



Universidad del
Rosario

Escuela de Ingeniería,
Ciencia y Tecnología

**PROCESAMIENTO DE IMÁGENES SATELITALES A TRAVÉS
DE ALGORITMOS DE APRENDIZAJE PROFUNDO, USO DEL
SUELO Y COBERTURA TERRESTRE PARA LA ESTIMACIÓN
DE LA DEMANDA DE TRÁFICO 5G**

Informe final

Presentado para obtener el título de

**MAGÍSTER EN MATEMÁTICAS APLICADAS Y CIENCIAS DE
LA COMPUTACIÓN**

Alex Felipe Sarmiento

Juan Sebastián Henao

Dirección:

Mario Fernando Jiménez Hernández, Ph.D.

Universidad del Rosario

Escuela de Ingeniería, Ciencia y Tecnología

Maestría en Matemáticas Aplicadas y Ciencias de la Computación

Los sistemas de comunicaciones móviles, también conocidos como Telecomunicaciones Móviles Internacionales (IMT), se han convertido en parte integrante de nuestra vida cotidiana y prestan diversos servicios de telecomunicaciones que contribuyen significativamente al bienestar social. Históricamente, estos sistemas se han centrado en las necesidades de voz y banda ancha. Sin embargo, con la llegada de la 5G, los objetivos se han ampliado significativamente para abarcar un espectro más amplio de aplicaciones, incluidas las adaptadas a las necesidades industriales y al Internet de las Cosas (IoT).

Aunque existen metodologías y recomendaciones internacionales para orientar el desarrollo de estos sistemas, a menudo se quedan cortas a la hora de identificar las necesidades únicas de la 5G. Los métodos de estimación tradicionales utilizan datos históricos sobre población y tráfico, pero pasan por alto las nuevas posibilidades que permite la 5G, como la comunicación ultra fiable y de baja latencia y el Internet de las cosas (IoT). El resultado son graves limitaciones en la estimación de la demanda potencial de tráfico para las redes 5G.

Este trabajo introduce un enfoque novedoso, utilizando técnicas de teledetección y aprendizaje profundo, en concreto métodos de uso y cobertura del suelo, para comprender el contexto geográfico. Estas técnicas ofrecen una estimación detallada de las características geográficas mediante la medición remota de la radiación electromagnética reflejada y emitida. La integración del aprendizaje profundo para el procesamiento de imágenes añade aún más valor, ya que estos algoritmos han demostrado su éxito en la clasificación, segmentación, detección de objetos, restauración y mejora de imágenes.

Adicionalmente, se pretende aplicar estas técnicas utilizando la base de datos de imágenes EuroSat, para mejorar el proceso de planificación de las tecnologías 5G en Colombia. El objetivo es incluir características geográficas en la planeación del despliegue, inferir casos de uso potenciales y mejorar significativamente los análisis de demanda, valoración, factibilidad y otros aspectos necesarios para el desarrollo de 5G.

Mobile communication systems, also called International Mobile Telecommunications (IMT), have become integral to our daily lives, furnishing diverse telecom services that contribute significantly to social welfare. These systems have historically centred around voice and broadband needs. However, with the advent of 5G, the objectives have expanded significantly to encompass a broader spectrum of applications, including those tailored to industrial needs and the Internet of Things (IoT).

While methodologies and international recommendations exist to guide the development of these systems, they often fall short of identifying the unique needs of 5G. Traditional estimation methods use historical data on population and traffic, but they overlook new possibilities enabled by 5G, such as ultra-reliable, low-latency communication and the Internet of Things (IoT). This results in serious limitations in estimating the potential traffic demand for 5G networks.

This study introduces a novel approach, utilising Remote Sensing techniques, specifically Land Use and Land Cover methods, to understand the geographical context. These techniques offer a detailed estimation of geographical characteristics by remotely measuring reflected and emitted electromagnetic radiation. Integrating deep learning for image processing further adds value, as these algorithms have proven successful in classification, segmentation, object detection, image restoration, and enhancement.

The work proposes applying these techniques, using the EuroSat image database, to enhance the planning process for 5G technologies in Colombia. The objective is to include geographical characteristics in the deployment planning, infer potential use cases, and significantly improve the analyses of demand, valuation, feasibility, and other necessary aspects for 5G development.

TABLA DE CONTENIDO

iv

Capítulo 1 JUSTIFICACIÓN Y DESCRIPCIÓN DEL PROBLEMA.....	1
Capítulo 2 MARCO TEÓRICO Y ESTADO DEL ARTE.....	8
2.1 Métodos de Land Use y Land Cover	9
2.2 Conceptos básicos de aprendizaje automático y aprendizaje profundo.....	17
2.3 Aplicación del aprendizaje automático y el aprendizaje profundo en la clasificación de imágenes	19
2.4 Redes residuales (ResNet), transformadores de visión (SWIN) y ResNetGeo.	21
2.4.1 Redes residuales (ResNet)	21
2.4.2. Transformers SWIN.....	22
2.4.3. TorchGeo ResNet.....	24
2.4.4. Aprendizaje por Transferencia.....	25
2.5. Necesidades de Telecomunicaciones Inalámbricas	28
Capítulo 3 METODOLOGÍA	31
3.1 Diseño experimental y datos utilizados	31
3.2 Arquitectura de la aplicación	33
3.3 Medidas de evaluación sobre los datos de entrenamiento fuera de muestra.....	35
3.4 Aplicación y <i>tunning</i> de los modelos a la demanda de telecomunicaciones móviles...	35
Capítulo 4 Aplicación al Contexto de las Telecomunicaciones 5G.....	37
4.1 Ventajas, limitaciones y retos del cálculo de MHz mediante LC/LU.....	50
Capítulo 5 CONCLUSIONES Y TRABAJO FUTURO	52
REFERENCIAS.....	57

LISTA DE FIGURAS

v

Figura 1. Casos de uso eMMB, mIoT y uRLL	3
Figura 2. Diagrama metodológico de estimación de necesidades de espectro	4
Figura 3: Ejemplo de LU/LC	10
Figura 4: Inteligencia Artificial, Machine Learning y Aprendizaje Profundo.....	18
Figura 5: Arquitectura ResNet50	22
Figura 6: Arquitectura Sliding Shifted Window	23
Figura 7: Matriz de Confusión modelos Swin Transformer y Resnet50	38
Figura 8: Matriz de Confusión modelos Resnet101 y GeoResnet50	38

Capítulo 1

JUSTIFICACIÓN Y DESCRIPCIÓN DEL PROBLEMA

El término 5G se ha consolidado en el ámbito de las telecomunicaciones como el nombre comercial de la quinta generación de tecnología móvil. No obstante, en el ámbito técnico y académico, se acostumbra a referirse a esta tecnología como *5G New Radio* (NR), designación atribuida por la 3rd Generation Partnership Project (3GPP), la organización responsable de la definición de estándares técnicos para las tecnologías móviles[1].

La NR se distingue de las tecnologías de radio anteriores en diferentes puntos. En primer lugar, utiliza un rango de frecuencias más amplio que las generaciones anteriores, incluyendo tanto las bandas de frecuencia por debajo de 6 GHz (FR1), como las bandas de frecuencia por encima de 24 GHz (FR2), conocidas como ondas milimétricas. Este uso más amplio del espectro permite velocidades de transmisión de datos significativamente más altas y una mayor capacidad de la red.

