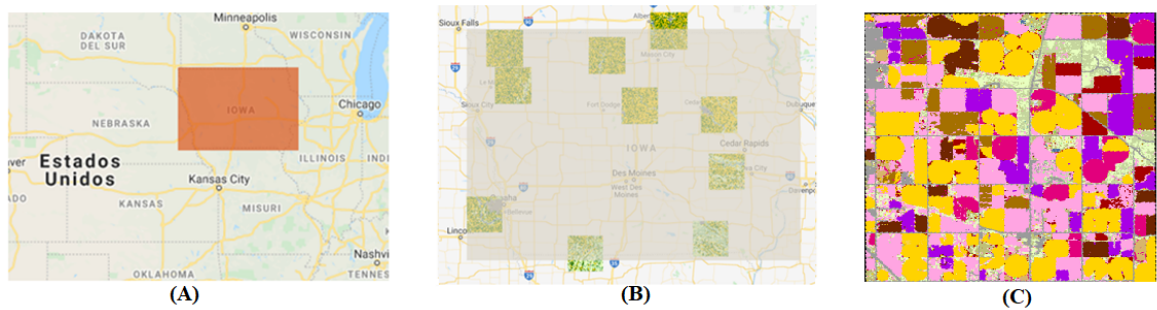
**Figura 6:** Imagen generada: (A) Imagen satelital NAIP. (B) Imagen Cropland.

### 3.2 CREACIÓN Y POST PROCESAMIENTO DE LA BASE DE DATOS CREADA.

El rendimiento del entrenamiento de la red neuronal depende directamente de la cantidad de imágenes que se tengan en la base de datos, por tanto, esta se conformará de cientos de imágenes satelitales, y cada una contará con una imagen la cual tendrá la distribución de cultivos que se encuentran en esta área.


Para efectos del proyecto, se procedió a seleccionar una región geográfica de referencia (Figura 7-A). Teniendo el área de extracción delimitada indicándonos de donde se tomara la imagen, se procede a la generación de cierta cantidad de puntos aleatorios. Posterior a esto se realiza la conversión de cada punto aleatorio en una zona circular con área definida y se convierte el área circular en un área cuadrada, la cual nos indicara el tamaño de cada imagen. Teniendo definido el tamaño de cada imagen, se procede a realizar la importación de las bases de datos en cada una de las áreas que están presentes en el polígono generado, como se muestra en la Figura 7-B. Finalmente se procede a realizar la exportación de la cantidad de imágenes en las cuales se cargaron las bases de datos, cada pareja irá con el mismo nombre, pero se enviarán a diferentes carpetas en Google Drive. Antes de exportar las imágenes se indica la resolución, para las bases de datos generadas se tendrán imágenes con una resolución de 30 metros por píxel, como se muestra

en la Figura 7-C.



**Figura 7:** Exportación de las imágenes: (A) Creación de un polígono. (D) Importación de las bases de datos. (E) Exportación de las imágenes.

Al realizar el proceso de exportación de imágenes es posible obtener imágenes con diferentes orientaciones (Figura 8-A). Para solucionar este problema, se implementó un algoritmo para hacer un registro afín que detecte la rotación y escala de la imagen para estandarizar todas las imágenes a una misma orientación (Figura 8-C).



**Figura 8:** Corrección de una imagen: (A) Imagen inclinada. (B) Imagen registrada con corrección de orientación y escala.

A partir del proceso anteriormente descrito, se obtuvo una base de datos con un total de 1450 imágenes, donde cada imagen tiene un tamaño de 256x256 píxeles.

## *CREACIÓN DE LA BASE DE DATOS DE IMÁGENES*

---

Realizando el conteo respectivo de la cantidad de clases (cultivos agrícolas) se tiene una cantidad de 123 clases en la base de datos generada.

Imágenes	1450
Tamaño	256x256 píxeles
Clases	123

**Cuadro 1:** Características de la base de datos.

---

## 4. DISEÑO DE LA ARQUITECTURA DE LA RED NEURONAL CONVOLUCIONAL

---


En esta sección se describe el diseño de la arquitectura de la red neuronal convolucional. En la sección 3.1 se describen los fundamentos sobre segmentación semántica mediante CNNs y la sección 3.2 describe la arquitectura desarrollada en este proyecto.

### 4.1 SEGMENTACIÓN SEMÁNTICA.

La segmentación semántica es un problema de aprendizaje de máquina que asocia una etiqueta o categoría a cada píxel presente en una imagen. Se utiliza para reconocer un conjunto de píxeles que conforman distintas categorías.

Para la segmentación semántica a nivel de píxel mediante redes neuronales convolucionales, se agrega una implementación inversa de una CNN. El proceso de aumento de la dimensión espacial se realiza el mismo número de veces que el proceso de reducción de la dimensión espacial para garantizar que la imagen final tenga el mismo tamaño que la imagen de entrada. Por último, se utiliza una capa de salida de clasificación de píxeles, que asigna cada píxel a una clase concreta. Esto conforma una arquitectura de codificador-decodificador, la cual permite la segmentación semántica [11].


