



UNIVERSIDAD NACIONAL DE COLOMBIA

# Clasificación de zonas agrícolas en Colombia por medio de imágenes satelitales con redes neuronales profundas

Sebastián Felipe Álvarez Montoya

Universidad Nacional de Colombia  
Facultad de Ingeniería  
Departamento de Ingeniería de Sistemas e Industrial  
Bogotá, Colombia  
2023



# Clasificación de zonas agrícolas en Colombia por medio de imágenes satelitales con redes neuronales profundas

Sebastián Felipe Álvarez Montoya

Trabajo de grado presentado como requisito parcial para optar al título de:  
**Magister en Ingeniería de Sistemas y Computación**

Director(a):

Fabio Augusto González Osorio, Ph.D.

Departamento de Ingeniería de Sistemas e Industrial

Codirector(a):

Raúl Ramos Pollán, Ph.D.

Departamento de Ingeniería de Sistemas

Universidad de Antioquia

Línea de Investigación:

Computación aplicada - Sistemas inteligentes

Grupo de Investigación:

MindLab

Universidad Nacional de Colombia

Facultad de Ingeniería

Departamento de Ingeniería de Sistemas e Industrial

Bogotá, Colombia

2023



## Dedicatoria

A Dios, mis padres, mi hermana y mis hermanos que me guiaron y apoyaron durante todo lo que he conseguido.



# Agradecimientos

Quiero expresar mi profundo agradecimiento a Dios, fuente inagotable de fortaleza y guía en este viaje académico. A mi amada familia, en especial a mi querida madre, Yolima Montoya, a mi padre, Nestor Alvarez, y mis hermanos quienes siempre han sido mi mayor apoyo, brindándome su amor incondicional y teniendo fe en cada paso que he dado. Agradezco sinceramente a mis respetados profesores, Fabio González y Raúl Ramos, por su invaluable orientación, paciencia y tolerancia durante mi proceso de aprendizaje. También, mi gratitud se extiende a la Universidad Nacional de Colombia, por proporcionar el ambiente propicio para mi desarrollo académico y personal. Este logro es resultado del apoyo conjunto de todos, y estoy profundamente agradecido por cada muestra de aliento y confianza a lo largo de este recorrido.





# Resumen

Clasificación de zonas agrícolas en Colombia por medio de imágenes satelitales con redes neuronales profundas.

Las imágenes satelitales son una fuente valiosa de información sobre la tierra, que nos permiten analizar su superficie y las estructuras creadas por el ser humano, como la cobertura del suelo, la vegetación, la topografía y las áreas urbanas. En las últimas décadas, se han producido avances significativos para mejorar la calidad de estas imágenes, incluyendo el uso de imágenes multiespectrales de alta resolución que brindan una descripción más precisa de los objetos y su entorno. Además, se han desarrollado modelos de aprendizaje profundo utilizando estas imágenes para la clasificación y segmentación de objetos; principalmente en ámbitos urbanos y climáticos, con pocos modelos enfocados en la agricultura y los cultivos. Sin embargo, dado que Colombia es un país con una vasta extensión de tierra dedicada a la agricultura, es importante desarrollar modelos de aprendizaje profundo para clasificar y predecir la distribución de estas áreas, lo que brinda información valiosa tanto al gobierno como a los agricultores. En este estudio se utilizaron imágenes de los satélites Sentinel 2 tomadas en el año 2020, que fueron preprocesadas y georreferenciadas. Luego se determinó la cantidad de área porcentual de zonas agrícolas en cada imagen, que es la variable que permite la etiquetación de las mismas, como *Frontera agrícola* o *No* en la tarea de clasificación. Se utilizaron redes neuronales convolucionales profundas, incluyendo MobileNet, ResNet50, Inception v3 y VGG 19, con una entrada de resolución de imagen de 100 x 100. De igual manera, se utilizaron modelos con arquitecturas más simples para hacer una comparación adicional entre estos tipos de modelos; los cuales se dividieron como modelos *shallow convolutional* y modelos basados en *Quantum Kernel Mixtures*. Donde se observan mejores resultados utilizando estas arquitecturas más simples para esta tarea de clasificación con este tipo de imágenes. En resumen, este estudio demuestra cómo el uso de modelos de aprendizaje profundo junto con imágenes satelitales de alta resolución puede proporcionar información valiosa para la agricultura, permitiendo una mejor comprensión y planificación de las áreas de cultivo en Colombia.

**Palabras clave:** Imágenes satelitales, zonas agrícolas en Colombia, aprendizaje por transferencia, redes neuronales profundas.

# Abstract

Classification of agricultural areas in Colombia through satellite images with deep neural networks.

Satellite images constitute a valuable source of information about the Earth, enabling the analysis of its surface and human-created structures, such as land cover, vegetation, topography, and urban areas. Significant advancements have been made in recent decades to enhance the quality of these images, including the utilization of high-resolution multispectral images that provide a more precise description of objects and their surroundings. Additionally, deep learning models have been developed using these images for object classification and segmentation, primarily in urban and climatic contexts, with limited focus on agriculture and crops. Given that Colombia encompasses vast agricultural lands, it is crucial to develop deep learning models for classifying and predicting the distribution of these areas, offering valuable insights to both the government and farmers. This study utilized images from Sentinel 2 satellites captured in the year 2020, which underwent preprocessing and georeferencing. The percentage of agricultural area in each image was then determined, serving as the variable for labeling them as either *agricultural land* or *No* in the classification task. Deep convolutional neural networks, including MobileNet, ResNet50, Inception v3, and VGG 19, were employed with an input image resolution of 100 x 100. Similarly, models with simpler architectures were used for additional comparison, categorized as *shallow convolutional* models and models based on *Quantum Kernel Mixtures*. Interestingly, superior results were observed using these simpler architectures for this classification task with high-resolution satellite images. In summary, this study demonstrates how the combination of deep learning models and high-resolution satellite images can provide valuable information for agriculture, facilitating a better understanding and planning of cultivation areas in Colombia.

**Keywords:** Satellite images, agricultural zones in Colombia, transfer learning, deep neural networks

Este Trabajo Final de maestría fue calificado en marzo de 2024 por el siguiente evaluador:

Jean Pierre Charalambos Hernandez PhD.  
Profesor Facultad de Ingeniería  
Universidad Nacional de Colombia

# Contenido

<b>Agradecimientos</b>	<b>VII</b>
<b>Resumen</b>	<b>IX</b>
<b>Lista de figuras</b>	<b>XIII</b>
<b>Lista de tablas</b>	<b>XV</b>
<b>1 Introducción</b>	<b>2</b>
1.1 Planteamiento del problema . . . . .	4
1.2 Justificación . . . . .	5
1.3 Objetivos . . . . .	6
1.3.1 Objetivo general . . . . .	6
1.3.2 Objetivos específicos . . . . .	6
1.4 Principales contribuciones . . . . .	6
<b>2 Antecedentes y trabajos relacionados</b>	<b>7</b>
2.1 Antecedentes . . . . .	7
2.1.1 Redes neuronales convolucionales . . . . .	7
2.1.2 Métodos aplicados antes de las redes convolucionales . . . . .	8
2.1.3 Métodos aplicados después de las redes convolucionales . . . . .	9
2.2 Trabajos relacionados 2017-2021 . . . . .	11
2.2.1 Bases de datos . . . . .	11
2.2.2 Aplicaciones en los años de referencia . . . . .	12
<b>3 Conjunto de datos y asignación de etiquetas</b>	<b>15</b>
3.1 Imágenes satelitales . . . . .	15
3.1.1 Satélite Sentinel 2 . . . . .	15
3.1.2 Biblioteca geotiles . . . . .	16
3.2 Asignación de etiquetas de área agrícola en las imágenes satelitales . . . . .	16
3.2.1 Mapa de frontera agrícola de Colombia . . . . .	16
3.2.2 Construcción de las imágenes satelitales etiquetadas . . . . .	18
3.2.3 Análisis exploratorio . . . . .	19
3.2.4 Construcción de los conjuntos de datos . . . . .	21

---

<b>4</b>	<b>Tarea de clasificación</b>	<b>23</b>
4.1	Arquitectura Propuesta . . . . .	23
4.1.1	Modelos de transferencia . . . . .	23
4.1.2	modelos <i>shallow convolutional</i> . . . . .	29
4.1.3	Modelos <i>Quantum Kernel Mixtures</i> . . . . .	32
4.2	Configuración experimental . . . . .	35
4.3	Resultados sobre el conjunto Prueba 1 . . . . .	37
4.4	Resultados sobre el conjunto Prueba 2 . . . . .	40
4.5	Discusión . . . . .	43
<b>5</b>	<b>Tarea de regresión</b>	<b>44</b>
5.1	Arquitectura Propuesta . . . . .	44
5.1.1	Modelos de transferencia . . . . .	44
5.1.2	modelos <i>shallow convolutional</i> . . . . .	48
5.1.3	Modelos <i>Quantum Kernel Mixtures</i> . . . . .	51
5.2	Configuración experimental . . . . .	55
5.3	Resultados sobre el conjunto Prueba . . . . .	58
5.4	Discusión . . . . .	64
<b>6</b>	<b>Conclusiones y trabajo futuro</b>	<b>65</b>
	<b>Bibliografía</b>	<b>67</b>

# Lista de Figuras

1-1	Tipos de imágenes satelitales. Tomadas de Google. . . . .	2
1-2	Niveles de clasificación para las imágenes satelitales. Tomado de [4]. . . . .	3
2-1	Red convolucional para el proceso de una imagen. Tomado de [9]. . . . .	8
2-2	Retos de la clasificación de imágenes satelitales. Tomado de [4]. . . . .	10
3-1	Mapa de Colombia identificando la Frontera y No Frontera agrícola. Elaboración propia. . . . .	17
3-2	Áreas de interés. Elaboración propia. . . . .	18
3-3	Conjunto de datos de las áreas de interés del satélite Sentinel 2 con su respectiva etiqueta para la tarea de clasificación. Elaboración propia. . . . .	19
3-4	Análisis de la Frontera agrícola en la primera área de interés. Elaboración propia. . . . .	20
3-5	Análisis de la Frontera agrícola en la segunda área de interés. Elaboración propia. . . . .	20
4-1	Arquitectura general de los modelos de transferencia para la tarea de clasificación. . . . .	24
4-2	Arquitectura original del modelo ResNet50. Tomado de [10]. . . . .	25
4-3	Arquitectura original del modelo VGG 19. Tomado de [31]. . . . .	26
4-4	Arquitectura original del modelo MobileNet. Tomado de [13]. . . . .	27
4-5	Arquitectura original del modelo Inception V3. Tomado de [32]. . . . .	28
4-6	Capas de paralelo de Inception. Tomado de [32]. . . . .	28
4-7	Arquitectura general de los modelos <i>shallow convolutional</i> para la tarea de clasificación. . . . .	29
4-8	Arquitectura general de los modelos de <i>Quantum Kernel Mixtures</i> para la tarea de clasificación. . . . .	32
4-9	Visualización de las imágenes para los modelos de transferencia y Quantum Kernel Mixtures para la tarea de clasificación de imágenes satelitales. Elaboración propia. . . . .	36
4-10	Visualización de las imágenes para los modelos shallow convolutional para la tarea de clasificación de imágenes satelitales. Elaboración propia. . . . .	36
4-11	Curvas ROC de los modelos de transferencia para el primer conjunto de prueba en la tarea de clasificación. . . . .	37

4-12	Curvas ROC de los modelos <i>shallow convolutional</i> para el primer conjunto de prueba en la tarea de clasificación. . . . .	38
4-13	Curvas ROC de los modelos <i>Quantum Kernel Mixtures</i> para el primer conjunto de prueba en la tarea de clasificación. . . . .	38
4-14	Curvas ROC de los modelos de transferencia para el segundo conjunto de prueba en la tarea de clasificación. . . . .	40
4-15	Curvas ROC de los modelos <i>shallow convolutional</i> para el segundo conjunto de prueba en la tarea de clasificación. . . . .	41
4-16	Curvas ROC de los modelos <i>Quantum Kernel Mixtures</i> para el segundo conjunto de prueba en la tarea de clasificación. . . . .	41
5-1	Arquitectura general de los modelos de transferencia para la tarea de regresión.	45
5-2	Arquitectura general de los modelos <i>shallow convolutional</i> para la tarea de regresión. . . . .	49
5-3	Arquitectura general de los modelos de <i>Quantum Kernel Mixtures</i> para la tarea de regresión. . . . .	52
5-4	Visualización de las imágenes utilizadas para el entrenamiento, validación y prueba de los modelos de regresión. Elaboración propia. . . . .	56
5-5	Mapa de calor del conjunto de prueba en función del área de frontera agrícola. Elaboración propia. . . . .	57
5-6	Histograma del conjunto de prueba en función del área de frontera agrícola. Elaboración propia. . . . .	57
5-7	Curvas ROC de los modelos de transferencia para el conjunto de prueba en la tarea de regresión. . . . .	58
5-8	Curvas ROC de los modelos <i>shallow convolutional</i> para el conjunto de prueba en la tarea de regresión. . . . .	59
5-9	Curvas ROC de los modelos <i>Quantum Kernel Mixtures</i> para el conjunto de prueba en la tarea de regresión. . . . .	59
5-10	Reconstrucción de la zona agrícola de prueba con los modelos de transferencia	60
5-11	Reconstrucción de la zona agrícola de prueba con los modelos <i>shallow convolutional</i> . . . . .	61
5-12	Reconstrucción de la zona agrícola de prueba con los modelos <i>Quantum Kernel Mixtures</i> . . . . .	62

# Lista de Tablas

<b>2-1</b>	Bases de datos públicamente disponibles para clasificación de imágenes satelitales. Tomado de [4]. . . . .	12
<b>3-1</b>	Distribución de las imágenes satelitales de ambos conjuntos para la tarea de clasificación. . . . .	21
<b>3-2</b>	Distribución de las imágenes satelitales de ambos conjuntos para la tarea de regresión. . . . .	22
<b>4-1</b>	Arquitectura del modelo ResNet50 para la tarea de clasificación de imágenes satelitales. . . . .	25
<b>4-2</b>	Arquitectura del modelo VGG 19 para la tarea de clasificación de imágenes satelitales. . . . .	26
<b>4-3</b>	Arquitectura del modelo MobileNet para la tarea de clasificación de imágenes satelitales. . . . .	27
<b>4-4</b>	Arquitectura del modelo Inception V3 para la tarea de clasificación de imágenes satelitales. . . . .	29
<b>4-5</b>	Arquitectura del modelo shallow convolutional 1 para la tarea de clasificación de imágenes satelitales. . . . .	30
<b>4-6</b>	Arquitectura del modelo shallow convolutional 2 para la tarea de clasificación de imágenes satelitales. . . . .	30
<b>4-7</b>	Arquitectura del modelo shallow convolutional 3 para la tarea de clasificación de imágenes satelitales. . . . .	31
<b>4-8</b>	Arquitectura del modelo shallow convolutional 4 para la tarea de clasificación de imágenes satelitales. . . . .	31
<b>4-9</b>	Hiperparámetros del modelo Quantum Kernel Mixtures 1 para la tarea de clasificación de imágenes satelitales. . . . .	33
<b>4-10</b>	Hiperparámetros del modelo Quantum Kernel Mixtures 2 para la tarea de clasificación de imágenes satelitales. . . . .	33
<b>4-11</b>	Hiperparámetros del modelo Quantum Kernel Mixtures 3 para la tarea de clasificación de imágenes satelitales. . . . .	34
<b>4-12</b>	Hiperparámetros del modelo Quantum Kernel Mixtures 4 para la tarea de clasificación de imágenes satelitales. . . . .	34
<b>4-13</b>	Hiperparámetros del modelo Quantum Kernel Mixtures 5 para la tarea de clasificación de imágenes satelitales. . . . .	35



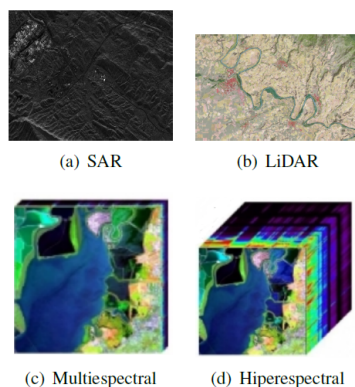
---

<b>4-14</b> Hiperparámetros del modelo Quantum Kernel Mixtures 6 para la tarea de clasificación de imágenes satelitales. . . . .	35
<b>4-15</b> Resultados sobre el conjunto de prueba 1 con los 14 modelos de estudio en la tarea de clasificación. . . . .	39
<b>4-16</b> Resultados sobre el conjunto de prueba 2 con los 14 modelos de estudio en la tarea de clasificación. . . . .	42
<b>5-1</b> Arquitectura del modelo ResNet50 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	46
<b>5-2</b> Arquitectura del modelo VGG 19 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	47
<b>5-3</b> Arquitectura del modelo MobileNet para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	47
<b>5-4</b> Arquitectura del modelo Inception V3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	48
<b>5-5</b> Arquitectura del modelo shallow convolutional 1 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	49
<b>5-6</b> Arquitectura del modelo shallow convolutional 2 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	50
<b>5-7</b> Arquitectura del modelo shallow convolutional 3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	50
<b>5-8</b> Arquitectura del modelo shallow convolutional 4 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	51
<b>5-9</b> Hiperparámetros del modelo Quantum Kernel Mixtures 1 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	52
<b>5-10</b> Hiperparámetros del modelo Quantum Kernel Mixtures 2 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	53
<b>5-11</b> Hiperparámetros del modelo Quantum Kernel Mixtures 3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	53
<b>5-12</b> Hiperparámetros del modelo Quantum Kernel Mixtures 4 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	54
<b>5-13</b> Hiperparámetros del modelo Quantum Kernel Mixtures 5 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	54
<b>5-14</b> Hiperparámetros del modelo Quantum Kernel Mixtures 6 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales. . . . .	55
<b>5-15</b> Resultados sobre el conjunto de prueba con los 14 modelos de estudio en la tarea de regresión. . . . .	63

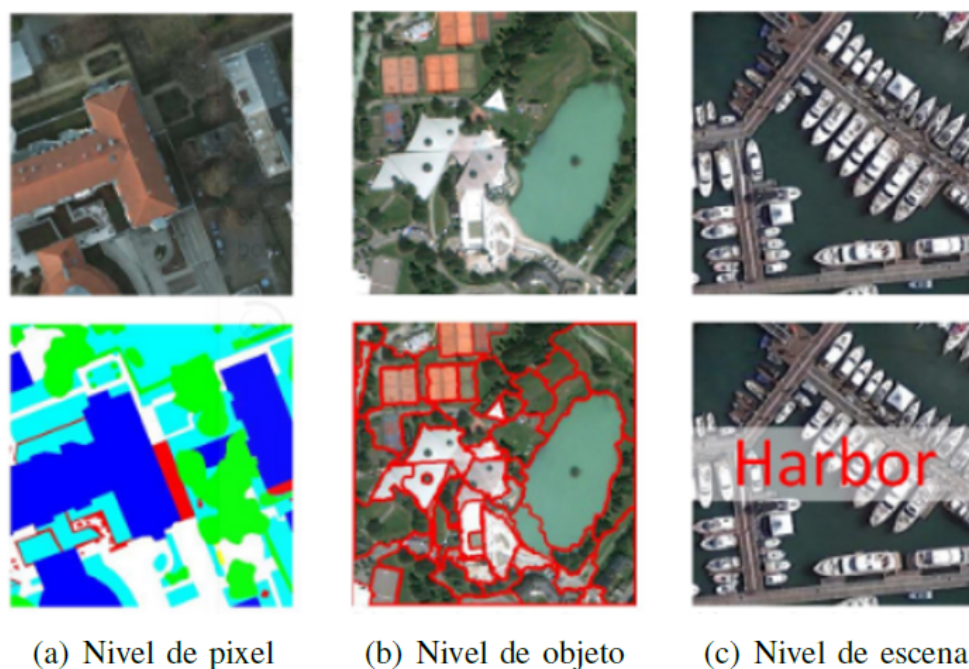
# 1 Introducción

Las imágenes satelitales son una valiosa fuente de información sobre la Tierra, ya que nos permiten analizar su superficie y las estructuras creadas por el ser humano [4]. En las últimas décadas, se han realizado importantes avances para obtener imágenes satelitales de mayor calidad que brinden información más detallada para su análisis y clasificación. Para ello, se utilizan cuatro tipos de imágenes: detección de luz y rango (LiDAR), radar de apertura sintética (SAR), multiespectral (MS) e hiperespectral (HS) [12, 38] (Figura 1-1). Las imágenes LiDAR proporcionan información sobre la elevación, altura y forma de los objetos con respecto al sensor [38]. Las imágenes SAR contienen información de texturas, forma y altura de los objetos, y debido al fenómeno de retrodispersión, se pueden obtener imágenes en cualquier momento del día, en cualquier clima y pueden atravesar las nubes [2, 20]. Por otro lado, las imágenes MS ofrecen una mejor descripción de los objetos y su entorno debido a su alta resolución, lo que permite un mejor entendimiento espacial de lo que se observa en la imagen [39, 46]. Finalmente, las imágenes HS presentan un mayor número de bandas espectrales y son continuas, lo que proporciona información valiosa para la clasificación y segmentación de objetos [38].

