

# **ESCUELA POLITÉCNICA NACIONAL**

## **FACULTAD DE INGENIERÍA DE SISTEMAS**

### **DESARROLLO DE UN MÉTODO PARA LA CLASIFICACIÓN AUTOMATIZADA DE IMÁGENES LANDSAT 8 MEDIANTE REDES NEURONALES ARTIFICIALES.**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE  
INGENIERO EN SISTEMAS INFORMÁTICOS Y DE COMPUTACIÓN**

**JUAN CARLOS TITUAÑA JAMI.**

juan.tituana@epn.edu.ec

**Director: Ing. Cindy Pamela López Chulca, MSc.**

cindy.lopez@epn.edu.ec

**Codirector: Sang Guun Yoo Park, Ph.D.**

sang.yoo@epn.edu.ec

**Quito, Octubre 2018**

## **CERTIFICACIÓN**

Certifico que el presente trabajo fue desarrollado por Juan Carlos Tituaña Jami, bajo mi supervisión.

---

**Ing. Cindy Pamela López Chulca, MSc.**

**DIRECTORA DEL PROYECTO**

## **DECLARACIÓN DE AUTORÍA**

Yo, Juan Carlos Tituaña Jami, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentada para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Escuela Politécnica Nacional puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.

---

**Juan Carlos Tituaña Jami.**

## **DEDICATORIA**

### **A Dios.**

Por escuchar mis oraciones y haberme dado salud para lograr mis objetivos, además agradezco su infinita bondad y amor hacia toda mi familia. "Todo lo puedo en Cristo que me Fortalece"

### **A mi madre Mariana.**

Por haberme apoyado en todo momento, por sus consejos, sus valores, por la motivación constante que me ha permitido ser una persona de bien, pero más que nada, por su amor incondicional.

### **A mi padre Abelino.**

Que me vio caer y levantarme continuamente sin rendirme, apoyarme, manteniéndose a mi lado y nunca haberse rendido conmigo, sabiendo que hubo muchos momentos difíciles que pasamos.

Alentándome siempre a seguir mis sueños para que se pudieran cumplir y llegar a lo más alto.

### **A mi abuelo Ángel María.**

Por los ejemplos de perseverancia y constancia que lo caracterizaban y que me infundo siempre, por el valor mostrado para salir adelante y por su infinito amor.

### **A mi amigo Erith.**

Por enseñarme el valor de las cosas, su significado de disciplina que lleva dentro, darme los ánimos necesarios y corregirme cuando algo este mal. Sobre todo valor para afrontar cada reto que nos pone la vida.

**Juan Carlos Tituaña**

## **AGRADECIMIENTO**

El presente trabajo va dirigido con una expresión de gratitud para mis distinguidos maestros, que con nobleza y entusiasmo, vertieron todo su apostolado en mi alma. Y, a mí querido colegio, porque en sus aulas he recibido las más gratas enseñanzas.

Además, manifiesto un agradecimiento especial a Kristy Guevara, uno de mis supervisores por el cual me inspiro en la culminación de este proyecto.

**Juan Carlos Tituaña**

# ÍNDICE DE CONTENIDO

LISTA DE FIGURAS	i
LISTA DE CUADROS	ii
LISTA DE ANEXOS	iii
LISTA DE ACRONIMOS	iv
RESUMEN	v
<i>ABSTRACT</i>	vi
<b>1. INTRODUCCIÓN</b> .....	1
1.1. Descripción del Problema .....	1
1.2. Objetivo General. ....	4
1.3. Objetivos Específicos.....	4
1.5. Marco Conceptual .....	4
<b>2. METODOLOGÍA DE LA INVESTIGACIÓN</b> .....	16
2.1. Área de Estudio .....	16
2.2. Generación de Mosaicos LANDSAT 8 .....	17
2.3. Generación de Mapa BNB .....	20
2.4. Datos de Entrenamiento .....	27
2.5. Criterio de Entrenamiento de la ANN .....	28
2.6. Técnica de Validación de Resultados .....	29
<b>3. RESULTADOS Y DISCUSIÓN</b> .....	30
3.1. Resultados .....	30
3.2. Discusión .....	39
<b>4. CONCLUSIONES</b> .....	42
<b>Referencias</b> .....	44
<b>ANEXOS</b> .....	47
A.1. Bias .....	48
A.2. Pesos .....	48

## LISTA DE FIGURAS

1.1. Evolución en el tiempo de la serie LANDSAT. ....	8
1.2. Los sensores OLI y TIRS montados en la plataforma LDCM (LANDSAT 8) .....	8
1.3. Cubo de datos generado a partir de la adquisición de una imagen L8. ....	9
1.4. Modelo matemático de una neurona (Xingui and Shaohua, 2010). ....	11
1.5. Modelo del Perceptron de una Capa (Hsieh, 2009).....	12
1.6. MLP, se muestra la capa de entrada, una capa oculta, y una capa de salida .....	12
2.1. Área de estudio.....	18
2.2. Interfaz gráfica de inicio para la generación de mosaicos en SEPAL .....	18
2.3. Pre-visualización del mosaico generado en SEPAL en combinación RGB .....	18
2.4. Selección de parámetros para la generación de mosaicos. ....	19
2.5. Interfaz de descarga de imágenes de SEPAL .....	20
2.6. Interfaz de descarga de SEPAL/CEO .....	21
2.7. Uso de una colección L8 de Google Earth Engine para la definición de Clases de píxeles con algoritmo Random Forest .....	22
2.8. Clasificación de puntos para entrenamiento mediante geovisor de SEPAL/CEO .....	23
2.9. Configuración del módulo de clasificación de SEPAL .....	23
2.10. Visión de la tabla dinámica de los datos de entrenamiento desde Google Drive ...	24
2.11. Verificación de localización de los puntos de entrenamiento desde Google Drive..	25
2.12. Id de la tabla dinámica con los datos de entrenamiento. ....	25
2.13. Mapa BNB generado mediante SEPAL. ....	26
2.14. Interfaz gráfica del módulo de diseño de muestreo estratificado de SEPAL .....	29
3.1. Mosaico L8 del área de estudio, contiene las bandas desde la 2 hasta la 7. ....	31
3.2. Información metadatos del mosaico. generada a partir del comando gdalinfo .....	32
3.3. Listado parcial de firmas espectrales identificadas .....	33
3.4. Mapa BNB generado a partir del proceso de clasificación con la ANN. ....	34
3.5. Mapa BNB generado a partir del algoritmo Random Forest .....	34
3.6. Distribución espacial de los puntos de muestreo para el área de estudio .....	35
3.7. Interfaz gráfica de SEPAL/CEO para el levantamiento de datos de validación usando imágenes satelitales. ....	36
3.8. Visión cercana de una parcela de muestreo. ....	37
3.9. Matriz de confusión para las clases B y NB del mapa BNB generado con la ANN. ...	37
3.10. Resultados del cálculo de precisión del mapa generado con la ANN. ....	38

## LISTA DE CUADROS

1.1. Listado de bandas de LANDSAT 8.....	8
3.1. Resumen del diseño de muestreo para la validación del mapa BNB.....	35

## LISTA DE ACRONIMOS

**AI** Acrónimo en inglés para Inteligencia Artificial

**OLI** Acrónimo en inglés para Reproductor de Imágenes Operacional de Superficie

**TIRS** Acrónimo en inglés para Sensor de Infrarrojo Térmico

**L8** Imagen captada por satelite Landsat 8

**ANN** Acrónimo en inglés para Redes Neuronales Artificiales

**SPUTNIK** Acrónimo en ruso para Satélite Artificial Terrestre

**TIROS** Television and Infrared Observation Satellite.

**NASA** National Aeronautics and Space Administration

**ERTS** Earth Resources Technological Satellite

**LANDSAT** Land Satellite

**VIS** Rango óptico del espectro electromagnético

**IR** Rango infrarrojo del espectro electromagnético

**MW** Rango de microondas del espectro electromagnético

**LDCM** Landsat Data Continuity Mission

## LISTA DE ANEXOS

<b>ANEXO A.</b> Pesos y Bias de la red neuronal artificial	
A.1. Bias	48
A.2. Pesos	48

## RESUMEN

Este trabajo de investigación presenta el desarrollo de un método para la clasificación automatizada de imágenes Landsat 8 a partir de la integración de redes neuronales artificiales y la identificación de píxeles de clases puras. El ejercicio realizado en esta investigación a partir de la plataforma SEPAL, permitió obtener un mosaico L8 del área de estudio, debidamente preprocesado y calibrado, automáticamente en lapsos de minutos. Este resultado representa un avance en cuanto a la capacidad de preprocesamiento que existe actualmente para el manejo de datos satelitales en comparación con el estado del área hace una década atrás. Este avance relevante ha sido posible debido al uso de redes neuronales artificiales y factores de correlación cruzada de los píxeles de las imágenes de la plataforma satelital Landsat 8. Su empleo y diferenciación de aéreas en la teledetección de áreas boscosas, agrícolas e hídricas son comentados.

**Palabras clave:** Redes Neuronales Artificiales, Teledetección, Landsat 8, Procesamiento digital de imágenes.

## ***ABSTRACT***

This research develop a method for the automated classification of Landsat 8 images from the integration of Artificial Neural Networks and the identification of pixels of pure classes. The exercise carried out in this research from the SEPAL platform, allowed to obtain a mosaic L8 of the study area, duly pre-processed and calibrated, automatically in minutes. This result represents a significant advance in terms of pre-processing capacity that currently exists for the management of satellite data compared to the state of the area a decade ago. This relevant advance has been possible due to the use of artificial neural networks and cross-correlation factors of the pixels of the Landsat 8 satellite platform images. Their use and differentiation of areas in remote sensing of wooded, agricultural and water areas are discussed.

**Keywords:** Artificial neural networks, Remote sensing, Landsat 8, Digital image processing.

# 1. INTRODUCCIÓN

## 1.1. Descripción del Problema

En las últimas tres décadas la teledetección satelital se ha convertido, en un medio imprescindible para la Observación de la Tierra. Actualmente, la teledetección es una disciplina científico-tecnológica que envuelve diferentes niveles de conocimiento. Estos niveles abarcan el desarrollo de sensores, sensibles a diferentes rangos del espectro electromagnético, que pueden operar en plataformas satelitales para observar la atmósfera o la superficie terrestre desde un campo de visión privilegiado, en referencia a la escala de observación, regularidad temporal, obtención de datos multi y/o hiper espectrales, entre otros. Particularmente, los sensores satelitales han demostrado potentes ventajas, tales como (i) la posibilidad de observar simultáneamente grandes extensiones de la Tierra y su atmósfera desde diferentes rangos del espectro electromagnético, (ii) también la disponibilidad de datos con resoluciones espectrales, espaciales, radiométricas y temporales regulares, (iii) series temporales de datos extensas, que en el caso de los satélites Landsat supera los 30 años. Investigaciones afirman que en la actualidad, se ha alcanzado el punto en el que la cantidad de información disponible, supera la capacidad humana actual para aprovechar los datos de forma eficiente. Esto puede deberse a diferentes factores, pero es de interés especial destacar que, la mayor limitación para aprovechar estos datos, es la necesidad de procesar e interpretar los datos de forma manual, para garantizar resultados satisfactorios. En base a esta limitación, es deseable contar con herramientas que faciliten en la medida posible, el procesamiento e interpretación de datos satelitales, para garantizar resultados confiables, en corto periodo de tiempo, y haciendo posible el aprovechamiento máximo de los datos en apoyo a la toma de decisiones. En este contexto, el desarrollo de los computadores modernos hace posible realizar tareas complejas, que involucran grandes cantidades de datos, denominados comúnmente Big Data, en periodos de tiempo que son inaccesibles para el ser humano. De esta forma, la limitación de procesar Big Data en el contexto de la teledetección puede ser resuelta a partir del diseño de herramientas para la automatización.

La automatización en el campo de la teledetección se puede llevar a cabo desde dos enfoques, (i) la automatización de tareas mecánicas que no impliquen toma de decisiones complejas, y (ii) tareas que requieren toma de decisiones complejas, es decir que requieran de un proceso de inteligencia. En el primer enfoque, las etapas de toma de

decisión pueden llevarse a cabo a partir de operadores lógicos elementales, mientras que en el segundo enfoque, es necesario utilizar herramientas más sofisticadas que apoyen al proceso de toma de decisiones automáticas, entre las que resalta la Inteligencia Artificial (AI, por sus siglas en inglés). Las principales técnicas de AI, se fundamentan en la capacidad asociada a un sistema para ejecutar acciones con precisión y exactitud de modo autónomo, a partir de un proceso de entrenamiento. El entrenamiento se lleva a cabo mediante datos derivados de situaciones comunes reales que debe resolver el sistema. En los sistemas AI modernos, el aprendizaje puede continuar de forma autónoma, de aquí el nombre de Inteligencia Artificial. En el campo de la teledetección, las técnicas de AI tienen una gran variedad de aplicaciones, que van desde los algoritmos diseñados para el control de orbitas de las plataformas satelitales, hasta la clasificación temática de las imágenes satelitales. En este trabajo, es de especial interés el uso de AI para la clasificación de imágenes satelitales, con el objetivo de proponer una alternativa operativa que disminuya la necesidad del procesamiento manual.

En este marco de referencia, en este trabajo se describe un método para la clasificación automatizada de imágenes satelitales ópticas, provenientes de los sensores Reproductor de Imágenes Operacional de Superficie (OLI, por sus siglas en inglés) y del Sensor de Infrarrojo Térmico (TIRS, por sus siglas en inglés), ambos a bordo de la plataforma Landsat 8, a partir de una de las técnicas más conocida de la AI, que son las Redes Neuronales Artificiales (ANN, por sus siglas en inglés).

## **Selección del Tópico de Investigación**

Actualmente, el monitoreo de la superficie terrestre tiene un rol preponderante en la toma de decisiones que garantizan la vida de la fauna y flora sobre el planeta. La observación de la superficie terrestre proporciona información imprescindible sobre distribución poblacional, índices de desarrollo humano, recursos naturales, dinámica de coberturas, degradación de los suelos y los bosques, efectos del cambio climático sobre el planeta, entre otros. El aporte de la teledetección satelital en la observación de la tierra influye desde enfoques a escalas locales hasta análisis a escala global, lo que lo convierte en una herramienta imprescindible para la gestión global de indicadores que hacen posible la vida en el planeta, y su permanencia a corto, mediano y largo plazo.

A pesar de la relevancia que tienen las imágenes satelitales como información base en apoyo a la toma de decisiones, actualmente la falta de capacidad para procesar los datos disponibles es una limitante. Esta incapacidad tiene su origen en que el volumen de datos disponibles generalmente es superior a las infraestructuras y recursos humanos con las que cuentan los actores vinculados con el procesamiento de los datos. En los últimos

años se han desarrollado sistemas capaces de procesar grandes cantidades de datos en tan solo minutos, lo que no solo ha traído la oportunidad de maximizar el aprovechamiento eficiente de los datos, sino que además ha optimizado el uso de recursos en durante la etapa de procesamiento e interpretación de imágenes satelitales.

Esta investigación está enfocada a proponer un método para la clasificación automática de imágenes Landsat 8, con la novedad de que las ANN serían entrenadas a partir de datos de aprendizaje que son generados de forma automática. En este contexto, la clasificación de imágenes satelitales de forma automática utilizando redes neuronales artificiales, y la detección autónoma de píxeles puros, sería un aporte orientado a mejorar las técnicas de clasificación no supervisadas, que se basan en algoritmos de redes neuronales artificiales, pero en los que el criterio para el entrenamiento de las redes neuronales se lo realiza, a partir de datos de entrenamientos generados de forma manual. De esta manera, el diseño de la investigación implica dos fases operativas principales, (i) el tratamiento de una imagen Landsat 8 piloto para determinar píxeles representativos de clases únicas o puras dentro de la escena, y (ii) utilizar la información espectral de estos píxeles para realizar una clasificación automática de la imagen.

### **Criterio para el uso de Redes Neuronales Artificiales**

Las redes neuronales artificiales son propuestas en este trabajo, para resolver la toma de decisiones complejas. El principal motivo para esto es que las redes neuronales han demostrado potencialidad para predecir relaciones no lineales en dominios de datos multivariantes (Khademi, 2017; Khorasani, 2017), pueden aprender a partir de datos de entrenamiento, se pueden incorporar como módulos en algoritmos de automatización, se pueden encoger entre diferentes opciones para el proceso de entrenamiento y la definición de la arquitectura de la red (Tibo, 2017).