Además, NR utiliza una arquitectura flexible y escalable, con un tamaño de portadora ajustable que va desde 5 MHz hasta 400 MHz, lo que permite una optimización más eficiente de los recursos de la red[2]. También introduce nuevas tecnologías, como la formación de haces (*beamforming*) y el uso de múltiples entradas y múltiples salidas (MIMO) masivas para mejorar la eficiencia espectral y la capacidad de la red[2].

A pesar de la precisión técnica que aporta el término "New Radio", en el presente trabajo utilizaremos el término "5G". Esta decisión se basa en la familiaridad y el reconocimiento generalizado de "5G" en comparación con "NR". Además, el término "5G" abarca un conjunto más amplio de innovaciones, incluyendo, pero no limitado a las mejoras en la tecnología de radio, como las mejoras en la infraestructura de la red, la arquitectura del sistema y la gestión del espectro.

El 5G o quinta generación de telecomunicaciones móviles inalámbricas, se concibió para proporcionar una conexión entre dispositivos de mayor velocidad, confiabilidad y eficiencia[3]. Asimismo, esta generación está diseñada para manejar grandes volúmenes de datos, facilitando velocidades de carga y descarga superiores, latencia reducida y mayor capacidad en comparación con las generaciones precedentes de tecnología inalámbrica¹.

El corazón de este trabajo, no obstante, reside en el hecho de que la tecnología 5G, a diferencia de sus antecesoras, ha sido creada para soportar nuevos escenarios de uso más allá de la comunicación de voz y datos convencional. Por ejemplo, posibilitará el surgimiento de nuevas aplicaciones en ámbitos como los vehículos autónomos, la realidad virtual y aumentada, y el Internet de las Cosas (IoT, por sus siglas en inglés). Estos nuevos escenarios de uso demandan un tipo de red innovadora que sólo puede ser establecida mediante un cambio en el paradigma de planificación, dado que debe estar diseñada para conectar a casi todo y todos, incluyendo máquinas y objetos, además de los dispositivos tradicionales, de ahora en adelante denominados Terminales Móviles (TM)[4]. Todo esto, sin malgastar recursos de inversión a través de despliegues de infraestructura innecesarios. Esta nueva generación ha sido estandarizada bajo el nombre de IMT-2020 por la Unión Internacional de Telecomunicaciones (UIT)[5]. Dicho de otro modo, la próxima tecnología de comunicaciones móviles presentará nuevos escenarios de uso y estará centrada en el Internet de las Cosas Masivo (IoT Masivo)²[6] y en casos de uso que requieran Latencia Ultra Baja³[7].

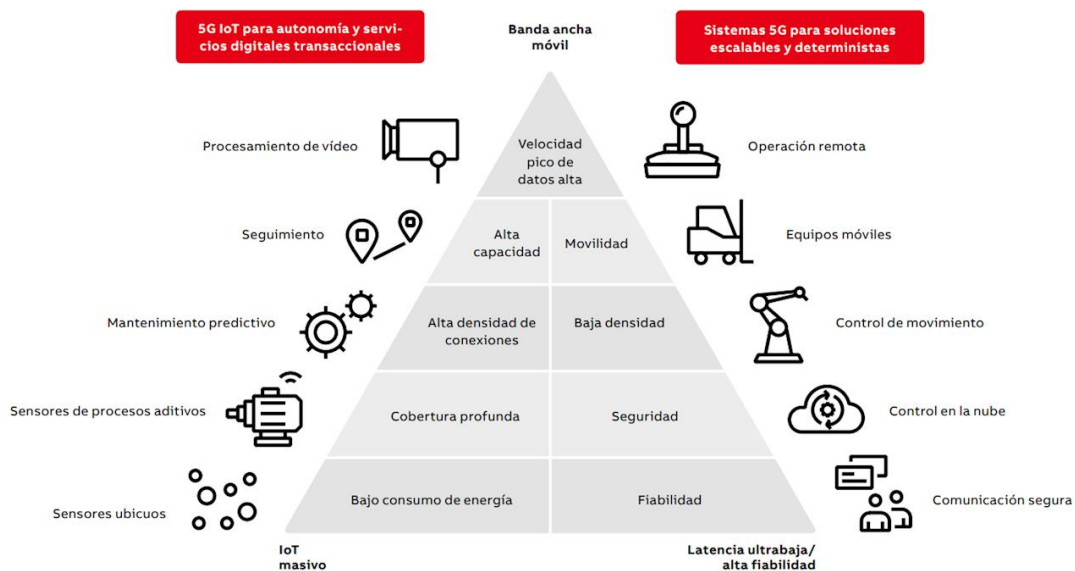
¹ Tecnologías anteriores representan (2G, 3G y 4G).

² Se reconoce IoT Masivo como los elementos conectados que requieren bajo consumo de energético bajas tasas de transferencia y baja latencia.

³ Se determina como la tasa de respuesta de una red. La latencia ultrabaja se mide en nanosegundos, mientras que la latencia baja se mide en milisegundos. Por lo tanto, la latencia ultrabaja ofrece una respuesta mucho más rápida, con menos demoras que la latencia baja.

Estos nuevos usos se conocen en la literatura como: i) eMMB⁴, ii) uRLL⁵ y iii) mIoT⁶ por las siglas en inglés de i) banda ancha móvil mejorada, ii) banda ancha ultra fiable y de baja latencia, y iii) Internet de las cosas masivo, tal como se ilustra en la Figura 1. Estos escenarios de uso se benefician de las características primordiales de esta generación, las cuales se traducen en altas velocidades, baja latencia y un consumo energético excepcionalmente reducido. Este conjunto de características permite a los operadores desplegar redes capaces de conectar hasta un millón de dispositivos por kilómetro cuadrado, potenciando escenarios de uso que no eran factibles con las anteriores generaciones de redes móviles[8].

Figura 1. Casos de uso eMMB, mIoT y uRLL [9]



Es entonces evidente que la novedad y el alto potencial de innovación de estas nuevas tecnologías móviles representan un reto respecto a su planificación de parte de los Estados,

⁴ *Enhanced Mobile Broadband*

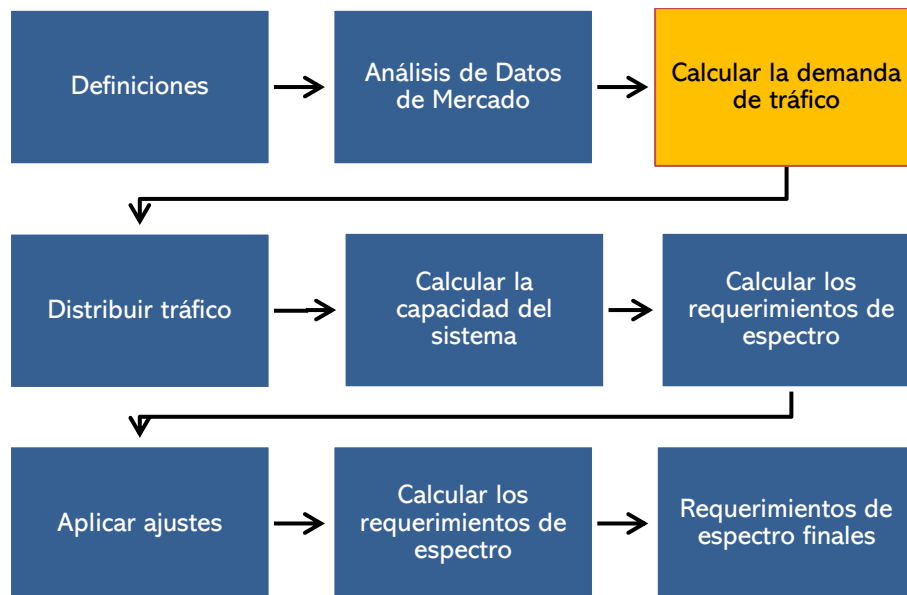
⁵ *Ultra Reliable Low Latency*

⁶ *Massive Internet of Things*

las autoridades reguladoras e incluso los proveedores de redes. En particular, los nuevos casos de uso requerirán nuevas formas de asignación del espectro radioeléctrico y de obligaciones de despliegue que deben ser considerados. Esto requiere metodologías distintas a las usadas actualmente en los procesos de gestión y administración de este recurso.