Puesto que se tiene una variedad de tipos de imágenes satelitales, las aplicaciones que se han mostrado en los últimos cinco años son: identificación y clasificación de especies de bosques [14], monitoreo y clasificación de campos de cultivos [30, 17], clasificación y estimación de intensidad de ciclones tropicales [43], clasificación del uso del suelo o cobertura del suelo



**Figura 1-1:** Tipos de imágenes satelitales. Tomadas de Google.



**Figura 1-2:** Niveles de clasificación para las imágenes satelitales. Tomado de [4].

[48, 11, 6, 27], clasificación de hielo marino [8], clasificación de humedales [15], identificación y clasificación de deslizamientos de tierras [25], detección de erupciones volcánicas [26], planeación y manejo urbano [16, 40, 42], clasificación de nubes y de sus sombras [34], entre otras aplicaciones.

Adicionalmente, la tarea de clasificación de las imágenes satelitales se ha abordado de tres formas diferentes: a nivel de pixel, a nivel de objeto y a nivel de escena [4, 34, 28] (Figura 1-2). La clasificación a nivel de pixel, también llamada segmentación semántica, implica etiquetar cada pixel con una clase. Sin embargo, en los inicios de los años 2000, había insatisfacción con la baja resolución de las imágenes satelitales y las limitaciones que esto generaba [4, 34, 28, 41]. Debido a esto, surgió la clasificación a nivel de objeto, que busca determinar los contornos de cada objeto dentro de la imagen para clasificarlos en una clase. A pesar de ello, la clasificación a nivel de objeto no presentaba una gran precisión y resolución [4, 28]. Por lo tanto, a partir de la década de 2010, la clasificación a nivel de escena ha tomado un gran interés en la investigación. Este nivel de clasificación implica etiquetar toda la imagen, centrándose en el objeto más relevante para la clasificación [4, 28, 41]. En la última década, ha habido un gran interés académico en los tres niveles de clasificación debido al avance tecnológico en la captura de imágenes satelitales.

Las entidades gubernamentales de Colombia definieron la *frontera agrícola* como la gestión e

inversiones del sector agropecuario y de desarrollo rural, con el fin de promover el uso eficiente del suelo rural agropecuario, el ordenamiento productivo y social de la propiedad rural, y el fortalecimiento de la productividad y competitividad de las actividades agropecuarias [1]. Asimismo, contribuye a estabilizar y disminuir la pérdida de ecosistemas de importancia ambiental [1]. Debido a esto, su monitoreo y control es importante ya que contribuye a un uso más sostenible de las zonas rurales, protegiendo la biodiversidad de tal forma que no se ocasione una disminución o degradación de los atributos básicos de composición, estructura y función del suelo [1]. Adicionalmente, permite orientar un proceso planificado para el uso y los procesos de regularización de la tierra [1].

Por consiguiente, es importante crear modelos de redes neuronales profundas para la clasificación de imágenes satelitales en la agricultura de Colombia, ya que esta tarea contribuye a un mejor control y manejo de las tierras para este fin [30, 17]. Además, el uso de imágenes satelitales proporciona información valiosa sobre la dinámica del uso del suelo agrícola durante el año [48]. Por lo tanto, en este trabajo se propone crear un modelo de red neuronal profunda para clasificar zonas agrícolas en Colombia utilizando imágenes del satélite Sentinel 2. Además, se utiliza el mapa de la frontera agrícola de Colombia del año 2020, el cual puede descargarse de manera gratuita del sistema de información para la planificación rural agropecuaria (SIPRA).

## 1.1. Planteamiento del problema

En [29] se menciona que la interpretación de las imágenes satelitales es una difícil tarea debido a la complicada información que hay en éstas. Esto se observa para la clasificación e identificación de los cultivos [30, 17], donde se encuentra gran dificultad para la separabilidad de clases. Debido a que, las imágenes satelitales presentan diferentes resoluciones espaciales, rotaciones y los sensores operan a diferentes alturas variando las escalas, los ángulos y el nivel de detalle de las imágenes [4, 45]. Por tanto, es importante realizar un modelo para Colombia, un país que cuenta con el 34,7% de su territorio apto para zonas agrícolas<sup>1</sup>, que identifique y clasifique las zonas agrícolas para el control y mantenimiento de los cultivos. Esto permitirá al gobierno y a los campesinos planificar mejor la utilización de la tierra para los cultivos, lo que conlleva a mejorar la productividad. La identificación y clasificación de la frontera agrícola es crucial para estabilizar y disminuir la pérdida de ecosistemas importantes, promover el uso eficiente del suelo, fortalecer la productividad y competitividad, orientar mejor la formulación de políticas públicas, disminuir la degradación de los bosques, la deforestación, la pérdida de fertilidad del suelo, la diversidad biológica, proteger el paisaje forestal, la calidad del agua y el desarrollo productivo competitivo [1]. Debido a que, se pueden descargar imágenes satelitales del Sentinel 2 del año 2020, se plantea un modelo de

---

<sup>1</sup>Ver: <https://sipra.upra.gov.co/>

aprendizaje supervisado al realizar un preprocesamiento a estas imágenes, y lo que conlleva a la siguiente pregunta:

*¿De qué forma se puede aprovechar la información de las imágenes satelitales para la clasificación de la zona agrícola de Colombia por medio de una red neuronal profunda?*

## 1.2. Justificación

Las imágenes satelitales proveen una gran cantidad de información sobre la superficie terrestre [4], lo que ha permitido realizar diversos análisis y estudios, como la clasificación de bosques [14], cultivos [30], usos del suelo [48], la intensidad de ciclones [43], la detección de deslizamientos de tierra [25], erupciones volcánicas [26], entre otros. Sin embargo, la complejidad de esta tarea se debe en parte a las variaciones de escala y orientación que presentan las imágenes debido a la altura y ángulo de operación de los sensores de los satélites y aviones que las toman. Esto hace que la correcta separación de las etiquetas para su clasificación sea un proceso complejo [4]. Otro factor que dificulta la clasificación de las imágenes satelitales es la limitada cantidad de imágenes etiquetadas que reducen la generalización y correcta separación e identificación de los objetos a clasificar, lo que puede conllevar a errores [11, 45, 35]. Aunque se han desarrollado diversas metodologías para la clasificación de imágenes satelitales, aún falta desarrollar un modelo que pueda generalizar eficazmente esta tarea [4, 12, 11]. Esto permitiría clasificar las imágenes satelitales en tiempo real [30], lo que sería de gran utilidad para dar alerta temprana para desastres naturales, un mejor manejo urbano y un control y mantenimiento de los cultivos [14, 48, 25].

La clasificación y manejo de la cobertura del suelo a partir de las imágenes satelitales brinda información importante sobre la dinámica de ésta, lo que puede contribuir a la disminución de la deforestación y la expansión agrícola no deseada<sup>2</sup> <sup>3</sup>. Además, se pueden determinar índices de vegetación que sirven para evaluar el desarrollo agrícola, el bienestar de los bosques y selvas, y la calidad y cantidad de la vegetación<sup>4</sup>.

En Colombia, el gobierno cuenta con un mapa de frontera agrícola que se actualizará cada vez que se considere necesario debido al tiempo y los recursos humanos necesarios para su realización[1]. La aplicación de redes neuronales profundas en esta tarea de clasificación puede contribuir a una actualización más frecuente y sin tanto costo, lo que conlleva a un

---

<sup>2</sup>European Space Agency. Climate assessment report 1.0, 2015. <https://www.esa-landcover-cci.org/?q=documents#>

<sup>3</sup>European Space Agency. User requirements document, 2011. <https://www.esa-landcover-cci.org/?q=documents#>

<sup>4</sup>European Space Agency. Detailed processing model, 2013. <https://www.esa-landcover-cci.org/?q=documents#>

mejor control y manejo de las tierras en el país.

## 1.3. Objetivos

### 1.3.1. Objetivo general

Desarrollar un modelo de red neuronal profunda para clasificar de manera automática las zonas agrícolas de Colombia a partir de imágenes satelitales.

### 1.3.2. Objetivos específicos

- Construir un conjunto de datos de imágenes satelitales anotados con información agrícola georreferenciada.
- Definir la tarea de clasificación alineada con el problema y diferentes arquitecturas de redes neuronales para resolverla.
- Implementar las arquitecturas propuestas y el flujo de trabajo experimental al conjunto de datos construida.
- Evaluar el desempeño de las arquitecturas propuestas para la clasificación de zonas agrícolas en Colombia.

## 1.4. Principales contribuciones

En este trabajo, se presenta una metodología para clasificar zonas agrícolas en imágenes satelitales de Colombia. Las principales contribuciones de este estudio son las siguientes:

- Etiquetado de un conjunto de imágenes satelitales de Colombia a partir del área porcentual de frontera agrícola dentro de las imágenes. Esto teniendo en cuenta un pre-procesamiento georreferenciado y el mapa de Colombia del SIPRA.
- Un modelo de clasificación binaria de una imagen satelital como *Frontera* o *No Frontera*, que se entrena con el conjunto de datos construido en este trabajo.
- Un modelo de predicción del área porcentual de frontera agrícola en una imagen satelital, el cual se entrena con una base de datos construida a partir de las imágenes satelitales del Sentinel 2 y el mapa de Colombia del SIPRA.

## 2 Antecedentes y trabajos relacionados

En este capítulo se exponen los conceptos fundamentales acerca de las imágenes satelitales y las redes neuronales profundas, así como los estudios previos y posteriores a la utilización de estas últimas en las tareas de clasificación de imágenes satelitales. También se abordan los desafíos que plantean estas imágenes debido a su captura, así como los trabajos relacionados con su uso y la tarea de clasificación.

En base a lo anterior, el capítulo se organiza de tal forma que en la sección 2.1 se exponen los conceptos de las imágenes satelitales y las redes neuronales profundas, así como los métodos aplicados antes y después de la utilización de estas últimas en la tarea de clasificación. También se abordan los retos que presentan estas imágenes en dicha tarea. Mientras tanto, en la sección 2.2 se presentan trabajos relacionados con la clasificación de imágenes satelitales llevados a cabo entre los años 2017 y 2021.

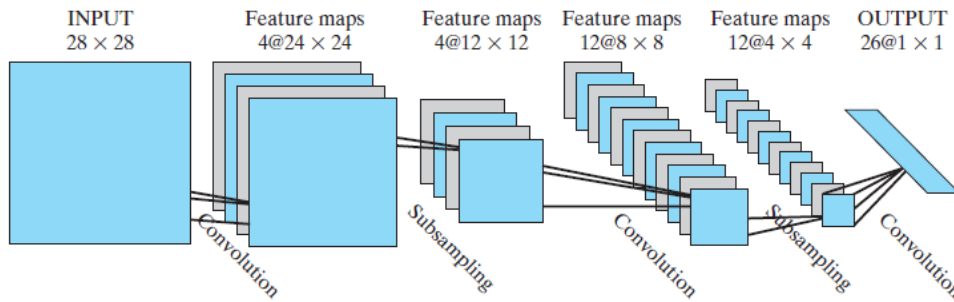
### 2.1. Antecedentes

Con los avances en la tecnología para tomar imágenes satelitales y el aumento en la cantidad de imágenes disponibles, cada vez más académicos se sienten atraídos por la tarea de interpretar estas imágenes debido a la gran cantidad de información que contienen y la complejidad de su interpretación [29, 33]. A continuación, se presentan los métodos de aprendizaje de máquina que se aplicaron a esta tarea antes del uso de las redes convolucionales, así como las diferentes formas en que se han utilizado las redes convolucionales para clasificar imágenes satelitales. También se discuten los retos y dificultades de esta tarea de clasificación y la evolución de la aplicación de las redes convolucionales en esta tarea desde el año 2017 hasta el 2021.

#### 2.1.1. Redes neuronales convolucionales

La red neuronal convolucional (figura 2-1) es un tipo de perceptrón multicapa diseñado específicamente para reconocer formas en dos dimensiones con un alto grado de invariancia a la traslación, la escala y otras formas de distorsión [9].

- **Extracción de características:** En la extracción de características, cada neurona recibe sus entradas sinápticas de un campo receptivo local en la capa anterior, lo que obliga a la red a extraer características locales [9].



**Figura 2-1:** Red convolucional para el proceso de una imagen. Tomado de [9].

- **Mapeo de características:** Cada capa computacional de la red consiste en múltiples mapas de características en forma de un plano, en los que cada neurona comparte el mismo conjunto de pesos sinápticos [9].
- **Submuestreo:** Después de cada capa convolucional, se aplica una capa computacional que realiza promedios y submuestreos locales, lo que reduce la resolución del mapa de características. Esta operación tiene el efecto de disminuir la sensibilidad del mapa de características [9].

### 2.1.2. Métodos aplicados antes de las redes convolucionales

En un principio, los métodos utilizados para la clasificación de imágenes satelitales se basaban en técnicas de aprendizaje de máquina, tales como las máquinas de vectores de soporte (SVM) [4, 36, 23], las bolsas-de-palabras-visuales (BoVW) [4, 22, 19], los árboles de decisión [23], la coincidencia de pirámide espacial (SPM) [4, 19], el modelo de tema probabilístico (PTM) [22], la transformación de características invariantes de escala (SIFT) [4, 22, 19], el histograma de gradientes orientados (HOG) [4] y el Kernel Fisher mejorado (IFK) [4]. Sin embargo, debido a la gran cantidad de esfuerzo humano y tiempo necesarios para etiquetar las imágenes, la utilidad y capacidad limitada de estos métodos de aprendizaje de máquina no permitían una generalización efectiva ni un desarrollo eficiente en respuesta a las rápidas necesidades de esta tarea de clasificación.

Por este motivo, se han utilizado métodos de aprendizaje no supervisado como el análisis de componentes principales (PCA) y el agrupamiento por k-means [4]. No obstante, estos métodos no podían hacer uso de toda la información disponible en las imágenes satelitales para su clasificación.



### 2.1.3. Métodos aplicados después de las redes convolucionales

En 2012, el modelo AlexNet basado en redes neuronales convolucionales obtuvo una victoria decisiva en la competencia de clasificación de imágenes ImageNet, lo que demostró el enorme potencial de estas redes para la clasificación de imágenes satelitales [4]. Desde entonces, se han desarrollado numerosos métodos novedosos basados en estas redes para la clasificación de imágenes satelitales. Además, se han comparado estos métodos con los métodos de aprendizaje de máquina tradicionales, y se ha concluido que las redes neuronales convolucionales son más eficientes y efectivas [16]. En este sentido, se ha analizado la evolución de estas redes durante los últimos cinco años para entender mejor su desarrollo.

#### Formas de uso de las redes convolucionales para la clasificación de imágenes satelitales

En los últimos cinco años, se han utilizado tres metodologías diferentes para abordar los desafíos en la clasificación de imágenes satelitales: construir el modelo desde cero, transferir el aprendizaje de modelos entrenados en bases de datos de imágenes naturales como ImageNet, y utilizar redes convolucionales pre-entrenadas como extractores de características combinados con otros modelos de aprendizaje de máquina [4]. Estudios han demostrado los beneficios y buenos resultados al utilizar un modelo pre-entrenado en otra base de datos y posteriormente adaptarlo a la tarea de clasificación de imágenes satelitales [18, 21]. Por otro lado, otros estudios apoyan la construcción del modelo de red convolucional desde cero, argumentando que la metodología de utilizar un modelo entrenado en otra base de datos ha alcanzado su máxima eficiencia y capacidad para el desarrollo de esta tarea [24, 37].

#### Retos de las imágenes satelitales

A pesar del aumento en la precisión que han mostrado los modelos de redes neuronales convolucionales para la clasificación de imágenes satelitales, estas imágenes presentan grandes retos para estas redes debido a su complejidad y características únicas, muy diferentes a las imágenes naturales: la gran diversidad que hay dentro de una misma clase, la baja separabilidad entre clases, una gran variación de escalas de los objetos y/o escenas, y la coexistencia de múltiples objetos a nivel de suelo [4, 44, 3]. La gran diversidad que hay dentro de una misma clase (figura 2-2(a)) donde una misma clase, como iglesia, presenta diferentes formas y patrones, dificulta la tarea de clasificación. Asimismo, la baja separabilidad entre clases (figura 2-2(b)) donde al menos dos clases, como campos de tenis y campos de baloncesto, presentan características muy similares, dificultan la diferenciación entre ellas. Además, la gran variación de escalas de los objetos y/o escenas (figura 2-2(c)) debido a las diferentes alturas desde donde se toman las imágenes, puede hacer que una misma clase de objeto aparezca en diferentes tamaños, lo que puede resultar en la pérdida de información en la extracción de características para su clasificación. Finalmente, la coexistencia de múltiples

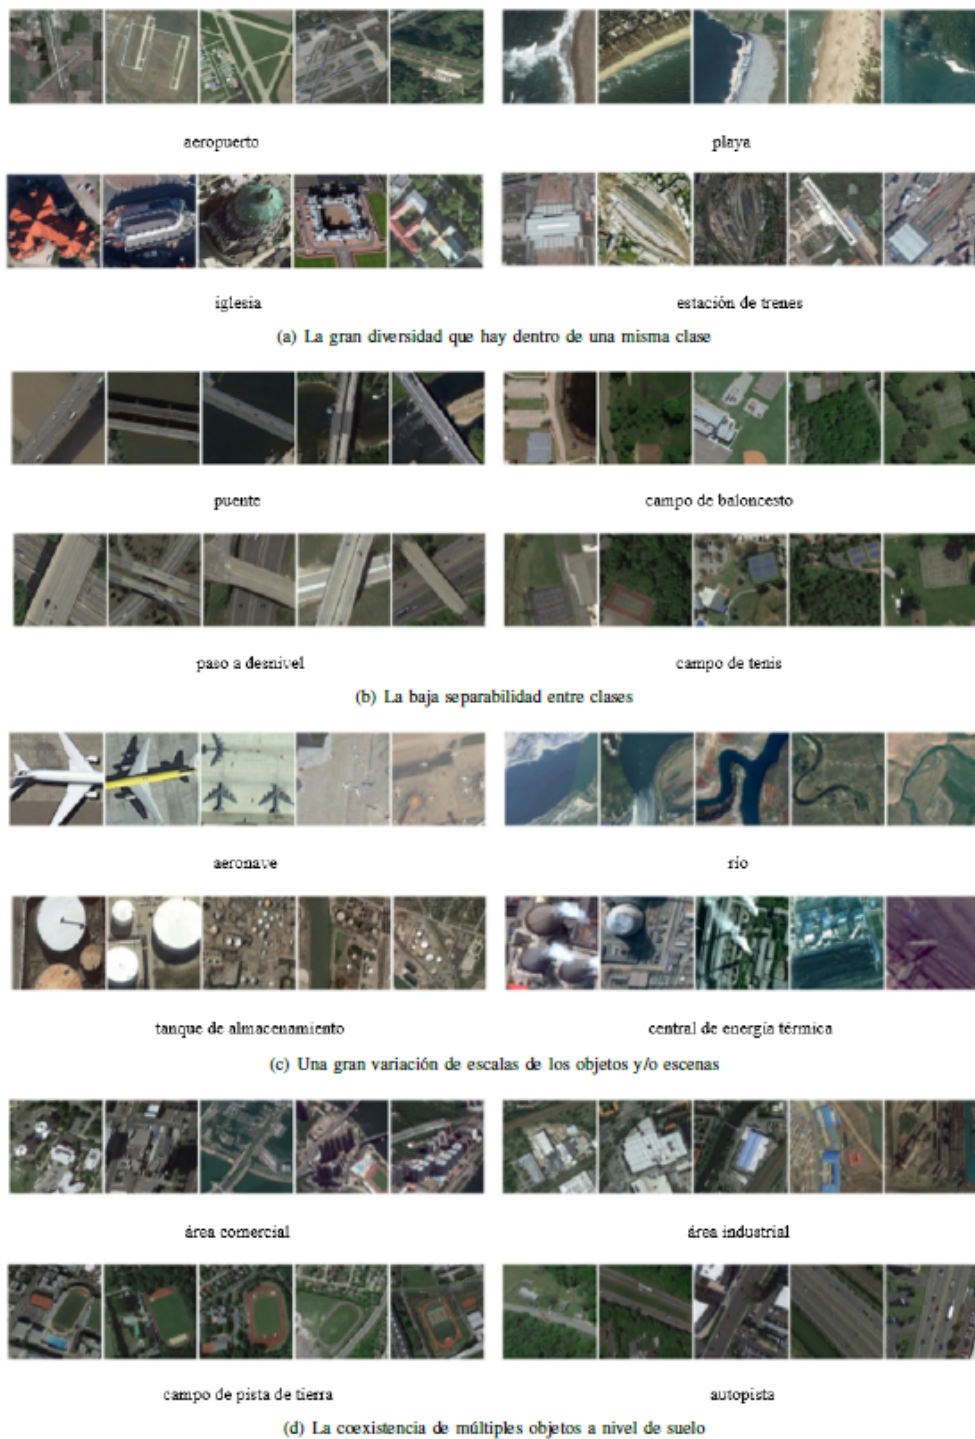


Figura 2-2: Retos de la clasificación de imágenes satelitales. Tomado de [4].

objetos a nivel de suelo (figura **2-2(d)**) donde diversas clases aparecen en una sola imagen, dificulta la clasificación a nivel de escena, es decir, que solo corresponda una clase a la imagen satelital.