De esta forma, considerando la posibilidad de realizar clasificaciones a partir del uso de imágenes Landsat 8 para generar mapas BNB (Maggiori, 2017), es posible también generar datos de entrenamiento que permitan el entrenamiento de un algoritmo de redes neuronales artificiales, mediante un enfoque automatizado (Devin, 2017). Y es en este contexto que las redes neuronales artificiales representan una oportunidad importante para el cumplimiento de los objetivos de este trabajo.

### **Selección de Imágenes Landsat 8**

Las imágenes Landsat 8, conjuntamente con las Landsat 4, 5 y 7, representan la serie temporal más extensa y regular de imágenes satelitales a nivel global (Matasci, 2018; Liu, 2017). Además de que poseen una importante cantidad de información

espectral, y tener una resolución espacial de 30m para sus bandas, y de 15m para la banda pancromática, en la actualidad son de acceso gratuito, lo que las convierte en la mejor opción como fuente de imágenes satelitales para la observación de la superficie terrestre, específicamente para el monitoreo de cobertura de bosques.

Existe otra opción para acceder a imágenes ópticas en la actualidad, estas son las imágenes sentinel 2, las cuales representan una mejora en la resolución espacial respecto a las imágenes Landsat 8 (Vuelo, 2018). Sin embargo, la desventaja de estas imágenes es que están disponibles para capturas a partir de 2016, lo que imposibilita la posibilidad de monitorear años previos, y también la conformación de series temporales.

Los aportes principales derivas de este trabajo son:

1. Revisión actual del estado del arte sobre el uso de redes neuronales artificiales en el campo de la clasificación de imágenes satelitales.
2. Propuesta metodológica de un algoritmo automatizado para crear datos de entrenamiento para redes neuronales artificiales, que permitan la clasificación de imágenes satelitales.
3. Análisis de resultados obtenidos mediante el método propuesto.

## **1.2. Pregunta de Investigación**

¿Permito que el entrenamiento automatizado de redes neuronales artificiales reduce errores de clasificación que ocurre en el proceso manual?

## **1.3. Objetivo General**

Desarrollar un método para la clasificación automatizada de imágenes Landsat 8 mediante redes neuronales artificiales.

## **1.4. Objetivos Específicos**

1. Desarrollar un método para la identificación de píxeles puros en imágenes satelitales Landsat 8, para clasificar de forma automática imágenes satelitales a partir de un entrenamiento automatizado de redes neuronales artificiales.
2. Automatizar el Entrenamiento automático de redes neuronales para la clasificación de imágenes Landsat 8, usando como datos de entrada los píxeles puros, para reducir el tiempo de procesamiento y en la estimación de errores de clasificación.

3. Validar los resultados a partir de la estimación de errores de clasificación, usando la herramienta de muestreo satelital Collect Earth.
4. Evaluar el resultado obtenido de la red neuronal artificial en función del tiempo de procesamiento y errores de clasificación.

## **1.5. Marco Teórico**

La teledetección es una técnica de observación de la Tierra en la que se usan sensores, que operan en rangos de longitudes de ondas que van desde el óptico a microonda, a bordo de plataformas satelitales artificiales o aeronaves (solo se abordan conceptos relacionados a la teledetección satelital, por lo que cualquier referencia aquí, al término teledetección, está vinculado a sensores satelitales). La teledetección, además de los sensores y las plataformas, también implica la etapa de colección de las imágenes capturadas, su procesamiento e interpretación. Cada una de estas tres etapas puede realizarse de forma distinta, dependiendo del tipo de sensor, y también del rango dentro del espectro electromagnético en el que este opera (Cheng, 2017).

Diferentes fuentes literarias coinciden en que el inicio de la teledetección moderna tuvo lugar en 1957 con el lanzamiento del satélite SPUTNIK por parte de la Unión Soviética (Guerra, 2017; Greco, 2018). Tres años después, la NASA realiza el lanzamiento del satélite meteorológico TIROS I, que en 1970 sería renombrado como NOAA. Sin embargo, no fue sino hasta 1972 después del lanzamiento del satélite LANDSAT 1 apoyado por el programa ERTS, cuando inicia la observación sistemática de la superficie terrestre. LANDSAT 1 es el primer satélite de una serie que hasta ahora alcanza a la plataforma LANDSAT 8, puesta en órbita en 2013 por la NASA. Desde el lanzamiento de LANDSAT 1, la evolución de la teledetección hasta el presente ha sido muy notable (Padró, 2017). Este avance se ve reflejado en la diversa cantidad de satélites de observación de la Tierra que se encuentran en órbita en la actualidad, barriendo espectros del rango óptico (VIS, por sus siglas en inglés), infrarrojo (IR, por sus siglas en inglés), y microondas (MW, por sus siglas en inglés) (Goward, 2017, Popkin, 2017).

De igual modo, en las últimas décadas ha habido un incremento relevante en el desarrollo de técnicas, algoritmos, e innovación tecnológica para mejorar el tratamiento de los datos y su interpretación, lo que ha impulsado cada vez más la inversión e implementación de la teledetección en diferentes aspectos de la vida (Zhu, 2017). La aplicación de la teledetección abarca áreas estratégicas como el monitoreo de la superficie terrestre, que implica el monitoreo de cobertura y uso de suelo, prospección y

control de recursos naturales, generación de información base para el ordenamiento territorial, generación de planes de adaptación y mitigación al cambio climático, análisis de de impacto ambiental por actividades antrópicas, entre otras (Pelton, 2017). También la teledetección ha demostrado una gran potencialidad para el estudio de la atmósfera, donde mediante el uso del espectro infrarrojo y microondas, a partir de sensores activo y pasivos, es posible construir perfiles atmosféricos, estimar tasas de precipitación, y en general apoyar en la predicción meteorológica (Torres,2018). Esta lista representa aportes generales, de lo que hoy en día representa la teledetección en la toma de decisiones a cualquier escala de análisis. A continuación, en los cuerpos restantes de este apartado, se presentan conceptos importantes sobre la teledetección con la finalidad de proporcionar al lector una línea base que garantice la comprensión del aporte de este trabajo.

## **Plataforma LANDSAT 8**

La plataforma LANDSAT 8, representa el octavo lanzamiento de la serie LANDSAT, y fue puesta en órbita en el año 2013. En la figura 2.1, se muestra cronológicamente detallado el progreso de la serie LANDSAT, desde el LANDSAT 1, que estuvo operativo desde 1972 hasta 1978, LANDSAT 2 que operó en el periodo 1975-1983, LANDSAT 3 en el período 1978-1983, LANDSAT 4 durante 1982-1993, LANDSAT 5 durante 1984-2013, LANDSAT 6 cuyo procedimiento de puesta en órbita fracasó, LANDSAT 7 operativo desde 1999 hasta la actualidad, y LANDSAT 8 operativo desde 2013 hasta el presente (USGS, 2018a). También se espera que en el 2020 sea el lanzamiento de LANDSAT 9, el siguiente escalón de la serie LANDSAT. Como se observa también en la figura 2.1, la serie LANDSAT en la actualidad suma 46 años de capturas de la superficie terrestre, motivo por el cual ostenta la mayor serie temporal construida por imágenes satelitales de la humanidad.

Además de garantizar la continuidad de la serie LANDSAT, cada nueva misión de lanzamiento incluye mejoras en las capacidades de los sensores, sin comprometer la compatibilidad relacionada con los datos generados por las misiones previas. En este contexto, cada misión LANDSAT es diseñada considerando estándares específicos en relación la resolución temporal, espacial, radiométrica y espectral de la serie.



**Figura 1.1:** Evolución en el tiempo de la serie LANDSAT. Se muestra por fechas la cronología de lanzamiento de cada una de las plataformas, el periodo de tiempo de actividad, y además se incluye la fecha planificada para el lanzamiento de la siguiente misión, la plataforma LANDSAT 9 (USGS, 2018).

En el caso particular de LANDSAT 8, está equipada con los sensores OLI, que incluye observación con nueve bandas que cubren los espectros ópticos e infrarrojo, y el TIRS conformado por dos bandas dentro del rango de infrarrojo térmico, tal y como puede apreciarse en la figura 1.2, en donde se muestra la plataforma LANDSAT 8 durante la fase de construcción en sala blanca (USGS,2018a). En el cuadro 1.1, se muestra un listado de las bandas de frecuencia en las que operan LANDSAR 8 a partir de los sensores OLI y TIRS. Se aprecia un listado de las 11 bandas, sus nombres, las ventanas de frecuencias de operación en micrómetros, la resolución espacial en metros, y a además se especifica a que sensor corresponde cada banda. Los nombres se conservan en inglés para evitar confusión al lector, al momento de referirse a los diferentes acrónimos aludidos en este trabajo.



**Figura 1.2:** Los sensores OLI y TIRS montados en la plataforma LDCM (LANDSAT 8). TIRS fue recubierto con una capa múltiple dorada de aislamiento, y OLI fue aislado con una cobertura blanca de Tedlar.(USGS, 2018).

De igual modo, el cuadro 1.1 muestra una de las principales ventajas asociadas a las serie LANDSAT, y esto es la característica multiespectral de sus imágenes. En este contexto, término multiespectral está relacionado con la capacidad que tiene LANDSAT 8 para observar la superficie terrestre en 11 ventanas de frecuencia diferentes, lo que mejora considerablemente la capacidad para identificar objetos en superficie a partir de estas imágenes.

Cada imagen L8 (en adelante se usará la contracción L8 para hacer referencias a las imágenes captadas a través de la plataforma LANDSAT 8) cubre un área de 170 km x 185 km sobre el terreno, lo que equivale aproximadamente a una superficie de 31140 km<sup>2</sup> dependiendo de la latitud de observación.

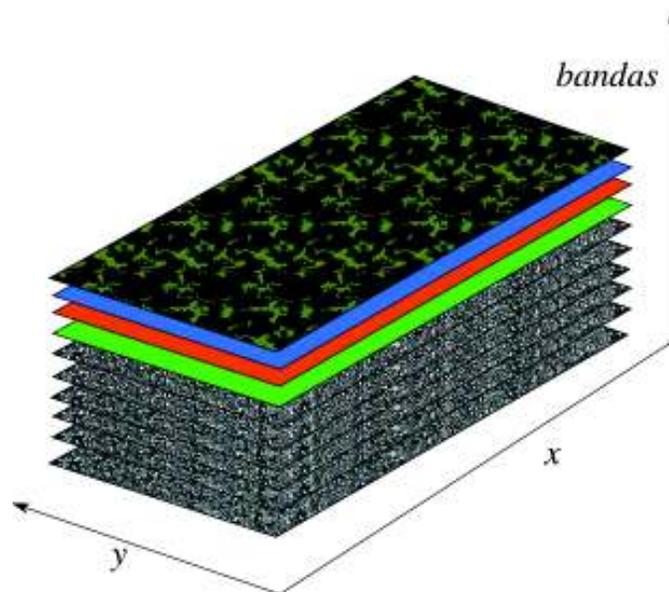
### **La Imagen Digital LANDSAT 8**

Una vez que una imagen es capturada por LANDSAT 8, y es transferida a una estación terrena en superficie, el dato que se tiene puede concebirse como un cubo de datos, similar al que se muestra en la figura 1.3, en donde los valores de las x

corresponden al número de fila, y al número de columna, y en el eje de las bandas, se asocia cada una de las 11 bandas adquiridas.

**Cuadro 1.1: Listado de bandas de LANDSAT 8 (USGS,2018a).**

Número de Banda	Denominación	Frecuencia de Operación ( $\mu$ )	Resolución Espacial (m)	Sensor
1	Coast	0.43-0.45m	30	OLI
2	Blue	0.45-0.51	30	OLI
3	Green	0.53-0.59	30	OLI
4	Red	0.64-0.67	30	OLI
5	Near Infrared (NIR)	0.85-0.88	30	OLI
6	SWIR 1	1.57-1.65	30	OLI
7	SWIR 2	2.11-2.29	30	OLI
8	Panchromatic (PAN)	0.50-0.68	15	OLI
9	Cirrus	1.36-1.38	30	OLI
10	TIRS 1	10.6-11.19	100	TIRS
11	TIRS 2	11.5-12.1	100	TIRS



**Figura 1.3:** Cubo de datos generado a partir de la adquisición de una imagen L8.

Las imágenes L8, son proporcionadas a una resolución radiométrica de 16 bits, lo que corresponde 55000 niveles de grises por cada píxel. Estas imágenes pueden ser adquiridas en números digitales (DN, por sus siglas en inglés), por lo que deben ser convertidas a radiancia para poder procesarlas. Actualmente, la USGS proporciona estas imágenes en nivel de procesamiento TIER 1, que ya poseen correcciones geométricas y radiométricas que cumplen con condiciones de pre-procesamiento general. Las imágenes TIER 1 de L8, puede ser clasificadas de forma directa.

En este contexto, una etapa importante en el tratamiento digital de imágenes satelitales es la etapa de clasificación. En esta etapa, una imagen digital en formato raster, es sectorizada en grupos de píxeles asociados a un tipo de objeto sobre la superficie. Cada uno de estos sectores son denominados clases, y cada clase corresponde a un objeto sobre la superficie que puede ser separable del resto de las clases. Por ejemplo, cuando se genera un mapa de dos clases, como lo es el caso de un mapa bosque no-bosque (BNB), la clase Bosque agrupa los píxeles que corresponden a la cobertura bosque sobre la superficie, con un valor de incertidumbre asociado. Por otra parte, la clase No-bosque agrupa en cambio todos los píxeles que no representan bosque sobre la superficie. Este principio es el mismo, para mapas con un mayor número de clases.

Existe una gran cantidad de metodologías para clasificar imágenes satelitales, sin embargo la mayoría de estas pueden dividirse en dos grupos, estas son las metodologías de clasificación supervisada y clasificación no supervisada (Wilkinson, 2005). La clasificación supervisada consiste en asociar clases a algunos píxeles de la imagen en base a conocimiento de referencia, y luego con el uso de un algoritmo los píxeles sin clases se van asignando entre las clases definidas de acuerdo a un criterio de similitud. Para llevar a cabo esta técnica se relaciona un píxel de una imagen geo-referenciada con la clases que representa sobre el terreno, para esto se puede utilizar información de campo, imágenes de muy alta resolución, o cualquier otro tipo de información disponible, como por ejemplo mapas de cobertura y uso del suelo. Una vez que se asigna la clase a los píxeles pilotos, estos píxeles son utilizados como datos de entrenamiento o de referencia para algoritmos de clasificación automática. Algunos ejemplos de estos algoritmos son: (i) *k nearest neighbor*, donde se utiliza una métrica de distancia, que puede ser euclidiana o mediante cualquier estimador de similitud, desde el píxel evaluado a las diferentes clases, y el píxel se asigna a la clase que tenga menor distancia respecto al píxel (ii) las redes neuronales artificiales, en donde los datos de entrenamiento son utilizados para diseñar redes que sean capaces de reproducir la relación entre las clases y los diferentes píxeles que conforman las clases, entre otros.

Por otra parte, la clasificación no supervisada, tiene por objetos generar clases de forma automática a partir de las imágenes digitales. En este contexto, los píxeles se van separando en clases con un criterio de similitud, que puede estar basados en estadísticos, firmas espectrales, métricas de texturas, intensidad de brillo, entre otros. En la clasificación no supervisada, el número de clases generalmente puede definirse, y de esta forma se parametriza los umbrales para las designaciones de las clases. A diferencia de la clasificación supervisada, no se conoce a priori la correspondencia de cada clase con objetos en la superficie, por lo que se deben utilizar datos de referencias para la asignación de etiquetas.

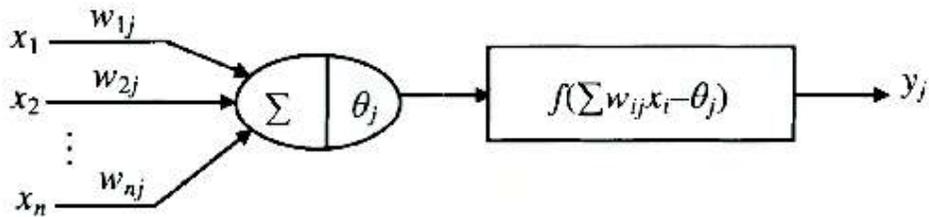
## **Redes Neuronales Artificiales**

Diversos autores coinciden en que la Redes Neuronales Artificiales (ANN, por sus siglas en inglés) son una representación matemática abstracta e idealizada, en la búsqueda del ser humano por emular las actividades de inteligencia y toma de decisión que tienen lugar en base a las redes neuronales cerebrales (Haykin, 1999, Mas and Flores, 2008). Las ANN, al igual que el cerebro humano, son modelos complejos que están conformados por partes más simples, como lo son las capas de neuronas, las neuronas, y las conexiones interneuronales. En ambos casos, tanto en el arreglo artificial como el natural, el conocimiento es adquirido a partir de un proceso de aprendizaje, o también denominado entrenamiento, y este conocimiento es almacenado en la red a partir de las relaciones interneuronales, que en el caso de la ANN se denomina peso sináptico. Otra analogía importante entre las ANN y las neuronas cerebrales, es que en el caso biológico el mecanismo de activación de cada neurona se lleva a cabo a partir de impulsos eléctricos que son modulados durante la etapa de aprendizaje, y en el caso de las ANN, la respuesta de las neuronas se lleva a cabo a partir de una función de activación que de forma sincronizada con los pesos sinópticos genera respuestas esperadas en base al conocimiento adquirido durante la etapa de entrenamiento.