En este sentido, es posible adaptar modelos que han funcionado para generaciones previas, ya que conceptualmente estos modelos prevén la identificación de las necesidades *prior* la determinación de la oferta requerida y la red necesaria para cursar el tráfico en mención. Para este caso la UIT en su reporte técnico (ITU-R M. 2290)[10] define un marco metodológico que tiene como objetivo el identificar las necesidades de espectro radioeléctrico nacional.

Figura 2. Diagrama metodológico de estimación de necesidades de espectro [10]



Para calcular el Ítem 3 “Calcular la demanda de tráfico” (Ver recuadro resaltado en color amarillo en la Figura 2), actualmente se realizan cálculos de densidad de usuarios, cantidad

de usuarios promedio, duración promedio de sesiones entre otras categorías de datos[10]. Sin embargo, la UIT no especifica el desarrollo de la demanda de tráfico para la nueva generación de telecomunicaciones móviles mientras que lo hace de forma general y por tanto deja espacio para el uso de metodologías que permitan la estimación de las necesidades de telecomunicaciones móviles⁷.

Comúnmente, los ejercicios de planeación de tráfico de telecomunicaciones se basan en al menos tres tipos de geo-tipos, siendo estos: denso (el cual incluye a las ciudades capitales), urbano y rural, como metodología del cálculo de tráfico requerido [11]. Esto determina el tráfico por usuario, expresado en términos de megabytes y/o gigabytes por mes cursados a través de redes móviles, el cual es relevante para calcular la demanda de tráfico requerida para ser atendida por la capacidad de la red. Sin embargo, dada la posibilidad de usar sistemas de información geográfica, especialmente es posible dividir dichos perfiles en nuevas tipificaciones al considerar mayor cantidad de información. Esto es posible debido a la creciente disponibilidad de imágenes satelitales gratuitas gracias a programas como Landsat[12] y Sentinel[13], además de los programas a nivel comunitario como OpenStreetMaps[14] que posibilitan una mejora sobre los modelos y la información actualmente considerada⁸ para este tipo de análisis. Así mismo, el uso de estas técnicas posibilitaría mecanismos de asignación regionales y locales para generar asignaciones más específicas, que permitan eventualmente la asignación de espectro incluso a actores distintos a los operadores de comunicaciones móviles en pro de la competitividad.

En este sentido, este trabajo está enfocado en utilizar i) el creciente volumen de información geográfica provistos por iniciativas de exploración de la tierra gratuitas para

⁷ Por ejemplo, se ilustra la National Land Cover Database – NLCD – que incluye 20 tipos de coberturas entre las cuales se encuentra categorías urbanas, vegetales (incluyendo cultivos) y zonas industriales.

⁸ Actualmente se consideran datos de población suministrados por Departamento Administrativo Nacional de Estadística – DANE

el caso puntual -Sentinel 2⁹, ii) los avances en Teledetección vía mejoras en el hardware de los satélites de EO que significa mejoras en los sensores de imágenes hiperespectrales¹⁰, iii) la analítica de datos aplicada al procesamiento de imágenes mediante aprendizaje profundo (*Deep Learning*) que permiten identificar elementos geográficos para generar información de contexto sobre los elementos que requieren conectividad en una determinada área o zona geográfica como edificios, carreteras, granjas, zonas de reserva ambiental, parques industriales, entre otros geo-tipos.

Es posible ampliar la base de información con el fin de determinar la demanda potencial de tráfico a un nivel de polígono o área. Esta información de contexto se convierte en un elemento adicional a los tradicionales y posibilitará identificar de manera óptima el diseño e instalación de infraestructura como estaciones base y sectores. Finalmente, se espera que, mediante la incorporación de esta información adicional, se obtengan resultados superiores a los obtenidos mediante el diseño de las necesidades de comunicaciones móviles vía cantidad de habitantes y series de población usados en la actualidad por los gobiernos y autoridades regulatorias en el mundo. Así, en este documento se propone el desarrollo de una herramienta que mediante el uso de imágenes satelitales asociadas a una determinada zona geográfica genere información relevante a la demanda potencial de datos y conectividad para redes 5G.

⁹ El programa Copernicus es un proyecto de la Unión Europea (UE) y la Agencia Espacial Europea (ESA) que construye y gestiona una flota de satélites de observación de la Tierra llamados Sentinel.

¹⁰ Una imagen hiperespectral es un conjunto de datos basado en la espectroscopia. Recoge cientos de imágenes a diferentes longitudes de onda para una misma área espacial. Mientras que el ojo humano sólo tiene tres receptores de color en el azul, el verde y el rojo, las imágenes hiperespectrales miden el espectro continuo de la luz para cada píxel de la escena con una determinada resolución de longitud de onda, no sólo en el espectro visible sino también en el infrarrojo cercano. La principal diferencia entre multiespectral e hiperespectral es el número de bandas y cuán estrechas son las bandas. Por su parte las imágenes multiespectrales generalmente se refieren a imágenes tomadas en de 3 a 10 bandas. [15].

El presente documento está dividido en 4 secciones. La primera sección indica la problemática y el aporte de la incorporación de más información sobre ejercicios de planeación en telecomunicaciones. La segunda sección hace un recuento de las técnicas utilizadas para definir la capa de LCLU entre las cuales se detallan DeepLearning, Transfer Learning y su aplicación sobre la base de datos EuroSat¹¹. La tercera sección explora las posibles arquitecturas y modelos de redes neuronales para esta tarea y relaciona los resultados del entrenamiento y pruebas de los modelos. La cuarta sección realiza la aplicación de las etiquetas predichas para tres municipios de Colombia indicando los efectos entre la planeación convencional y la propuesta en el presente documento. Finalmente, la sección 5 hace una recopilación de las conclusiones del desarrollo y pasos futuros.

¹¹ EuroSat es un conjunto de 27.000 imágenes satelitales que cubren 13 bandas espectrales etiquetadas con 10 categorías del uso del suelo y georreferenciadas.

Capítulo 2

MARCO TEÓRICO Y ESTADO DEL ARTE

Dado que la temática central de este trabajo gira en torno a la implementación y el mejoramiento de técnicas para el procesamiento de imágenes satelitales hiperespectrales, con el objetivo de estimar la demanda de tráfico 5G, los temas claves a explorar en este marco teórico incluyen las técnicas de Uso del Suelo/Cobertura del Suelo, la observación de la Tierra a través de satélites, el aprendizaje automático o (Machine Learning, ML), y las técnicas de estimación de demanda de espectro.