Por otro lado, una gran limitante que se ha presentado en esta tarea de clasificación es la cantidad de bases de datos etiquetas [11]. Es por esto que, se han planteado modelos de aprendizaje semi o no supervisado para obtener una mejor generalización y así afrontar esa limitante de bases de datos [2].

## **2.2. Trabajos relacionados 2017-2021**

En esta sección se realiza un análisis de la literatura comprendida en los años 2017 a 2021 para determinar el progreso de la investigación en la tarea de clasificación de imágenes satelitales. En este análisis se evalúan los métodos que se han desarrollado para mejorar los modelos de clasificación en este tipo de imágenes, así como las áreas en las que se han aplicado y los tipos de bases de datos que se han utilizado.

### **2.2.1. Bases de datos**

En la literatura, las bases de datos más utilizadas para la tarea de clasificación de imágenes satelitales se han enfocado principalmente en la clasificación de escenas (Tabla **2-1**) [4]. Estas bases de datos tienen la gran ventaja de ser de acceso libre, lo que permite llevar a cabo investigaciones de manera más sencilla. Sin embargo, muchas de estas bases de datos están enfocadas en la clasificación de la cobertura y uso del suelo en general, o en zonas urbanas [4]. Solo la base de datos Brazilian Coffee Scene aborda la diferenciación de zonas agrícolas, pero se centra en el cultivo del café. Además, ninguna de estas bases de datos es del territorio de Colombia, que es de particular interés para el desarrollo del modelo.

Por esta razón, el uso de satélites como el Sentinel 2, que permite el acceso gratuito a periodos de tiempo para descargar imágenes satelitales, es fundamental para esta tarea de clasificación.

**Tabla 2-1:** Bases de datos públicamente disponibles para clasificación de imágenes satelitales. Tomado de [4].

Data sets	Image number per class	Number of scene classes	Total image number	Image size	Training ratios		Data sources	Year
UC Merced	100	21	2100	256x256	50 %	80 %	Aerial orthoimagery	2010
WHU-RS19	50~61	19	1005	600x600	40 %	60 %	Google Earth	2012
RSSCN7	400	7	2800	400x400	20 %	50 %	Google Earth	2015
Brazilian Coffee Scene	1438	2	2876	64x64	50 %		SPOT sensor	2015
SAT-4/-6	125000/67500	4/6	500000/405000	28x28	80 %		National Agriculture Imagery Program	2015
SIRI-WHU	200	12	2400	200x200	50 %		Google Earth	2016
RSC11	~100	11	1232	512x512	50 %		Google Earth	2016
AID	220~420	30	10000	600x600	20 %	50 %	Google Earth	2017
NWPU-RESISC45	700	45	31500	256x256	10 %	20 %	Google Earth	2017
RSI-CB128 /-CB256	~800/690	45/35	36000 /24000	128x128 /256x256	50 %	80 %	Google Earth & Bing Maps	2017
OPTIMAL-31	60	31	1860	256x256	80 %		Google Earth	2018
EuroSAT	2000~3000	10	27000	64x64	80 %		Sentinel-2	2019
OPTIMAL-31	60	31	1860	256x256	80 %		Google Earth	2018
BigEarthNet	328~217119	44	590326	120x120	60 %		Sentinel-2	2019

## 2.2.2. Aplicaciones en los años de referencia

En el periodo de referencia, comprendido entre los años 2017 y 2021, se llevaron a cabo diferentes análisis para obtener mejores resultados en lo que respecta a la clasificación con imágenes satelitales; mostrando diferentes aproximaciones y limitaciones frente al uso de este tipo de imágenes.

### Año 2017

En los trabajos [27, 41, 36], se analizan diferentes redes convolucionales pre-entrenadas y se realiza transferencia de aprendizaje, evaluando las formas de extracción de características y el uso de data augmentation debido a la limitada cantidad de bases de datos etiquetadas. Se determina que es necesario utilizar otros tipos de data augmentation para generalizar mejor el modelo. Por otro lado, en [17] se crea el modelo desde cero para compararlo con otros modelos de aprendizaje de máquina, como Random Forest y perceptrones multicapa, y se confirma la superioridad de las redes convolucionales para la tarea de clasificación de imágenes satelitales.

**Año 2018**

En los trabajos [38, 42], se combinan dos modelos diferentes de redes convolucionales. Por su parte, en [19], se combina una red convolucional con un modelo de aprendizaje de máquina, en este caso, aprendizaje múltiple de kernel para la clasificación. Estas combinaciones se realizan con el fin de extraer más características de las imágenes satelitales, variando escalas o utilizando dos tipos diferentes de imágenes, con el propósito de generalizar mejor la tarea de clasificación de imágenes satelitales.

**Año 2019**

En [16, 40] se profundiza en la comparación de redes convolucionales y otros modelos de aprendizaje de máquina, como support vector machine, Random Forest y perceptrones multicapa. Estos trabajos siguen reforzando la superioridad de las redes neuronales convolucionales para la tarea de clasificación de imágenes satelitales. Por otro lado, en [21, 5], se llevan a cabo otras combinaciones de dos redes convolucionales para optimizar el rendimiento y la eficiencia en el desarrollo de esta tarea de clasificación de imágenes satelitales.

**Año 2020**

En [20, 44, 3, 47], se agregan capas adicionales a las redes neuronales convolucionales para manejar la incertidumbre de las imágenes SAR, y para extraer y almacenar de manera más efectiva las características espaciales de los objetos dentro de las imágenes satelitales. No obstante, en futuros trabajos se busca mejorar el rendimiento y reducir la complejidad del modelo. Por otro lado, en [18], se compara la transferencia de aprendizaje con la creación de arquitecturas de redes para la tarea deseada, encontrando que no hay grandes diferencias y que esta tarea de clasificación puede ser realizada mediante la transferencia de modelos de otras bases de datos.

**Año 2021**

Durante este año se han utilizado diferentes enfoques para afrontar la tarea de clasificación de imágenes satelitales. A diferencia de [18], en [24] se considera que la transferencia de aprendizaje ha alcanzado su máxima capacidad para solucionar esta tarea, por lo que se propone una nueva arquitectura de red neuronal convolucional desde cero. En [12], a diferencia de [38], se comparan diversas formas de combinar los tipos de imágenes y de extraer características, llegando a la conclusión de que la mejor combinación es la hiperespectral con LiDAR, y que la combinación de esta extracción de características debe ser de la mitad o el final de la red. Por otro lado, en [2, 29] se centran en el aprendizaje semi o no supervisado debido a la limitación de las bases de datos y de la cantidad de imágenes satelitales etiquetadas correctamente, aunque se debe mejorar la segmentación y el rendimiento del modelo para esta tarea. Además, en comparación con años anteriores, [14, 30, 43, 8, 26] se han enfocado

más en la aplicabilidad de la clasificación de imágenes satelitales, como en los cultivos y la identificación de árboles, mostrando avances significativos en este enfoque. Se menciona que el uso de las redes neuronales recurrentes (LSTM) es ideal para la evaluación en periodos de tiempo.

## 3 Conjunto de datos y asignación de etiquetas

En este capítulo se expone el desarrollo de la creación del conjunto de imágenes satelitales necesarias para las tareas deseadas y los criterios para asignar su correspondiente etiqueta a cada una de las imágenes satelitales. Debido a esto, el capítulo se organiza de la siguiente manera: en la sección 3.1 se explica de dónde y cómo se obtendrán las imágenes satelitales que conformarán el conjunto de datos para las tareas deseadas. Posteriormente, en la sección 3.2 se explica de dónde se obtendrá la información para la creación del conjunto de datos, siendo una breve explicación del mapa desarrollado por entidades gubernamentales de Colombia, los criterios para la asignación de de las etiquetas a cada una de las imágenes del conjunto de datos, y un análisis exploratorio de los datos para tener un mejor entendimiento del comportamiento de éstos.

### 3.1. Imágenes satelitales

Al no existir un conjunto de datos etiquetados sobre las zonas agrícolas en Colombia, se debe crear uno para poder entrenar y evaluar el modelo. Para esto, se utiliza el acceso gratuito a imágenes satelitales del Sentinel 2. Asimismo, para obtener las imágenes satelitales georeferenciadas deseadas, se utiliza la biblioteca de Python *geetiles* desarrollada por el profesor Raúl Ramos Pollán<sup>1</sup>.

#### 3.1.1. Satélite Sentinel 2

La misión Copernicus Sentinel 2 consta de dos satélites que están sobre la misma órbita y se encuentran a 180° entre ellos, es decir, en polos opuestos. El primer satélite fue lanzado en junio de 2015 y el segundo satélite fue lanzado en marzo del 2017, que tienen como objetivo capturar imágenes de alta resolución sobre la superficie de la Tierra para usarse en aplicaciones como la agricultura, monitoreo de ecosistemas terrestres, manejo de bosques, seguridad social y otros<sup>2</sup>.

---

<sup>1</sup>Raúl Pollán. *geetiles*. <https://github.com/rramosp/geetiles>

<sup>2</sup>European Space Agency. Sentinel Online. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>

Debido a que el Sentinel 2 es para capturar imágenes de alta resolución, consta de 13 bandas espectrales, tomando ondas de infrarrojo visible y no visible (VNIR y SWIR). De esas 13 bandas son de interés las bandas roja, verde y azul (RGB); siendo las 4, 3, y 2 respectivamente, con una resolución espacial de 10 metros<sup>3</sup>.

### 3.1.2. Biblioteca *geetiles*

La biblioteca *geetiles* permite descargar las imágenes satelitales del satélite Sentinel 2. Para llevar a cabo esto, se debe pasar un archivo geojson donde se encuentra la información georeferenciada de las imágenes satelitales con las coordenadas expresadas en el sistema WSG84, el identificador de cada imagen satelital (si se desea uno diferente al predeterminado generado por la biblioteca) y el área de cobertura de la imagen satelital. Adicionalmente, se define que sean las bandas rojo, verde y azul (RGB) las que conforman las imágenes satelitales resultantes, el año de interés en el que se tomaron las imágenes satelitales por parte del satélite Sentinel 2, siendo para este caso el año 2020, y la resolución de las imágenes satelitales, siendo para este caso de 100 por 100 píxeles. A partir de esto, se descargan y guardan las imágenes satelitales deseadas en la misma carpeta donde se encuentra el archivo geojson.

## 3.2. Asignación de etiquetas de área agrícola en las imágenes satelitales

Para la creación del conjunto de datos se requiere la información necesaria para la identificación de las zonas agrícolas en Colombia, para lo cual se utiliza el mapa creado por la entidad UPRA por medio del sistema de información para la planificación rural agropecuaria (SIPRA); donde luego se identifican las zonas de interés para la creación de los conjuntos de datos con la biblioteca *geetiles* por medio de los archivos geojson y un análisis exploratorio de los conjuntos de datos.

### 3.2.1. Mapa de frontera agrícola de Colombia

Colombia desarrolló un mapa interactivo para mostrar los usos del suelo utilizados en la agropecuaria, las zonas de bosques y selvas, y las zonas privadas para el año 2020 por medio de varias entidades gubernamentales que tuvo una duración de 4 años. La entidad UPRA con el sistema SIPRA tiene los resultados de esos años de trabajo donde se puede especificar el tipo de cultivo o tipo de actividad agropecuaria de interés. Sin embargo, ya que se desea

---

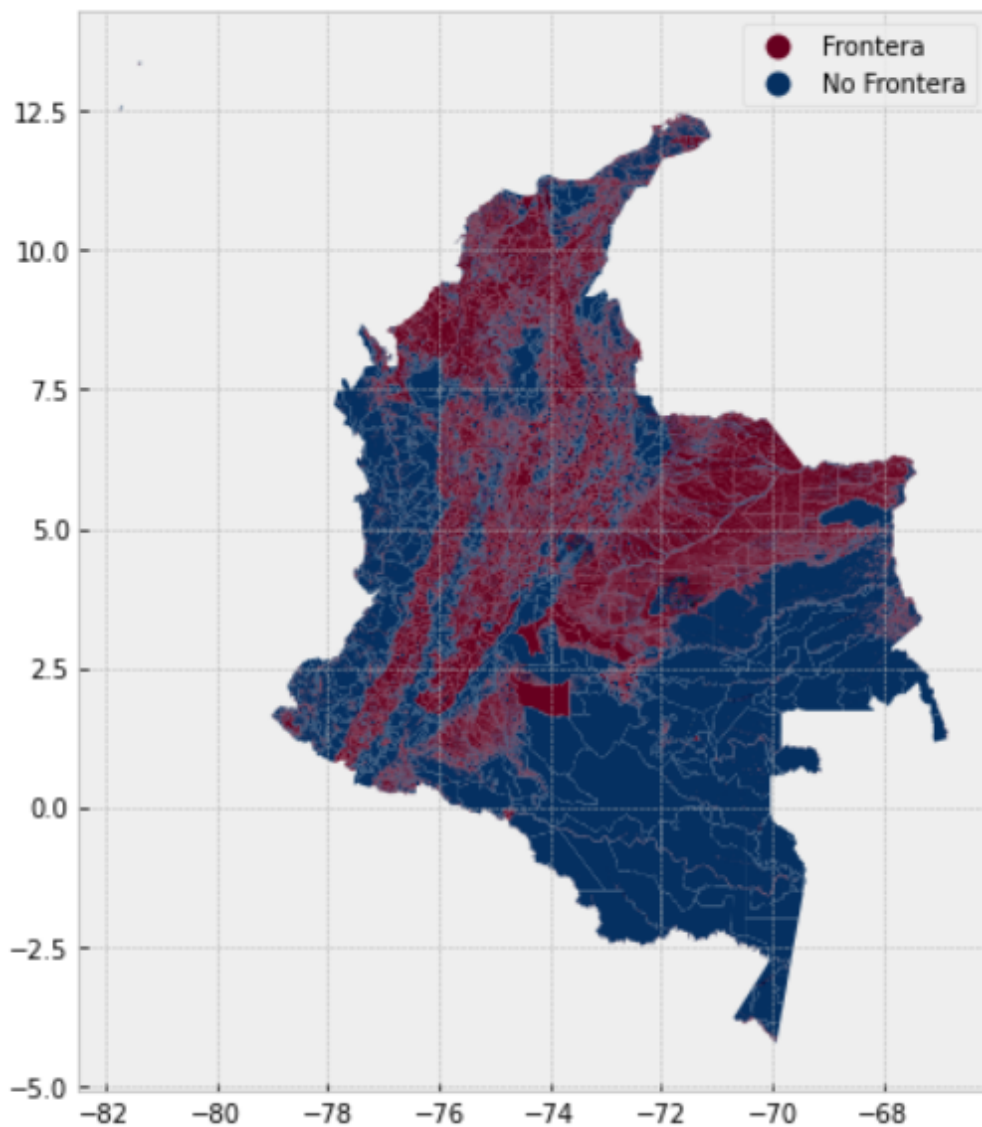
<sup>3</sup>European Space Agency. MultiSpectral Instrument (MSI) Overview.  
<https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>



### 3.2 Asignación de etiquetas de área agrícola en las imágenes satelitales 17

la identificación de toda actividad agropecuaria, se especifica este tipo de mapa en el menú del SIPRA.

Posterior a realizar un preprocesamiento a la identificación de las zonas que se mostraban en el mapa del SIPRA, se generan dos zonas de interés: la Frontera agrícola, siendo el territorio en Colombia que es usado en alguna actividad agropecuaria, y la No Frontera agrícola, siendo el territorio en Colombia que no es usado en ningún tipo de actividad agropecuaria, como se observa en la figura 3-1.



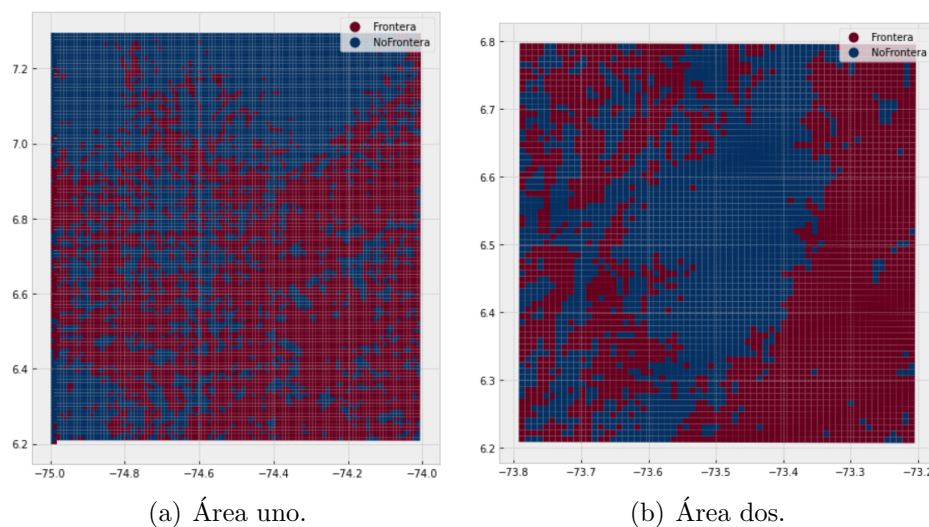
**Figura 3-1:** Mapa de Colombia identificando la Frontera y No Frontera agrícola. Elaboración propia.

### 3.2.2. Construcción de las imágenes satelitales etiquetadas

Con la información del mapa de Colombia necesaria para el desarrollo del trabajo, se identifican dos zonas de interés para poder entrenar los modelos y evaluarlos con una cantidad de datos más idónea, en términos de costo computacional y tiempo. Se escogen dos áreas de interés para la generalización del modelo de la siguiente manera: la área de interés más grande es utilizada para el entrenamiento, validación y prueba del modelo; mientras que, la segunda área de interés es utilizada únicamente para la prueba del modelo y revisar su generalización con respecto a la tarea de interés. A continuación se muestran las coordenadas geográficas de ambas áreas de interés en el sistema WGS84 (longitud y latitud) y se pueden observar en la figura 3-2:

- **Área de interés 1:**  $[(-75,0; 7,3), (-75,0; 6,2), (-74,0; 6,2), (-74,0; 7,3)]$ .
- **Área de interés 2:**  $[(-73,8; 6,8), (-73,8; 6,2), (-73,2; 6,2), (-73,2; 6,8)]$ .