## **Arquitectura de una ANN**

La unidad de procesamiento más simple de una red neuronal artificial es la neurona (Haykin, 1999). En la figura 1.4, se aprecia el esquema de esta estructura. El umbral de respuesta de la neurona está supeditado a la superposición de cada una de las señales de entrada a neurona, multiplicada por su peso sinóptico. Una vez que la neurona es estimulada por las señales de entrada y se supera el umbral de activación la neurona

emite una salida que es modulada por la función de activación y esta última es encargada de generar la respuesta.



**Figura 1.4:** Modelo matemático de una neurona (Xingui and Shaohua, 2010).

Es importante destacar, que la neurona debe estar entrenada para responder ante cada posible entrada de estímulo que esta reciba, de lo contrario la neurona puede generar respuesta inesperadas. Cada vez que se pretenda agregar entradas nuevas a una neurona, se requiere un proceso de entrenamiento para que esta pueda generar respuestas satisfactorias.

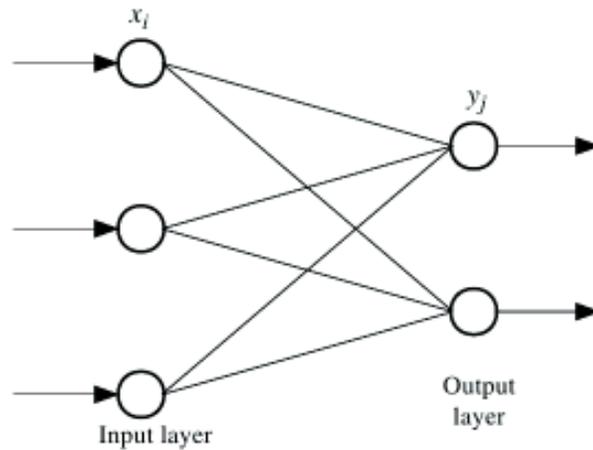
De la figura 1.4 se puede derivar el modelo matemático de una neurona (Haykin,1999). Para esto se supone que  $j$  es un identificador de la neurona estimulada, y también que  $\tilde{X} = x_1, x_2, x_3, \dots, x_n$  es un vector que contiene todas las posibles entradas asociadas con las  $n$  neuronas inter-conectadas con  $j$ .

Además, si  $\omega_{ij}$  es el peso sináptico asociado a cada  $i$ -ésima neurona etiquetadas como  $i = 1, 2, 3, \dots, n$ , y la neurona  $j$ . Considerando también que  $\theta_j$  es el umbral de activación o umbral de la neurona  $j$ ; y  $f$  es la función de activación asociada a la  $j$ -ésima neurona, entonces la salida  $y_j$  asociada a la neurona  $j$  de la primera capa oculta de la red neuronal está dada por la combinación lineal de las neuronas de la capa de entrada de acuerdo a la ecuación 1.1 (Haykin,1999):

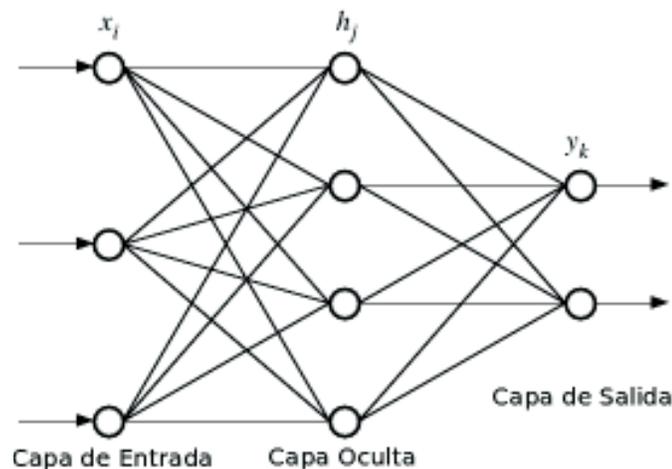
$$y_j = f(\sum_{i=1}^n \omega_{ij} x_i - \theta_j) \quad (1.1)$$

Donde,  $f$  es la función de activación de las neuronas de la primera capa oculta,  $w_{ij}$  son los pesos sinápticos,  $x_i$  es la respuesta de la neurona  $i$  de la capa de entrada, y  $\theta_j$  es el umbral de activación de la neurona  $j$  de la primera capa oculta. De este modo, a partir de una neurona, se pueden construir arquitecturas de ANN más complejas, como lo son el perceptrón de una capa (Rosenblatt, 1958, 1962, Widrow and Hoff, 1960), cuyo modelo se muestra en la figura 1.5, o el perceptrón multicapas (Rumelhart et al., 1986, Werbos, 1974) mostrado en la figura 1.6. En el caso del perceptrón multicapa, el modelo matemático de neurona se extiende hacia las capas ocultas, de tal forma que el modelo

para las neuronas de la capa oculta está dado a partir de la ecuación 1.2, y de las neuronas de salida está dado a partir de la ecuación 1.3.



**Figura 1.5:** Modelo del Perceptrón de una Capa (Hsieh, 2009).



**Figura 1.6:** MLP, se muestra la capa de entrada de datos, una capa oculta, y una decapa de salida (Hsieh, 2009).

$$h_j = f\left(\sum_{i=1}^n \omega_{ij} x_i - b_j\right) \quad (1.2)$$

$$y_k = g\left(\sum_{j=1}^n \hat{\omega}_{jk} h_j - b_k\right) \quad (1.3)$$

De forma análoga a la ecuación (1.1), los símbolos de las ecuaciones (1.2) y (1.3), tienen un significado similar, con la excepción de que la salida de la ecuación (1.2) hace referencia a la respuesta de las neuronas de la capa oculta y los pesos están definidos

por las interconexiones de las neuronas de la capa de entrada y de la capa oculta. De forma similar, la ecuación (1.3) representa la salida de la neurona de la capa de salida, y sus pesos están definidos por la relación que hay entre las neuronas de la capa oculta y las de la capa de salida.

En el caso de un perceptrón multicapa con mayor número de capas ocultas, la ecuación (1.2) se ajusta a las salidas de cada capa oculta. De esta forma, el modelo matemático sería una generalización del presentado en este apartado (Munoz et al., 2015).

## **Entrenamiento de ANN**

El proceso de entrenamiento de un ANN, una vez definida la arquitectura de la red, consiste en utilizar datos de entrenamiento conformado por datos de entrada y de salida, y mediante un algoritmo de optimización determinar pesos sinápticos y bias que minimicen la función de error presentada en la ecuación 1.4 (Loranca, 2009):

$$J = \frac{1}{N} \sum_{n=1}^N \left\{ \frac{1}{2} \sum_k [y_k^n - y_{dk}^n]^2 \right\} \quad (1.4)$$

El proceso de entrenamiento es iterativo, y en cada ciclo de entrenamiento se calcula la función de error entre los datos que genera la red, y los datos objetivos de entrenamiento.

## **Selección de Píxeles Puros**

Una característica fundamental para que dos píxeles  $n$  y  $m$  pertenezcan a la misma clase, desde un enfoque teórico, es que sean espectralmente similares. En este trabajo se ha optado por estimar el nivel de similitud a partir de la implementación del coeficiente de correlación cruzada  $\rho_{nm}$ .  $\rho_{nm}$  es un coeficiente normalizado utilizado en el procesamiento digital de señales para estimar la dependencia entre dos secuencias de impulsos  $x_1[n]$  y  $x_2[n]$ . En el dominio de la frecuencia, cada impulso de la secuencia corresponde a un componente del espacio vectorial, de tal manera que si dos secuencias son dependientes, deben tener una alta correlación entre sus diferentes componentes vectoriales, y en el caso contrario se consideran independientes. De esta forma,  $\rho_{nm}$  es un coeficiente cuyos valores pertenecen al conjunto  $[-1, 1]$ , donde  $-1$  significa máxima correlación inversa,  $0$  significa que no hay correlación, y  $1$  máxima correlación directa. En analogía al campo del procesamiento digital de señales discretas, si se supone a una

escena L8 en un cubo de dato similar al mostrado en la figura 1.3, en el caso de procesamiento digital de imágenes satelitales, un píxel puede ser representado como un vector cuyas componentes vectoriales están definidas a partir del número total de bandas de frecuencias que integran la captura. De esta forma, un píxel L8 puede tener hasta 11 componentes vectoriales, y dos píxeles son dependientes, o espectralmente similares si el coeficiente de correlación cruzada  $r_{nm}$  entre ambos es alto, o independientes si es bajo. De esta forma, en este trabajo se propone el uso del coeficiente  $r_{nm}$  para seleccionar píxeles espectralmente puros que correspondan a las clases bosque y no-bosque. Para esto se identificaran umbrales de correlación que permita detectar píxeles representativos, y que simultáneamente reduzcan la cantidad de píxeles necesarios para construir un conjunto de datos de entrenamiento.

El coeficiente de correlación cruzado  $\rho_{nm}$  se muestra en la ecuación (Curetti, 2013):

$$\rho_{nm} = \frac{\sum_{i=1}^N n_i m_i}{\sqrt{\sum_{i=1}^N n_i^2 \sum_{i=1}^N m_i^2}} \quad (1.5)$$

## Estado del Arte

Las redes neuronales artificiales han sido usadas en la clasificación de imágenes multiespectrales por más de 3 décadas, demostrando cualidades importantes para la clasificación y post-clasificación en comparación con algoritmos ampliamente conocidos y utilizados tradicionalmente, tal y como el algoritmo de máxima verosimilitud (Bischof et al., 1992). Las principales aplicaciones en las que tiene lugar el uso de redes neuronales artificiales, particularmente en el tratamiento de imágenes multiespectrales LANDSAT abarca clasificación temática en general (Kamata et al., 1992, Salahova, 2007), clasificación de nubes (Lee et al., 1990), clasificación de uso de suelo y cobertura (Gao et al., 2007, Mas, 2003, Paola and Schowengerdt, 1995), clasificación multi-temporal (Chae et al., 1997), en el desarrollo de algoritmos de descomposición espectral (Lee and Lathrop, 2006, Yoshida and Omatu, 2001), estudios de biodiversidad (Foody and Cutler, 2002), detección de cambios (Feldberg et al., 2002), normalización radiométrica (Velloso et al., 2002), métodos de inversión para estimar parámetros biofísicos (Fang and Liang, 2003, Zhao et al., 2007), reconocimiento de patrones (Neagoe and Strugaru, 2008),

Estas cualidades han sido incrementadas considerablemente en la última década debido principalmente a (i) el desarrollo de nuevos algoritmos y estrategias de entrenamiento que minimizan de mejor forma la función de error sin comprometer la generalidad de la red, (ii) el avance tecnológico en el desarrollo de computadores

potentes de bajo costo relativo, (iii) un aumento en la comprensión de la generalidad de los datos de entrenamiento para mejorar la respuesta de la red neuronal, entre otros. Entre las diferentes ventajas que aportan las redes neuronales a la clasificación de imágenes satelitales, y muy particularmente de imágenes LANDSAT, es la capacidad probada para tomar adecuadamente decisiones de clasificación en relaciones no lineales entre diferentes clases (Kamata et al., 1992). De esta forma, la complejidad asociada a relaciones no lineales en el proceso de clasificación dentro de una imagen multiespectral puede ser resuelta a partir de una estrategia adecuada de entrenamiento y el uso de los datos apropiados para el aprendizaje de la red neuronal.

Además de esto, las redes neuronales artificiales han demostrado utilidad tanto en procesos de clasificación temática directa, como en procesos de clasificación indirectos, en los cuales se utiliza la técnica de segmentación para delimitar grupos o clases de píxeles. Solaiman et al. (1994) propusieron un algoritmo para la segmentación de imágenes LANDSAT entrenando una red neuronal artificial a partir de datos generados por expertos obteniendo resultados promisorios al ser comparados con el método de clasificación maestra. Muchos estudios han concluido que una etapa indispensable para el entrenamiento adecuado de ANN, es la generación o selección de los datos y el algoritmo de entrenamiento.

## **2. METODOLOGÍA DE LA INVESTIGACION**

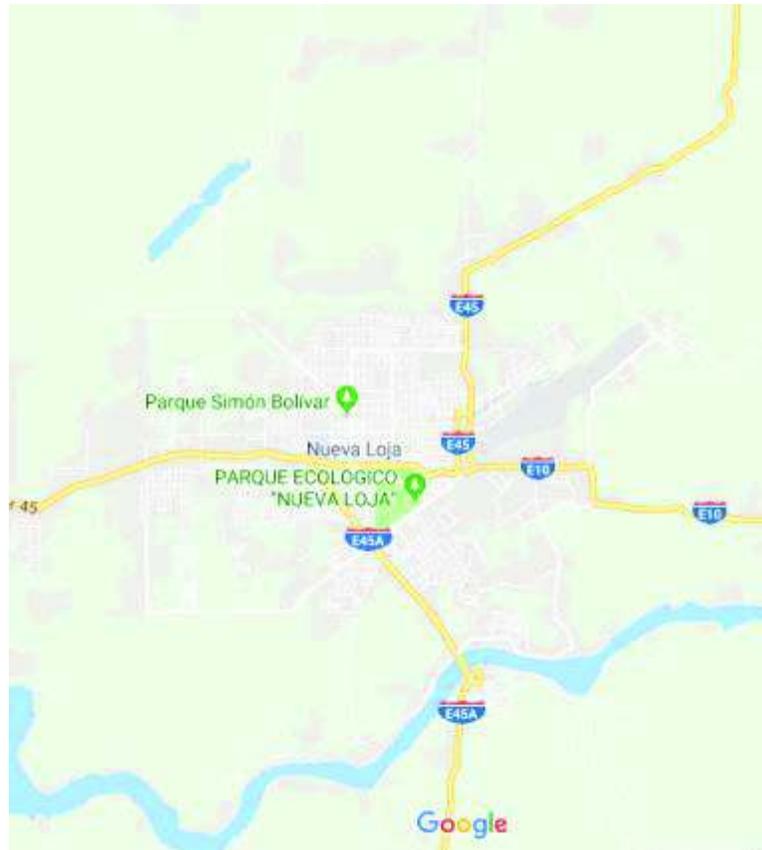
En este capítulo se presenta el diseño metodológico empleado para el logro de los diferentes objetivos de esta investigación. De esta forma, este marco metodológico contempla el desarrollo de 5 etapas, (i) La definición y caracterización del área de estudio, (ii) Definición de firmas espectrales de las clases bosque (B) y no bosque (NB), (iii) presentación del algoritmo para la generación automatizada de datos de entrenamiento para la red neuronal, (iv) entrenamiento de la red neuronal, (v) validación de resultados.

El método de investigación planteado en este trabajo es del tipo inductivo, en el cual se pretende concluir sobre la pregunta de investigación a partir de un proceso de investigación experimental con enfoque cuantitativo. La información base a procesar para responder la pregunta, está representada por imágenes satelitales provenientes de los servidores de almacenamiento LANDSAT 8 de *Google Earth Engine*, y fueron accedidos mediante el uso de SEPAL. Los datos utilizados para entrenar y validar, fueron generados con apoyo de imágenes satelitales a partir de un muestreo satelital, utilizando

parcelas de 30x30 metros en correspondencia al valor de los píxeles de las imágenes LANDSAT 8.

## **2.1. Área de Estudio**

La selección del área de estudio implica, además de la delimitación geográfica de la misma, definir el instante de tiempo para generar el mapa BNB. En este sentido, en el contexto del programa de Reducción de Emisiones por Deforestación y Degradación Forestal del Convenio Marco de las Naciones Unidas (ONU-REDD), el Ecuador ha reportado una disminución importante de la tasa de deforestación nacional. En este contexto, resulta de interés generar un mapa BNB en una zona de interés en donde exista una actividad importante de deforestación. Si bien es cierto, que en este estudio no se incluyen objetivos orientados a estimar tasa de deforestación, las zonas que presentan deforestación presentan escenarios complejos para clasificar zonas de bosque y no-bosque. En este contexto, el Ministerio del Ambiente del Ecuador publicó en el año 2015 un informe sobre datos de bosques, ecosistemas, especies, carbono y deforestación del Ecuador continental titulado Estadísticas del Patrimonio Natural (MAE, 2015). En este informe, se reporta a la provincia de Sucumbíos como la cuarta a nivel nacional, al alcanzar 5416 hectáreas deforestadas. Particularmente, una ciudad en desarrollo de Sucumbíos y que muestra patrones interesantes de deforestación es Nueva Loja, motivo por el cual se ha seleccionado esta ciudad para generar un mapa BNB. En la figura 2.1, se muestra la zona de interés para este estudio.