El análisis detallado de la utilización y cobertura del suelo constituye el punto de partida para este trabajo. Las imágenes hiperespectrales ofrecen una visión única de la interacción entre las sociedades humanas y su entorno físico, y las técnicas para su interpretación y clasificación son esenciales para convertir esta información en datos útiles.

Por su parte la observación de la Tierra, y en particular la observación satelital, juega un papel integral en este estudio. El énfasis aquí se encuentra en la comprensión de los métodos y tecnologías para obtener, procesar y analizar las imágenes satelitales, con el objetivo de extraer la información más relevante para el problema en cuestión, que es la estimación de la demanda de tráfico 5G.

Los algoritmos de aprendizaje automático y el aprendizaje profundo o (Deep Learning, DL), son de vital importancia para el desarrollo propuesto en este documento. Estos algoritmos permiten el procesamiento de grandes conjuntos de datos, como las imágenes satelitales, y la extracción de características y patrones relevantes para la estimación de la demanda de tráfico. En este apartado se analizarán los avances más significativos en estos campos y su aplicación en el contexto de las imágenes hiperespectrales y la demanda de tráfico 5G.

Finalmente, se examinarán las técnicas existentes para estimar la demanda de espectro. Con la creciente necesidad de una mejor gestión del espectro en la era del 5G, se necesita una comprensión profunda de los métodos tradicionales y emergentes para esta estimación. Esta sección brindará la base necesaria para desarrollar y mejorar las técnicas de estimación de la demanda utilizando imágenes hiperespectrales.

2.1 Métodos de Land Use y Land Cover

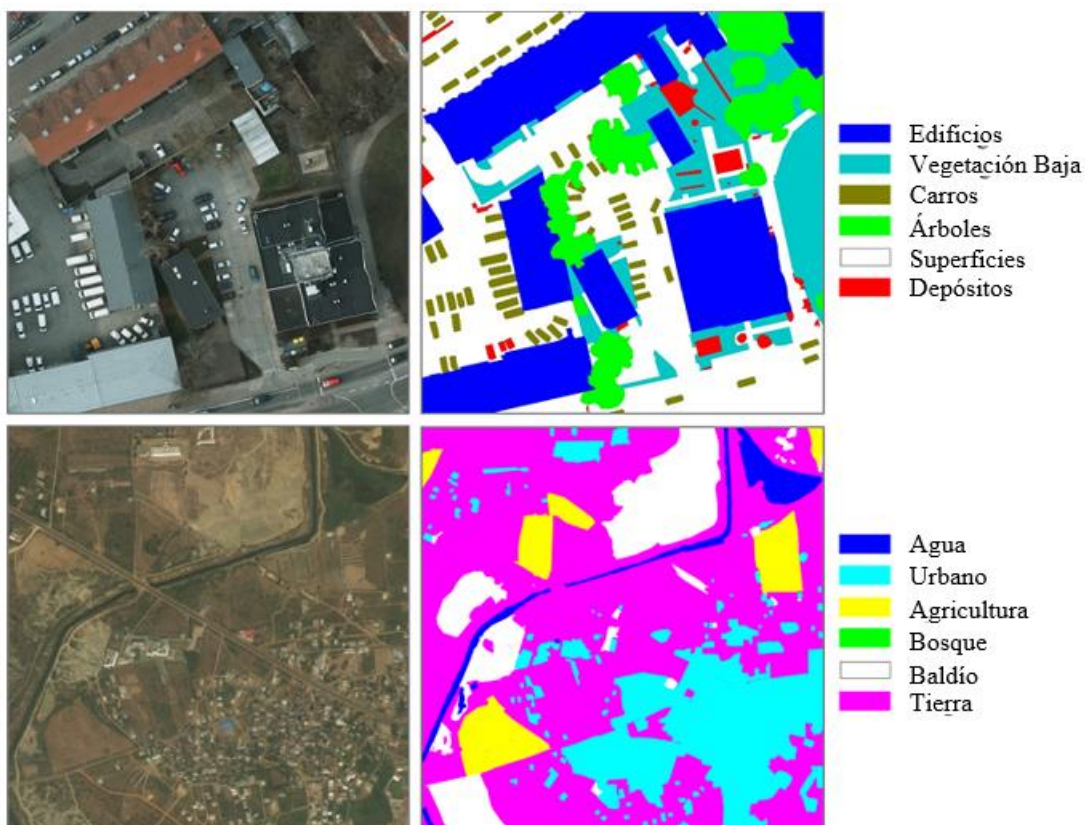
El Uso del Suelo/Cobertura del Suelo (US/CS) y sus cambios son considerados como un factor fundamental en el cambio ambiental global[16]. La identificación precisa y el monitoreo del US/CS son esenciales para la gestión de recursos terrestres, dado que el mapeo de US/CS constituye una parte importante del sistema de gestión del territorio[17].

El concepto de "cobertura del suelo" se refiere a las características físicas del terreno en la superficie de la Tierra, mientras que el "uso del suelo" refleja cómo los seres humanos utilizan el terreno disponible, por ejemplo, a través del desarrollo urbano o la explotación de los terrenos[18] (Comber, 2005). El conocimiento preciso del US/CS proporciona información crítica para actividades de planificación y gestión[19]. Esto se debe a que la tierra es uno de los recursos naturales más importantes del sistema terrestre, contribuyendo a la vida y a diversas actividades de desarrollo[20].

La información de US/CS y sus patrones de distribución espacial son esenciales para una amplia gama de temas de investigación, especialmente los estudios urbanos caracterizados por clases heterogéneas y para planes de mantenimiento y desarrollo[21]. Los cambios en el US/CS han sido percibidos como un factor clave en el cambio ambiental mundial al afectar la superficie terrestre[22].

El monitoreo de los cambios en el US/CS se vuelve particularmente importante en áreas que están en constante cambio, como periferias urbanas, cuencas fluviales, humedales y áreas agrícolas. Estos cambios en el US/CS pueden incluir la reducción de la cobertura forestal para dar paso a la expansión agrícola, la urbanización, la industrialización, etc.[23]

Figura 3: Ejemplo de LU/LC [24]



La evaluación del US/CS y sus cambios es importante para comprender varios problemas ambientales relacionados tanto con las áreas urbanas como con los paisajes circundantes. Estos problemas pueden incluir la variación de la temperatura superficial debido al aumento del concreto en las ciudades, la pérdida de biodiversidad, la degradación del suelo y de la tierra, la disminución de la calidad del aire, los problemas de disposición de residuos, la disminución de la infiltración de agua, el aumento de la escorrentía y la

consecuente inundación/crecida rápida, la deterioración de la calidad del agua y la disminución de la productividad agrícola[25]. En este sentido, la teledetección ha surgido como una tecnología muy poderosa que proporciona información espacial precisa y la distribución de US/CS en el período temporal[25].

En el ámbito de mapeo del uso y cobertura del suelo, se ha pasado de los métodos convencionales, como las encuestas de campo y observaciones in situ, a métodos de teledetección[26]. Los métodos convencionales, aunque confiables, son generalmente costosos y requieren mucho tiempo. La teledetección, en cambio, ofrece mayor precisión, eficiencia de costos, ahorro de tiempo y cobertura más amplia del área para el mapeo.

La detalla las especificaciones de varios sensores de teledetección satelital, incluyendo las series Landsat, Sentinel, WorldView, entre otros. Cada uno de estos sensores tiene diferentes resoluciones temporales, espaciales y espectrales, lo que los hace más adecuados para ciertas aplicaciones que otros.