Definidas las áreas de interés para el entrenamiento y prueba del modelo, se superponen sobre el mapa de Colombia ya definido para así obtener la información de Frontera agrícola y No Frontera agrícola en cada una de las áreas. Adicionalmente, se crea una malla de un kilómetro por un kilómetro para posteriormente obtener las imágenes satelitales del Sentinel 2 usando la biblioteca *geotiles*.

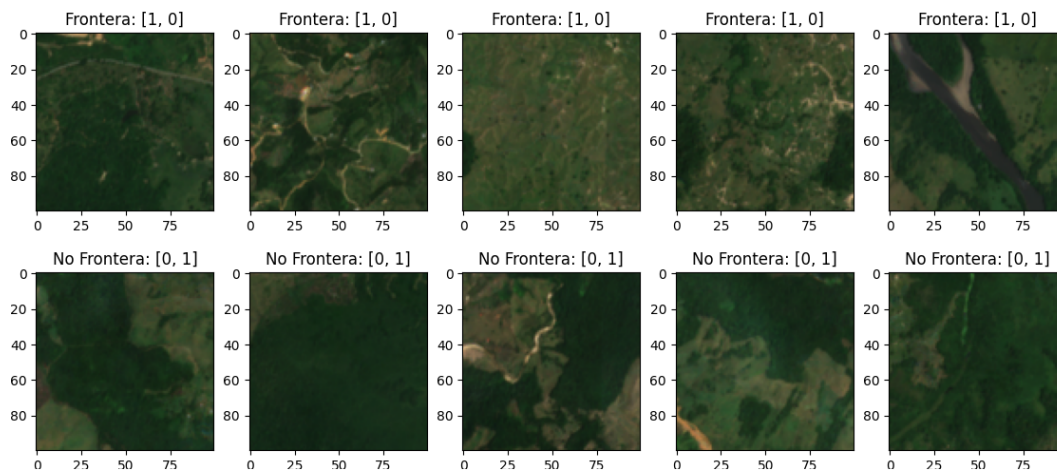


**Figura 3-2:** Áreas de interés. Elaboración propia.

Luego de definir las mallas de un kilómetro cuadrado, se debe crear el identificador de cada imagen satelital para la construcción de los archivos geojson. Para esto, se determina que

el identificador de cada imagen satelital constará de: el índice (tomando valores de cero a la cantidad menos uno de cuadritos dentro de la malla de cada área de interés), el valor de *Frontera* o *NoFrontera* (usando como criterio el porcentaje de área agrícola dentro de cada imagen satelital y el umbral de 0,5; de tal forma que, si el valor porcentual de área agrícola dentro de cada imagen satelital es mayor o igual a 0,5 se asigna el valor de *Frontera*, y si es menor a 0,5, se asigna el valor de *NoFrontera*), seguido por los valores de porcentaje de área agrícola dentro de cada imagen satelital y los valores porcentuales de no área agrícola dentro de cada imagen satelital. Luego de crear el identificador para cada imagen satelital, la georeferencia de cada imagen satelital en el sistema WSG84 y el área de cada imagen satelital en kilómetros cuadrados, se crean los dos archivos geojson (uno para cada área de interés). De esta forma, se puede utilizar la biblioteca *geotiles* especificando el año 2020, las bandas RGB y una resolución de 100 por 100 píxeles para descargar y guardar las imágenes satelitales de las dos áreas de interés construyendo así los dos conjuntos de datos necesarios para el desarrollo de este trabajo.

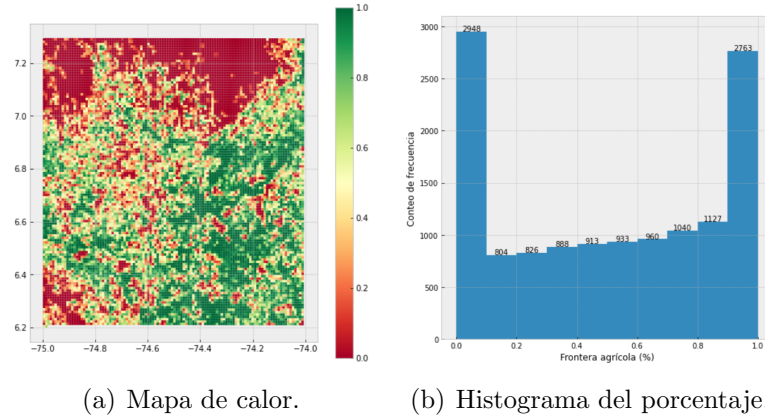
En la figura **3-3** se muestra como se ven las imágenes satelitales para la tarea de clasificación binaria usando el codificador one hot.



**Figura 3-3:** Conjunto de datos de las áreas de interés del satélite Sentinel 2 con su respectiva etiqueta para la tarea de clasificación. Elaboración propia.

### 3.2.3. Análisis exploratorio

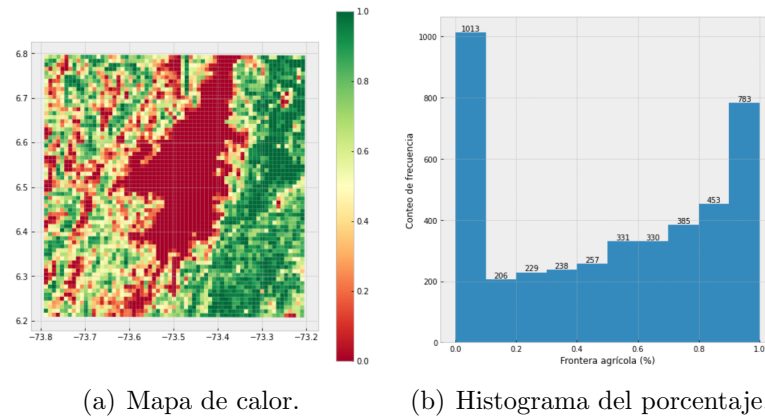
El área de interés más grande consta de 13.202 imágenes, la cantidad de cuadros de la malla. A continuación, se muestra un mapa de calor con respecto a la cantidad porcentual de área agrícola dentro de cada cuadro de la malla y un conteo de imágenes en rangos del 10%, como se muestra en la figura **3-4**.



**Figura 3-4:** Análisis de la Frontera agrícola en la primera área de interés. Elaboración propia.

Se observa que la primera área de interés tiene un comportamiento bimodal en la cantidad de imágenes identificadas como Frontera agrícola y usando el criterio del umbral de 0,5, se determina que para esta primera área de interés se obtienen 6.823 imágenes con etiqueta *Frontera* y 6.379 imágenes con etiqueta *NoFrontera*.

Por otro lado, la segunda área de interés consta de 4.225 imágenes, la cantidad de cuadros en la malla construida. A continuación se muestra un mapa de calor con respecto a la cantidad porcentual de Frontera agrícola dentro de cada cuadro de la malla y un conteo de imágenes en rangos del 10 %, como se observa en la figura 3-5.



**Figura 3-5:** Análisis de la Frontera agrícola en la segunda área de interés. Elaboración propia.

Al igual que la primera área de interés, la segunda área de interés tiene un comportamiento bimodal. Usando el criterio del umbral de 0,5, se determina que para esta segunda área de interés se obtienen 2.282 imágenes con la etiqueta *Frontera* y 1.943 imágenes con la etiqueta *NoFrontera*.

### 3.2.4. Construcción de los conjuntos de datos

Dado que se tienen imágenes satelitales de dos diferentes áreas de Colombia, y se realiza dos tareas con los modelos, de clasificación y de regresión, se deben crear los conjuntos de datos para cada caso.

#### Tarea de clasificación

Para esta tarea de clasificación se determina que el área con mayor cantidad de datos, con 13.202 imágenes satelitales, sea utilizada para la etapa de entrenamiento, validación y prueba de los modelos; mientras que, la otra área, con 4.225 imágenes satelitales, sea usado únicamente para la prueba de generalización de los modelos. La distribución de las imágenes satelitales de ambas áreas se muestra en la tabla 3-1.

**Tabla 3-1:** Distribución de las imágenes satelitales de ambos conjuntos para la tarea de clasificación.

Área de interés	Coordenadas en el sistema WSG84	Conjunto	Etiqueta	Cantidad de imágenes satelitales
Área 1	[(-75,0; 7,3), (-75,0; 6,2),(-74,0; 6,2), (-74,0; 7,3)]	Entrenamiento	Frontera	4.000
			No Frontera	4.000
		Validación	Frontera	1.000
			No Frontera	1.000
		Prueba 1	Frontera	1.823
			No Frontera	1.379
Área 2	[(-73,8; 6,8), (-73,8; 6,2), (-73,2; 6,2), (-73,2; 6,8)]	Prueba 2	Frontera	2.282
			No Frontera	1.943

#### Tarea de regresión

Para esta tarea de regresión se define que el área con mayor cantidad de imágenes satelitales sea usado para el proceso de entrenamiento y validación, con una separación aleatoria del 80 % y 20 % respectivamente; mientras que, el conjunto con menor cantidad de imágenes satelitales es utilizado para el proceso de prueba de los modelos. Esta distribución se puede observar en la tabla 3-2.

**Tabla 3-2:** Distribución de las imágenes satelitales de ambos conjuntos para la tarea de regresión.

Área de interés	Coordenadas en el sistema WSG84	Conjunto	Cantidad de imágenes satelitales
Área 1	[(-75,0; 7,3), (-75,0; 6,2), (-74,0; 6,2), (-74,0; 7,3)]	Entrenamiento	10.560
		Validación	2.642
Área 2	[(-73,8; 6,8), (-73,8; 6,2), (-73,2; 6,2), (-73,2; 6,8)]	Prueba	4.225

## 4 Tarea de clasificación

En este capítulo se expone la configuración experimental y los resultados de los modelos con los que se evaluaron esta tarea, con una discusión acerca de los resultados de cada modelo.

Este capítulo se encuentra organizado en cinco secciones: la sección 4.1 expone las arquitecturas generales de los modelos explicando los componentes que tienen estos modelos y su labor dentro del modelo para llevar a cabo esta tarea. De esta forma, la sección 4.2 explica cómo se distribuyeron los conjuntos para el entrenamiento, validación y prueba para esta tarea. Se hicieron tres grupos comparativos de modelos; el primer grupo corresponde a los modelos de transferencia que fueron entrenados en la competencia de *ImageNet*; el segundo grupo hace referencia a modelos con arquitecturas más pequeñas y que son entrenadas desde cero con este conjunto de datos, llamados modelos *shallow convolutional*; y el último grupo hace referencia a los modelos basados en *Quantum Kernel Mixtures* y que igualmente constan de arquitecturas pequeñas. Posteriormente, la sección 4.3 muestra los resultados sobre el conjunto de prueba 1 de todos los modelos: *ResNet50*, *VGG 19*, *MobileNet* e *Inception V3*, cuatro modelos de *shallow convolutional* y seis modelos de *Quantum Kernel Mixtures*. Luego, la sección 4.4 muestra los resultados sobre el conjunto de prueba 2 de todos los modelos: *ResNet50*, *VGG 19*, *MobileNet* e *Inception V3*, cuatro modelos de *shallow convolutional* y seis modelos de *Quantum Kernel Mixtures*. Por último, en la sección 4.5 se realiza una discusión sobre los resultados obtenidos.

### 4.1. Arquitectura Propuesta


Se muestran de forma general los componentes de la arquitectura de los modelos de transferencia, los modelos *Shallow Convolutional* y los modelos *Quantum Kernel Mixtures*; propuestos para el desarrollo de esta tarea.

#### 4.1.1. Modelos de transferencia

Se escoge trabajar con cuatro modelos entrenados en la competencia *ImageNet* para realizar una transferencia para esta tarea de clasificación de frontera agrícola con imágenes satelitales en Colombia. Estos modelos son: *ResNet50*, *VGG 19*, *MobileNet* e *Inception V3*; donde todos

son descargados con sus pesos de la competencia de la biblioteca *tensorflow*<sup>1</sup> y se obtiene una arquitectura de capas convolucionales seguida por una capa de aplanamiento (Flatten).

Todos estos modelos se basan en la arquitectura que se muestra en la figura 4-1, donde se empieza especificando que su entrada de imágenes satelitales es de 100 por 100 píxeles. Luego, estas imágenes satelitales pasan por las capas convolucionales del modelo de transferencia correspondiente, que es donde se identifica y extrae la información de estas imágenes satelitales para la clasificación de zonas agrícolas. Posterior a la capa de aplanamiento, se agregan unas capas de neuronas totalmente conectadas encargadas de interpretar esa información adquirida anteriormente y determinar si la imagen satelital corresponde a frontera agrícola o no, por lo que la última capa consta de dos neuronas (usando la codificación one hot). Teniendo en cuenta que la función de pérdida durante el proceso de entrenamiento es categorical crossentropy y su métrica para evaluar su desempeño durante su entrenamiento es el éxito (accuracy).



**Figura 4-1:** Arquitectura general de los modelos de transferencia para la tarea de clasificación.

El entrenamiento de estos modelos de transferencia se realiza en dos etapas: la primera etapa se llama aprendizaje por transferencia, donde no se permite el entrenamiento de las capas convolucionales del modelo de transferencia evitando que se modifiquen los pesos de estas conexiones. Esto mientras se define la cantidad de capas neuronales densas y la cantidad de neuronas por capa, que van después de las capas convolucionales del modelo de transferencia. Una vez definida la arquitectura del bloque de capas neuronales densas, se prosigue a la segunda etapa, el refinamiento, donde se permite la actualización de los pesos de las capas convolucionales de los modelos de transferencia y del bloque de capas neuronales densas mientras se varía el valor de la tasa de aprendizaje y así obtener un mejor desempeño en las métricas.

<sup>1</sup>Ver: [https://www.tensorflow.org/api\\_docs/python/tf/keras/applications](https://www.tensorflow.org/api_docs/python/tf/keras/applications)



### Modelo Resnet50

La arquitectura del modelo *ResNet50* desarrollada en [10] se puede observar en la figura 4-2. El modelo *ResNet50* se identifica ya que realiza conexiones secuenciales en las capas convolucionales, y adicionalmente, realiza conexiones saltando capas principalmente para evitar el desvanecimiento del error durante el proceso de backpropagation. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		$1.8 \times 10^9$	$3.6 \times 10^9$	$3.8 \times 10^9$	$7.6 \times 10^9$	$11.3 \times 10^9$

**Figura 4-2:** Arquitectura original del modelo ResNet50. Tomado de [10].

Posterior a descargar el modelo *ResNet50* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 4-1. Ya que se está utilizando una codificación one hot, la última capa de neuronas densas consta de dos neuronas con una función de activación igual a *softmax*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $1\epsilon^{-4}$ , un optimizador de *Adam* y un tamaño de lote igual a 32.

**Tabla 4-1:** Arquitectura del modelo ResNet50 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo ResNet50
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (30 %)
Capa de neuronas densas (2 neuronas)

## Modelo VGG 19

La arquitectura del modelo *VGG 19* desarrollada en [31] se puede observar en la figura 4-3. El modelo *VGG 19* tiene una profundidad de 19 capas con unos filtros de convolución pequeños (3x3). Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

**Figura 4-3:** Arquitectura original del modelo VGG 19. Tomado de [31].

Posterior a descargar el modelo *VGG 19* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 4-2. Ya que se está utilizando una codificación one hot, la última capa de neuronas densas consta de dos con una función de activación igual a *softmax*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $8\epsilon^{-5}$ , un optimizador de *Adam* y un tamaño de lote igual a 32.

**Tabla 4-2:** Arquitectura del modelo VGG 19 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo VGG 19
Capa de aplanamiento (Flatten)
Capa de neuronas densas (512 neuronas)
Dropout (40 %)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (2 neuronas)

### Modelo MobileNet

La arquitectura del modelo *MobileNet* desarrollada en [13] se puede observar en la figura 4-4. El modelo *MobileNet* se basa en una arquitectura simplificada que utiliza convoluciones separables en profundidad para construir redes neuronales con estructura ligera y profunda. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5× Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool $7 \times 7$	$7 \times 7 \times 1024$
FC / s1	$1024 \times 1000$	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

**Figura 4-4:** Arquitectura original del modelo MobileNet. Tomado de [13].

Posterior a descargar el modelo *MobileNet* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 4-3. Ya que se está utilizando una codificación one hot, la última capa de neuronas densas consta de dos con una función de activación igual a *softmax*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $5\epsilon^{-4}$ , un optimizador de *Adam* y un tamaño de lote igual a 32.

**Tabla 4-3:** Arquitectura del modelo MobileNet para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo MobileNet
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (40 %)
Capa de neuronas densas (128 neuronas)
Capa de neuronas densas (2 neuronas)

## Modelo Inception V3

La arquitectura del modelo *Inception V3* desarrollada en [32] se puede observar en la figura 4-5. El modelo *Inception V3* cuenta con capas en un solo nivel que se conforman de múltiples filtros de diferentes tamaños; lo que hace un modelo más ancho en vez de profundo por tener capas en paralelo. Estas capas en paralelo se observan en la figura 4-6, que es lo que aparece dentro de la arquitectura del modelo *Inception V3*. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

type	patch size/stride or remarks	input size
conv	3×3/2	299×299×3
conv	3×3/1	149×149×32
conv padded	3×3/1	147×147×32
pool	3×3/2	147×147×64
conv	3×3/1	73×73×64
conv	3×3/2	71×71×80
conv	3×3/1	35×35×192
3×Inception	As in figure 5	35×35×288
5×Inception	As in figure 6	17×17×768
2×Inception	As in figure 7	8×8×1280
pool	8 × 8	8 × 8 × 2048
linear	logits	1 × 1 × 2048
softmax	classifier	1 × 1 × 1000

Figura 4-5: Arquitectura original del modelo Inception V3. Tomado de [32].

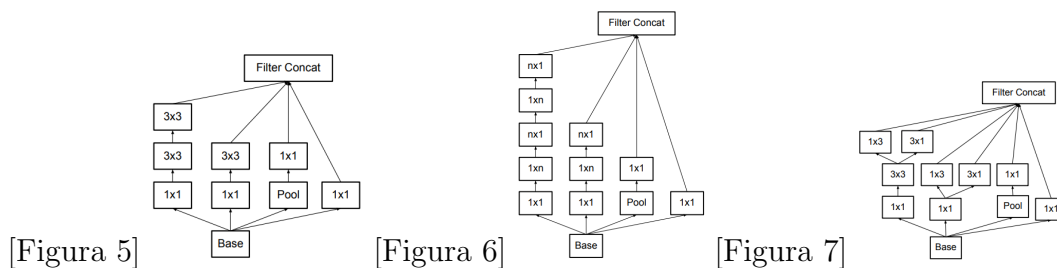


Figura 4-6: Capas de paralelo de Inception. Tomado de [32].


Posterior a descargar el modelo *Inception V3* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 4-4. Ya que se está utilizando una codificación one hot, la última capa de neuronas densas consta de dos con una función de activación igual a *softmax*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $5\epsilon^{-4}$ , un optimizador de *Adam* y un tamaño de lote igual a 32.

**Tabla 4-4:** Arquitectura del modelo Inception V3 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo Inception V3
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (30 %)
Capa de neuronas densas (2 neuronas)

### 4.1.2. modelos shallow convolutional

Estos modelos son de arquitectura más pequeña en comparación a los modelos de transferencia, tal como se muestra en la figura 4-7. Estos modelos tienen una entrada de imagen igual a 100 por 100 píxeles, seguido por una capa *Lambda* convirtiendo cada ejemplo en un formato de float 32 y se subtrae 0,5. Posteriormente, los datos pasan por un bloque de capas convolucionales que extraen e identifican las características de las imágenes satelitales para esta tarea de clasificación. Luego, una capa de aplanamiento para proseguir un bloque de capas neuronales densas totalmente conectadas; las cuales interpretan la información proveniente de las capas convolucionales y determinar de esta forma si la imagen satelital corresponde a frontera agrícola o no. Debido a esto, la última capa tiene dos neuronas para esta clasificación ya que se está usando una codificación one hot. Todo este proceso de entrenamiento se realiza teniendo en cuenta la función de pérdida sparse categorical crossentropy y la métrica de desempeño sparse categorical accuracy.



**Figura 4-7:** Arquitectura general de los modelos *shallow convolutional* para la tarea de clasificación.

El entrenamiento de estos modelos *shallow convolutional* se realiza en una etapa: una vez definida la arquitectura del modelo en estudio, se entrena el modelo variando el valor de la tasa de aprendizaje.

### Modelo shallow convolutional 1

La arquitectura de este modelo se puede observar en la tabla 4-5 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 16 imágenes satelitales.