**Figura 2.1:** Área de estudio

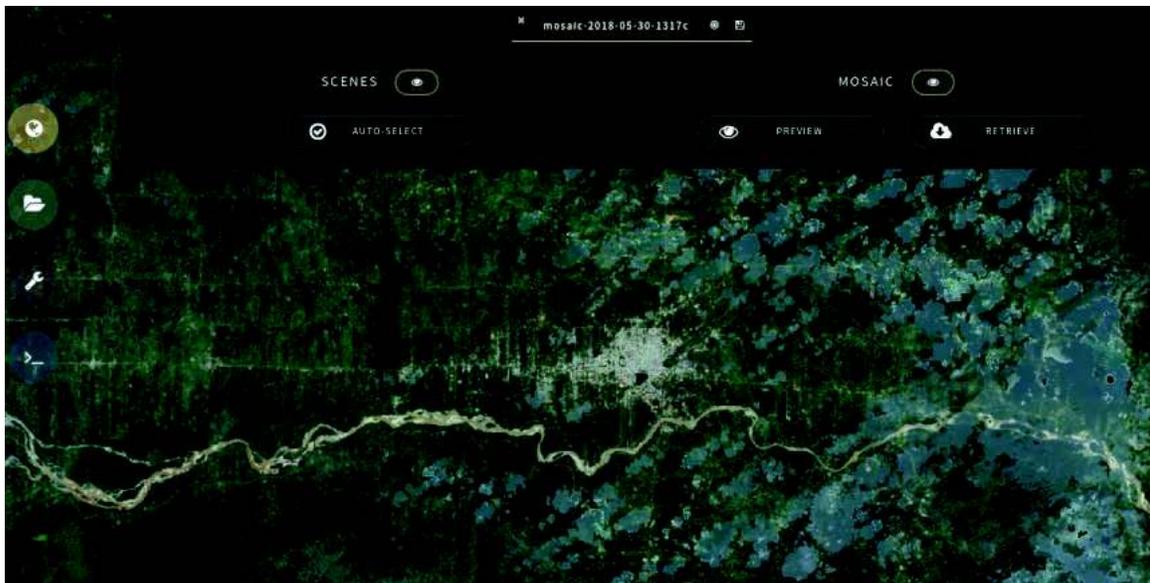
## **2.2. Generación de Mosaicos LANDSAT 8**

Para el área de estudio la generación de los mosaicos L8 se lo realizó mediante el uso de la plataforma SEPAL(FAO, 2018). La motivación principal para esto es que en la actualidad SEPAL cuenta con una interfaz gráfica para la descarga automatizada de imágenes, mosaicos y series de tiempo de LANDSAT 4, 5 y 7 y 8. Además de la descarga, es posible personalizar diversas opciones, entre las que destacan definir la fecha específica de descarga, también decidir si se desea aplicar mascara de nube o de nieve, aplicar normalización radiométrica mediante BDRF. En el caso de generación de compositos se puede escoger en dar prioridad a imágenes con menos cobertura de nube, o si se prefiere tomar imágenes muy cercanas a la fecha de interés. En la figura 2.2 se muestra la interfaz inicial para la generación de mosaicos en SEPAL, la primera etapa consiste en selección del área de interés para la descarga y definir la fecha objetivo.

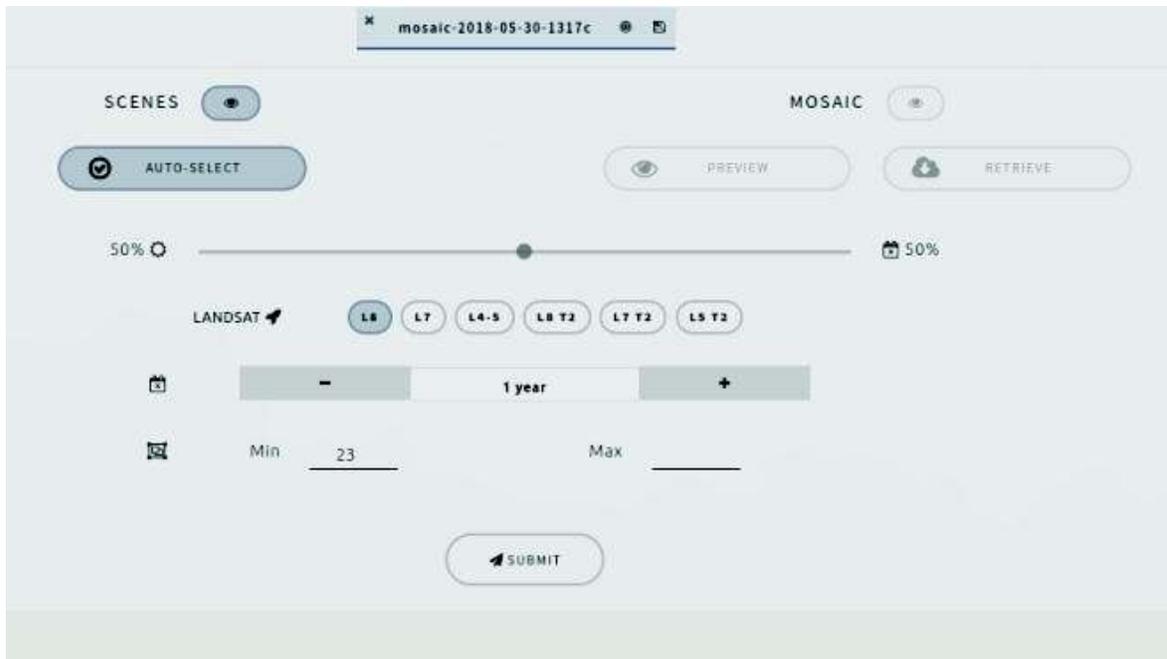


**Figura 2.2:** Interfaz gráfica de inicio para la generación de mosaicos en SEPAL

En este sentido, se utilizó como fecha objetivo el 15 de abril de 2016, y como área de interés se escogió un rectángulo que contiene el perímetro urbano principal de la ciudad de Nueva Loja. En la figura 2.3 se muestra un pre-visualización del mosaico generado, mientras que en la figura 2.4 se muestra a selección de parámetros.

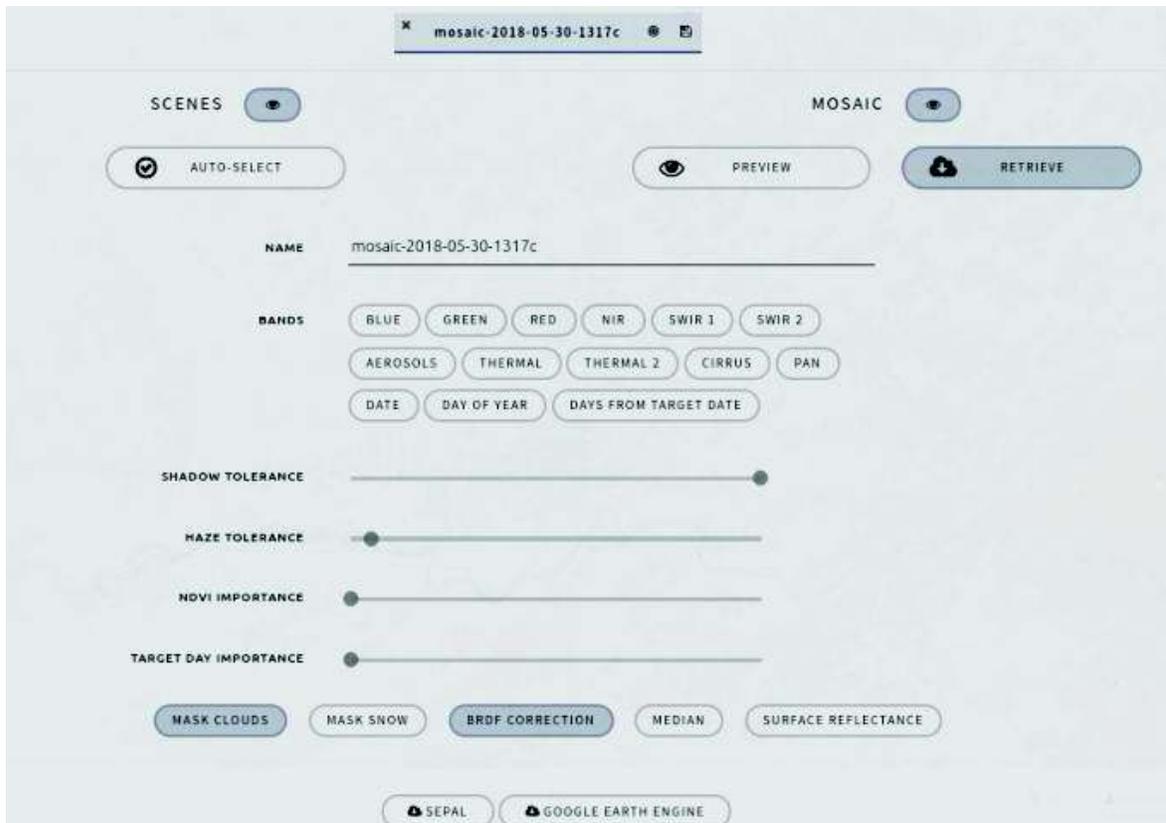


**Figura 2.3:** Pre-visualización del mosaico generado en SEPAL en combinación RGB



**Figura 2.4:** Selección de parámetros para la generación de mosaicos. Se ha seleccionado un mínimo de 23 imágenes para garantizar cubrir un año para la generación de un compuesto que permita eliminar la presencia de nubes.

En la figura 2.5 se muestra la interfaz de descarga de mosaicos de SEPAL. En esta interfaz se puede seleccionar las bandas a descargar, algunas parametrizaciones, y también si el usuario desea descargar su mosaico dentro de la plataforma SEPAL, o si prefiere descargarla a su cuenta de Google Drive, donde podrá utilizar el mismo desde Google Earth Engine.



**Figura 2.5:** Interfaz de descarga de imágenes de SEPAL. Entre las diferentes opciones que proporciona esta interfaz, resalta la posibilidad de escoger las bandas a descargar, y la posibilidad de aplicar algunos filtros adicionales.

## 2.3. Generación de Mapa BNB

En este trabajo se ha previsto la generación de dos mapas BNB para el área de estudio. El primer mapa será generado utilizando el algoritmo random forest incluido en SEPAL (Pal, 2005), y el segundo es generado mediante la ANN entrenada para clasificar. La generación del mapa BNB con SEPAL tiene dos objetivos, el primero es que sirva como dato de entrenamiento para la ANN, y el segundo es que una vez clasificados ambos mapas, este mapa de SEPAL permitirá evaluar de modo preliminar la salida obtenida mediante la ANN.

### Generación de mapa BNB en SEPAL

La generación del mapa BNB mediante SEPAL, requiere de datos de entrenamiento. Estos datos de entrenamiento son generados a partir del módulo *Collect Earth Online* (CEO) de *SEPAL* (SEPAL/FAO, 2018). En la figura 2.6 se muestra la

interfaz gráfica de la herramienta SEPAL/CEO para la generación de nuevos proyectos.

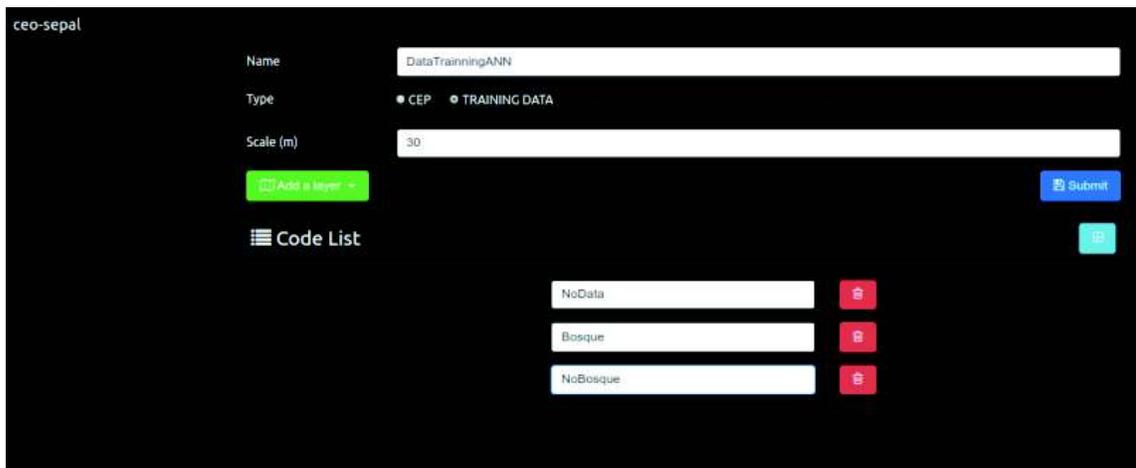
Los principales elementos para la creación de proyectos en SEPAL/CEO son:

(i) definir el nombre del proyecto.

(ii) escoger entre CEP o *Training Data*. El CEP consiste en generar o importar datos para validación en el formato *collect earth project*, mientras que Training Data se utiliza para generar datos de entrenamiento utilizando imágenes satelitales

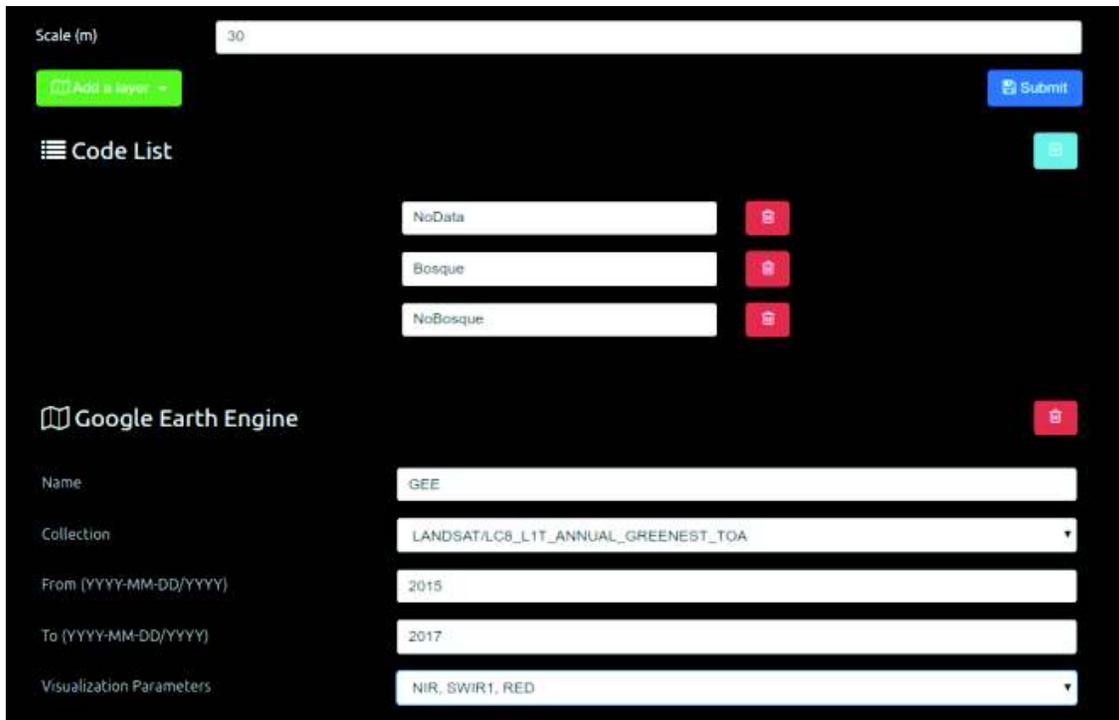
(iii) definir las clases para las que se generarán los datos de entrenamiento-

(iv) definir las imágenes bases que se utilizarán para clasificar los puntos de entrenamiento.



**Figura 2.6:** Interfaz de descarga de SEPAL/CEO para la generación de un proyecto que permita crear datos de entrenamiento utilizando imágenes satelitales

En la figura 2.7 se muestra la selección de una colección L8 de Google Earth Engine (*GEE*) como base para la definición de clases de píxeles durante la generación de datos de entrenamiento para el algoritmo *Random Forest* de SEPAL. Además también se muestran las tres clases para la generación de los datos. Para la generación de datos de entrenamientos, además de la combinación de GEE, también se incluyó una colección de *Digital Globe Basement* (DGB), y el mosaico generado con SEPAL para el área de estudio.