Para poder desarrollar el aumento espacial es importante tener en cuenta que esta se logra mediante convolución transpuesta la cual funciona de forma inversa que la convolución normal, esto con el fin de aumentar el tamaño de la imagen. En la Figura 9 se puede observar la finalidad de realizar el upsampling, en donde la salida del sistema sera una imagen etiquetada de la imagen original.



**Figura 9:** Aumento y reducción espacial para segmentación semántica. Tomado de [11]

#### **4.2 ARQUITECTURA PROPUESTA.**

Para realizar la selección de la arquitectura de la red neuronal es necesario basarse en tres principales puntos: base de datos con la cual deberá ser entrenada la red neuronal, cantidad de clases utilizadas en el entrenamiento de la red neuronal y cantidad de imágenes utilizadas para el entrenamiento de la red neuronal. El éxito del entrenamiento de las redes neuronales profundas requiere de extensas muestras de entrenamiento por tanto esta es la mayor limitante debido al tamaño de los datos de entrenamiento disponibles, por ejemplo en [1] usaron 1 millón de imágenes de entrenamiento. En [10] se presenta una red y una técnica de entrenamiento basada en el aumento de datos para usar las muestras de entrenamiento con mayor eficiencia, por tanto se muestra que una red se puede entrenar a partir de muy pocas imágenes siendo esta la mayor motivación para hacer uso de esta arquitectura, llamada U-NET. Esta arquitectura consiste en una ruta de contracción para capturar la información de la imagen y una ruta de expansión simétrica que permite una localización precisa de las etiquetas.




**Figura 10:** Arquitectura de la red neuronal para realizar el proceso de downsampling.

En la Figura 10 se puede observar la ruta de contracción y en la Figura 11 se puede observar el camino expansivo. La ruta de contracción sigue la arquitectura típica de una red neuronal convolucional. Consiste en la aplicación repetida de dos convoluciones de  $3 \times 3$ , cada una de ellas seguida de una unidad lineal rectificadora (ReLU) y una operación de agrupación máxima de  $2 \times 2$  con stride 2. En cada paso de downsampling se duplica el número de canales de características y se reduce el ancho y alto de las imágenes.

Ahora en el upsampling, cada paso de la ruta expansiva consiste en un aumento dimensional del mapa de características mediante una convolución transpuesta  $2 \times 2$  que reduce a la mitad el número de canales de características y aumenta el ancho y alto de la imagen en la misma proporción de la ruta de contracción. Después de realizar la convolución transpuesta se realiza la concatenación con el mapa de características de la ruta de contracción y posteriormente se desarrollan dos convoluciones  $3 \times 3$ , cada una de ellas seguida de un ReLU. Así es como clasifica cada

## DISEÑO DE LA ARQUITECTURA DE LA RED NEURONAL CONVOLUCIONAL

uno de los píxeles en una de las clases, y se pueda visualizar como el mapa de segmentación que se muestra a la salida de la red. [10].



**Figura 11:** Arquitectura de la red neuronal para realizar el proceso de upsampling.

---

## 5. ENTRENAMIENTO Y EVALUACIÓN DE LA RED NEURONAL CONVOLUCIONAL

---

El tercer reto corresponde al entrenamiento y evaluación de la red neuronal convolucional.

### 5.1 PARÁMETROS DE IMPLEMENTACIÓN

Para realizar el entrenamiento de la red neuronal se utiliza la plataforma de Google Colab. Para el primer entrenamiento se procede a dividir la base de datos de 1450 imágenes en un 90 % de imágenes (1305 imágenes) para realizar el entrenamiento, el 5 % (72 imágenes) para ejecutar la validación de la red durante el entrenamiento y un 5 % (72 imágenes) para realizar la evaluación de la red.

Para el proceso de entrenamiento se hace uso de la técnica de pérdida entropía cruzada categórica y el algoritmo de optimización Adam.

Se inicia con una tasa de aprendizaje de 0.001 ya que al realizar los primeros entrenamientos y viendo los resultados del conjunto de datos de validación se observa que esta tasa es la más óptima. Además, se implementa el algoritmo ReduceLROnPlateau con el objetivo de reducir la tasa de aprendizaje cuando la medida de rendimiento deja de mejorar, en [14] se evidencia la optimización de la red haciendo uso de esta técnica.

Finalmente el algoritmo EarlyStopping es usado con el objetivo de elegir la cantidad de épocas a entrenar la red con el fin de evitar el sobre-entrenamiento. Este mecanismo fue tomado por los resultados mostrados en [6].