La resolución espacial y espectral son factores significativos en la evaluación de la precisión general del mapeo. La resolución espacial determina el tamaño mínimo de los objetos en la Tierra que pueden distinguirse en la imagen del satélite. Los sistemas con alta resolución espacial proporcionan datos más detallados, lo que es particularmente importante para el análisis de características específicas y detalladas del terreno. Por otro lado, la resolución espectral se refiere a la capacidad de un sensor para distinguir entre diferentes longitudes de onda de luz. La resolución espectral afecta directamente la cantidad y el tipo de información espectral que un sensor puede capturar sobre cada objeto en la Tierra.

Tabla 1: Descripción de las principales misiones satelitales y sus características

No.	Sensores	Plataforma	Rango/espectro de resolución	Resolución espacial/espectral (m)	Canales	Tiempo de revisita	Anchura de la franja	Organización / Nación	Año de lanzamiento
1	LANDSAT MSS		0.5–1.1 um	Óptico: 60 m	4 Bandas	18 Días	185 km	NASA	LANDSAT 1 (1972). LANDSAT 2 (1975). LANDSAT 3 (1983)
2	LANDSAT TM		0.45–12.50 um	Óptico: 30 m. Térmico: 120 m	7 Bandas	16 días	185 km	NASA	LANDSAT 4 (1982). LANDSAT 5 (1984)
3	LANDSAT ETM+		0.45–12.50 um	Óptico: 30 m. Térmico: 60 m. Pan: 15 m	8 Bandas	16 Días	185 km	NASA	LANDSAT 7 (15 Abril 1999)
4	LANDSAT 8 EO - 1		0.43–12.51 um	Óptico: 30 m. Cirrus: 30 m. Pan: 15 m. Térmico: 100 m	11 Bandas	16 Días	185 km	NASA	LANDSAT 8 (11 Feb 2013)
5	LISS-I	IRS- 1A, 1B	0.45–0.86 um	72 m	4 Bandas	22 Días	148 km	ISRO	IRS 1A (17 Marzo 1988). IRS 1B (29 Agosto 1991)
6	LISS-II	IRS- 1A, 1B	0.45–0.86 um	36 m	4 Bandas	22 Días	148 km	ISRO	IRS 1A (17 Marzo 1988). IRS 1B (29 Agosto 1991)

No.	Sensores	Plataforma	Rango/espectro de resolución	Resolución espacial/espectral (m)	Canales	Tiempo de revisita	Anchura de la franja	Organización / Nación	Año de lanzamiento
7	LISS- III	IRS-1C ResourceSat-1	0.52–1.70 um	Verde, Rojo, NIR: 23 Mid-IR: 70	4 Bandas	24 Días	142 km(G,R,NIR); 148 km(Mid-IR); 140 km (ResourceSat-1)	ISRO	IRS 1C (28 Dic 1995)
8	LISS-IV	ResourceSat-1	0.52–0.86 um	5.8 m	3 Bandas	5–24 Días	70 km	ISRO	17-oct-03
9	SPOT 5		Verde: 0.5–0.59 um. Rojo: 0.61–0.68 um. Cerca IR: 0.78–0.89 um. SWIR: 1.54–1.75 um	5 m PAN; 2.5–3 m en tierra; B1-B2-B3 = 10 M; SWIR = 20 M	1 banda (PAN). 4 bandas (MS)	2-3 días	60 × 60 km o 60 km × 120 km	Francia	03-may-02
13	WorldView-1		0.45–0.90 mm	50 cm (Nadir) 55 cm (off-Nadir)	1 Banda (Pan)	1.7 Días (1 m o menos). 5.9 Días	17.6 km	USA	18-sep-2007
14	WorldView-2		450–800 nm	Pan: 0.46 (Nadir) Multiespectral: 1.84 Nadir	1 Banda (Pan). 8 Bandas (MS)	1.1 Días (1 m o menos). 3.7 Días (52 cm de resolución).	16.4 km	USA	08-oct-09
15	WorldView -3		400–2365 nm	Pan: 0.31 Multiespectral Nadir: 1.21. SWIR Nadir = 3.7 m CAVIS Nadir = 30m	1 Banda (Pan). 8 Bandas (MS). 8 Bandas (SWIR). 12 Bandas(CAVIS)	4.5 Días	13.1 km	USA	13-ago-14
16	WorldView-4		450–920 nm	PAN Nadir = 30 m Multiespectral Nadir = 1.24m	1 Banda (Pan). 4 Bandas (MS)	4.5 Días	13.1 km	USA	11-nov-16

No.	Sensores	Plataforma	Rango/espectro de resolución	Resolución espacial/espectral (m)	Canales	Tiempo de revisita	Anchura de la franja	Organización / Nación	Año de lanzamiento
17	Sentinel 1		4.0–8.0 cm	Pan: 5	1 Banda (C-SAR)	6 Días	80 km	ESA	03-abr-14
18	Sentinel 2		0.44–2.19 um	10–60	13 Bandas	5 Días (2 Satélites) 10 Días(1 Satélite)	290 km	ESA	23-jun-15
19	QUICKBIRD		450–900 um	Pan: 65 cm MS: 2.62(Nadir). Pan: 73 cm MS:2.90 (off Nadir)	5 Bandas	1–3.5 Días	16.8 km. 18 km(Early 2013)	USA	18-oct-01
20	IKONOS		0.45–0.90 um	Pan: 0.82 MS:3.28 (at Nadir). Pan: 1.0 MS:4.0 (off Nadir)	5 Bandas	Aprox. 3 Días	11.3 km(Nadir). 11.8 km(off-Nadir)	USA	24-sep-1999

Fuentes: [19], [27]

Pan: Una imagen pancromática es un tipo de imagen satelital que utiliza una única banda que combina las bandas roja, verde y azul, lo que permite una mayor resolución espacial[28]. La imagen resultante no contiene ninguna información específica de la longitud de onda. Las imágenes pancromáticas son producidas por los mismos satélites que producen imágenes multiespectrales. Dado que una imagen pancromática es una combinación de las tres bandas visibles, la intensidad total de la radiación solar es mucho mayor en cada píxel que en una imagen multiespectral. El uso de las bandas RGB sacrifica el color por el brillo, por lo que todas las imágenes pancromáticas son imágenes en escala de grises.

Nadir: Se refiere a la dirección directamente por debajo del satélite o del sensor. En otras palabras, cuando el sensor de un satélite apunta directamente hacia el centro de la Tierra, se dice que apunta al nadir. La línea del nadir es la línea que va del satélite al centro de la Tierra. El ángulo nadir es el ángulo entre la dirección directamente debajo del satélite (el nadir) y la dirección real de observación. Cuando el sensor está mirando exactamente al nadir, el ángulo nadir es 0°. Cuando el sensor mira hacia un lado del nadir (lo que se denomina visión fuera del nadir), el ángulo nadir es mayor que 0°.

Como las características espectrales proporcionan más información sobre las características, las imágenes hiperespectrales tienen más poder para mapear US/CS en comparación con las imágenes multiespectrales. Aunque la información espectral forma la base de la clasificación e interpretación de imágenes de teledetección hiperespectrales, la información espectral por sí sola no es útil para la clasificación y el mapeo.