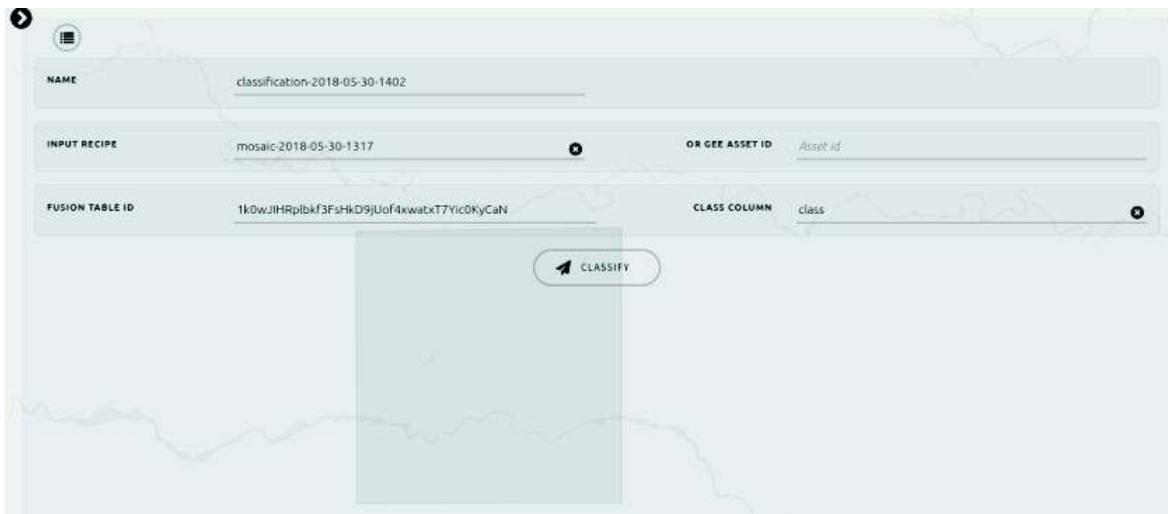
**Figura 2.7:** Uso de una colección L8 de *Google Earth Engine* como base para la definición de clases de píxeles durante la generación de datos de entrenamiento para el algoritmo Random Forest de SEPAL.

La siguiente fase, consiste en utilizar el módulo de clasificación de SEPAL, en la que se encuentra incluido el algoritmo *Random Forest*, para generar la clasificación del mosaico. La figura 2.9 muestra la interfaz del módulo de clasificación.

Una vez generado el proyecto, se seleccionan puntos sobre el geovisor, y se clasifican tomando como referencia las colecciones de imágenes base, de la forma como se muestra en la figura 2.8. Una vez clasificados todos los puntos de entrenamiento, los datos son exportados a csv o a una tabla dinámica de GEE (conocidas como *fusion table* en inglés).



**Figura 2.8:** La clasificación de puntos para la generación de entrenamiento se realiza mediante el geovisior de SEPAL/CEO, tomando como referencia las imágenes base se selecciona entre las diferentes clases disponibles.



**Figura 2.9:** Configuración del módulo de clasificación de SEPAL

En esta interfaz de usuario, se debe asignar un nombre al mapa de clasificación de salida, también se debe definir el mosaico que se desea clasificar, que en este caso es el generado con L8 para el área de estudio, también el id de la tabla dinámica que se exportó desde SEPAL/CEO. En la figura 2.10 se puede apreciar la apariencia de la tabla dinámica dentro de Google Drive, ya la misma está conformada por 5 columnas: la primera columna contiene un identificador para cada dato de entrenamiento (id), la segunda la coordenada Y, la tercera la coordenada X, la cuarta contiene la clase asociada a cada dato, y la quinta la localización de cada punto. A modo de control de

calidad, la localización de los puntos de entrenamiento puede verificarse dentro de Google Drive, como lo muestra la figura 2.11.

**DataTrainingANN-1527706951**

Edited at 14:01

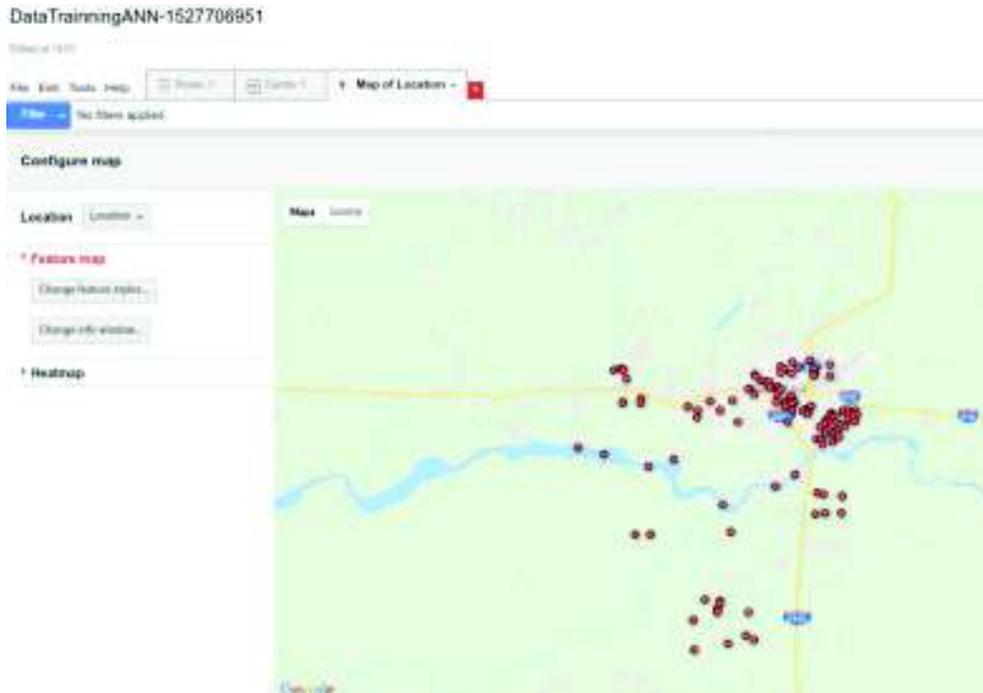
File Edit Tools Help Rows 1 Cards 1 Map of Location

Filter No filters applied

1-100 of 109

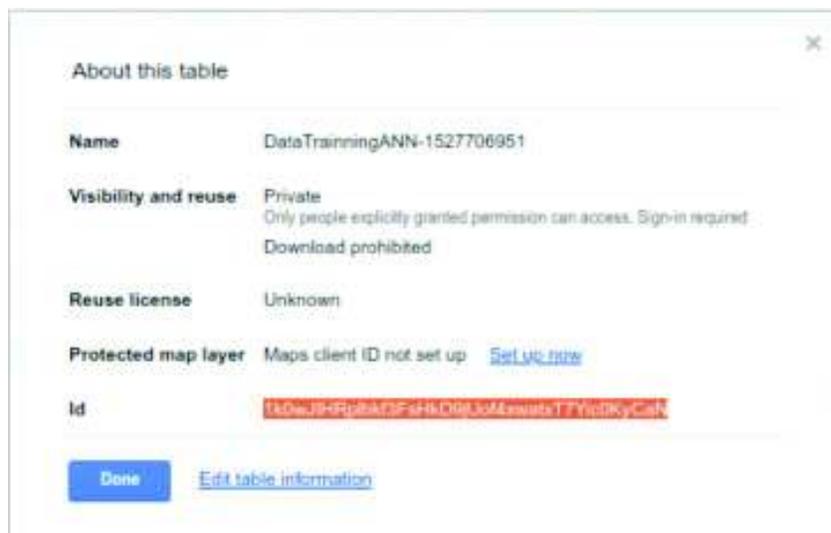
id	YCoordinate	XCoordinate	class	Location
1527705903500	0.0905304591940106	-76.90286864765011	2	0.0905304591940106 -76.90286864765011
1527705894700	0.0936203599889524	-76.89292301662289	2	0.0936203599889524 -76.89292301662289
1527705877212	0.08777946773867257	-76.8984048159902	1	0.08777946773867257 -76.8984048159902
1527705883609	0.09145313793158744	-76.89296593196713	2	0.09145313793158744 -76.89296593196713
1527705872995	0.08773655244479049	-76.89729974587607	1	0.08773655244479049 -76.89729974587607
1527705869893	0.08592338123290522	-76.8971602710073	2	0.08592338123290522 -76.8971602710073
1527705864438	0.08472369868727454	-76.89308559240811	2	0.08472369868727454 -76.89308559240811
1527705859956	0.08473442751159746	-76.89381515326016	2	0.08473442751159746 -76.89381515326016
1527705852980	0.08632229347925159	-76.89383661093228	2	0.08632229347925159 -76.89383661093228
1527705847972	0.09092495864159417	-76.88891207518094	2	0.09092495864159417 -76.88891207518094
1527705844493	0.09266302785257799	-76.891444080491	2	0.09266302785257799 -76.891444080491

**Figura 2.10:** Visión de la tabla dinámica de los datos de entrenamiento desde Google Drive.



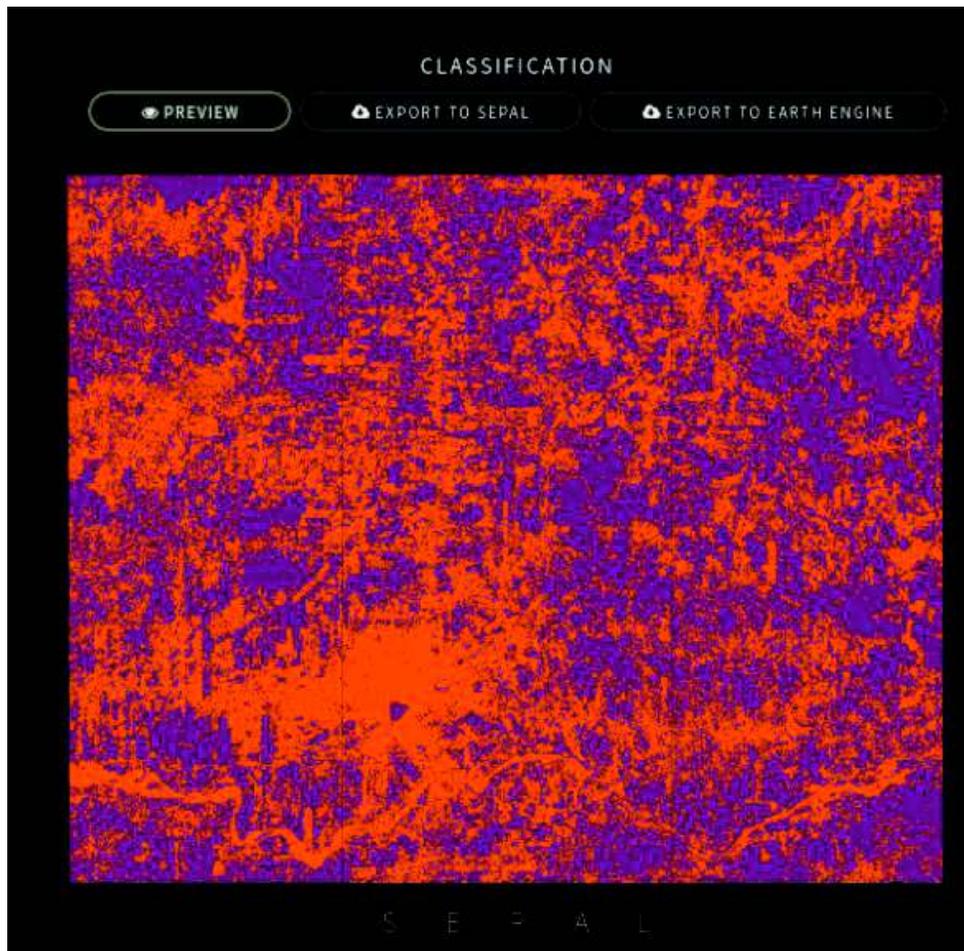
**Figura 2.11:** Verificación de la localización de los puntos de entrenamiento desde Google Drive.

Para importar la tabla dinámica, se debe escribir el ID2 de la tabla dinámica en SEPAL. Adviértase que el Id de la tabla dinámica es una ruta única que asigna Google Drive para el acceso desde cualquier conexión internet. .Para asegurar el acceso, la tabla dinámica debe estar configurada en modo público. En la figura 2.12 se muestra el id de la tabla dinámica que contiene los datos de entrenamiento.



**Figura 2.12:** Id de la tabla dinámica con los datos de entrenamiento. Este id es usado para importar la tabla a SEPAL.

Completado el paso de llenado de la interfaz de la figura 3.9, se inicia el proceso de clasificación. En la figura 2.13 se muestra el mapa BNB dentro del visualizador de SEPAL. Este mapa de BNB se utiliza en la neurona de salida para el entrenamiento de la Artificial Neural Networks (ANN) que será utilizada para la clasificación BNB. Es importante destacar, que la calidad de este resultado, depende fundamentalmente de los datos generados para el entrenamiento. Estos datos son generados uno a uno a partir de SEPAL/CEO utilizando la técnica de muestreo satelital. En este contexto, en este trabajo se espera utilizar este resultado para proponer un método automatizado para la generación de datos de entrenamiento para una ANN. La ventaja de este enfoque es que una vez entrenada la ANN, no sería necesario volver a pasar por un proceso de muestreo satelital, lo que se traduce en ahorro de tiempo y recursos.



**Figura 2.13:** Mapa BNB generado mediante SEPAL. Los píxeles en color naranja corresponden a la clase No-Bosque, y los píxeles en color púrpura pertenecen a la clase Bosque.

## Generación de mapa BNB usando la ANN

La generación del mapa BNB utilizando la ANN entrenada, se lleva a cabo utilizando las seis bandas del mosaico L8, es decir, Blue, Green, Red, NIR, SWIR 1, y SWIR2 como datos de entrada, y la salida esperada de la ANN son los valores 0, para No-Datos, 1 para No-Bosque y 2 para Bosque. El proceso de manipulación del mosaico implica (i) separación de las seis bandas del mosaico utilizando *oft-calc* de *Open Foris Geospatial Toolkit*, (2) Integración como datos de entrada utilizando un *script* de C++ que utiliza la librería OpenCV, (iii) producción de la ANN utilizando las librerías ALGLIB y OPENNN. La salida final del algoritmo es una imagen de clasificación BNB en formato TIF.

### 2.4. Datos de Entrenamiento

El contenido espectral muestreado en las bandas 2, 3, 4, 5, 6 y 7 del mosaico L8 generado mediante SEPAL, puede ser visto como una firma espectral discreta y acotada de las clases Bosque y No-Bosque. De esta forma, es posible diseñar algoritmos de clasificación no supervisada, a partir de la generación de datos de entrenamiento. Generalmente, los datos de entrenamiento son generados a partir de conocimiento humano; esto es, se utilizan datos generados por expertos en clasificación de imágenes satelitales, o por la integración de datos de campos, para entrenar algoritmos basados en inteligencia artificial.

El objetivo de este trabajo es proponer un método para generar datos de entrenamiento de forma automatizada, orientada a facilitar el proceso de entrenamiento de una ANN. Un problema frecuente de generar datos para entrenar una ANN para la clasificación de imágenes satelitales es identificar el número de píxeles que se deben considerar en la muestra, y garantizar las propiedades de generalización de la ANN. Recuérdese que en este trabajo, el área de estudio está conformada por un mosaico L8 cuya dimensión es de 867 filas y 905 columnas, lo que se traduce en 784635 píxeles. Así se plantea una solución al problema de muestreo; para la generación de datos de entrenamiento; implementando la correlación cruzada.

El coeficiente de correlación cruzada se definió en la ecuación 1.5, y para comodidad se reescribe a continuación(Curetti, 2013):

$$\rho_{nm} = \frac{\sum_{i=1}^N n_i m_i}{\sqrt{\sum_{i=1}^N n_i^2 \sum_{i=1}^N m_i^2}} \quad (2.1)$$

Para aplicar esta relación se asume que la imagen está conformada por  $n$  filas y  $m$  columnas, lo que equivale a una imagen de  $n \times m$  píxeles. Para establecer si dos píxeles arbitrarios cualesquiera (digamos  $k_{ij}$  y  $l_{qp}$ ) pertenecen o no a la misma clase espectral, de modo de escoger los listados de datos de entrenamiento  $l_{qp}$ , se compara con el valor de su correlación cruzada  $\rho_{nm}$ . Los píxeles  $l_{qp}$  para los cuales se propone la ecuación (2.2):

$$\rho_{nm} > \gamma \quad (2.2)$$

donde para algún número real  $\gamma$ , previamente definido como indicador de correlación mínima, pertenecerán a la misma clase, y por lo tanto se descartarán, pues no formará parte del listado de datos de entrenamiento. Por el contrario, cuando la ecuación (2.2) no se verifica, entonces  $l_{qp}$  pasa a la lista de píxeles de los datos de entrenamiento. Este proceso se hace entre todos los píxeles de la imagen, y el resultado es obtener un listado de píxeles de clases únicas que representan al resto de píxeles de la escena, tomando como referencia mínima el valor de correlación  $\gamma$ .