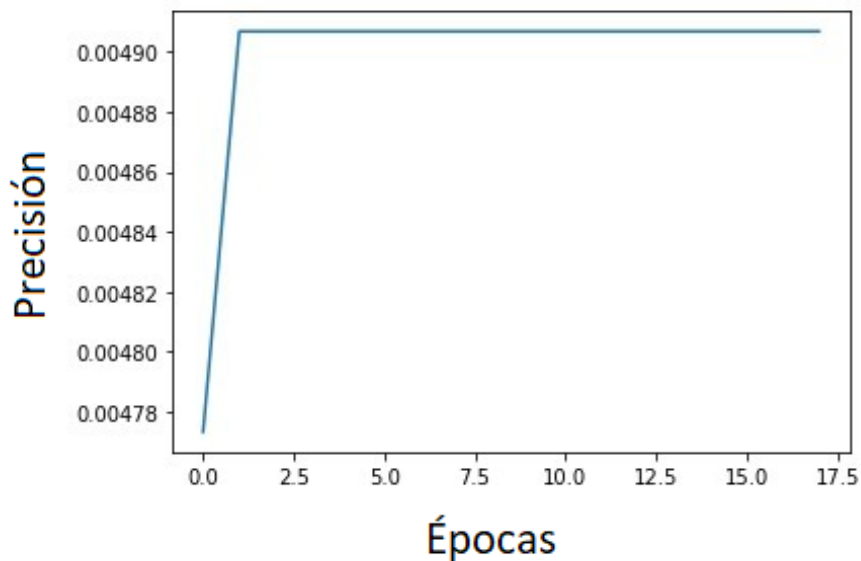
### 5.2 RESULTADOS OBTENIDOS

Para realizar la evaluación del entrenamiento de la red neuronal se utilizarán las medidas de precisión que calcula con qué frecuencia las predicciones son iguales a las etiquetas y de IOU (Intersección sobre unión) esta métrica nos indica el grado de

## ENTRENAMIENTO Y EVALUACIÓN DE LA RED NEURONAL CONVOLUCIONAL

similitud entre la imagen de salida de la red neuronal y la imagen etiquetada original.

En la Figura 12 se puede observar el la gráfica de precisión del primer entrenamiento de la red neuronal con 1450 imágenes y 123 clases. Es notable como al tener tal cantidad de clases la red no logra comenzar a realizar un entrenamiento óptimo y llega a un punto menor al 1 % de precisión en este entrenamiento. Al realizar este entrenamiento no es posible observar la gráfica de intersección sobre unión, ya que en cualquier momento del entrenamiento tendría un valor de 0.




**Figura 12:** Resultados del primer entrenamiento con carpeta de imágenes de entrenamiento.

A partir de los resultados del primer entrenamiento se toma la decisión de realizar la agrupación de clases, en el Cuadro 2 se pueden observar los resultados de esta agrupación de clases:

CANTIDAD DE CLASES	PRECISIÓN
123	0,0049 %
93	0,0063 %
63	0,0124 %
33	0,0169 %

**Cuadro 2:** Resultados de la agrupación de clases.

Al realizar la agrupación de clases se puede notar como existen mejoras en el entrenamiento de la red neuronal convolucional, sin embargo, no es un cambio notable, ya que al ir agrupando clases se sigue manteniendo el desbalance de la clase agrupada con clases originales de los cultivos. En la Figura 13 se puede observar un ejemplo del resultado del entrenamiento para la red con 33 clases.



**Figura 13:** Resultado del primer entrenamiento: (A) Imagen satelital. (B) Imagen etiquetada realizada. (C) Imagen etiquetada original.

A partir de los resultado obtenidos se decide generar una segunda base de datos, la cual estará enfocada en zonas pequeñas, dando como resultado una base de datos con pocas clases. Para realizar el entrenamiento de la red neuronal se procede a la creación de la base de datos de imágenes. Esta se compone de un total de 920 imágenes, cada una con un tamaño de 256x256 píxeles. Para esta ultima prueba se debió reducir el tamaño de los datos de entrenamiento con el objetivo de realizar

## ENTRENAMIENTO Y EVALUACIÓN DE LA RED NEURONAL CONVOLUCIONAL

una mejor selección de las clases y tener una base de datos balanceada. En el Cuadro 3 se pueden observar las seis clases que tiene la base de datos.

<b>CULTIVO</b>	<b>PORCENTAJE DE ÁREA DE CADA CULTIVO</b>
Algodón	25 %
Maíz	31 %
Pastizales/Pastos	21 %
Arroz	13 %
Humedales	10 %

**Cuadro 3:** Distribución de porcentajes de cultivos en la base de datos.


Teniendo en cuenta la diferencia que hay entre algunas clases de cultivo se realiza la acumulación de 4 clases, generando una clase en donde se agrupan las clases que menos porcentaje de área tienen. En el Cuadro 4 se pueden observar los porcentajes de los cultivos posterior a la agrupación.