Cómo se observa en la , el satélite Sentinel 2 de la Agencia Espacial Europea (ESA) presenta un gran potencial en este contexto, ya que ofrece una combinación de alta resolución espacial (10-60 metros), amplia cobertura (290 km de ancho de franja) y alta resolución espectral (13 bandas)[13]. Además, Sentinel 2 tiene una resolución temporal muy alta, con un tiempo de revisita de sólo 5 días cuando se utilizan dos satélites, lo que significa que las mismas áreas de la Tierra pueden ser observadas con mucha frecuencia. Esto es particularmente útil para el seguimiento de cambios rápidos en la superficie terrestre, aunado a lo anterior, los datos de Sentinel 2 son abiertos, lo que significa que están disponibles gratuitamente para investigadores y usuarios finales.

Con base en estos sensores, se han desarrollado varios sistemas y mapas de clasificación de la cobertura del suelo a nivel internacional. Algunos ejemplos incluyen la Base de Datos de Características Globales de la Cobertura del Suelo (USGS), CORINE (Agencia Europea de Medio Ambiente), GLC2000 (Centros de Investigación Conjunta de la Comisión Europea) y GeoBase (Consejo Canadiense de Geomática y Recursos Naturales). Para estos se determina el uso del suelo por cada uno de los píxeles o zonas (agrupación de píxeles) en adelante “*tiles*” en los cuales

se encuentra su información geográfica y su respectivo uso determinado mediante censo u otros mecanismos de predicción.

De acuerdo con la revisión bibliográfica existen diferentes iniciativas que han propuesto el uso de Land Use / Land Cover (LULC) en la industria de telecomunicaciones aportando una base de conocimiento al tema. Algunos de estos estudios han trabajado en la determinación de geometrías urbanas que pueden utilizarse para varias aplicaciones. Por ejemplo, estadísticas sobre la densidad de población municipal o regional, así como sobre los emplazamientos industriales, pueden derivarse de los datos[29]. Los autores indican sobre el potencial de su uso debido a que las nuevas generaciones (4G) son sustancialmente más complejas que las anteriores (3G) y advierten sobre la creciente complejidad y necesidad de información que permita reforzar la demanda de una planeación de una red efectiva ya que como mencionan el rango de cobertura esta intrínsecamente relacionado con la capacidad del sistema “más tráfico resulta en una menor área de cobertura” [30].

Adicionalmente, las aplicaciones de técnicas de LULC han sido prominentes en áreas de planeación urbana y política pública. Una de estas implementaciones fue mediante el uso de imágenes de la iniciativa Landsat¹² para detectar la población en Sierra Leona al Oeste de África[31]. Los autores indican que fueron capaces de proyectar la población del área de interés (AoI) con un 8.0% de error sobre los datos oficiales mediante el algoritmo de Bayesian Mixture¹³. Finalmente, concluyen que la técnica referenciada proporciona un método rápido y eficaz para construir modelos de

¹² El programa estadounidense Landsat es un programa conjunto entre la NASA y el Servicio Geológico de los Estados Unidos (USGS) que el ofrece el catálogo más amplio de observaciones de la Tierra a nivel global.

¹³ Bayesian Mixture es una forma de aprendizaje no supervisado este puede ser aplicado para ajustar datos multimodales a tareas como la agrupación (Clustering), la compresión de datos, la detección de valores atípicos o los clasificadores generativos.

predicción de densidades y recuentos de población a partir de imágenes de teledetección.

Además de la exploración y la determinación de la población se han realizado estudios sobre la identificación del cambio en las cuencas de Etiopia debido al aumento de la presión antropogénica. Este se desarrolló mediante el análisis de los cambios en el uso y la ocupación del suelo (LULCs, por sus siglas en inglés), la cual es una de las técnicas más utilizadas para comprender cómo se ha utilizado la tierra en los últimos años, qué tipos de detecciones cabe esperar en el futuro, así como las fuerzas y procesos impulsores de estos cambios[32]. Como conclusión los autores determinan que mediante el uso de esta técnica fue posible evidenciar que todas las cuencas estudiadas experimentaron una tendencia general hacia "más gente más erosión", con implicaciones en términos de degradación del suelo y respuesta hidrológica.

2.2 Conceptos básicos de aprendizaje automático y aprendizaje profundo

El Aprendizaje Automático, es un importante subconjunto de la Inteligencia Artificial (IA), proporciona a los sistemas la capacidad de aprender de forma autónoma y adaptarse a las experiencias sin necesidad de programación explícita[33]. Consiste en diseñar y aplicar algoritmos informáticos capaces de analizar datos, identificar patrones y hacer predicciones[34]. En esencia, trata de crear sistemas que mejoren su rendimiento en las tareas a lo largo del tiempo, y la naturaleza iterativa de este proceso de aprendizaje constituye la piedra angular del ML.

El aprendizaje profundo, es un subconjunto del ML, es una técnica que intenta emular los procesos de aprendizaje del cerebro humano utilizando redes neuronales artificiales. El DL emplea múltiples capas de unidades de procesamiento no lineal para la extracción, transformación y predicción de características a partir de conjuntos de datos de alta dimensión[35]. Inspirados en la estructura y la función del cerebro humano, los modelos de AD intentan imitar las redes neuronales para interpretar los datos y proporcionar resultados[36].

Figura 4: Inteligencia Artificial, Machine Learning y Aprendizaje Profundo [37]



La clasificación general de los modelos de aprendizaje profundo incluye modelos supervisados, semi-supervisados y no supervisados[37]. Los modelos supervisados se entrenan con datos etiquetados, los no supervisados aprovechan los datos sin etiquetar y los semi-supervisados utilizan una combinación de ambos[38].

En los últimos años, la DL ha demostrado superar a los métodos tradicionales de ML en términos de precisión, especialmente cuando se entrena con una gran cantidad de datos. La disponibilidad cada vez mayor de macrodatos y los avances en las capacidades computacionales han contribuido al rápido crecimiento del aprendizaje profundo.

A pesar de su éxito, el aprendizaje profundo se enfrenta a retos y limitaciones como la sobreadaptación, la inadaptación, la interpretabilidad de los modelos, la posibilidad de sesgos y los problemas éticos[39]. Además, aunque en esta introducción se ha analizado principalmente la aplicación de la DL a la clasificación de imágenes es fundamental señalar su uso en una serie de aplicaciones, como el procesamiento del lenguaje natural, el reconocimiento del habla, los sistemas de recomendación y los vehículos autónomos, por nombrar sólo algunas.

2.3 Aplicación del aprendizaje automático y el aprendizaje profundo en la clasificación de imágenes

La clasificación de imágenes, una de las principales tareas de la visión por computador, consiste en asignar etiquetas predefinidas a imágenes digitales [40]. Con la llegada del ML y DL, este proceso se ha revolucionado, especialmente en campos como la teledetección, donde las clasificaciones pueden abarcar tipos de cobertura terrestre como masas de agua, zonas urbanas o vegetación.

Figura 5: ImageNet clasificación [40]



Las metodologías tradicionales de clasificación de imágenes, que incluían técnicas como los árboles de decisión o las máquinas de vectores de soporte, a menudo requerían características elaboradas a mano y extraídas de los datos de las imágenes[41]. La introducción del aprendizaje automático redujo la necesidad de esta extracción manual de características, permitiendo a los sistemas aprender y mejorar directamente a partir de los datos.