El objetivo de este filtrado es seleccionar de forma automatizada los píxeles más representativos de la escena. Para una clase como bosque o no-bosque, donde existen diferentes tipos de firmas espectrales, es común encontrar píxeles espectralmente muy distintos, con esta técnica se propone integrar los diferentes tipos de bosques bajo la misma clase Bosque de forma automática, y de igual forma integrar los diferentes tipos de píxeles no-bosque, como lo son píxeles de cobertura urbana, suelo desnudo, cuerpos de agua, coberturas agrícolas, entre otros, en una misma clase.

## 2.5. Criterio de Entrenamiento de la ANN

Para el entrenamiento de la ANN, se utilizaron 6 neuronas de entrada, correspondientes a las bandas Blue, Green, Red, NIR, SWIR1, y SWIR2, y una neurona de salida relacionada con el mapa BNB generado a partir de SEPAL. Con la finalidad de obtener generalidad suficiente para definir las diferentes coberturas que están asociadas en las clases Bosque y No-Bosque, se ha decidido utilizar una primera capa oculta con 10 neuronas, y una segunda capa oculta de 5 neuronas. En las neuronas de la capa oculta se utilizó como función de activación a la función tangente hiperbólica, mientras que para la capa de salida se implementó la función lineal. Siguiendo las recomendaciones de Muñoz et al. (2015), en donde se presentan experiencias para el diseño de ANN con la finalidad de reproducir relaciones no lineales entre observaciones y

mediciones satelitales, en este trabajo se ha utilizado el algoritmo de segundo orden L-BFGS para el entrenamiento de la ANN, y se utilizan los parámetros de entrenamiento y criterios de parada por defecto incluidos en ALGLIB (ALGLIB, 2018) y OPENNN (OPENNN, 2018).

## 2.6. Técnica de Validación de Resultados

La validación del mapa BNB generado mediante la ANN, será realizada implementando la metodología de Olofsson et al. (2014) a partir de SEPAL. Para esto, se realiza un diseño de muestreo estratificado usando el módulo disponible en SEPAL, cuya interfaz gráfica se muestra en la figura 2.14. El diseño consiste en la determinación matemática del número de muestras de validación a determinar por clase, así como también la localización de cada uno de estos puntos. Para la ejecución de este módulo es imprescindible contar con el mapa de clases BNB.



**Figura 2.14:** Interfaz gráfica del módulo de diseño de muestreo estratificado de SEPAL.

Durante la ejecución de este módulo se debe guardar el archivo de cálculo de áreas y el archivo con las muestras que se obtiene al finalizar el proceso. El archivo con las muestras, puede almacenarse en csv, cep, o shp. Una vez que se ha realizado el proceso de diseño de muestreo, se deben clasificar los diferentes puntos de muestreo, y esto se ha realizado en este trabajo mediante el uso de SEPAL/CEO (SEPAL/FAO, 2018), que permite la generación de puntos de validación utilizando imágenes satelitales. Finalmente, los datos de validación son analizados en el módulo de análisis estratificado de SEPAL para obtener la precisión temática de la clasificación.

### **3. RESULTADOS Y ANÁLISIS**

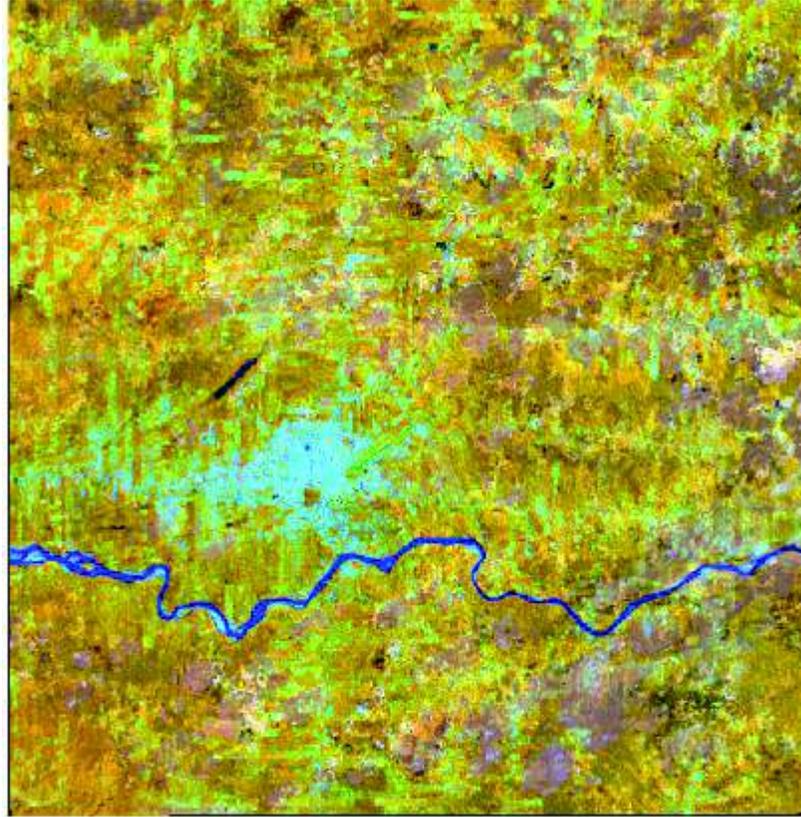
En este capítulo se presentan los resultados principales de la investigación, en referencia a (i) construcción de mosaicos, (ii) definición de firmas espectrales, (iii) generación de los datos de entrenamiento, (iv) entrenamiento de la ANN, (v) resultados del proceso de clasificación mediante la ANN, (vi) Comparación de resultados con técnica de clasificación supervisada y (vii) finalmente también se reportan resultados sobre la etapa de validación. Además, se presenta en cada caso una discusión detallada sobre los resultados obtenidos y sus implicancias.

#### **3.1. Resultados**

##### **Sobre la Construcción de Mosaicos**

El mosaico L8 generado en SEPAL, se muestra en la figura 4.1. Esta escena contiene 6 bandas (2, 3, 4, 5, 6, y 7), y en la figura se muestra la combinación RGB 564; vale decir R para NIR, G para la banda SWIR 1 y B para RED. En esta combinación, las coberturas de bosque aparecen en tonos de marrón oscuro, el suelo desnudo aparece en tonos naranja, las coberturas agrícolas en verde, las zonas urbanas en celeste intenso, y los cuerpos de agua en azul oscuro.

Este mosaico de la Figura 3.1 fue generado mediante la plataforma SEPAL, con fecha objetivo para el 15 de abril de 2016. EL mosaico contiene las bandas desde la 2 hasta la 7, y en la figura se muestra la composición RGB 564. Este mosaico, ha sido construido a partir de la implementación de varias técnicas de reprocesamiento que incluye, (i) calibración radiométrica, (ii) corrección atmosférica, (iii) Normalización radiométrica, (iv) enmascaramiento de nubes, (v) creación de composito con criterio de mejor píxel. Generalmente, el proceso de enmascaramiento de las nubes deja espacios sin información en la escena, debido a que todos los píxeles que formen parte de nubes son eliminados.



**Figura 3.1:** Mosaico L8 del área de estudio.

Para evitar la ausencia de datos, se procede a generar un compuesto, que es rellenar los píxeles faltantes por nubes, con píxeles que correspondan a imágenes cercanas en tiempo, y para las que si existan datos en los píxeles que han sido filtrados.

El efecto de implementar esta técnica de compuesto para completar información faltante, se puede apreciar en la figura 3.1, con parches en marrón claro. Estos parches a primera vista, podrían dar la falsa sensación de que hay deforestación o algún otro proceso de cambio de cobertura. Sin embargo, esta diferencia en tonos se debe a diferencias de radiometría, que existen entre la imagen original, y las diversas imágenes suplementarias que se usan para el llenado de información. Los compositos no solo presentan este tipo de problemas visuales, sino que además si la diferencia radiométrica es importante, esto puede ser una fuente de incertidumbre grande cuando se llevan a cabo técnicas de clasificación no supervisadas, o automatizadas.

Las características más relevantes del mosaico, pueden apreciarse en la figura 4.2. La primera característica a destacar, es que las dimensiones de este mosaico es de 867 filas por 905 columnas, para un total de 784635 píxeles, el tamaño del píxel esta expresado en grados, sin embargo el valor mostrado equivale a 30 metros. Además de información sobre la proyección y parámetros de la georeferencia, también se observan

las seis bandas que conforman el mosaico, donde se puede confirmar la banda azul, verde, rojo, NIR, SWIR1, y SWIR2.

```

Size is 867, 905
Coordinate System is:
GEOGCS["WGS 84",
  DATUM["WGS 1984",
    SPHEROID["WGS 84",6378137,298.257223563,
      AUTHORITY["EPSG","7030"]],
    AUTHORITY["EPSG","6326"]],
  PRIMEM["Greenwich",0],
  UNIT["degree",0.0174532925199433],
  AUTHORITY["EPSG","4326"]]
Origin = (-76.977894337599565,0.229339892035714)
Pixel Size = (0.000269494585236,-0.000269494585236)
Metadata:
  AREA_OR_POINT=Area
Image Structure Metadata:
  COMPRESSION=LZW
  INTERLEAVE=PIXEL
Corner Coordinates:
Upper Left ( -76.9778943,  0.2293399) ( 76d58'40.42"W,  0d13'45.62"N)
Lower Left ( -76.9778943, -0.0145527) ( 76d58'40.42"W,  0d 0'52.39"S)
Upper Right ( -76.7442425,  0.2293399) ( 76d44'39.27"W,  0d13'45.62"N)
Lower Right ( -76.7442425, -0.0145527) ( 76d44'39.27"W,  0d 0'52.39"S)
Center ( -76.8610684,  0.1073936) ( 76d51'39.85"W,  0d 6'26.62"N)
Band 1 Block=256x256 Type=UInt16, ColorInterp=Gray
  Description = blue
  Metadata:
    BAND_NAME=blue
Band 2 Block=256x256 Type=UInt16, ColorInterp=Undefined
  Description = green
  Metadata:
    BAND_NAME=green
Band 3 Block=256x256 Type=UInt16, ColorInterp=Undefined
  Description = red
  Metadata:
    BAND_NAME=red
Band 4 Block=256x256 Type=UInt16, ColorInterp=Undefined
  Description = nir
  Metadata:
    BAND_NAME=nir
Band 5 Block=256x256 Type=UInt16, ColorInterp=Undefined
  Description = swir1
  Metadata:
    BAND_NAME=swir1
Band 6 Block=256x256 Type=UInt16, ColorInterp=Undefined
  Description = swir2
  Metadata:
    BAND_NAME=swir2

```

**Figura 3.2:** Información metadatos del mosaico. Esta información fue generada a partir de la aplicación del comando gdalinfo sobre el mosaico.

## Generación Automatizada de Datos de Entrenamiento

La generación automatizada de datos de entrenamiento para la ANN, resultó en 268 firmas espectrales, incluyendo las bandas 2, 3, 4, 5, 6, 7, y además como séptima banda se ha incluido la clasificación BNB obtenida mediante *Random Forest* utilizando SEPAL. De esta forma, se determinaron que de los 784635 píxeles de la escena, existen 268 con firmas espectrales diferentes o puras con una precisión de 0.95. Estas 268 firmas fueron utilizados como datos de entrada, las primeras 6 bandas, y como datos de

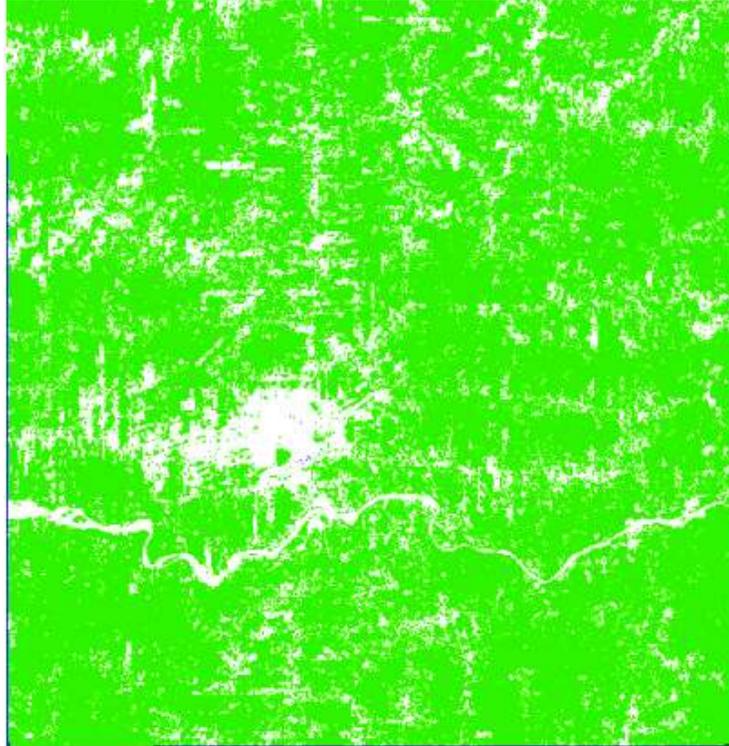
salida en el caso de la séptima banda, para entrenar la ANN de clasificación. en la figura 3.3, se muestran algunos de los resultados obtenidos para los datos de entrenamiento. Las imágenes utilizadas para la generación del mosaico están almacenadas en 8 bits, por lo que el rango de valores de las firmas espectrales varía desde 0 a 255.

```
0:0:0:0:0:0:0
26:131:129:209:11:76:1
161:84:38:40:55:69:1
225:139:84:76:196:130:1
17:104:105:13:234:86:1
50:178:231:176:90:177:2
46:253:40:173:14:182:2
105:26:66:187:166:215:2
204:40:101:80:182:212:2
4:216:7:98:104:224:2
38:171:89:38:18:215:2
23:161:172:0:198:207:2
222:45:49:148:78:248:1
226:38:28:189:170:14:1
9:109:105:219:127:129:1
246:45:34:188:4:2:1
249:58:71:25:55:191:2
19:131:168:98:110:48:2
249:72:68:248:25:171:2
```

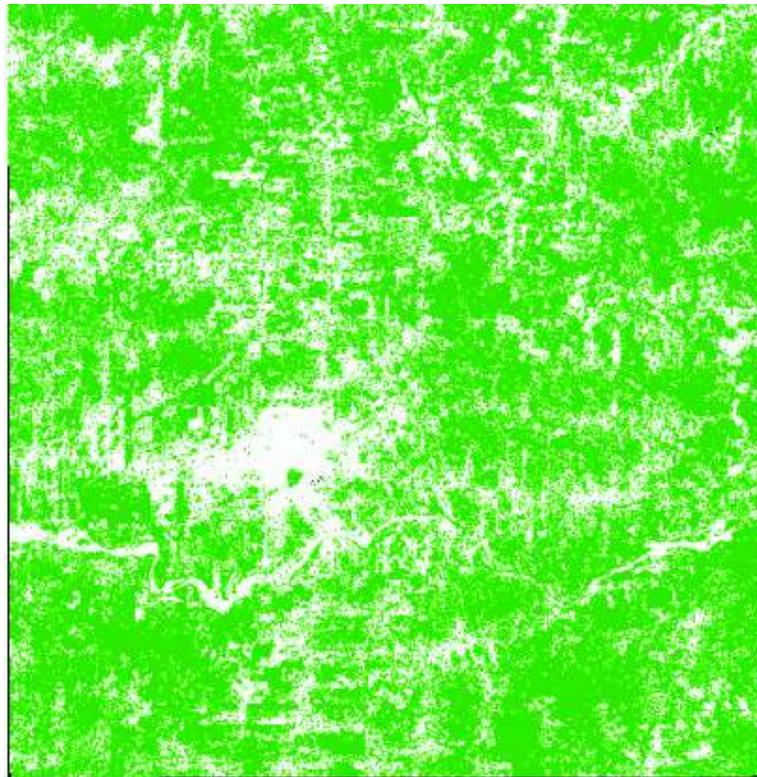
**Figura 3.3:** Listado parcial de firmas espectrales identificadas de forma automatizada para el proceso de entrenamiento de la ANN. 0 es para No-datos, 1 es para bosque, y 2 es para no-bosque.