<b>CULTIVO</b>	<b>PORCENTAJE DE ÁREA DE CADA CULTIVO</b>
Algodón	21 %
Maíz	29 %
Pastizales/Pastos	27 %
Arroz/Humedales	23 %

**Cuadro 4:** Características de la segunda base de datos.

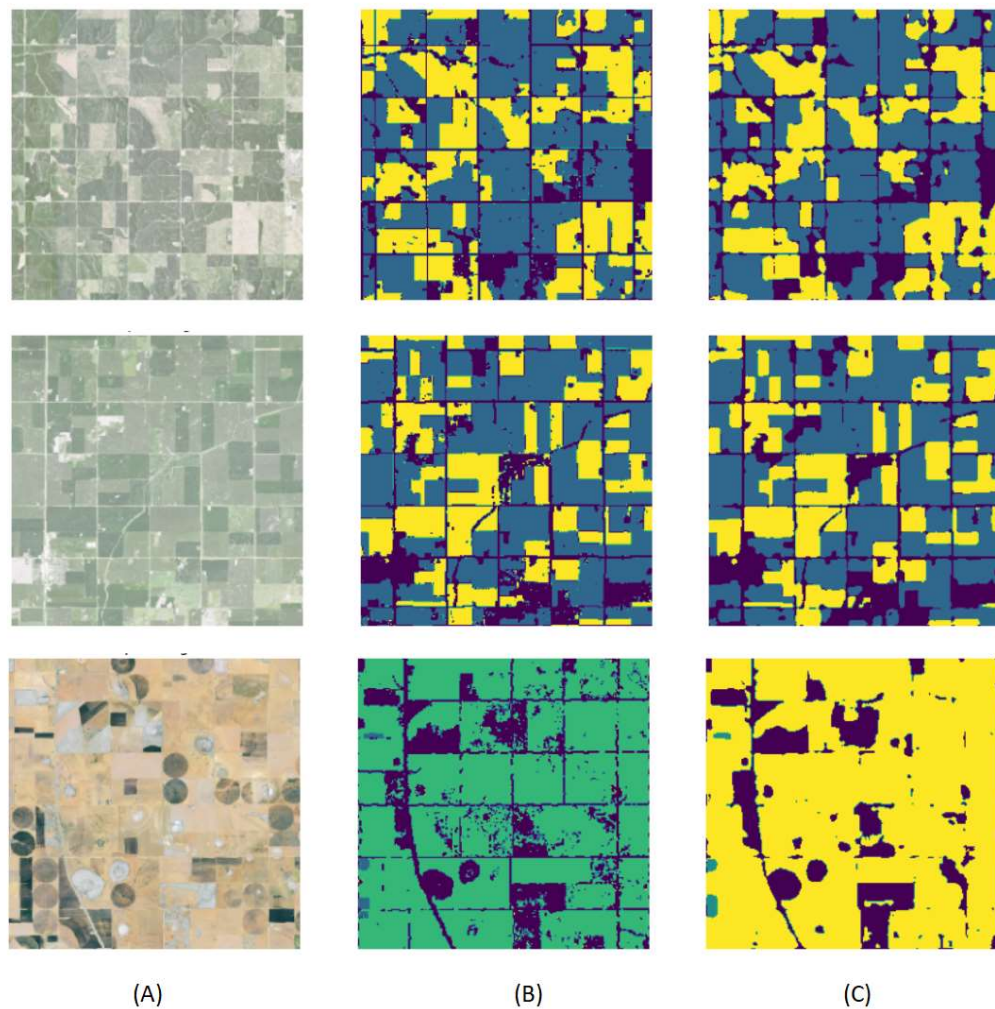
En la Figura 14 se puede observar en la gráfica de precisión y de IoU en el entrenamiento de la red neuronal con la base de datos final de 4 clases. Realizado el entrenamiento con un total de 132 épocas dadas por el algoritmo EarlyStopping, se obtiene un resultado final de precisión de 88.3% y una medida de intersección sobre union del 76%.