**Tabla 4-5:** Arquitectura del modelo shallow convolutional 1 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (7x7x64)
Capas convolucional (1x1x256)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (2 neuronas)

### Modelo shallow convolutional 2

La arquitectura de este modelo se puede observar en la tabla 4-6 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 16 imágenes satelitales.

**Tabla 4-6:** Arquitectura del modelo shallow convolutional 2 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (34x34x32)
Capas convolucional (34x34x64)
Capas convolucional (34x34x64)
Capas convolucional (28x28x144)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (36 neuronas)
Capa de neuronas densas (36 neuronas)
Capa de neuronas densas (2 neuronas)

### Modelo shallow convolutional 3

La arquitectura de este modelo se puede observar en la tabla 4-7 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 16 imágenes satelitales.

**Tabla 4-7:** Arquitectura del modelo shallow convolutional 3 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (2x2x64)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Batch Normalization
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (2 neuronas)

### Modelo shallow convolutional 4

La arquitectura de este modelo se puede observar en la tabla 4-8 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 16 imágenes satelitales.

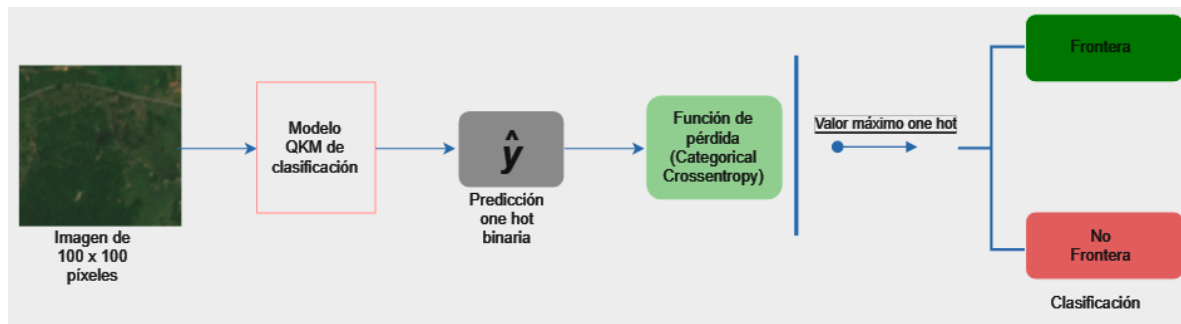
**Tabla 4-8:** Arquitectura del modelo shallow convolutional 4 para la tarea de clasificación de imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (7x7x64)
Capas convolucional (1x1x64)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Batch Normalization
Capa de neuronas densas (32 neuronas)
Batch Normalization
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (2 neuronas)

### 4.1.3. Modelos Quantum Kernel Mixtures

El modelo *Quantum Kernel Mixtures*<sup>2</sup>, también llamadas *kernel density matrices*, fue desarrollado en [7], los cuales se basan en las matrices de densidad en el espacio de kernel. Estas matrices de densidad son la forma más general de describir el estado de un sistema cuántico y que permite ser definidas en un espacio de kernel de Hilbert. Estas matrices de densidad en el espacio de kernel son un mecanismo versátil que representa tanto distribuciones probabilísticas continuas como discretas. Lo cual convierte a este método capaz de desarrollar inferencias diferenciables, composicionales y reversibles permitiendo la aplicación en un amplio rango de tareas de aprendizaje de máquina[7].

Como se observa en la figura 4-8, la aplicación de este modelo es simple ya que consta de un único componente de modelo *Quantum Kernel Mixtures*. Sin embargo, deben especificarse varios hiperparámetros para su entrenamiento, los cuales son: el número de componentes (n.comp) siendo la cantidad de componentes del conjunto QKM; el tamaño del parche (patch\_size) siendo el tamaño del cuadro para la extracción de parches de la imagen; el tamaño del encoder (encoder\_size) haciendo referencia a la dimensión del estado de entrada para la capa QKM; el tamaño del paso (strides) siendo el paso durante la extracción de parches de las imágenes; la dimensión de salida (dim\_y) correspondiente a la dimensión del estado de salida; el tamaño de la imagen (image\_size) y el codificador (encoder) que transforma las dimensiones de los parches de las imágenes al tamaño deseado para el modelo.



**Figura 4-8:** Arquitectura general de los modelos de *Quantum Kernel Mixtures* para la tarea de clasificación.

El entrenamiento de estos modelos *Quantum Kernel Mixtures* se realiza en una etapa: una vez definida la arquitectura del modelo en estudio, se entrena el modelo variando el valor de la tasa de aprendizaje. Teniendo en cuenta la que la función de pérdida es categorical crossentropy y la métrica de desempeño es categorical accuracy.

<sup>2</sup>Ver: Quantum Kernel Mixtures, <https://github.com/fagonzalezo/quakemix>



### Modelo Quantum Kernel Mixtures 1

La arquitectura de este modelo se puede observar en la tabla 4-9 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-5}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

**Tabla 4-9:** Hiperparámetros del modelo Quantum Kernel Mixtures 1 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	6
encoded_size	16
strides	3
dim_y	2
image_size	100
encoder	capa densa (encoded_size*2) Batch Normalization capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 2

La arquitectura de este modelo se puede observar en la tabla 4-10 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

**Tabla 4-10:** Hiperparámetros del modelo Quantum Kernel Mixtures 2 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	6
encoded_size	patch_size*patch_size
strides	3
dim_y	2
image_size	100
encoder	capa densa (encoded_size*4) Batch Normalization capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 3

La arquitectura de este modelo se puede observar en la tabla 4-11 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

**Tabla 4-11:** Hiperparámetros del modelo Quantum Kernel Mixtures 3 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	3
encoded_size	patch_size*patch_size
strides	6
dim_y	2
image_size	100
encoder	capa densa (encoded_size*2) Batch Normalization Dropout (30 %) capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 4

La arquitectura de este modelo se puede observar en la tabla 4-12 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-5}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

**Tabla 4-12:** Hiperparámetros del modelo Quantum Kernel Mixtures 4 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	patch_size*patch_size*3
strides	4
dim_y	2
image_size	100
encoder	lambda x: x

### Modelo Quantum Kernel Mixtures 5

La arquitectura de este modelo se puede observar en la tabla 4-13 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje

de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

**Tabla 4-13:** Hiperparámetros del modelo Quantum Kernel Mixtures 5 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	16
strides	4
dim_y	2
image_size	100
encoder	capa densa (encoded_size*4) Batch Normalization Dropout (40%) capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 6

La arquitectura de este modelo se puede observar en la tabla 4-14 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-5}$ , el optimizador es *Adam* y el tamaño del lote es de 32 imágenes satelitales.

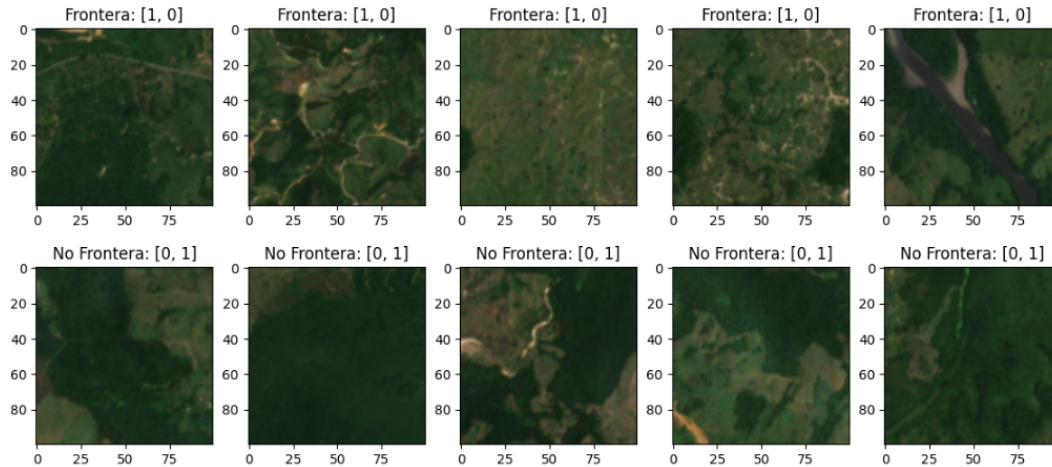
**Tabla 4-14:** Hiperparámetros del modelo Quantum Kernel Mixtures 6 para la tarea de clasificación de imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	6
encoded_size	patch_size*patch_size*3
strides	3
dim_y	2
image_size	100
encoder	capa convolucional 1D (encoded_size, 5, 1) Batch Normalization capa densa (encoded_size)

## 4.2. Configuración experimental

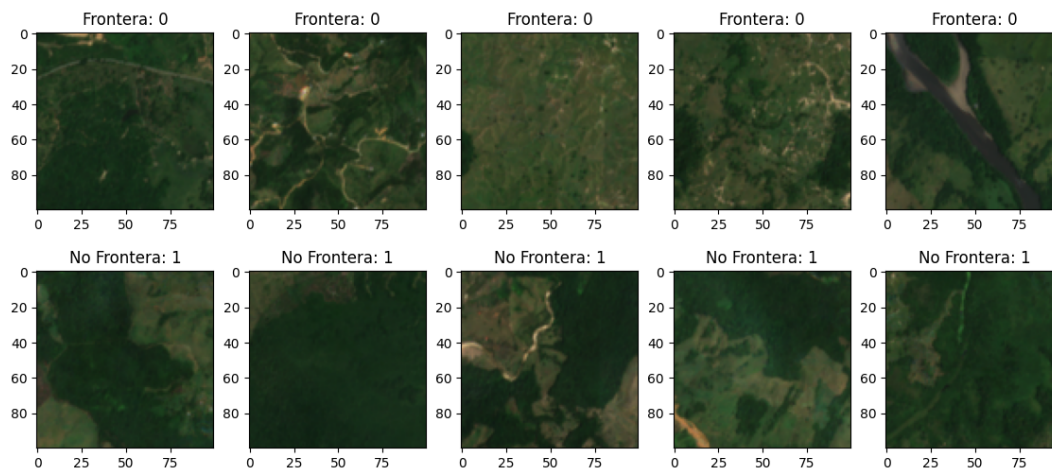
Durante la creación de los conjuntos de entrenamiento, validación, prueba 1 y prueba 2 (tal como se observa en la tabla 3-1), se define el tamaño de las imágenes a 100 por 100

píxeles y se transforman las etiquetas a la codificación one-hot de la siguiente forma: la etiqueta *Frontera* toma la forma del vector  $[1, 0]$ ; mientras que, la etiqueta *No Frontera* toma la forma del vector  $[0, 1]$ . Esta codificación one-hot es utilizada para los modelos *VGG 19*, *ResNet 50*, *MobileNet*, *Inception V3* y para los modelos basados en *Quantum Kernel Mixtures*, como se ve en la figura 4-9.



**Figura 4-9:** Visualización de las imágenes para los modelos de transferencia y Quantum Kernel Mixtures para la tarea de clasificación de imágenes satelitales. Elaboración propia.

Por el contrario, aunque se dejan las imágenes satelitales con la misma resolución, la forma de codificación de las etiquetas cambia para los modelos *shallow convolutional*. Para estos modelos, la etiqueta de las imágenes de *Frontera* toma el valor de 0 y las imágenes con la etiqueta *No Frontera* toma el valor de 1, como se observa en la figura 4-10.




**Figura 4-10:** Visualización de las imágenes para los modelos shallow convolutional para la tarea de clasificación de imágenes satelitales. Elaboración propia.


La forma en que se evaluaron los modelos fue por sus resultados de precisión, el F1-score, la exactitud, el error tipo 1, el error tipo 2, la sensibilidad, la especificidad y el área bajo la curva ROC.

### 4.3. Resultados sobre el conjunto Prueba 1


Se evalúan los cuatro modelos de transferencia, los cuatro modelos *shallow convolutional* (SC) y los seis modelos *Quantum Kernel Mixtures* (QKM) sobre el conjunto de prueba 1 que consta de 3.202 imágenes, tal como se observa en la tabla 3-1. Los resultados de estos catorce modelos se muestran en la tabla 4-15 pero se realiza una gráfica mostrando las curvas ROC por grupo de familia de modelos, obteniendo las figuras 4-11, 4-12 y 4-13, para los modelos de transferencia, modelos *shallow convolutional* y modelos *Quantum kernel Mixtures* respectivamente.



**Figura 4-11:** Curvas ROC de los modelos de transferencia para el primer conjunto de prueba en la tarea de clasificación.



**Figura 4-12:** Curvas ROC de los modelos *shallow convolutional* para el primer conjunto de prueba en la tarea de clasificación.




**Figura 4-13:** Curvas ROC de los modelos *Quantum Kernel Mixtures* para el primer conjunto de prueba en la tarea de clasificación.

**Tabla 4-15:** Resultados sobre el conjunto de prueba 1 con los 14 modelos de estudio en la tarea de clasificación.

Modelo	Precisión	F1-Score	Exactitud	Error tipo 1	Error tipo 2	Sensibilidad	Especificidad	AUC ROC
ResNet50	89,69 %	91,51 %	92,54 %	<b>6,60 %</b>	8,12 %	91,88 %	<b>93,40 %</b>	<b>0,9755</b>
Inception V3	79,57 %	81,54 %	83,70 %	16,39 %	16,24 %	83,76 %	83,61 %	0,9172
MobileNet	<b>90,83 %</b>	<b>91,74 %</b>	<b>92,82 %</b>	7,32 %	<b>7,08 %</b>	<b>92,92 %</b>	92,68 %	0,9701
VGG 19	84,34 %	82,56 %	82,29 %	19,14 %	11,35 %	88,65 %	80,86 %	0,9238
SC 1	76,05 %	79,22 %	81,32 %	17,33 %	19,69 %	80,31 %	82,67 %	0,8887
SC 2	78,78 %	79,24 %	82,01 %	20,30 %	16,24 %	83,76 %	79,70 %	0,8956
SC 3	79,30 %	77,39 %	80,98 %	24,44 %	14,92 %	85,08 %	75,56 %	0,8831
SC 4	84,15 %	80,62 %	83,98 %	22,63 %	11,03 %	88,97 %	77,37 %	0,9168
QKM 1	76,15 %	77,74 %	80,42 %	20,59 %	18,82 %	81,18 %	79,41 %	0,8788
QKM 2	75,13 %	78,98 %	80,92 %	16,75 %	20,84 %	79,16 %	83,25 %	0,8874
QKM 3	77,34 %	77,90 %	80,82 %	21,54 %	17,39 %	82,61 %	78,46 %	0,8798
QKM 4	79,25 %	78,97 %	81,95 %	21,32 %	15,58 %	84,42 %	78,68 %	0,8901
QKM 5	77,69 %	77,86 %	80,89 %	21,97 %	16,95 %	83,05 %	78,03 %	0,8787
QKM 6	77,30 %	79,11 %	81,57 %	19,00 %	17,99 %	82,01 %	81,00 %	0,8884


## 4.4. Resultados sobre el conjunto Prueba 2

Se evalúan los cuatro modelos de transferencia, los cuatro modelos *shallow convolutional* (SC) y los seis modelos *Quantum Kernel Mixtures* (QKM) sobre el conjunto de prueba 2 que consta de 4.225 imágenes, tal como se observa en la tabla 3-1. Los resultados de estos catorce modelos se muestran en la tabla 4-16 pero se realiza una gráfica mostrando las curvas ROC por grupo de familia de modelos, obteniendo las figuras 4-14, 4-15 y 4-16, para los modelos de transferencia, modelos *shallow convolutional* y modelos *Quantum kernel Mixtures* respectivamente.




**Figura 4-14:** Curvas ROC de los modelos de transferencia para el segundo conjunto de prueba en la tarea de clasificación.





**Figura 4-15:** Curvas ROC de los modelos *shallow convolutional* para el segundo conjunto de prueba en la tarea de clasificación.



**Figura 4-16:** Curvas ROC de los modelos *Quantum Kernel Mixtures* para el segundo conjunto de prueba en la tarea de clasificación.

**Tabla 4-16:** Resultados sobre el conjunto de prueba 2 con los 14 modelos de estudio en la tarea de clasificación.

Modelo	Precisión	F1-Score	Exactitud	Error tipo 1	Error tipo 2	Sensibilidad	Especificidad	AUC ROC
ResNet50	72,35 %	72,87 %	74,86 %	26,61 %	23,88 %	76,12 %	73,39 %	0,8120
Inception V3	79,53 %	69,04 %	74,84 %	39,01 %	<b>13,37 %</b>	<b>86,63 %</b>	60,99 %	0,8484
MobileNet	72,60 %	76,20 %	76,97 %	19,81 %	25,77 %	74,23 %	80,19 %	0,8533
VGG 19	80,34 %	76,37 %	79,29 %	27,23 %	15,16 %	84,84 %	72,77 %	0,8760
SC 1	73,99 %	80,82 %	80,57 %	10,96 %	26,64 %	73,36 %	89,04 %	0,9048
SC 2	76,74 %	80,99 %	81,49 %	14,26 %	22,13 %	77,87 %	85,74 %	0,9027
SC 3	<b>81,19 %</b>	81,59 %	82,98 %	18,01 %	16,17 %	83,83 %	81,99 %	0,9108
SC 4	79,30 %	78,89 %	80,69 %	21,51 %	17,44 %	82,56 %	78,49 %	0,8791
QKM 1	76,39 %	81,90 %	82,06 %	11,73 %	23,23 %	76,77 %	88,27 %	0,9085
QKM 2	77,37 %	81,39 %	81,94 %	14,15 %	21,38 %	78,62 %	85,85 %	0,9043
QKM 3	79,38 %	<b>82,17 %</b>	<b>83,01 %</b>	14,82 %	18,84 %	81,16 %	85,18 %	<b>0,9120</b>
QKM 4	79,19 %	77,76 %	79,91 %	23,62 %	17,09 %	82,91 %	76,38 %	0,8793
QKM 5	75,21 %	81,06 %	81,11 %	12,09 %	24,67 %	75,33 %	87,91 %	0,9041
QKM 6	70,24 %	78,81 %	77,80 %	<b>10,24 %</b>	32,38 %	67,62 %	<b>89,76 %</b>	0,8865

## 4.5. Discusión

Observando los resultados de las tablas 4-15 y 4-16, se determina que en la mayoría de los modelos muestran un mejor desempeño en la correcta clasificación de las imágenes satelitales correspondientes al grupo *Frontera* agrícola; por lo que, se debe perfeccionar la identificación de las imágenes satelitales correspondiente al grupo *No Frontera* agrícola. De igual forma, son los modelos *Quantum Kernel Mixtures* los que presentan una mejor generalización al comparar los resultados de precisión, F1 score y exactitud entre el conjunto de prueba 1 y prueba 2, ya que si se observa una mejoría. De forma contraria, los modelos de transferencia y *shallow convolutional* presentan menores valores para estas métricas en el conjunto de prueba 2.

Para el conjunto de prueba 1, el **modelo MobileNet** es el que presenta mejor desempeño en forma general, como se observa en sus métricas de precisión, F1 score y exactitud; y adicionalmente, es el modelo que mejor desempeño tiene en la correcta clasificación de las imágenes satelitales correspondientes al grupo de *Frontera* agrícola. Por otra parte, el **modelo ResNet50** es el que presenta mejor desempeño en la correcta clasificación de las imágenes satelitales correspondientes al grupo de *No Frontera* agrícola de este conjunto de prueba 1 y el que tiene más área bajo la curva ROC. Mostrando una cierta superioridad de los modelos de transferencia sobre los modelos entrenados desde cero, los *shallow convolutional* y los *Quantum Kernel Mixtures*. Sin embargo, para el conjunto de prueba 2, que realiza una evaluación de la generalización de los modelos de mejor forma ya que hace parte a otra área geográfica de Colombia, los modelos con arquitecturas más simples y entrenados desde cero son los que presentan mejor desempeño sobre los modelos de transferencia. Para este conjunto de prueba 2, el **modelo shallow convolutional 3** es el que presenta mejor precisión; el **modelo Quantum Kernel Mixtures 3** es el que mejor valor presenta para el F1 score, la exactitud y el área bajo la curva ROC; el **modelo Quantum Kernel Mixtures 6** es el que presenta mejor desempeño en la correcta clasificación de las imágenes satelitales correspondientes al grupo *No Frontera* agrícola; y el **modelo Inception V3** es el que muestra el mejor desempeño en la correcta clasificación de los imágenes satelitales correspondientes al grupo *Frontera* agrícola. Por lo tanto, por este primer método de clasificación directa de las imágenes satelitales de Colombia, los modelos pequeños y entrenados desde cero, más específicamente los *Quantum Kernel Mixtures*, son los que presentan la mejor generalización en esta tarea de clasificación.