### **Clasificación mediante ANN**

En la figura 3.4 se muestra el mapa BNB resultante para el área de estudio. Los píxeles verdes pertenecen a cobertura de bosque, los blancos a No-Bosque, y los Azules oscuro a NO-Datos. Los píxeles verdes pertenecen a cobertura de bosque, los blancos a No-Bosque, y negros a NO-Datos. A modo de referencia, en la figura 3.5 se muestra el mapa BNB generado mediante el algoritmo *Random Forest* (RF) usando SEPAL. La comparación preliminar de estos dos resultados da muestras de que el resultado obtenido mediante el algoritmo de ANN es una resultado factible, y que además es ligeramente superior para discriminar BNB en coberturas urbanas y de cuerpos de agua.



**Figura 3.4:** Mapa BNB generado a partir del proceso de clasificación con la ANN. Los píxeles verdes pertenecen a cobertura de bosque, los blancos a No-Bosque, y los Azules oscuro a NO-Datos.



**Figura 3.5:** Mapa BNB generado a partir del algoritmo Random Forest usando SEPAL.

## Validación del Mapa BNB

En el cuadro 3.1, se muestra el diseño de muestreo generado mediante la herramienta de diseño de análisis estratificado de SEPAL para la validación del mapa BNB. En el cuadro 3.1, se puede apreciar que para la clase 1, que representa la clase No-Bosque se han seleccionado 172 píxeles de 165420, lo que representa un tamaño de muestra de 0,103 %, para la clase 2 que representa la clase Bosque se seleccionaron 636 píxeles de 611846 para un tamaño de muestra de 0.103 %, y de la clase 3, que representa la clase No-Datos se seleccionaron 100 píxeles de 7369 para un tamaño de muestra de 1.357 %. Este muestreo ha sido realizado garantizando una significancia muestral de 95 %. En la figura 3.6 se muestra la distribución espacial de los puntos de muestreos para el área de estudio.

**Cuadro 3.1: Resumen del diseño de muestreo para la validación del mapa BNB.**

Clase en el Mapa	Proporcional	Ajustado	Final	Total Píxeles
1	191	172	172	165420
2	708	636	636	611846
3	8	100	100	7369

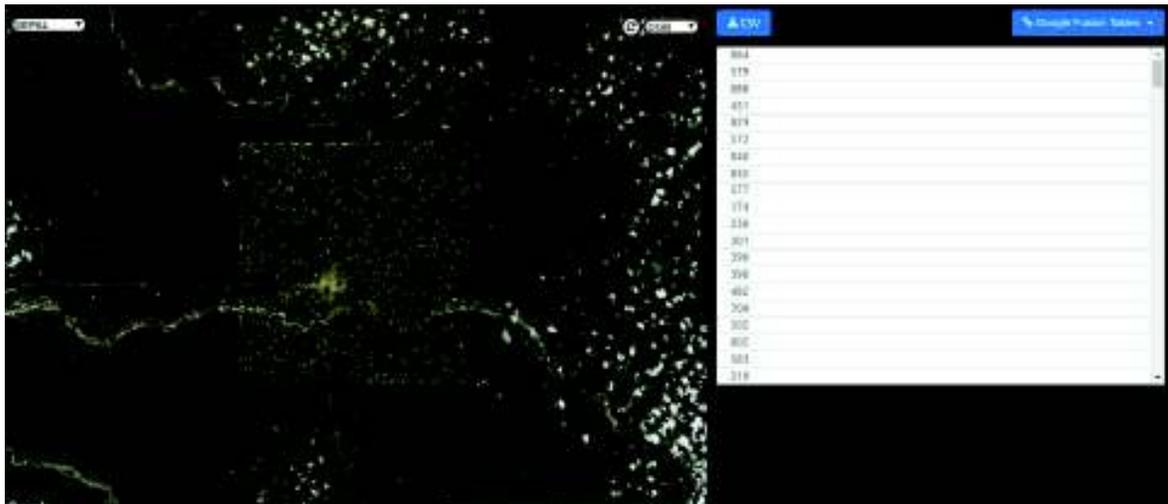
En el cuadro 1; la Clase 1 corresponde a No-Bosque(NB), el 2 corresponde a la clase Bosque (B), y el 3 corresponde a la clase No- Datos(ND)



**Figura 3.6:** Distribución espacial de los puntos de muestreo para el área de estudio

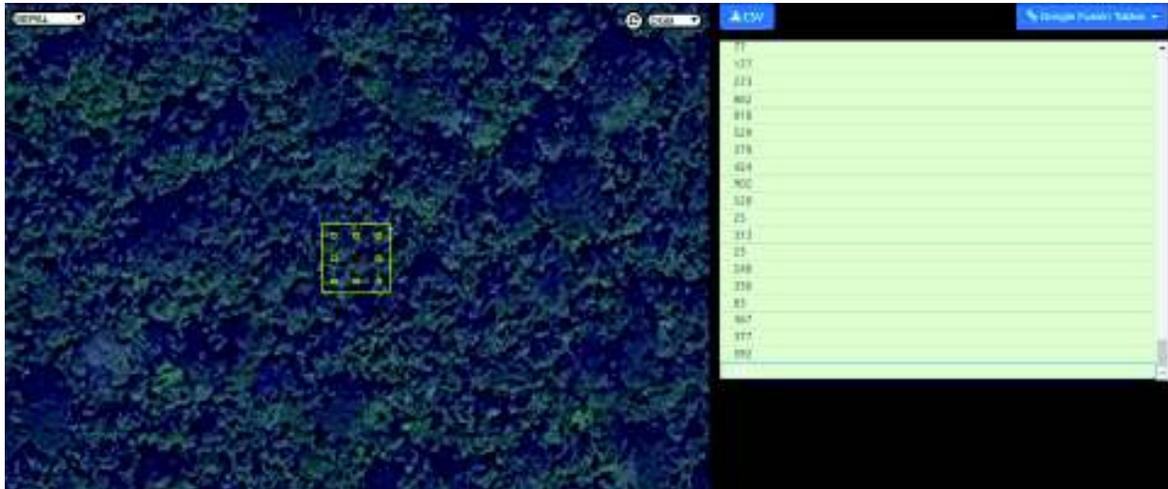
Los puntos de muestreo fueron descargados en un archivo de tipo .cep. Este tipo de archivo recibe su nombre por el acrónimo para *Collect Earth Project*, y es un formato para el levantamiento de puntos de muestreo utilizando imágenes satelitales nativo de la plataforma *Collect Earth* de *Open Foris* de la FAO. Posteriormente se utilizan en el módulo *Collect Earth Online* (CEO) de SEPAL para levantar los datos de validación a partir del muestreo satelital.

Con este fin se generó un proyecto en CEO, para levantar los datos de validación utilizando como base un composito de L8 generado entre 2015 y 2016 del píxel más verde, y utilizando *DigitalGlobe Basemap* (DGB). En la figura 3.7 se muestra la apariencia de la interfaz gráfica de SEPAL/CEO para levantar datos de validación usando imágenes L8 y DGB. Los puntos amarillos, realmente son parcelas de 30x30 metros, y son utilizados para la captura de datos de validación.



**Figura 3.7:** Interfaz gráfica de SEPAL/CEO para el levantamiento de datos de validación usando imágenes satelitales.

En el geovisor se pueden observar en amarillo las diferentes parcelas que conforman el conjunto de muestras. El proceso de captura de datos de validación mediante imágenes satelitales, se lo realizó para los 905 puntos que conforman la muestra y se descargaron en un archivo CSV, para ser utilizados en la herramienta de análisis de SEPAL. La figura 3.8 muestra la parcela de muestreo desde cerca, y al momento de la toma del dato; el usuario debe escoger a que clase corresponde la parcela.



**Figura 3.8:** Visión cercana de una parcela de muestreo.

Se aprecia la dimensión cuadrada de la parcela, con la finalidad de aclarar que los puntos de muestreo representan parcelas de 30x30 metros y no puntos geométricos. Los datos de validación generados mediante la herramienta SEPAL/CEO, contienen las clases generadas del mapa, y también los datos de referencia o validación. Estos datos son utilizados en el módulo de análisis estratificado de SEPAL para generar la matriz de confusión que se muestra en la figura 3.9.

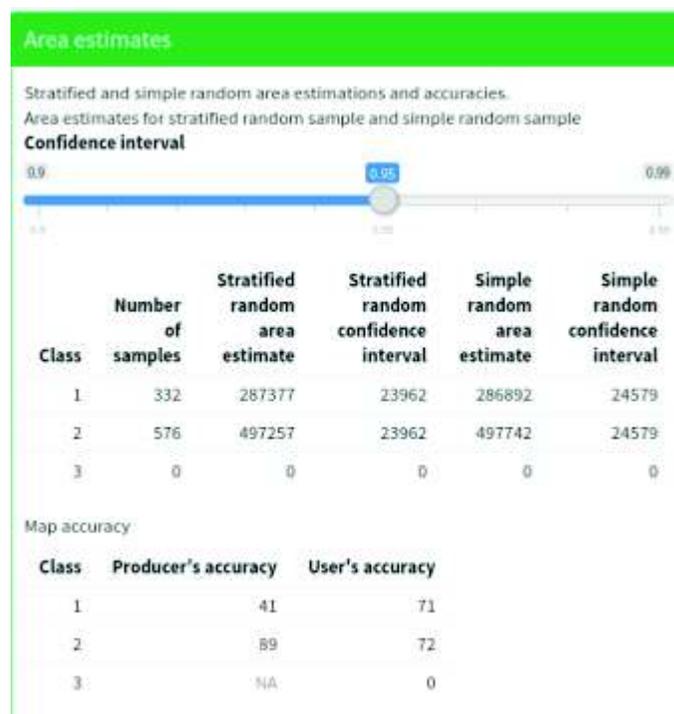
Confusion Matrix			
	1	2	3
1	123	49	0
2	173	463	0
3	36	64	0

**Figura 3.9:** Matriz de confusión para las clases B y NB del mapa BNB generado con la ANN.

En la matriz de confusión se puede apreciar que de las 172 parcelas que pertenecen a la clase 1, que es la clase no bosque, 123 parcelas fueron clasificadas de forma correcta como no-bosque, y 49 fueron clasificadas de forma incorrecta por el algoritmo a asignarlas como bosque. Ninguna parcela de la clase NB fue clasificado como No-datos.

En este orden de ideas, de las 636 parcelas de muestreo de la clase Bosque, 173 parcelas fueron clasificadas como no bosque de forma equivocada, mientras que 463 fueron clasificadas de forma correcta como bosque, y ninguna parcela de esta clase fue clasificada como ND. Vale la pena destacar, que todas las parcelas ND, que se obtuvieron del mapa BNB realizado en SEPAL, fueron clasificados como B o NB, debido a que existían datos en las bases de DGB y GEE, sin embargo estas clasificaciones no tienen incidencia en la estimación de la precisión temática de la clasificación.

El siguiente paso, consiste en utilizar la matriz de confusión de la figura 3.9 para estimar la precisión de clasificación asociada a cada clase. Este procedimiento se realiza de forma automática en SEPAL, y el resultado se muestra en la figura 3.10.



**Figura 3.10:** Resultados del cálculo de precisión del mapa generado con la ANN.

En la figura 3.10 se muestran (i) el intervalo de confianza utilizado para el cálculo de precisión que resultó ser de 0.95, (ii) un resumen sobre las estratificaciones utilizadas para el proceso de cálculo de áreas de las clases, y (iii) los valores kappa para cada una de las clases, tanto para productor como para usuario.

La precisión del productor está relacionado con el hecho de que un píxel del mapa generado este clasificado como clase A, y que este realmente corresponda a la clase A, mientras que la precisión de usuario está relacionada con que un píxel en

la superficie corresponda a la clase A, y que en el mapa también corresponda a la clase A. En este contexto, la figura 4.10, muestra que la precisión de productor del mapa BNB generado mediante la ANN tuvo un índice capa de 0.41 para la clase No-bosque. Por su parte, la precisión de productor para la clase Bosque, muestra un índice kappa de 0.89. En referencia a la estimación de precisión de usuario, las dos precisiones mostraron valores muy similares, al obtener un 0,71 para la clase No-bosque y 0.72 para la clase Bosque.

## **3.2. Discusión**

### **Sobre la generación de mosaicos**

Hasta hace una década, la generación de un mosaico de LANDSAT suponía una serie de retos para su conformación. Empezando por la engorrosa tarea de realizar la descarga o colecta de las imágenes desde servidores dedicados, luego pasar por una etapa de preprocesamiento y calibración que dependiendo del área de estudio, la experticia del equipo humano de procesamiento, la disponibilidad de hardware, entre otros, podían cubrir esta etapa en meses y en algunos casos en años. Y partir de este punto, era cuando podían comenzar con la etapa de procesamiento, o clasificación.

El ejercicio realizado en esta investigación a partir de la plataforma SEPAL, permitió obtener un mosaico L8 del área de estudio, debidamente pre procesado y calibrado, en cuestión de minutos. Este resultado representa un avance prominente en cuanto a la capacidad de preprocesamiento que existe actualmente para el manejo de datos satelitales en comparación con el estado del área hace una década atrás. Este avance relevante ha sido posible debido a múltiples factores, uno de los factores que ha servido de impulso para este desarrollo ha sido liberación de toda la serie histórica LANDSAT, además del acceso gratuito a las colecciones nuevas, también un aumento considerable en las características de hardware para el procesamiento, y el avance científico tecnológico ha permitido avances en técnicas y algoritmos que han mejorado notablemente todas las etapas de procesamiento.

Una opción muy popular a SEPAL es *Google Earth Engine*, de hecho una buena parte de los algoritmos de descarga y procesamiento de SEPAL son traducciones de GEE, que se realizan desde Javascript a Python. Esta tendencia se espera que siga en crecimiento durante los próximos años, ya que estas plataformas con enfoque de Nube han quebrado paradigmas en referencia a las limitaciones que se conocían para el procesamiento, almacenamiento y acceso de datos.

## **Sobre la detección de píxeles de clases puras**

La idea de detectar píxeles de clases puras, se originó por la necesidad de definir píxeles representativos en una escena, sin tener que repetir píxeles correlacionados entre sí. Poder identificar píxeles representativos, permite tomar muestras más pequeñas, pero a la vez más eficientes para el proceso de entrenamiento de una red neuronal artificial.

En este trabajo, se ha utilizado el coeficiente de correlación para descartar pares de píxeles con alta correlación, y de forma automática generar una lista con información espectral asociada a clases puras que faciliten el proceso de entrenamiento de las redes neuronales artificiales. Los resultados obtenidos en este trabajo para los píxeles de clases pura, permitieron entrenar una red neuronal de forma automática, y además generar un mapa BNB del área de estudio. Este método, si bien es ampliamente conocido en el área de procesamiento de señales para la comparación de espectros, en el campo del procesamiento de imágenes puede ser extraordinariamente útil en algoritmos de clasificación y detección de cambios.

## **Sobre la detección de píxeles de clases puras**

El entrenamiento de la Red Neuronal Artificial se llevo a cabo utilizando el algoritmo de segundo orden L-BFGS, disponible en la librería ALGLIB. También se utilizó de manera simultánea la librería OPENNN, porque esta contiene alguna clases para el manejo de datos que termina siendo fuertemente ventajosas. Los pesos y bias obtenidos para la red neuronal artificial se muestran en el apéndice A.

## **Sobre la clasificación de BNB usando la ANN**

El proceso de la producción de la ANN, se llevo a cabo utilizando la librería ALGLIB en lenguaje C++. El resultado obtenido mostró una alta capacidad para detectar dentro de la clase No-bosque a los cuerpos de agua y a las coberturas urbanas. Sin embargo mostro algunas dificultades para distinguir inequívocamente coberturas agrícolas. El tiempo de corrida del script de clasificación no superó el minuto para procesar el mosaico de 867x905 píxeles, lo cual demostró un costo computacional satisfactorio y factible de implementación en escenas LANDSAT enteras.

## **Sobre la validación del mapa BNB**

El análisis de validación del mapa BNB generado mediante la ANN, develó una dificultad para clasificar píxeles de la clase No-bosque, mientras que la clasificación de bosque mostró un alto índice Kappa de 0.89. Se presume que la baja precisión para la clasificación de la clase No-Bosque, puede deberse a la necesidad de aumentar el muestreo de entrenamiento de clases No-bosque utilizado para entrenar el algoritmo *Random Forest*. Esta dificultad es natural, debido a que la clase No-bosque tiene una mayor cantidad de sub-clases como subconjunto. Esto presume un reto en orden de mejorar la calidad de los datos de entrenamiento para la red neuronal.