## ENTRENAMIENTO Y EVALUACIÓN DE LA RED NEURONAL CONVOLUCIONAL



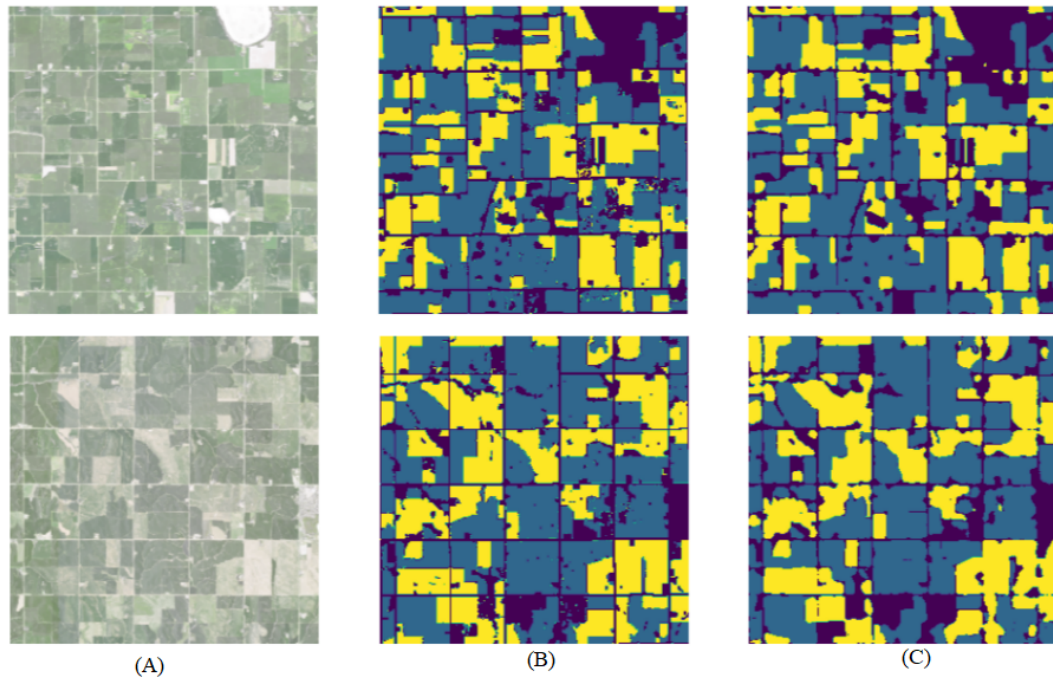
**Figura 14:** Resultados entrenamiento: (A) Medida de precisión. (B) Medida de IoU.

En la Figura 15 se puede observar tres imágenes resultantes del entrenamiento de la red neuronal convolucional.



**Figura 15:** Ejemplo de caracterización: (A) Imagen satelital. (B) Imagen etiquetada realizada. (C) Imagen etiquetada original.

En la Figura 16 se puede observar dos imágenes resultantes de la prueba de rendimiento de la red neuronal. En esta prueba se obtiene un 86.6% de precisión y una medida de intersección sobre unión de 75%.



**Figura 16:** Ejemplo de caracterización: (A) Imagen satelital. (B) Imagen etiquetada realizada. (C) Imagen etiquetada original.

Finalmente se procede a realizar la prueba de la red neuronal con imágenes Colombianas. Estas imágenes fueron extraídas de sectores con gran cantidad de cultivos de maíz, algodón y arroz. En la Figura 17 se puede observar la mascara generada al clasificar estas imágenes satelitales.



**Figura 17:** Caracterización de imágenes de terrenos Colombianos: (A) Imagen satelital. (B) Imagen etiquetada generada.

---

## 6. CONCLUSIONES

---

En este trabajo se ha presentado un método de resolución del problema de caracterizar automáticamente terrenos para agricultura con redes neuronales convolucionales. Para esto se comenzó con el estudio de conceptos teóricos en los que se sustenta la solución desarrollada, desde los aspectos mas básicos hasta las arquitecturas utilizadas en segmentación semántica.

Para el desarrollo del código se utilizo el lenguaje Python, usando Google Colab como entorno de ejecución. Además utilizaron diferentes librerías, destacando la librería Keras con la que se realizo el desarrollo de la red neuronal convolucional.

Un sistema de caracterización automática de terrenos para agricultura con redes neuronales convolucionales tiene la necesidad de un modelo de clasificación robusto con gran cantidad de imágenes etiquetadas. Para esto se creo una base de datos con imágenes satelitales e imágenes etiquetadas mediante Google Earth Engine, cada una con un tamaño de 256x256 píxeles y una resolución de 30 píxeles por metro. Se obtuvieron 920 imágenes con un total de 6 diferentes cultivos. En las pruebas experimentales se obtuvieron porcentajes de precisión y de IoU como medidas de desempeño. En cuanto al entrenamiento se genero un 88.3% de precisión y 76% de IoU, en las pruebas de test se genero un 86.6% de precisión y un 75% de IoU.

Con el sistema generado es posible la creación de mapas de grandes extensiones de tierra con la caracterización de los diferentes tipos de cultivos que pertenezcan a cada una de las zonas. Realizando la creación de estos mapas de manera periódica, es posible generar información con la cual realizar un seguimiento estricto de los terrenos utilizados para cada uno de los cultivos y de esta forma poder realizar predicciones en cuanto a potencial de los terrenos. Además de la agricultura, estos mapas también brindan la posibilidad de generar un seguimiento en diferentes temas ambientales, tales como: minería, deforestación, incendios forestales, etc.