# 5 Tarea de regresión

En este capítulo se expone la configuración experimental y los resultados de los modelos con los que se evaluaron esta tarea, con una discusión acerca de los resultados de cada modelo.

Este capítulo se encuentra organizado en cuatro secciones: la sección se muestra de forma general las arquitecturas de los modelos con una breve explicación de sus labores para el aprendizaje de esta tarea de regresión. De esta manera, en la sección 5.2 explica cómo se distribuyeron los conjuntos para el entrenamiento, validación y prueba para esta tarea. Al igual que para la tarea de clasificación, se hicieron tres grupos comparativos de modelos; los modelos grandes de *ImageNet*, los modelos convolucionales de pequeñas arquitecturas llamados *shallow convolutional* y los modelos basados en *Quantum Kernel Mixture*. Luego, en la sección 5.3 se muestra los resultados sobre el conjunto de prueba de todos los modelos: *ResNet50*, *VGG 19*, *MobileNet* e *Inception V3*, cuatro modelos de *shallow convolutional* y seis modelos de *Quantum Kernel Mixtures*. Finalmente, en la sección 5.4 se realiza una discusión sobre los resultados obtenidos.

## 5.1. Arquitectura Propuesta

Se muestran de forma general los componentes de la arquitectura de los modelos de transferencia, los modelos *Shallow Convolutional* y los modelos *Quantum Kernel Mixtures*; propuestos para el desarrollo de esta tarea.

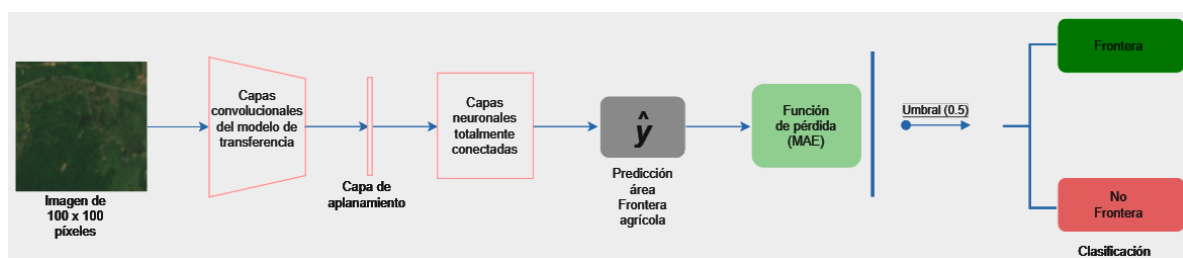
### 5.1.1. Modelos de transferencia

Se escoge trabajar con cuatro modelos entrenados en la competencia *ImageNet* para realizar una transferencia para esta tarea de regresión del área de frontera agrícola con imágenes satelitales en Colombia. Estos modelos son: *ResNet50*, *VGG 19*, *MobileNet* e *Inception V3*; donde todos son descargados con sus pesos de la competencia de la biblioteca *tensorflow*<sup>1</sup> y se obtiene una arquitectura de capas convolucionales seguida por una capa de aplanamiento (Flatten).

---

<sup>1</sup>Ver: [https://www.tensorflow.org/api\\_docs/python/tf/keras/applications](https://www.tensorflow.org/api_docs/python/tf/keras/applications)

Todos estos modelos se basan en la arquitectura que se muestra en la figura 5-1, donde se empieza especificando que su entrada de imágenes satelitales es de 100 por 100 píxeles. Luego, estas imágenes satelitales pasan por las capas convolucionales del modelo de transferencia correspondiente, que es donde se identifica y extrae la información de estas imágenes satelitales para la regresión de zonas agrícolas. Posterior a la capa de aplanamiento, se agregan unas capas de neuronas totalmente conectadas encargadas de interpretar esa información adquirida anteriormente y predecir el porcentaje de área agrícola dentro de la imagen satelital, por lo que la última capa consta de una neurona. Teniendo en cuenta que la función de pérdida durante el proceso de entrenamiento es el error cuadrático (MAE) y su métrica para evaluar su desempeño durante su entrenamiento es el error cuadrático (MAE).



**Figura 5-1:** Arquitectura general de los modelos de transferencia para la tarea de regresión.

El entrenamiento de estos modelos de transferencia se realiza en dos etapas: la primera etapa se llama aprendizaje por transferencia, donde no se permite el entrenamiento de las capas convolucionales del modelo de transferencia evitando que se modifiquen los pesos de estas conexiones. Esto mientras se define la cantidad de capas neuronales densas y la cantidad de neuronas por capa, que van después de las capas convolucionales del modelo de transferencia. Una vez definida la arquitectura del bloque de capas neuronales densas, se prosigue a la segunda etapa, el refinamiento, donde se permite la actualización de los pesos de las capas convolucionales de los modelos de transferencia y del bloque de capas neuronales densas mientras se varía el valor de la tasa de aprendizaje y así obtener un mejor desempeño en las métricas.

Una vez finalizado todo el proceso de entrenamiento, se utiliza el umbral de 0,5 para determinar si la correspondiente imagen satelital pertenece al grupo de *Frontera* agrícola o *No*. Donde si es igual o mayor a 0,5 es *Frontera* agrícola; de lo contrario, es *No Frontera* agrícola.

### Modelo Resnet50

La arquitectura del modelo *ResNet50* desarrollada en [10] se puede observar en la figura 4-2. El modelo *ResNet50* se identifica ya que realiza conexiones secuenciales en las capas convo-

lucionales, y adicionalmente, realiza conexiones saltando capas principalmente para evitar el desvanecimiento del error durante el proceso de backpropagation. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

Posterior a descargar el modelo *ResNet50* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla **5-1**. Como se está prediciendo el porcentaje de área agrícola, la última capa de neuronas densas consta de una neurona con una función de activación igual a *sigmoid*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $8\epsilon^{-5}$ , un optimizador de *Adam* y un tamaño de lote igual a 128.

**Tabla 5-1:** Arquitectura del modelo ResNet50 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo ResNet50
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (30 %)
Capa de neuronas densas (512 neuronas)
Dropout (15 %)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo VGG 19

La arquitectura del modelo *VGG 19* desarrollada en [31] se puede observar en la figura **4-3**. El modelo *VGG 19* tiene una profundidad de 19 capas con unos filtros de convolución pequeños (3x3). Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

Posterior a descargar el modelo *VGG 19* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla **5-2**. Como se está prediciendo el porcentaje de área agrícola, la última capa de neuronas densas consta de una neurona con una función de activación igual a *sigmoid*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $1\epsilon^{-4}$ , un optimizador de *Adam* y un tamaño de lote igual a 128.

**Tabla 5-2:** Arquitectura del modelo VGG 19 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo VGG 19
Capa de aplanamiento (Flatten)
Capa de neuronas densas (512 neuronas)
Dropout (40 %)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo MobileNet

La arquitectura del modelo *MobileNet* desarrollada en [13] se puede observar en la figura 4-4. El modelo *MobileNet* se basa en una arquitectura simplificada que utiliza convoluciones separables en profundidad para construir redes neuronales con estructura ligera y profunda. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

Posterior a descargar el modelo *MobileNet* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 5-3. Como se está prediciendo el porcentaje de área agrícola, la última capa de neuronas densas consta de una neurona con una función de activación igual a *sigmoid*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $1\epsilon^{-3}$ , un optimizador de *Adam* y un tamaño de lote igual a 128.

**Tabla 5-3:** Arquitectura del modelo MobileNet para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo MobileNet
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (40 %)
Capa de neuronas densas (128 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo Inception V3

La arquitectura del modelo *Inception V3* desarrollada en [32] se puede observar en la figura 4-5. El modelo *Inception V3* cuenta con capas en un solo nivel que se conforman de múltiples filtros de diferentes tamaños; lo que hace un modelo más ancho en vez de profundo por tener capas en paralelo. Estas capas en paralelo se observan en la figura 4-6, que es lo que aparece dentro de la arquitectura del modelo *Inception V3*. Este modelo se descarga de la biblioteca *tensorflow* con los pesos de la competencia de *ImageNet* pero sin las capas neuronales densas posteriores a la capa de aplanamiento, definiendo el tamaño de entrada de los datos como 100 por 100 píxeles y que tenga un pooling igual a average.

Posterior a descargar el modelo *Inception V3* y de realizar las dos etapas de entrenamiento en este modelo, se define la arquitectura del modelo igual a lo que se observa en la tabla 5-4. Como se está prediciendo el porcentaje de área agrícola, la última capa de neuronas densas consta de una neurona con una función de activación igual a *sigmoid*. Finalmente, los valores de los hiperparámetros: tasa de aprendizaje igual a  $1\epsilon^{-4}$ , un optimizador de *Adam* y un tamaño de lote igual a 128.


**Tabla 5-4:** Arquitectura del modelo Inception V3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capas convolucionales del modelo Inception V3
Capa de aplanamiento (Flatten)
Capa de neuronas densas (1024 neuronas)
Dropout (30 %)
Capa de neuronas densas (1 neurona)

#### 5.1.2. modelos shallow convolutional

Estos modelos son de arquitectura más pequeña en comparación a los modelos de transferencia, tal como se muestra en la figura 5-2. Estos modelos tienen una entrada de imagen igual a 100 por 100 píxeles, seguido por una capa *Lambda* convirtiendo cada ejemplo en un formato de float 32 y se subtrae 0,5. Posteriormente, los datos pasan por un bloque de capas convolucionales que extraen e identifican las características de las imágenes satelitales para esta tarea de regresión. Luego, una capa de aplanamiento para proseguir un bloque de capas neuronales densas totalmente conectadas; las cuales interpretan la información proveniente de las capas convolucionales y predecir el porcentaje de área agrícola dentro de la imagen satelital, por lo que la última capa consta de una neurona. Teniendo en cuenta que la función de pérdida durante el proceso de entrenamiento es el error cuadrático (MAE) y su métrica para evaluar su desempeño durante su entrenamiento es el error cuadrático (MAE).





**Figura 5-2:** Arquitectura general de los modelos *shallow convolutional* para la tarea de regresión.

El entrenamiento de estos modelos *shallow convolutional* se realiza en una etapa: una vez definida la arquitectura del modelo en estudio, se entrena el modelo variando el valor de la tasa de aprendizaje. Una vez finalizado todo el proceso de entrenamiento, se utiliza el umbral de 0,5 para determinar si la correspondiente imagen satelital pertenece al grupo de *Frontera* agrícola o *No*. Donde si es igual o mayor a 0,5 es *Frontera* agrícola; de lo contrario, es *No Frontera* agrícola.

### Modelo shallow convolutional 1

La arquitectura de este modelo se puede observar en la tabla 5-5 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-5}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-5:** Arquitectura del modelo shallow convolutional 1 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (7x7x64)
Capas convolucional (1x1x256)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (64 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo shallow convolutional 2

La arquitectura de este modelo se puede observar en la tabla 5-6 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-3}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-6:** Arquitectura del modelo shallow convolutional 2 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (34x34x32)
Capas convolucional (34x34x64)
Capas convolucional (34x34x64)
Capas convolucional (28x28x144)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (36 neuronas)
Capa de neuronas densas (36 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo shallow convolutional 3

La arquitectura de este modelo se puede observar en la tabla 5-7 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-3}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-7:** Arquitectura del modelo shallow convolutional 3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (2x2x64)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Batch Normalization
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (1 neurona)

### Modelo shallow convolutional 4

La arquitectura de este modelo se puede observar en la tabla 5-8 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-5}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-8:** Arquitectura del modelo shallow convolutional 4 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

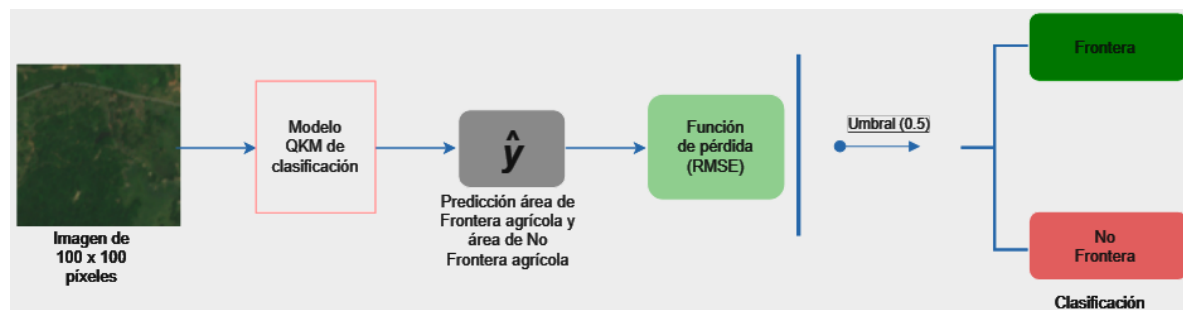
Entrada de imagen satelital (100x100x3)
Capa Lambda (tf.float32) - 0,5
Capas convolucional (100x100x32)
Capas convolucional (25x25x32)
Capas convolucional (13x13x64)
Capas convolucional (7x7x64)
Capas convolucional (1x1x64)
Capa de aplanamiento (Flatten)
Capa de neuronas densas (64 neuronas)
Batch Normalization
Capa de neuronas densas (32 neuronas)
Batch Normalization
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (16 neuronas)
Capa de neuronas densas (1 neurona)

### 5.1.3. Modelos Quantum Kernel Mixtures

El modelo *Quantum Kernel Mixtures*<sup>2</sup>, también llamadas *kernel density matrices*, fue desarrollado en [7], los cuales se basan en las matrices de densidad en el espacio de kernel. Estas matrices de densidad son la forma más general de describir el estado de un sistema cuántico y que permite ser definidas en un espacio de kernel de Hilbert. Estas matrices de densidad en el espacio de kernel son un mecanismo versátil que representa tanto distribuciones probabilísticas continuas como discretas. Lo cual convierte a este método capaz de desarrollar inferencias diferenciables, composicionales y reversibles permitiendo la aplicación en un amplio rango de tareas de aprendizaje de máquina[7].

Como se observa en la figura **5-3**, la aplicación de este modelo es simple ya que consta de un único componente de modelo *Quantum Kernel Mixtures*. Sin embargo, deben especificarse varios hiperparámetros para su entrenamiento, los cuales son: el número de componentes (`n_comp`) siendo la cantidad de componentes del conjunto QKM; el tamaño del parche (`patch_size`) siendo el tamaño del cuadro para la extracción de parches de la imagen; el tamaño del encoder (`encoder_size`) haciendo referencia a la dimensión del estado de entrada para la capa QKM; el tamaño del paso (`strides`) siendo el paso durante la extracción de parches de las imágenes; la dimensión de salida (`dim_y`) correspondiente a la dimensión del estado de salida; el tamaño de la imagen (`image_size`) y el codificador (`encoder`) que transforma las dimensiones de los parches de las imágenes al tamaño deseado para el modelo.

<sup>2</sup>Ver: Quantum Kernel Mixtures, <https://github.com/fagonzalezo/quakemix>



**Figura 5-3:** Arquitectura general de los modelos de *Quantum Kernel Mixtures* para la tarea de regresión.

El entrenamiento de estos modelos *Quantum Kernel Mixtures* se realiza en una etapa: una vez definida la arquitectura del modelo en estudio, se entrena el modelo variando el valor de la tasa de aprendizaje. Teniendo en cuenta la que la función de pérdida es el error de raíz cuadrada media (RMSE) y la métrica de desempeño es categorical accuracy. Una vez finalizado todo el proceso de entrenamiento, se utiliza el umbral de 0,5 para determinar si la correspondiente imagen satelital pertenece al grupo de *Frontera* agrícola o *No*. Donde si es igual o mayor a 0,5 es *Frontera* agrícola; de lo contrario, es *No Frontera* agrícola.

### Modelo Quantum Kernel Mixtures 1

La arquitectura de este modelo se puede observar en la tabla 5-9 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-3}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-9:** Hiperparámetros del modelo Quantum Kernel Mixtures 1 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	16
strides	4
dim_y	2
image_size	100
encoder	capa densa (encoded_size*2) Batch Normalization capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 2

La arquitectura de este modelo se puede observar en la tabla 5-10 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-3}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-10:** Hiperparámetros del modelo Quantum Kernel Mixtures 2 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	patch_size*patch_size
strides	4
dim_y	2
image_size	100
encoder	capa densa (encoded_size*4) Batch Normalization capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 3

La arquitectura de este modelo se puede observar en la tabla 5-11 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-11:** Hiperparámetros del modelo Quantum Kernel Mixtures 3 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	3
encoded_size	patch_size*patch_size
strides	6
dim_y	2
image_size	100
encoder	capa densa (encoded_size*2) Batch Normalization Dropout (30 %) capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 4

La arquitectura de este modelo se puede observar en la tabla 5-12 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-3}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-12:** Hiperparámetros del modelo Quantum Kernel Mixtures 4 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	patch_size*patch_size*3
strides	4
dim_y	2
image_size	100
encoder	lambda x: x

### Modelo Quantum Kernel Mixtures 5

La arquitectura de este modelo se puede observar en la tabla 5-13 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-13:** Hiperparámetros del modelo Quantum Kernel Mixtures 5 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	16
strides	4
dim_y	2
image_size	100
encoder	capa densa (encoded_size*4) Batch Normalization Dropout (40%) capa densa (encoded_size)

### Modelo Quantum Kernel Mixtures 6

La arquitectura de este modelo se puede observar en la tabla 5-14 y luego de llevar a cabo la etapa de entrenamiento, se obtienen los siguientes hiperparámetros: la tasa de aprendizaje de  $1\epsilon^{-4}$ , el optimizador es *Adam* y el tamaño del lote es de 128 imágenes satelitales.

**Tabla 5-14:** Hiperparámetros del modelo Quantum Kernel Mixtures 6 para la tarea de regresión del porcentaje de área agrícola en las imágenes satelitales.

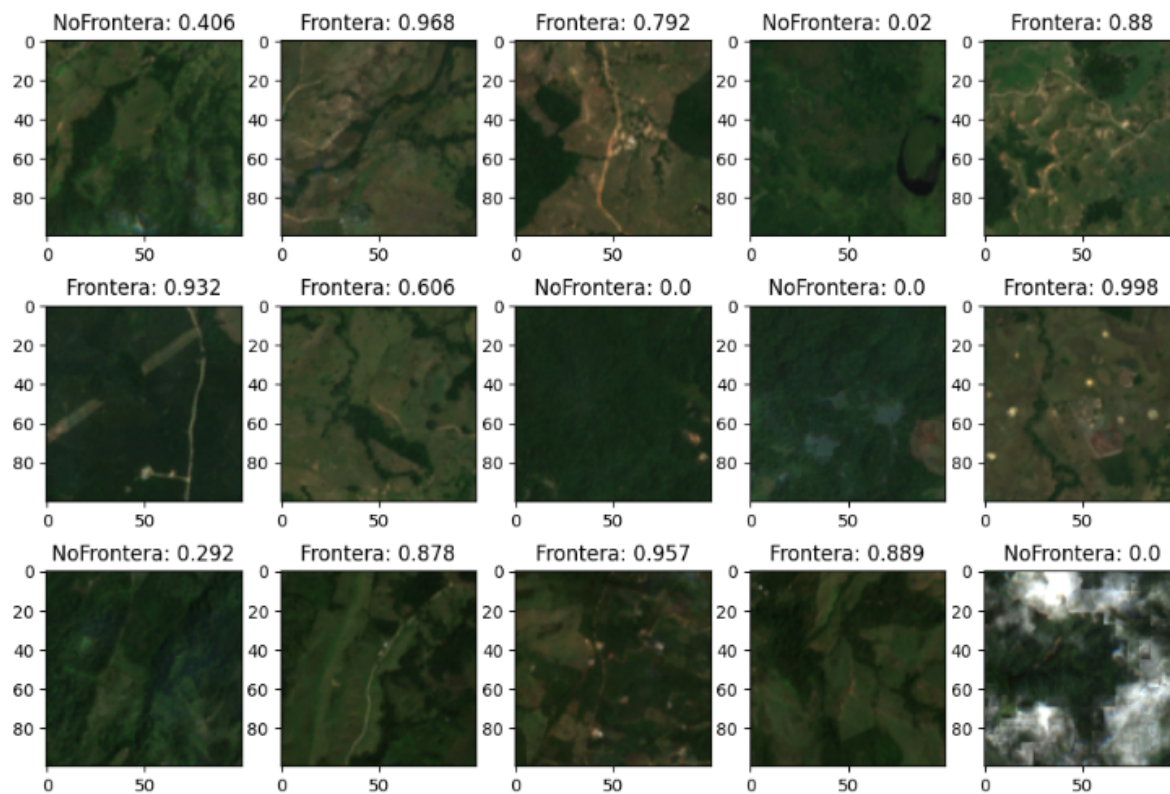
Hiperparámetro	Valor
n_comp	128
patch_size	8
encoded_size	patch_size*patch_size*3
strides	4
dim_y	2
image_size	100
encoder	capa convolucional 1D (encoded_size, 5, 1) Batch Normalization capa densa (encoded_size)

## 5.2. Configuración experimental

Para esta tarea de regresión se construyeron los conjuntos de entrenamiento, validación y prueba, tal como se observa en la tabla 3-2, donde se define el tamaño de las imágenes igual a 100 por 100 píxeles, y se deja como etiqueta el valor decimal de la cantidad de área en kilómetros cuadrados que es utilizada como zona agrícola en Colombia que varía entre cero y uno; así como se observa en la figura 5-4.