Los resultados obtenidos son ampliamente satisfactorios, al lograr un 0.89 de precisión para la clase Bosque, y además se ha identificado una oportunidad de mejora del algoritmo al aumentar el muestreo para la clasificación de entrenamiento en la clase No-Bosque.

## 4. CONCLUSIONES

Se ha desarrollado un método que permite generar datos de entrenamiento de forma automatizada, para la clasificación de imágenes LANDSAT 8, a partir del uso del coeficiente de correlación Interpixel. Este enfoque permitió generar una lista de datos de entrenamiento, con la certeza de no incorporar píxeles que posean un coeficiente de correlación igual o superior a 0.95 con cualquier candidato existente dentro del conjunto de datos. El principal aporte de este resultado, ha sido la capacidad para seleccionar de forma óptima los datos de entrenamiento de la red, al incorporar píxeles representativos de las clases puras presentes en la escena.

El proceso de automatización de entrenamiento de la red neuronal artificial, fue posible a partir de la detección de píxeles puros, lo cual permitió realizar una selección automatizada de píxeles para conformar el conjunto de datos de entrenamiento. Es importante destacar, que la ventaja asociada a este proceso de automatización, es que una vez entrenada la red neuronal, se puede utilizar para clasificar bosque no bosque para cualquier conjunto de datos LANDSAT 8 del área de estudio que se desee ingresar. De tal forma, que se suprime la necesidad de generar datos de entrenamiento cada vez que se requiera clasificar, lo que se traduce en un ahorro de tiempo considerable a largo plazo, y además también de disminuye la presencia de errores asociados al sesgo que puede generarse durante el proceso de toma de datos de forma manual.

El mapa Bosque No-bosque generado por la red neuronal artificial, fue validado utilizando SEPAL. Los resultados mostraron un índice kappa de 0.89 para la clasificación y detección de bosques, mientras que para la detección de no bosques el kappa fue de solo 0.41, esto para el caso de precisión de productor. Para mejorar estos resultados se sugiere mejorar el proceso inicial de clasificación mediante el uso de datos de campo. Esto mejoraría considerablemente los datos de entrenamiento a la red neuronal para la clase No-bosque. En cuanto a la precisión de usuario los resultados fueron buenos para ambas clases, obteniendo 0.71 para la clase No-bosque, y 0.72 para la clase Bosque.

En relación a la mejora obtenida en la red neuronal por realizar el proceso de entrenamiento de forma automática, no se obtuvieron evidencias que permitan concluir que la calidad de precisión del resultado final pueda ser mejor que cuando se entrena redes neuronales de forma tradicional, es decir tomando regiones de interés de forma manual de las imágenes y conformando los datos de entrenamiento. Sin embargo, si se notó una reducción importante del tiempo necesario para seleccionar los datos de entrenamiento, y para el entrenamiento propio de la red, como consecuencia del algoritmo de detección de píxeles de clases puras. La red neuronal artificial fue entrenada utilizando como entrada los datos generados a partir de la detección de píxeles de clases puras. El algoritmo de entrenamiento fue el L-BFGS, implementado mediante la librería ALGLIB, y además también se incorporó la librería OPENNN, para utilizar las facilidades que presta para el manejo de grandes datos. La arquitectura de la red neuronal fue de 6 neuronas de entrada, correspondientes a las bandas azul, verde, rojo, infrarrojo cercano, infrarrojo de onda corta 1, e infrarrojo de onda corta 2, 2 capas ocultas, la primera de 10 neuronas y la segunda de 5, y una neurona en la capa de salida correspondiente a la clase Bosque o No bosque que son los posibles resultados.

En referencia a la pregunta de investigación, los resultados obtenidos muestran una alta factibilidad de realizar procesos de clasificación de imágenes LANDSAT, a partir del entrenamiento automatizado de redes neuronales artificiales. Se ha identificado la necesidad de fortalecer la etapa de generación de datos de entrenamiento, ya que estos tienen una fuerte incidencia sobre la precisión temática obtenido con el mapa resultante de la red neuronal artificial. Una futura investigación en este tema, podría abarcar la capacidad de discriminar entre sub-clases, tanto en coberturas de Bosque, como de No-bosque.

## REFERENCIAS BIBLIOGRÁFICAS

- ALGLIB, 2018. Alglib. <http://www.alglib.net/>, accessed: 2018-05-30.
- Bischof, H., Schneider, W., Pinz, A. J., 1992. Multispectral classification of landsat-images using neural networks. *IEEE transactions on Geoscience and Remote Sensing* 30 (3), 482–490.
- Chae, H. S., Kim, S. J., Ryu, J. A., 1997. A classification of multitemporal landsat tm data using principal component analysis and artificial neural network. In: *Geoscience and Remote Sensing, 1997. IGARSS'97. Remote Sensing-A Scientific Vision for Sustainable Development.*, 1997 IEEE International. Vol. 1. IEEE, pp. 517–520.
- Cheng, G., Han, J., & Lu, X. (2017). Remote sensing image scene classification: benchmark and state of the art. *Proceedings of the IEEE*, 105(10), 1865-1883.
- Curetti, M., Bravo, S. G., Arri, G. S., & Mathe, L. (2013). Adjustable tracking algorithm with adaptive template matching. *IEEE Latin America Transactions*, 11(1), 34-39.
- Devin, C., Gupta, A., Darrell, T., Abbeel, P., & Levine, S. (2017, May). Learning modular neural network policies for multi-task and multi-robot transfer. In *Robotics and Automation (ICRA), 2017 IEEE International Conference on* (pp. 2169-2176). IEEE.
- Fang, H., Liang, S., 2003. Retrieving leaf area index with a neural network method: Simulation and validation. *IEEE Transactions on Geoscience and Remote Sensing* 41 (9), 2052–2062.
- FAO, 2018. Sepal. <https://sepal.io/>, accessed: 2018-05-30.
- Feldberg, I., Netanyahu, N., Shoshany, M., 2002. A neural network-based technique for change detection of linear features and its application to a mediterranean region. In: *Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International. Vol. 2. IEEE*, pp. 1195-1197.
- Foody, G., Cutler, M. E., 2002. Remote sensing of biodiversity: using neural networks to estimate the diversity and composition of a bornean tropical rainforest from landsat tm data. In: *Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International. Vol. 1. IEEE*, pp.497–499.
- Gao, Y., Zhang, W., Wang, J., Liu, C., 2007. Lulc classification of landsat- 7 etm+ image from rugged terrain using tc, ca and sofm neural network. In: *Geoscience and Remote Sensing Symposium, 2007. IGARSS 2007. IEEE International. IEEE*, pp. 3490–3493.
- Greco, R. D., Bernadowski, C., & Parker, S. (2018). Using Illustrations to Depict Preservice Science Teachers' Self-Efficacy: A Case Study. *International Journal of Instruction*, 11(2), 75-88.

- Goward, S. N., Williams, D. L., Arvidson, T., Rocchio, L. E., Irons, J. R., Russell, C. A., & Johnston, S. S. (2017). *Landsat's Enduring Legacy: Pioneering Global Land Observations from Space*.
- Guerra, M. (2017). *A comparative study of the empirical relationship in student performance between physics and other stem subjects* (Doctoral dissertation).
- Haykin, S., 1999. *Neural networks. a comprehensive foundation*. Upper Saddle River.
- Hsieh, W. W., 2009. *Machine learning methods in the environmental sciences. neural networks and kernels*. (document)
- Kamata, S.-i., Eason, R., Perez, A., Kawaguchi, E., 1992. A neural network classifier for landsat image data. In: *Pattern Recognition, 1992. Vol. II. Conference B: Pattern Recognition Methodology and Systems, Proceedings., 11th IAPR International Conference on. IEEE*, pp. 573–576.
- Khademi, F., Akbari, M., Jamal, S. M., & Nikoo, M. (2017). Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete. *Frontiers of Structural and Civil Engineering*, 11(1), 90-99.
- Khorasani, A., & Yazdi, M. R. S. (2017). Development of a dynamic surface roughness monitoring system based on artificial neural networks (ANN) in milling operation. *The International Journal of Advanced Manufacturing Technology*, 93(1-4), 141-151.
- Lee, J., Weger, R. C., Sengupta, S. K., Welch, R. M., 1990. A neural network approach to cloudclassification. *IEEE Transactions on Geoscience and Remote Sensing* 28 (5), 846–855.
- Lee, S., Lathrop, R. G., 2006. Subpixel analysis of landsat etm/sup+/using self-organizing map (som) neural networks for urban land cover characterization. *IEEE Transactions on Geoscience and Remote Sensing* 44 (6), 1642–1654.
- Liu, L., Zhang, X., Hu, Y., & Wang, Y. (2017, July). Automatic land cover mapping for Landsat data based on the time-series spectral image database. In *Geoscience and Remote Sensing Symposium (IGARSS), 2017 IEEE International* (pp. 4282-4285). IEEE.
- Bernabe Loranca, M. B., Espinosa Rosales, J. E., & Ramírez, J. (2009). Evaluación de un algoritmo de recocido simulado con superficies de respuestas. *Revista de Matemática: Teoría y Aplicaciones*, 16(1).
- MAE, 2015. *Estadísticos de patrimonio natural*. Publicación Interna.
- Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657.

- Mas, J., Flores, 2008. The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing*, 617–663.
- Mas, J.-F., 2003. An artificial neural networks approach to map land use/cover using landsat imagery and ancillary data. In: *Geoscience and Remote Sensing Symposium, 2003. IGARSS'03. Proceedings. 2003 IEEE International*. Vol. 6. IEEE, pp. 3498–3500.
- Matasci, G., Hermosilla, T., Wulder, M. A., White, J. C., Coops, N. C., Hobart, G. W., ... & Bater, C. W. (2018). Three decades of forest structural dynamics over Canada's forested ecosystems using Landsat time-series and lidar plots. *Remote Sensing of Environment*, 216, 697-714.
- Munoz, E. A., Di Paola, F., Lanfri, M. A., 2015. Advances on rain rate retrieval from satellite platforms using artificial neural networks. *IEEE Latin America Transactions* 13 (10), 3179–3186.
- Neagoe, V., Strugaru, G., 2008. A concurrent neural network model for pattern recognition in multispectral satellite imagery. In: *Automation Congress, 2008. WAC 2008. World*. IEEE, pp. 1–6.
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., Wulder, M. A., 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 148, 42–57.
- OPENNN, 2018. Opennn. <http://www.opennn.net/>, accessed: 2018-05-30.
- Padró, J. C., Pons, X., Aragonés, D., Díaz-Delgado, R., García, D., Bustamante, J., ... & Doktor, D. (2017). Radiometric Correction of Simultaneously Acquired Landsat-7/Landsat-8 and Sentinel-2A Imagery Using Pseudoinvariant Areas (PIA): Contributing to the Landsat Time Series Legacy. *Remote Sensing*, 9(12), 1319.
- Pal, M., 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* 26 (1), 217–222.
- Paola, J. D., Schowengerdt, R. A., 1995. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and remote sensing* 33 (4), 981–996.
- Pelton, J. N., Madry, S., & Camacho-Lara, S. (2017). *Handbook of satellite applications*. Springer Publishing Company, Incorporated.
- Popkin, G. (2017). Commercial space sensors go high-tech. *Nature*, 545(7655), 397-398.
- Rosenblatt, F., 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 386–408.
- Rosenblatt, F., 1962. *Principles of neurodynamics*. New York: Spartan.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986. Learning internal representations by error propagation. *Parallel Distributed Processing*, 318–62.

- Salahova, S., 2007. Remote sensing and gis application for earth observation on the base of the neural networks in aerospace image classification. In: Recent Advances in Space Technologies, 2007. RAST'07. 3rd International Conference on. IEEE, pp. 275–278.
- SEPAL/FAO, 2018. Ceo. <https://sepal.io/ceo/>, accessed: 2018-05-30.
- Solaiman, B., Mouchot, M., Koffi, R., 1994. Multispectral landsat images segmentation using neuralnetworks and multi-experts approach. In: Geoscience and Remote Sensing Symposium, 1994.
- Tibo, A., Frasconi, P., & Jaeger, M. (2017, September). A network architecture for multi-multi-instance learning. In Joint European Conference on Machine Learning and Knowledge Discovery in Databases (pp. 737-752). Springer, Cham.
- Torres, B., & Dubovik, O. (2018, April). Sensitivity tendencies in remote sensing of atmospheric aerosols. In EGU General Assembly Conference Abstracts (Vol. 20, p. 13181).
- USGS, 2018. Usgs landsat platform description. <https://landsat.usgs.gov/landsat-missions-timeline>, accessed: 2018-04-30. (document),
- U.S.G.S. (2018a) URL: <https://landsat.usgs.gov> Page Contact Information: Ask Landsat Page Last Modified: 04/25/18 01:57 pm
- IGARSS'94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation., International. Vol. 4. IEEE, pp. 2109–2111.
- Velloso, M. L. F., de Souza, F. J., Simoes, M., 2002. Improved radiometric normalization for land cover change detection: An automated relative correction with artificial neural network. In: Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International. Vol. 6. IEEE, pp. 3435–3437.
- Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., & Ng, W. T. (2018). How much does multi-temporal Sentinel-2 data improve crop type classification?. *International Journal of Applied Earth Observation and Geoinformation*, 72, 122-130.
- Werbos, P. J., 1974. Beyond regression: new tools for prediction and analysis in the behavioural sciences.
- Widrow, B., Hoff, M. E., 1960. Adaptive switching circuits. IRE WESCON Convention Record, 96–104.
- Wilkinson, G. G. (2005). Results and implications of a study of fifteen years of satellite image classification experiments. *IEEE Transactions on Geoscience and remote sensing*, 43(3), 433-440.
- Xingui, H., Shaohua, X., 2010. Process neural network: Theory and applications. (document),

- Yoshida, T., Omatu, S., 2001. A remotely sensed data separation method with neural networks. In: Geoscience and Remote Sensing Symposium, 2001. IGARSS'01. IEEE 2001 International. Vol. 7. IEEE, pp. 3300–3302.
- Zhao, D., Zhang, W., Shijin, X., 2007. A neural network algorithm to retrieve nearsurface air temperature from landsat etm+ imagery over the hanjiang river basin, china. In: Geoscience and Remote Sensing Symposium, 2007. IGARSS 2007. IEEE International. IEEE, pp. 1705–1708.
- Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: a comprehensive review and list of resources. IEEE Geoscience and Remote Sensing Magazine, 5(4), 8-36.

## **ANEXOS**

## Anexo A – Pesos y Bias de la red neuronal artificial

### A.1. Bias

0 0 0 0 0 0 -0.54738 -5.63504 12.3045 0.919219 10.6348 -1.53914 14.367 -0.656389  
0.794236 0.334863 -18.105 -2.76234 -14.7223 8.58636 12.5046 -12.0881

### A.2. Pesos

-0.22488 2.15133 -1.79687 0.0279349 -8.9611 0.357517 -0.029957 -3.17414 0.336468 -  
1.66032 0.0431508 -2.72648 8.38058 0.0332804

-2.49403 -0.00765092 1.51777 1.17606 0.0120331 1.81763 -1.9771 4.6716 -24.5374  
2.05999 0.204186 0.570831 -2.35838 3.80634

5.82389 -12.6362 8.95723 -6.39566 36.6919 -7.97499 -0.0760522 1.0932 -3.8423 -  
5.07505 -26.6597 24.5657 -8.02767 7.04979

-27.8177 6.35554 -2.49723 -10.239 16.2901 0.53196 34.9603 -20.4918 2.66783 -5.73217  
8.74089 -1.54727 11.401 18.5149 -10.313

2.39632 -19.3008 11.9833 -0.71113 3.97433 0.7158 0.36191 -7.1769 -7.89573 -12.5725 -  
0.961627 4.86517 -4.40027 6.28332 -7.14638

-2.87576 -11.3584 2.62461 -13.0766 -8.43644 6.25091 -12.0944 2.2592 -12.7654  
11.6878 -25.4348 2.51381 -1.13637 14.5175 -15.5655

-0.741976 -18.9604 4.46285 -2.2319 2.14293 12.3539 3.09345 -8.5772 -0.716009  
0.72028 -0.762182 -0.142405 -0.170845 9.95668

-9.37292 -9.43335 -0.265456 0.8003 -0.346609 0.273245 8.23575 -0.252202 -0.716414  
0.411087 -0.448775 34.6913 -6.12984 -2.24207

0.465411 -0.395806 -19.2993 4.68124 1.95376 31.1734 31.9847 -13.7691 -14.9136  
12.3343 0 0 0 0 0

0 0 0 0 0 0 0 0 0