---

## BIBLIOGRAFÍA

---

- [1] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, “Imagenet classification with deep convolutional neural networks,” *NIPS*, 2012.
- [2] Business Center Geospatial Enterprise Operations, “Usda farm production and conservation,” 2022.
- [3] Chen Y., Jiang H., Li C., Jia X., and Ghamisi P., “Deep feature extraction and classification of hyperspectral images based on convolutional neural networks,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232–6251, 2016.
- [4] Clinton C. Brown, “Down to earth with ai platform,” *Google Earth and Earth Engine*, 2019.
- [5] Gonzalez R. and Woods R., “Digital image processing,” *Prentice-Hall*, 2002.
- [6] H Arun A. Balakrishnan; Bijoy M. S; Supriya M., “Classification of low quality underwater objects using convolutional neural networks and transfer learning,” *OCEANS 2022 - Chennai*, 2022.
- [7] imagery program NAIP: National Agriculture, “Published crop-specific data layer,” Available at <https://naip-usdaonline.hub.arcgis.com/>, Washington, DC., 2022.
- [8] Layer USDA National Agricultural Statistics Service Cropland Data, “Published crop-specific data layer,” Available at <https://nassgeodata.gmu.edu/CropScape/>. USDA-NASS, Washington, DC., 2022.
- [9] Perilla, Gabriel Mas, Jean., “Google earth engine: una poderosa herramienta que vincula el potencial de los datos masivos y la eficacia del procesamiento en la nube.” 2020.
- [10] Ronneberger O., Fischer P., and Brox T., *U-net: Convolutional networks for biomedical image segmentation*, vol. 9351 of *Lecture Notes in Computer Science*

(including subseries *Lecture Notes in Artificial Intelligence* and *Lecture Notes in Bioinformatics*), 2015.

- [11] Semantic Segmentation *MATLAB - The MathWorks Inc.*, 2022.
- [12] Suarez L, Arnol S; Jimenez L, Andrés F; Castro-Franco Mauricio and Cruz-Roa Angel., “Clasificación y mapeo automático de coberturas del suelo en imágenes satelitales utilizando redes neuronales convolucionales,” *Orinoquia [online]*, 2017.
- [13] Tilman David, Balzer Christian, Hill Jason, and Befort Belinda L., “Global food demand and the sustainable intensification of agriculture,” *Proceedings of the National Academy of Sciences*, vol. 108, no. 50, pp. 20260–20264, 2011.
- [14] Zhou Zihao Deng; Peixi Liu; Jiahui Zheng; Hanyang, “Convolutional neural networks based study for multi-class skin cancer plaque images classification,” *3rd International Conference on Electronic Communication and Artificial Intelligence (IWECAI)*, 2022.

---

## APÉNDICES

---

### **Apéndice A. Repositorio general del proyecto - GitHub**

Link: <https://github.com/Julioro98/Caracterizacion-automatizada-de-terrenos>

### **Apéndice B. Pagina web del trabajo de investigación**

Link: <https://sites.google.com/view/redesneuronalesconv-uis/inicio>

### **Apéndice C. Video-demostración del trabajo**

Link: <https://youtu.be/jlx1g9n-B20>

### **Apéndice D. Plantilla de acreditación internacional ABET**

# Proposal for the portfolio of project themes

**Title: Automatic land characterization for agriculture with convolutional neural networks**

**Sponsor: CPS Research Group**

**Proposer: Diego Andrés Naranjo Infante y Julio Roberto Suarez Flechas**

## **Description of the proposal:**

This paper presents the design of a system to automatically characterize agricultural land using convolutional neural networks. The project proposes to provide surface estimations in terms of arable land, allowing to classify, characterize and describe georeferenced land. By means of machine learning, a supervised classification of satellite images is performed, with the architecture of a convolutional neural network, which is trained using images already characterized by the United States Department of Agriculture (USDA).

## **Constraints:**

- It should investigate the different cropland databases and choose the one that best suits our needs to develop a balanced cropland database and achieve better network performance.
- It is necessary to carefully take images of areas suitable for the characteristics with which the training will be carried out.
- It is important to implement an optimal process that allows creating the database, storing it and exporting it to a development environment where the training of the neural network is executed.
- According to research, the network architecture that best adapts to the limitations but that demonstrates good performance should be chosen.
- It is necessary to carry out training and validation of results in order to take corrective actions in the choice of hyperparameters using techniques and algorithms that improve network performance.

**Phases for the project:**

1. Project selection, team selection, definition of the requirements and definition of the project's scope
2. Registration, and approval of the Project Theme by the Degree Work Committee.
3. Detailed design phase
  - a. Preparing a design
  - b. Developing the system for automatic land characterization for agriculture with convolutional neural networks
  - c. Testing the system
4. Final report, presentation, and demonstration phase.