Adicionalmente se visualiza un mapa de calor y un histograma para ver el comportamiento de las imágenes en función de la cantidad de zona agrícola en el conjunto de prueba. Para evaluar el desempeño de los modelos y compararlos entre sí se utilizan varias métricas, la primera es el error absoluto medio (MAE); y para las otras métricas, se determina el umbral de 0,5 para determinar si una imagen es *Frontera* o *No Frontera* y de esta forma mirar: la precisión, el F1-score, la exactitud, el error tipo 1, el error tipo 2, la sensibilidad, la especificidad y el área bajo la curva ROC.


En la figura 5-5 se explora el comportamiento o distribución de la zona que conforman las 4.225 imágenes del conjunto de prueba con respecto a la cantidad de área de frontera agrícola en kilómetros cuadrados tomando valores entre cero (rojo) y uno (verde); esto debido a que el tamaño de las imágenes son de un kilómetro por un kilómetro. Por otra parte, en la imagen




**Figura 5-4:** Visualización de las imágenes utilizadas para el entrenamiento, validación y prueba de los modelos de regresión. Elaboración propia.

**5-6** se observa un comportamiento bimodal en el conteo de las imágenes en función de la cantidad de área agrícola dentro de cada una; donde se presenta una gran concentración de imágenes en valores entre 0 y 0,1. Además, se presenta una gran disminución de cantidad de imágenes para valores mayores a 0,1 pero va aumentando progresivamente.






**Figura 5-5:** Mapa de calor del conjunto de prueba en función del área de frontera agrícola. Elaboración propia.



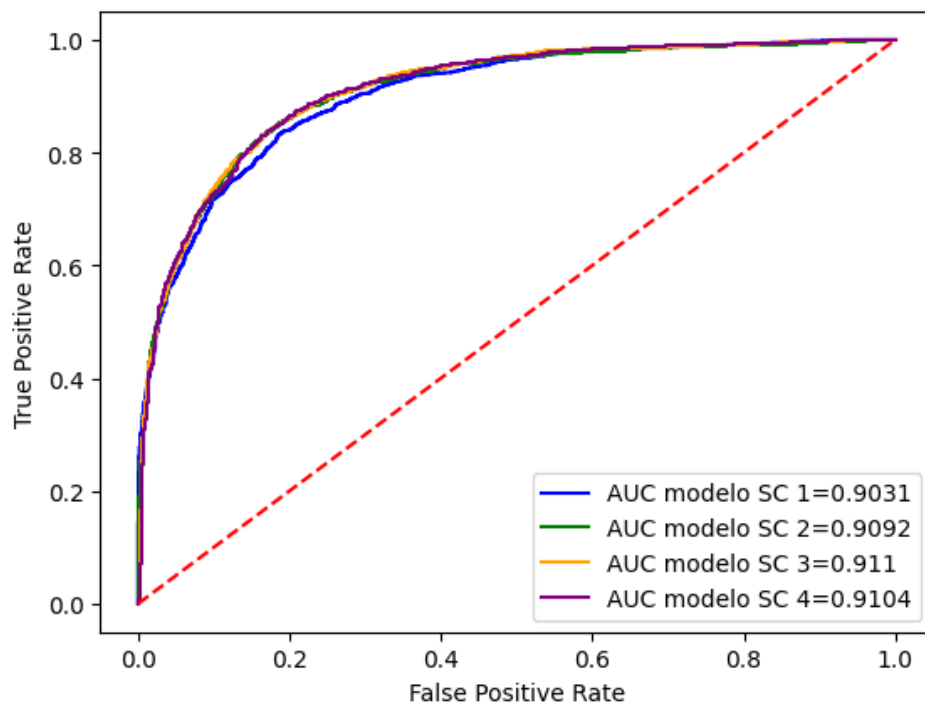
**Figura 5-6:** Histograma del conjunto de prueba en función del área de frontera agrícola. Elaboración propia.

### 5.3. Resultados sobre el conjunto Prueba


Se evalúan los cuatro modelos de transferencia, los cuatro modelos *shallow convolutional* (SC) y los seis modelos *Quantum Kernel Mixtures* (QKM) sobre el conjunto de prueba que consta de 4.225 imágenes, tal como se observa en la tabla 3-2. Los resultados de estos catorce modelos se muestran en la tabla 5-15 pero se realiza una gráfica mostrando las curvas ROC por grupo de familia de modelos, obteniendo las figuras 5-7, 5-8 y 5-9, para los modelos de transferencia, modelos *shallow convolutional* y modelos *Quantum kernel Mixtures* respectivamente. De igual forma, se realiza una visualización de la reconstrucción del área agrícola de prueba con cada modelo agrupándolos en sus respectivas familias de modelos; tal como se observa en las figuras 5-11, 5-10 y 5-12.



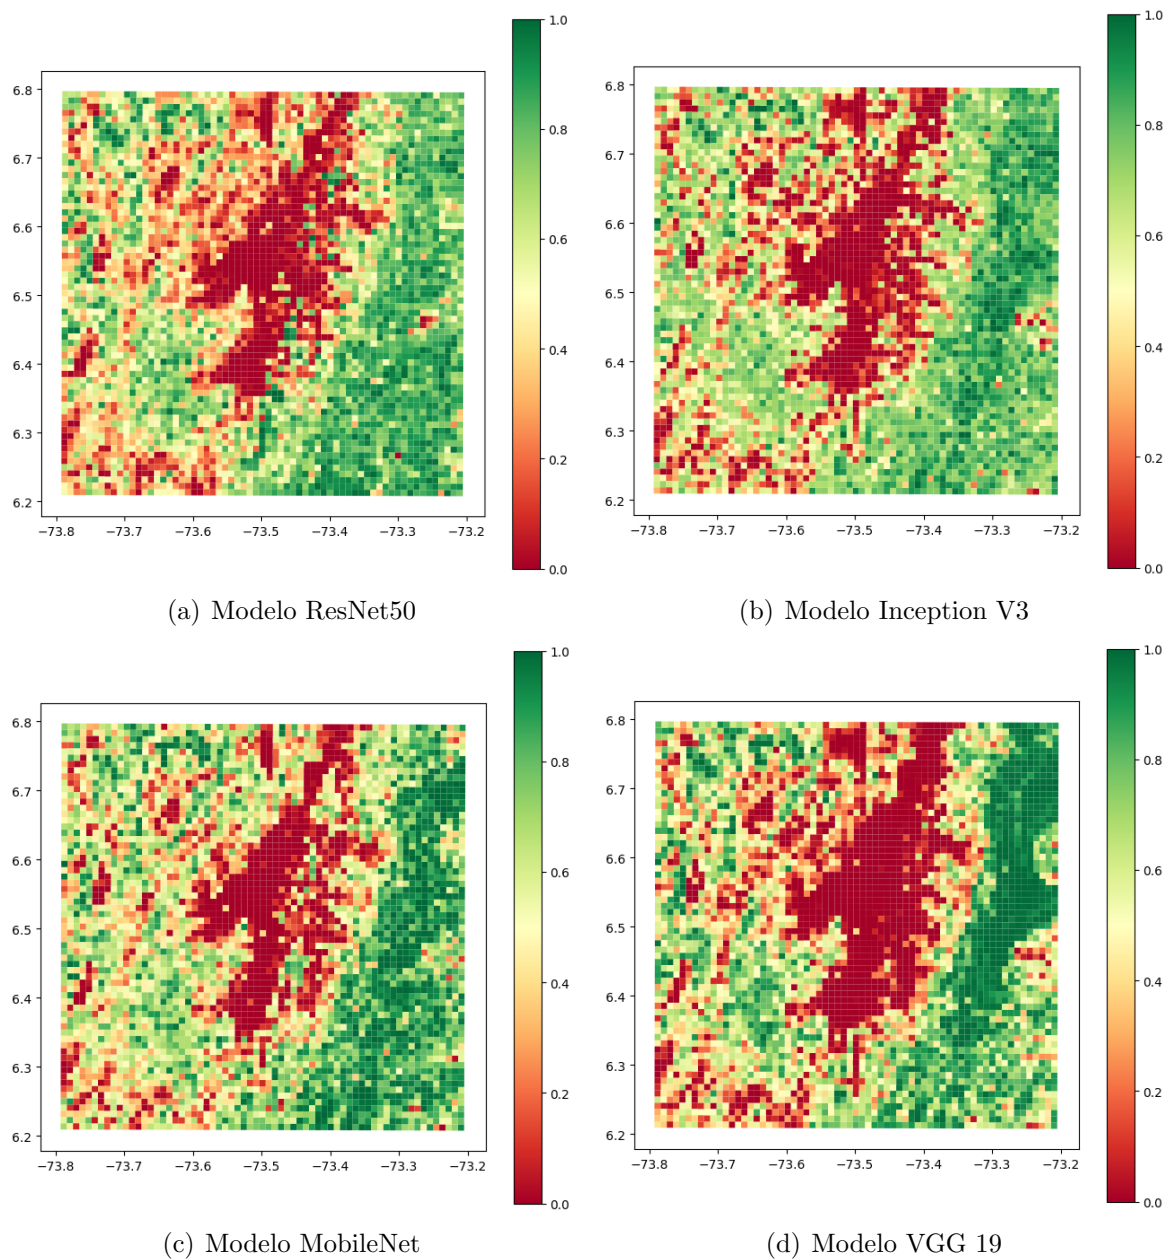
**Figura 5-7:** Curvas ROC de los modelos de transferencia para el conjunto de prueba en la tarea de regresión.



**Figura 5-8:** Curvas ROC de los modelos *shallow convolutional* para el conjunto de prueba en la tarea de regresión.



**Figura 5-9:** Curvas ROC de los modelos *Quantum Kernel Mixtures* para el conjunto de prueba en la tarea de regresión.



**Figura 5-10:** Reconstrucción de la zona agrícola de prueba con los modelos de transferencia

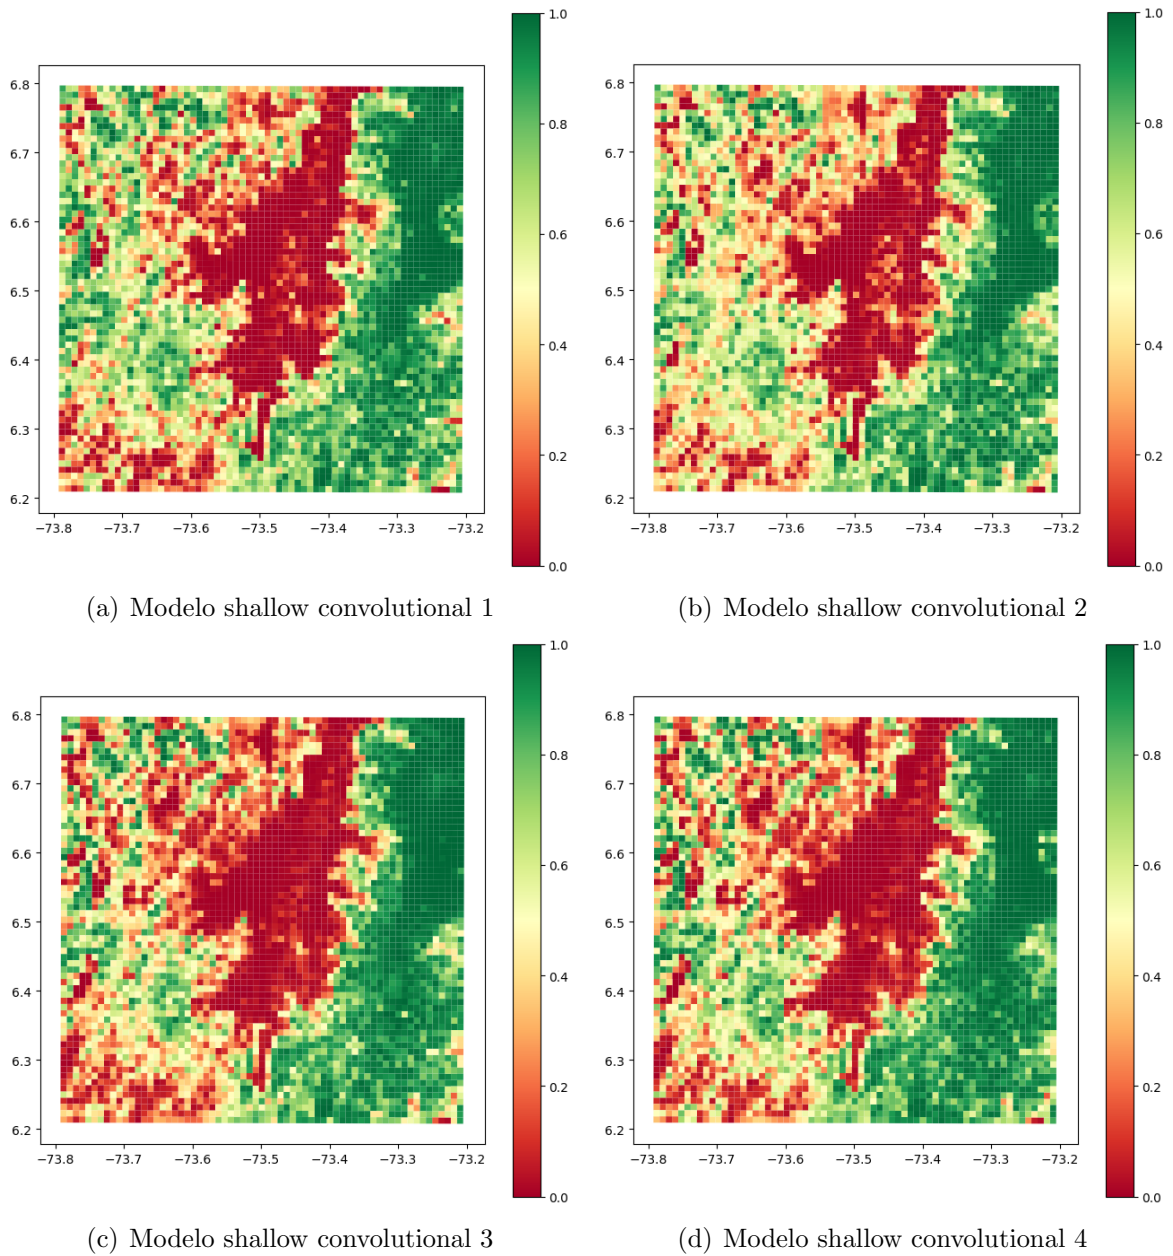
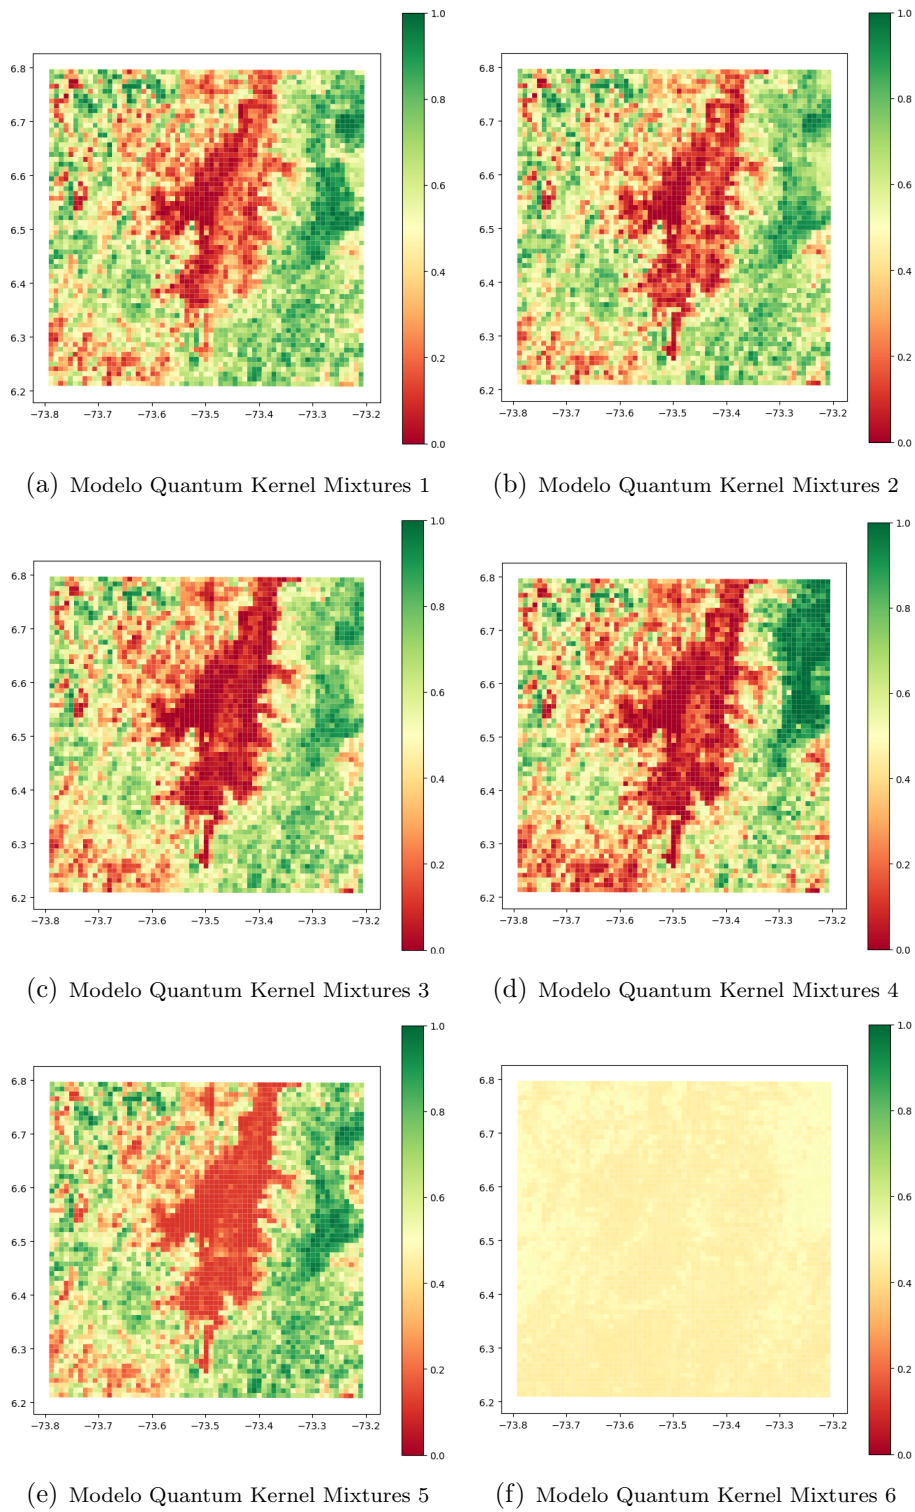


Figura 5-11: Reconstrucción de la zona agrícola de prueba con los modelos shallow convolutional