El aprendizaje profundo, en particular, ha transformado significativamente la clasificación de imágenes. Las redes neuronales convolucionales (CNN), un tipo de modelo de aprendizaje profundo, fueron el estándar para los datos de imágenes hasta finales de 2020, punto a partir del cual el paradigma dominante ha pasado a ser el de las arquitecturas de tipo transformer aplicadas a la visión (Vision Transformer o ViT)[42].

Las CNN aprenden características jerárquicas directamente de los píxeles en bruto, lo que evita la necesidad de ingeniería manual de características. Estas redes constan de capas convolucionales y de agrupación, seguidas de capas totalmente conectadas. Las capas convolucionales extraen características locales, mientras que las capas de agrupamiento reducen las dimensiones espaciales, garantizando la invariabilidad del modelo a la escala y la rotación[41].

Los avances en arquitecturas como las redes residuales (ResNet)[43], los transformadores de visión (ViT) [44] y los diseños para tareas específicas como GeoResNet[45] han ampliado los límites de las aplicaciones de aprendizaje profundo en la clasificación de imágenes. Estas arquitecturas permiten aumentar la profundidad del modelo, mejorar el rendimiento y permitir el procesamiento de datos geoespaciales, algo crucial para tareas como el análisis de imágenes de satélite.

Sin embargo, cabe destacar los retos y limitaciones asociados al uso de ML y DL para la clasificación de imágenes. Entre ellos se incluyen cuestiones relacionadas con la calidad de los datos, la necesidad de aumentar los datos, la complejidad del modelo, la generalización, la interpretabilidad, los posibles sesgos y las cuestiones éticas[46]. Además, es importante tener en cuenta las métricas de evaluación y comparación utilizadas en los modelos de clasificación de imágenes ML y DL, tales como la exactitud (accuracy), la precisión, la recuperación (recall), el score F1, la matriz de confusión y la curva ROC.

Aunque esta discusión se ha centrado en la teledetección, es importante señalar que el ML y el DL para la clasificación de imágenes encuentran aplicaciones en varios otros dominios, incluyendo el reconocimiento facial, la detección de objetos, la comprensión de escenas, las imágenes médicas, entre otros.

2.4 Redes residuales (ResNet), transformadores de visión (SWIN) y ResNetGeo.


2.4.1 Redes residuales (ResNet)

La arquitectura ResNet, introducida por Kaiming He, influyó poderosamente el enfoque de las redes neuronales profundas [43]. Las ResNets abordan el problema del desvanecimiento del gradiente (*vanishing gradient*), un problema común en el entrenamiento de redes profundas¹⁴. Este problema emerge cuando una red es demasiado profunda, los gradientes a partir de los cuales se calcula la función de pérdida se reducen fácilmente a cero tras varias aplicaciones de la regla de la cadena.

¹⁴ A medida que se añaden a las redes neuronales más capas que utilizan determinadas funciones de activación, los gradientes de la función de pérdida se aproximan a cero, lo que dificulta el entrenamiento de la red.

El resultado es que los pesos nunca actualizan sus valores y, por lo tanto, no se está realizando ningún aprendizaje.

Figura 6: Arquitectura ResNet50 [47]



La ResNet aborda este problema mediante la implementación de "atajos entre conexiones" o "saltos de conexiones (*skip connections*)". Estas conexiones permiten realizar el *backpropagation* del gradiente directamente a las capas anteriores, lo que permite entrenar redes excepcionalmente profundas, con arquitecturas de hasta 152 capas. La introducción de ResNet mejoró significativamente el rendimiento de los modelos de aprendizaje profundo en tareas de clasificación de imágenes, estableciendo el benchmarking de referencia en conjuntos de datos como ImageNet entre el 2016 y el 2020.

2.4.2. Transformers SWIN

Los Transformers de Visión (ViT), introducidos por Dosovitskiy et al. en 2020, supusieron un cambio con respecto a las arquitecturas convolucionales tradicionales utilizadas en tareas de visión por computador[48]. ViT aplica la arquitectura de

transformadores, utilizada principalmente en tareas de procesamiento del lenguaje natural, a los datos de imágenes.

Figura 7: Arquitectura con dos bloques de Swin Transformers [44]

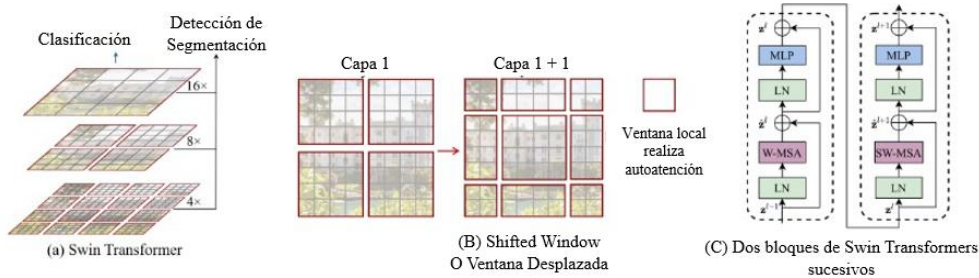
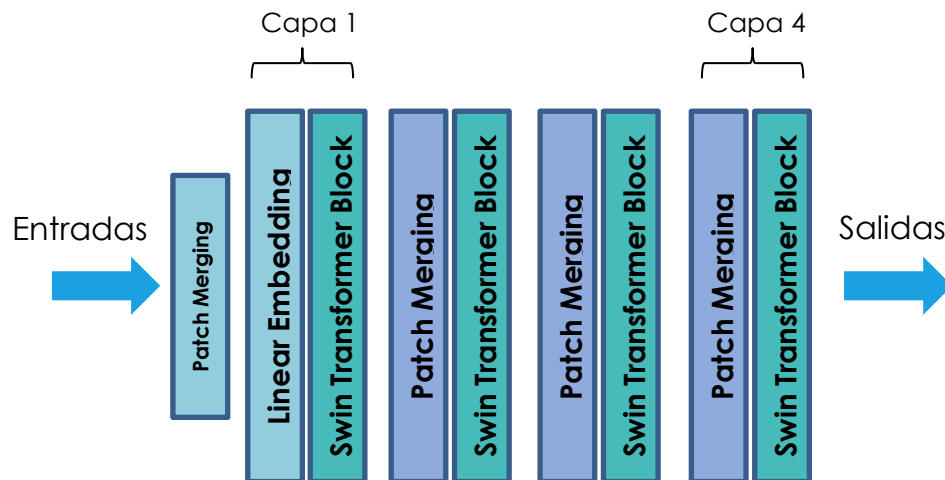


Figura 8: Arquitectura Sliding Shifted Window [49]



Las SWIN Transformers, una variante de las ViT, introducen un mecanismo de ventana de desplazamiento para gestionar datos de imagen a gran escala y mejorar la escalabilidad de los transformadores en visión por ordenador[44]. En lugar de procesar toda la imagen a la vez, los Transformadores SWIN procesan pequeños parches locales de la imagen secuencialmente, reduciendo sustancialmente los requisitos computacionales y manteniendo un rendimiento excelente. Al momento de


escribir este trabajo, las arquitecturas de tipo transformer son el benchmarking de referencia actual en el conjunto de datos ImageNet.

2.4.3. TorchGeo ResNet

Para hacer frente a los desafíos únicos que presentan las imágenes satelitales y aéreas, como las distorsiones espaciales y la naturaleza multiescala y jerárquicamente estructurada de los datos, Stewart y otros autores introdujeron en septiembre de 2022 TorchGeo[45], una biblioteca Python diseñada específicamente para integrar datos geospaciales en el ecosistema de aprendizaje profundo PyTorch4.