## TABLA DE CAPSTONE DESIGN PARA INGENIERÍA ELECTRÓNICA

Requerimiento	Descripción	Evidencia
ID del Proyecto	CATARNC2022	
Título del proyecto	Caracterización automática de terrenos para agricultura con redes neuronales convolucionales.	Libro, página 1.
Página web del proyecto	<a href="https://sites.google.com/view/redesneuronalesconv-uis/inicio">https://sites.google.com/view/redesneuronalesconv-uis/inicio</a>	Libro, apéndices, página 30.
Descripción	El objetivo general es diseñar un sistema para caracterizar automáticamente terrenos para agricultura mediante redes neuronales convolucionales. El proyecto propone brindar estimaciones de superficie en cuanto a tierras de cultivo, permitiendo clasificar, caracterizar y describir terrenos georreferenciados. Por medio de aprendizaje automático se realiza una clasificación supervisada de imágenes satelitales, con la arquitectura de una red neuronal convolucional, la cual se entrena usando imágenes ya caracterizadas por el departamento de agricultura de Estados Unidos (USDA).	Libro, página 5.
Conocimientos previos y habilidades usadas	<p>Asignaturas:</p> <ul style="list-style-type: none"> <li>● Procesamiento digital de imágenes</li> <li>● Programación I y II,</li> <li>● Probabilidad y estadística</li> </ul> <p>Habilidades:</p> <ul style="list-style-type: none"> <li>● Capacidad de resolución de problemas.</li> <li>● Trabajo en equipo.</li> <li>● Comunicación clara y precisa.</li> <li>● Investigación y constante aprendizaje de nuevas tecnologías.</li> <li>● Dominio de lenguajes de programación JavaScript y Python.</li> </ul>	<p>Libro, capítulo 3, página 14.</p> <p>Libro, capítulo 4, página 18.</p>

Restricciones de diseño	Restricciones de software: <ul style="list-style-type: none"> <li>• Uso de la plataforma Google Earth Engine para la creación de la base de datos.</li> <li>• Creación de algoritmo para la exportación de varias imágenes desde Google Earth Engine hacia Google Drive.</li> <li>• Almacenamiento de las imágenes extraídas.</li> <li>• Plataforma necesaria para realizar el entrenamiento de la red neuronal.</li> <li>• Librerías necesarias para el entrenamiento de la red neuronal.</li> </ul>	Libro, capítulo 3, página 14. Libro, capítulo 5, página 21.
Es un sistema, componente o proceso	Es un sistema ya que el resultado final se dividirá en tres diferentes procesos: creación de la base de datos, diseño de la arquitectura de la red neuronal convolucional y entrenamiento de la red neuronal diseñada.	Libro, capítulo 3. Libro, capítulo 4. Libro, capítulo 5.
Estándares de ingeniería o normas	Normas ICONTEC, tipo NTC 1486.	Libro.
Necesidades y especificaciones deseadas cumplidas	<ul style="list-style-type: none"> <li>• Desarrollo del algoritmo para la creación de bases de datos de imágenes satelitales e imágenes cropland con mínimo 4 clases de cultivos.</li> <li>• Entrenamiento de la red neuronal para caracterizar mínimo 4 clases de cultivos.</li> </ul>	Libro, capítulo 2, página 9. Libro, capítulo 5, página 21.
Proceso iterativo, creativo y de toma de decisiones	<ul style="list-style-type: none"> <li>• Selección de bases de datos para creación de la base de datos.</li> <li>• Metodología para realizar la extracción de las imágenes satelitales y cropland.</li> <li>• Elección de la arquitectura de la red neuronal convolucional.</li> <li>• Elección de callbacks utilizados en el entrenamiento de la red neuronal convolucional.</li> </ul>	Libro, capítulo 3, página 11. Libro, capítulo 3, página 14. Libro, capítulo 4, página 18. Libro, capítulo 5, página 21.
<ul style="list-style-type: none"> <li>• Múltiples soluciones consideradas</li> </ul>	Para realizar el diseño de la red neuronal convolucional se tienen en cuenta tres trabajos como guía:	Libro, introducción, página 7.

	<ul style="list-style-type: none"> <li>• En [11] se presenta un método de aprendizaje automático basado en redes neuronales convolucionales. Esta red fue entrenada a partir de las anotaciones manuales por medio de interpretación visual sobre las imágenes satelitales con la que expertos generaron el mapa de cobertura del parque nacional el Tuparro.</li> <li>• En [3] se presenta un método regularizado de extracción de características profundas para la clasificación de imágenes hiperespectrales utilizando una red neuronal convolucional. La arquitectura de esta red neuronal está enfocada en la clasificación de cientos de cultivos presentes en las bases de datos utilizadas..</li> <li>• En [9] se plantea una arquitectura de red neuronal convolucional utilizada en la detección de cáncer de seno, siendo usada en la segmentación de las imágenes para lograr generar clasificaciones de más de dos clases.</li> </ul>	<p>Libro, introducción, página 8.</p>
<ul style="list-style-type: none"> <li>• Análisis y síntesis realizados</li> </ul>	<ul style="list-style-type: none"> <li>• Se plantea utilizar la base de datos con la cual realizaron el entrenamiento de la red neuronal en [11]. Sin embargo, no cumplía con la cantidad de cultivos mínimos planteados, además que el tener una base de datos generada a partir de anotaciones manuales podría generar resultados con alto porcentaje de error.</li> <li>• En [3] se plantea la posibilidad de estudio y modificación de esta red neuronal y de técnicas de duplicación de información, esto con el fin de agregar copias ligeramente modificadas de los datos ya existentes para lograr mejores resultados en el entrenamiento. Sin embargo, al ser una red neuronal diseñada para la clasificación de cientos de cultivos se genera la necesidad de una base de datos con millones de imágenes, haciendo este el principal limitante a la hora de realizar el</li> </ul>	<p>Libro, capítulo 4, página 18.</p>