**Figura 5-12:** Reconstrucción de la zona agrícola de prueba con los modelos Quantum Kernel Mixtures

**Tabla 5-15:** Resultados sobre el conjunto de prueba con los 14 modelos de estudio en la tarea de regresión.

Modelo	Test MAE	Precisión	F1-Score	Exactitud	Error tipo 1	Error tipo 2	Sensibilidad	Especificidad	AUC ROC
ResNet50	0,1747	82,00 %	81,73 %	80,33 %	21,00 %	18,54 %	81,46 %	79,00 %	0,8715
Inception V3	0,1710	77,88 %	82,67 %	80,05 %	29,39 %	<b>11,92 %</b>	<b>88,08 %</b>	70,61 %	0,8921
MobileNet	0,1724	78,16 %	81,72 %	79,31 %	28,10 %	14,37 %	85,63 %	71,90 %	0,8784
VGG 19	0,1555	84,14 %	82,12 %	81,14 %	17,76 %	19,81 %	80,19 %	82,24 %	0,8972
SC 1	0,1513	82,07 %	83,32 %	81,70 %	21,72 %	15,38 %	84,62 %	78,28 %	0,9031
SC 2	<b>0,1460</b>	83,16 %	<b>84,74 %</b>	83,20 %	20,54 %	13,63 %	86,37 %	79,46 %	0,9092
SC 3	0,1494	<b>88,23 %</b>	82,70 %	82,41 %	12,20 %	22,17 %	77,83 %	87,80 %	<b>0,9110</b>
SC 4	0,1495	84,95 %	84,38 %	<b>83,24 %</b>	17,45 %	16,17 %	83,83 %	82,55 %	0,9104
QKM 1	0,1802	82,53 %	83,06 %	81,59 %	20,79 %	16,39 %	83,61 %	79,21 %	0,8946
QKM 2	0,1866	80,97 %	82,06 %	80,36 %	22,95 %	16,83 %	83,17 %	77,05 %	0,8833
QKM 3	0,1750	85,39 %	81,75 %	81,09 %	15,75 %	21,60 %	78,40 %	84,25 %	0,8935
QKM 4	0,1860	87,77 %	75,37 %	76,69 %	10,81 %	33,96 %	66,04 %	89,19 %	0,8833
QKM 5	0,1804	81,69 %	82,66 %	81,04 %	22,03 %	16,35 %	83,65 %	77,97 %	0,8940
QKM 6	0,3208	84,59 %	21,43 %	51,41 %	<b>2,62 %</b>	87,73 %	12,27 %	<b>97,38 %</b>	0,6334

## 5.4. Discusión

Este método de clasificación indirecta partiendo desde modelos de regresión que predicen el porcentaje de área agrícola dentro de imágenes satelitales brinda una revisión de los modelos no solo con métricas de clasificación binaria, sino que, permite revisar y comparar la métrica del error absoluto medio (MAE). Con la cual se puede realizar una reconstrucción de la zona de interés o prueba y poder compararlo con la distribución original de la zona (figura 5-5). A partir de esto, observando la métrica MAE y en la reconstrucción de la zona de prueba, detallando el patrón y distribución de las áreas agrícolas, el **modelo shallow convolucional 2** es el que tiene el mejor desempeño (figura 5.11(b)). Por otro lado, observando la tabla 5-15, los modelos que presentan mejores valores con respecto a las métricas de precisión, F1 score y exactitud son los *shallow convolutional*, más específicamente el **modelo shallow convolucional 3**, el **modelo shallow convolucional 2** y el **modelo shallow convolucional 4**, respectivamente. Por otro lado, es el **modelo Inception V3** que presenta el mejor desempeño en la correcta clasificación de las imágenes satelitales correspondientes al grupo *Frontera* agrícola. Mientras que, es el **modelo Quantum Kernel Mixtures 6** que presenta el mejor desempeño en la correcta clasificación de las imágenes satelitales correspondientes al grupo *No Frontera* agrícola. Sin embargo, este **modelo Quantum Kernel Mixtures 6** predice el valor de porcentaje de área agrícola dentro de una imagen satelital alrededor del valor del 50 % (figura 5.12(f)), y en su mayoría tiende a etiquetarlos como *No Frontera* agrícola, tal como se observa en sus resultados (tabla 5-15). Por lo tanto, este modelo es poco útil; es por esto que, al observar el segundo mejor valor en la tabla 5-15 para la métrica especificidad, el **modelo Quantum Kernel Mixtures 4** con un valor de 89,19 %, presenta mejor utilidad que el **modelo Quantum Kernel Mixtures 6**. En consecuencia, por este método de clasificación indirecta partiendo de modelos de regresión, muestra mejores desempeños con modelos de arquitectura más simple y entrenándolos desde cero, más específicamente los modelos *shallow convolutional*, ya que muestran una buena generalización con zonas geográficas distintas en Colombia.



## 6 Conclusiones y trabajo futuro

En este trabajo se crea un conjunto de imágenes satelitales sobre Colombia que informa sobre las zonas de frontera agrícola identificadas por parte del gobierno nacional, con el cuál se pueden hacer otros tipos de investigaciones que brinden un apoyo en el desarrollo nacional en lo que respecta a la agricultura; además, permite un evalúo más rápido sobre el uso de las tierras para un mejor aprovechamiento.

Adicionalmente, se desarrollan varios modelos que identifican las zonas donde se encuentra la frontera agrícola por medio de la clasificación de las imágenes satelitales. Para llevar a cabo esto, se utilizan dos aproximaciones con tres diferentes arquitecturas de modelos para realizar un análisis de cuál aproximación da mejores resultados y qué arquitectura tiene mejor comportamiento para esta tarea de clasificación.

Los modelos utilizados en este trabajo se agruparon en tres categorías: la primera categoría hace referencia a los modelos de transferencia, los cuales fueron entrenados en la competencia *ImageNet*, que presentan arquitecturas de gran tamaño y han sido utilizados en diversos trabajos y tareas mostrando buenos resultados. La segunda categoría respecta a modelos de arquitecturas pequeñas, denominados *shallow convolutional*, debido a la reducida cantidad de capas convolucionales y capas densas usadas; con el fin de mostrar el desempeño de modelos más simples y desarrollados para esta tarea de clasificación. Por último, la tercera categoría parte del mismo principio que en el segundo grupo, utilizar modelos con arquitecturas simples. Este tercer grupo corresponde a la familia de los modelos *Quantum Kernel Mixtures* ya que se basan en las matrices de densidad en espacio de kernel; siendo un principio de la computación cuántica, y que muestra una comprensión más profunda en las distribuciones de probabilidad tanto continuas como discretas.

Como se observa en el documento, las dos aproximaciones para la clasificación de las imágenes satelitales fueron: la primera que es el método directo de entrenar los modelos para la clasificación binaria de *Frontera* agrícola o *No*; y la segunda, en la que primero se entrena el modelo como una tarea de regresión donde se busca predecir el valor decimal de la cantidad de área de frontera agrícola dentro de cada imagen y se le asignaba la etiqueta de *Frontera* a los valores iguales o mayores a 0.5. De tal forma que, en este segundo método se obtiene una información adicional para evaluar los modelos, mirando la distribución, la forma e intensidad en la que se recreaba la zona de prueba y por la métrica del error absoluto medio.

A partir de esto, se analiza que para ambos métodos de clasificación los modelos de transferencia son los que menor valor de exactitud obtiene dando la intuición de que para esta tarea con este tipo de imágenes satelitales, es mejor utilizar arquitecturas más simples. Sin embargo, son los modelos de transferencia los que mejor comportamiento presentan para etiquetar las imágenes satelitales correspondientes al grupo de *Frontera* agrícola. Por otro lado, los modelos *shallow convolutional* y *Quantum Kernel Mixtures* demuestran que el uso de modelos más sencillos frente a este tipo de tareas pueden mostrar mejores resultados. Adicionalmente, los modelos *Quantum Kernel Mixtures* por ambos métodos de entrenamiento son los que mejor identifica las imágenes satelitales correspondientes al grupo de *No Frontera* agrícola, mostrando una gran ventaja por medio del uso de las matrices de densidad en espacio de kernel.

Por otro lado, por el método de regresión para la clasificación de zonas agrícolas en imágenes satelitales de Colombia, los modelos *shallow convolutional* son los que presentan el mejor desempeño global en las métricas de precisión, F1 score y exactitud. Adicionalmente, estos modelos *shallow convolutional* son los que mejor reconstruyen la zona agrícola de prueba.

El trabajo futuro contempla en no solo identificar las imágenes como *Frontera* agrícola o *No*, sino que, dar el valor decimal del área de zona agrícola dentro de la imagen y mostrar cómo es su distribución o forma dentro de cada imagen por medio de máscaras. Adicionalmente, en la discretización agrícola para brindar una mejor información respecto a la distribución y uso de las tierras en Colombia.

# Bibliografía

- [1] DE AGRICULTURA, Ministerio (Ed.): *Metodología para la identificación general de la frontera agrícola en Colombia*. Unidad de Planificación Rural Agropecuaria, 2018
- [2] CHATTERJEE, A. ; SHA, J. ; MUKHERJEE, J. ; AIKAT, S. ; MISRA, A.: Unsupervised land cover classification of hybrid and dual-polarized images using deep convolutional neural network. En: *IEEE Geoscience and Remote Sensing Letters* 18 (6) (2021), p. 969–973
- [3] CHEN, Z. ; WANG, Y. ; HAN, W. ; FENG, R. ; CHEN, J.: An improved pretraining strategy-based scene classification with deep learning. En: *IEEE Geoscience and Remote Sensing Letters* 15 (5) (2020), p. 844–848
- [4] CHENG, G. ; XIE, X. ; HAN, J. ; GUO, L. ; XIA, G.: Remote sensing image scene classification meets deep learning: challenges, methods, benchmarks, and opportunities. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13 (2020), p. 3735–3756
- [5] DAI, X. ; WU, X. ; WANG, B. ; ZHANG, L.: Semisupervised scene classification for remote sensing images: a method based on convolutional neural networks and ensemble learning. En: *IEEE Geoscience and Remote Sensing Letters* 16 (6) (2019), p. 869–873
- [6] GAO, Y. ; LI, Q.: A segmented particle swarm optimization convolutional neural network for land cover and land use classification of remote sensing images. En: *Remote Sensing Letters* 10 (12) (2019), p. 1182–1191
- [7] GONZÁLEZ, F. ; RAMOS-POLLÁN, R. ; GALLEGO-MEJIA, J.: Kernel density matrices for probabilistic deep learning. En: *arXiv: 2305.18204v2* (2023)
- [8] HAN, Y. ; LIU, Y. ; HONG, Z. ; ZHANG, Y. ; YANG, S. ; WANG, J.: Sea ice image classification based on heterogeneous data fusion and deep learning. En: *Remote Sensing* 13 (4) (2021), p. 1–20
- [9] HAYKIN, S.: *Neural Networks and Learning Machines, 3rd edition*. Prentice Hall, 2008
- [10] HE, K. ; ZHANG, X. ; REN, S. ; SUN, J.: Deep residual learning for image recognition. En: *arXiv: 1512.03385v1* (2015)

- 
- [11] HELBER, P. ; BISCHKE, B. ; DENGEL, A. ; BORTH, D.: Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 12 (7) (2019), p. 2217–2226
- [12] HONG, D. ; GAO, L. ; YOKOYA, N. ; YAO, J. ; CHANUSSOT, J. ; DU, Q. ; ZHANG, B.: More diverse means better: multimodal deep learning meets remote-sensing imagery classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 59 (5) (2021), p. 4340–4354
- [13] HOWARD, A. ; ZHU, M. ; CHEN, B. ; KALENICHENKO, D. ; WANG, W. ; WEYAND, T. ; ANDREETTO, M. ; ADAM, H.: MobileNets: Efficient convolutional neural networks for mobile version applications. En: *arXiv: 1704.04861v1* (2017)
- [14] ILLARIONOVA, S. ; TREKIN, A. ; IGNATIEV, V. ; OSELEDETS, I.: Neural-based hierarchical approach for detailed dominant forest species classification by multispectral satellite imagery. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14 (2021), p. 1810–1820
- [15] JAMALI, A. ; MAHDIANPARI, M. ; BRISCO, B. ; GRANGER, J. ; MOHAMMADIMANESH, F. ; SALEHI, B.: Comparing solo versus ensemble convolutional neural networks for wetland classification using multi-spectral satellite imagery. En: *Remote Sensing* 13 (11) (2021)
- [16] JOZDANI, S. ; JOHNSON, B. ; CHEN, D.: Comparing deep neural networks, ensemble classifiers, and support vector machine algorithms for object-based urban landuse/land cover classification. En: *Remote Sensing* 11 (14) (2019)
- [17] KUSSUL, N. ; LAVRENIUK, M. ; SKAKUN, S. ; SHELESTOV, A.: Deep learning classification of land cover and crop types using remote sensing data. En: *IEEE Geoscience and Remote Sensing Letters* 14 (5) (2017), p. 778–782
- [18] DE LIMA, R. ; MARFURT, K.: Convolutional neural network for remote-sensing scene classification: transfer learning analysis. En: *Remote Sensing* 12 (1) (2020)
- [19] LIU, Q. ; HANG, R. ; SONG, H. ; LI, Z.: Learning multiscale deep features for high-resolution satellite image scene classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 56 (1) (2018), p. 117–126
- [20] LIU, X. ; HE, C. ; ZHANG, Q. ; LIAO, M.: Statistical convolutional neural network for land-cover classification from SAR images. En: *IEEE Geoscience and Remote Sensing Letters* 17 (9) (2020), p. 1548–1552

- 
- [21] LIU, X. ; ZHOU, Y. ; ZHAO, J. ; YAO, R. ; LIU, B. ; ZHENG, Y.: Siamese convolutional neural networks for remote sensing scene classification. En: *IEEE Geoscience and Remote Sensing Letters* 16 (8) (2019), p. 1200–1204
- [22] LIU, Y. ; ZHONG, Y. ; QIN, Q.: Scene classification based on multiscale convolutional neural network. En: *IEEE Transactions on Geoscience and Remote Sensing* 56 (12) (2018), p. 7109–7121
- [23] MAGGIORI, E. ; TARABALKA, Y. ; CHARPIAT, G. ; ALLIEZ, P.: Convolutional neural networks for large-scale remote-sensing image classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 55 (2) (2017), p. 645–657
- [24] PENG, C. ; LI, Y. ; JIAO, L. ; SHANG, R.: Efficient convolutional neural architecture search for remote sensing image scene classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 59 (7) (2021), p. 6092–6105
- [25] QIN, S. ; GUO, X. ; SUN, J. ; QIAO, S. ; ZHANG, L. ; YAO, J. ; CHENG, Q. ; ZHANG, Y.: Landslide detection from open satellite imagery using distant domain transfer learning. En: *Remote Sensing* 13 (11) (2021)
- [26] ROSSO, M. D. ; SEBASTIANELLI, A. ; SPILLER, D. ; MATHIEU, P. ; ULLO, S.: On-board volcanic eruption detection through CNNs and satellite multispectral imagery. En: *Remote Sensing* 13 (17) (2021)
- [27] SCOTT, G. ; ENGLAND, M. ; STARMS, W. ; MARCUM, R. ; DAVIS, C.: Training deep convolutional neural networks for land-cover classification of high-resolution imagery. En: *IEEE Geoscience and Remote Sensing Letters* 14 (4) (2017), p. 549–553
- [28] SHENDRYK, Y. ; RIST, Y. ; TICEHURST, C. ; THORBURN, P.: Deep learning for multi-modal classification of cloud, shadow and land cover scenes in PlanetScope and Sentinel-2 imagery. En: *IEEE Geoscience and Remote Sensing Letters* 157 (2019), p. 124–136
- [29] SHI, C. ; LV, Z. ; SHEN, H. ; FANG, L. ; YOU, Z.: Improved metric learning with the CNN for very-high-resolution remote sensing image classification. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14 (2021), p. 631–644
- [30] SIESTO, G. ; FERNÁNDEZ-SELLERS, M. ; LOZANO-TELLO, A.: Crop classification of satellite imagery using synthetic multitemporal and multispectral images in convolution neural networks. En: *Remote Sensing* 13 (17) (2021)
- [31] SIMONYAN, K. ; ZISSERMAN, A.: Very deep convolutional networks for large-scale image recognition. En: *arXiv: 1409.1556v6* (2015)

- 
- [32] SZEGEDY, C. ; VANHOUCKE, V. ; IOFFE, S. ; SHLENS, J.: Rethinking the inception architecture for computer vision. En: *arXiv: 1512.00567v3* (2015)
- [33] TANG, X. ; MA, Q. ; ZHANG, X. ; LIU, F. ; MA, J. ; JIAO, L.: Attention consistent network for remote sensing scene classification. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14 (2021), p. 2030–2045
- [34] TAO, C. ; LU, W. ; QI, J. ; WANG, H.: Spatial information considered network for scene classification. En: *IEEE Geoscience and Remote Sensing Letters* 18 (6) (2021), p. 948–988
- [35] TU, B. ; KUANG, W. ; HE, W. ; ZHANG, G. ; PENG, Y.: Robust learning of mislabeled training samples for remote sensing image scene. En: *IEEE Geoscience and Remote Sensing Letters* 18 (2) (2021), p. 241–245
- [36] WANG, G. ; FAN, B. ; XIANG, S. ; PAN, C.: Aggregating rich hierarchical features for scene classification in remote sensing imagery. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10 (9) (2017), p. 4104–4115
- [37] WU, Z. ; HOU, B. ; JIAO, L.: Multiscale CNN with autoencoder regularization joint contextual attention network for SAR image classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 59 (2) (2021), p. 1200–1213
- [38] XU, X. ; LI, W. ; RAN, Q. ; DU, Q. ; GAO, L. ; ZHANG, B.: Multisource remote sensing data classification based on convolutional neural network. En: *IEEE Transactions on Geoscience and Remote Sensing* 56 (2) (2018), p. 937–949
- [39] YANG, N. ; TANG, H. ; SUN, H. ; YANG, X.: Dropband: a simple and effective method for promoting the scene classification accuracy of convolutional neural networks for VHR remote sensing imagery. En: *IEEE Geoscience and Remote Sensing Letters* 15 (2) (2018), p. 257–261
- [40] YOO, C. ; HAN, D. ; IM, J. ; BECHTEL, B.: Comparison between convolutional neural networks and random forest for local climate zone classification in mega urban areas using landsat images. En: *ISPRS Journal of Photogrammetry and Remote Sensing* 157 (2019), p. 155–170
- [41] YU, X. ; WU, X. ; LUO, C. ; REN, P.: Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework. En: *GIScience and Remote Sensing* 54 (5) (2017), p. 741–758
- [42] ZHANG, C. ; SARGENT, I. ; PAN, X. ; LI, H. ; GARDINER, A. ; HARE, J. ; ATKINSON, P.: An object-based convolutional neural network (OCNN) for urban land use classification. En: *Remote Sensing of Environment* 216 (2018), p. 57–70

- 
- [43] ZHANG, C. ; WANG, X. ; MA, L. ; LU, X.: Tropical cyclone intensity classification and estimation using infrared satellite images with deep learning. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14 (2021), p. 2070–2086
- [44] ZHANG, Y. ; ZHENG, X. ; YUAN, Y. ; LU, X.: Attribute-cooperated convolutional neural network for remote sensing image classification. En: *IEEE Transactions on Geoscience and Remote Sensing* 58 (12) (2020), p. 8358–8371
- [45] ZHAO, Z. ; LI, J. ; LUO, Z. ; LI, J. ; CHEN, C.: Remote sensing image scene classification based on an enhanced attention module. En: *IEEE Geoscience and Remote Sensing Letters* 18 (11) (2021), p. 1926–1930
- [46] ZHONG, Y. ; FEI, F. ; LIU, Y. ; ZHAO, B. ; JIAO, H. ; ZHANG, L.: SatCNN: satellite image dataset classification using agile convolutional neural networks. En: *Remote Sensing Letters* 8 (2) (2017), p. 136–145
- [47] ZHOU, S. ; ZHOU, Y. ; LIU, B.: Using siamese capsule networks for remote sensing scene classification. En: *Remote Sensing Letters* 11 (8) (2020), p. 757–766
- [48] ZHU, Y. ; GEIS, C. ; SO, E. ; JIN, Y.: Multitemporal relearning with convolutional LSTM models for land use classification. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14 (2021), p. 3251–3265