	<p>diseño de la red neuronal basados en esta arquitectura.</p> <ul style="list-style-type: none"> <li>● Se plantea la migración utilizada en [9] hacia el campo de la caracterización de terrenos para agricultura. Sin embargo, la poca utilización de esta red neuronal en otras áreas dificulta su elección ya que la mayoría de trabajos en que se ha utilizado esta red neuronal han sido en detección de cáncer.</li> </ul>	
<ul style="list-style-type: none"> <li>● Oportunidades identificadas</li> </ul>	<p>Opciones identificadas:</p> <ul style="list-style-type: none"> <li>● Utilización de la base de datos [11] para realizar el entrenamiento de la red neuronal convolucional.</li> <li>● Estudio y modificación de la arquitectura de la red neuronal presentada en [3].</li> <li>● Investigación de metodología para la creación de una base de datos propia y modificación de la red neuronal presentada en [9].</li> </ul>	<p>Libro, introducción, páginas 7 y 8.</p>
<ul style="list-style-type: none"> <li>● Evaluación de soluciones frente a requisitos</li> </ul>	<p>El investigar la herramienta Google Earth Engine con la finalidad de crear la base de datos con la cantidad de cultivos deseados enfoca la decisión a utilizar la arquitectura propuesta en [9], esta vez modificando la arquitectura para la clasificación de por lo menos 4 clases presentes en las imágenes.</p>	<p>Libro, capítulo 3, página 10.</p>
<ul style="list-style-type: none"> <li>● Concesiones consideradas</li> </ul>	<p>La concesión considerada es el utilizar una base de datos existente y probada en el entrenamiento de una red neuronal.</p>	
<ul style="list-style-type: none"> <li>● Riesgos considerados</li> </ul>	<p>El mayor riesgo tomado en la decisión es la incertidumbre de crear una base de datos propia a partir de Google Earth Engine, además de realizar la modificación de la arquitectura de la red neuronal propuesta en [9] con la finalidad de caracterizar más de 4 cultivos presentes en las imágenes.</p>	<p>Libro, capítulo 3, páginas 14, 15 y 16. Libro, capítulo 4, páginas 18, 19 y 20.</p>
<p>Solución</p>	<p>Para este proyecto las bases de datos seleccionadas de Google Earth Engine fueron: USDA NASS Cropland Data Layer, el cual cuenta con una base de datos de cobertura del suelo específica de los cultivos, creada</p>	<p>Libro, capítulo 3, páginas 14, 15 y 16.</p>

	<p>anualmente para el territorio continental de los Estados Unidos utilizando imágenes de satélite de resolución moderada y una amplia variedad agrícola sobre el terreno, y el NAIP (National Agriculture Imagery Program), el cual cuenta con una base de datos de imágenes aéreas adquiridas durante las temporadas de crecimiento agrícola en el territorio continental de Estados Unidos. Este proceso se utilizará la arquitectura Unet [9], la cual es una arquitectura de red neuronal convolucional utilizada en la detección de cáncer de seno, siendo usada en la segmentación semántica de las imágenes y la cual se puede migrar a diferentes áreas de aplicación.</p>	<p>Libro, capítulo 4, páginas 18, 19 y 20.</p>
Sponsor	Grupo de investigación CPS	
Resultados y/o productos a entregar	<p>Resultados entregados:</p> <ul style="list-style-type: none"> <li>● Página web con información y vídeo explicativo para el sistema ABET del diseño del sistema para la caracterización automática de terrenos para agricultura con redes neuronales convolucionales.</li> <li>● Algoritmo para la extracción de imágenes satelitales y cropland desde la plataforma Google Earth Engine.</li> <li>● Algoritmo para entrenamiento de red neuronal convolucional para la caracterización de 4 cultivos.</li> </ul>	<p>Libro, apéndices, página 30.</p>
Modalidad del proyecto	Trabajo de investigación	
Equipo de trabajo	<ul style="list-style-type: none"> <li>● Julio Suarez Flechas, desarrollador</li> <li>● Diego Naranjo Infante, desarrollador</li> </ul>	
Director	Said Pertuz	
Codirector		
Área del proyecto	Desarrollo de software.	

**ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES**

Ciudad Universitaria, Carrera 27 – Calle 9, Edificio Ingeniería Eléctrica, IE-101

PBX: (7) 6344000 Ext. 2360 FAX: 6359622 A.A. 678 Bucaramanga, Colombia

Correo-e: e3t@uis.edu.co URL: <http://www.e3t.uis.edu.co>

Versión de la plantilla: planTG.2022si.v1

Palabras y/o Términos Clave	Imágenes satelitales, imágenes cropland, redes neuronales, cultivos, base de datos.	
--------------------------------	---	--