TorchGeo ofrece cargadores de datos para varios conjuntos de datos de referencia, conjuntos de datos componibles para fuentes de datos geospaciales genéricos, muestreadores para datos geospaciales y transformaciones compatibles con imágenes multiespectrales.

Figura 9: Ejemplo de aplicación TorchGeo en el que se combinan A) una imagen de Landsat 8 y B) etiquetas de la base de datos Cropland Data Layer, aunque estos archivos estén en diferentes proyecciones EPSG. Es posible muestrear los parches C) y D) de estos conjuntos de datos utilizando TorchGeo [45]



Cabe destacar que TorchGeo es la primera biblioteca que ofrece modelos preentrenados para imágenes de satélite multispectrales, como las que utilizan todas las bandas de los satélites Sentinel-2, incluyendo modelos de tipo ResNet. En el caso de los modelos ResNet pre entrenados disponibles en TorchGeo estos fueron entrenados sobre un conjunto de datos que consiste en tripletas de parches de imágenes satelitales sin etiquetar (Sentinel-1 dual-pol SAR, Sentinel-2 top-of-atmosphere multispectral, Sentinel-2 surface reflectance multispectral) de 251,079 lugares de todo el mundo, cada parche cubre 2640mx2640m e incluye cuatro marcas temporales estacionales[50]. Esto permite avances significativos en el aprendizaje por transferencia.

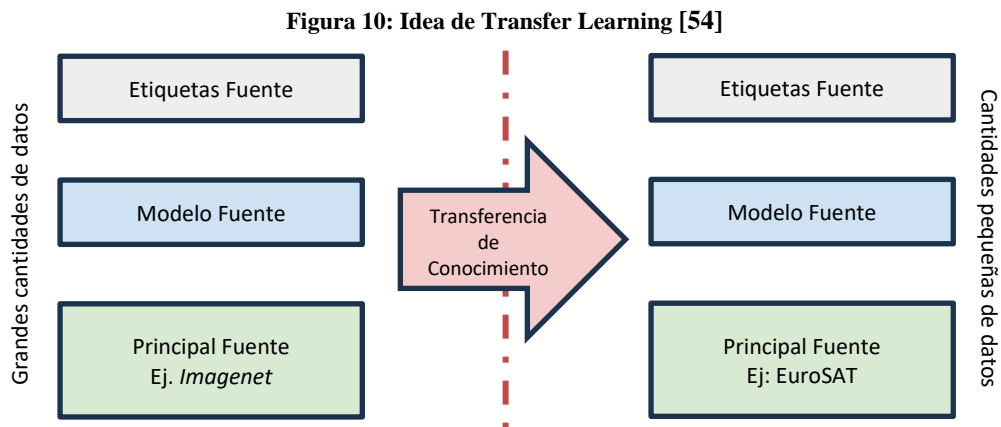
2.4.4. Aprendizaje por Transferencia

La idea general del aprendizaje por transferencia (“*transfer learning*”) es utilizar los conocimientos adquiridos en tareas para las que se dispone de muchos datos etiquetados en entornos en los que sólo se dispone de pocos datos etiquetados. La creación de datos etiquetados es cara, por lo que es fundamental aprovechar al máximo los conjuntos de datos existentes[51].

En un modelo de aprendizaje automático tradicional, el objetivo principal es generalizar a datos desconocidos basándose en patrones aprendidos de los datos de entrenamiento. Con el aprendizaje por transferencia, se intenta poner en marcha este proceso de generalización partiendo de patrones aprendidos para una tarea diferente[52].

El entrenamiento de grandes modelos desde cero en el aprendizaje profundo requiere una gran cantidad de datos etiquetados, importantes recursos informáticos y un tiempo considerable. A menudo, estos requisitos son difíciles de cumplir. Como se ilustra en la Figura 10, el aprendizaje por transferencia ayuda a superar estos retos

aprovechando modelos pre-entrenados, normalmente entrenados en grandes conjuntos de datos como ImageNet, que ya han aprendido características robustas y generalizables[53]. Estos modelos pueden ajustarse a una tarea específica con un conjunto de datos mucho más pequeño, lo que reduce significativamente los recursos y el tiempo necesarios.



En el contexto de la clasificación de imágenes, las primeras capas de un modelo de aprendizaje profundo suelen aprender características de bajo nivel, como bordes y texturas, mientras que las capas posteriores aprenden características de alto nivel, como partes de objetos u objetos enteros. Con el aprendizaje por transferencia, básicamente estamos aprovechando estas características aprendidas previamente, que probablemente sean útiles en diferentes tareas de clasificación de imágenes.

Sin embargo, es importante señalar que el aprendizaje por transferencia no está exento de dificultades. Pueden surgir problemas como la adaptación al dominio, la transferencia negativa y el olvido catastrófico si la tarea original y la nueva son demasiado diferentes o si el modelo olvida la tarea original mientras aprende la nueva[55].

- **Adaptación de dominios:** Tiene el objetivo de tomar un modelo de aprendizaje automático entrenado en un dominio y adaptarlo a otro dominio en el que la distribución de datos puede ser diferente[55]. Por ejemplo, un modelo entrenado en imágenes tomadas durante el día puede no funcionar bien en imágenes tomadas por la noche porque las condiciones de iluminación (es decir, la distribución de datos) difieren significativamente. En el aprendizaje por transferencia, si las tareas de origen y destino pertenecen a dominios muy diferentes, el modelo puede no transferirse bien porque las características aprendidas en el dominio de origen pueden no ser efectivas o relevantes en el dominio de destino.
- **Transferencia negativa:** Se refiere al escenario en el que el conocimiento transferido de la tarea de origen a la tarea de destino perjudica, en lugar de beneficiar, el rendimiento en la tarea de destino[56]. Suele ser el resultado de una gran disparidad entre las tareas de origen y de destino. Por ejemplo, si un modelo entrenado para identificar animales se utiliza como punto de partida para identificar vehículos, las características aprendidas de los animales podrían no sólo no ser útiles, sino que incluso podrían inducir a error al modelo, provocando un peor rendimiento que si se hubiera entrenado desde cero con los datos de los vehículos.
- **Olvido catastrófico:** Los modelos de aprendizaje profundo tienen tendencia a olvidar la información previamente aprendida cuando se entrenan en nuevas tareas, un problema conocido como olvido catastrófico[57]. Cuando un modelo pre-entrenado se pone a punto en una nueva tarea, los pesos del modelo se actualizan para aprender la nueva tarea, lo que podría llevar a olvidar los conocimientos adquiridos en la tarea original. Esto es

especialmente problemático cuando se espera que el modelo funcione bien tanto en la tarea original como en la nueva.

El empleo del aprendizaje por transferencia es especialmente valioso en tareas como la clasificación de imágenes hiperespectrales para el análisis del uso y la cobertura del suelo (LU/LC), donde los datos etiquetados pueden ser escasos o caros de obtener. Al utilizar un modelo pre-entrenado en un conjunto de datos amplio y diverso, puede beneficiarse de las representaciones de características aprendidas del modelo y ajustar el modelo a su tarea específica, consiguiendo potencialmente un mayor rendimiento con menos datos y menos recursos informáticos[58].

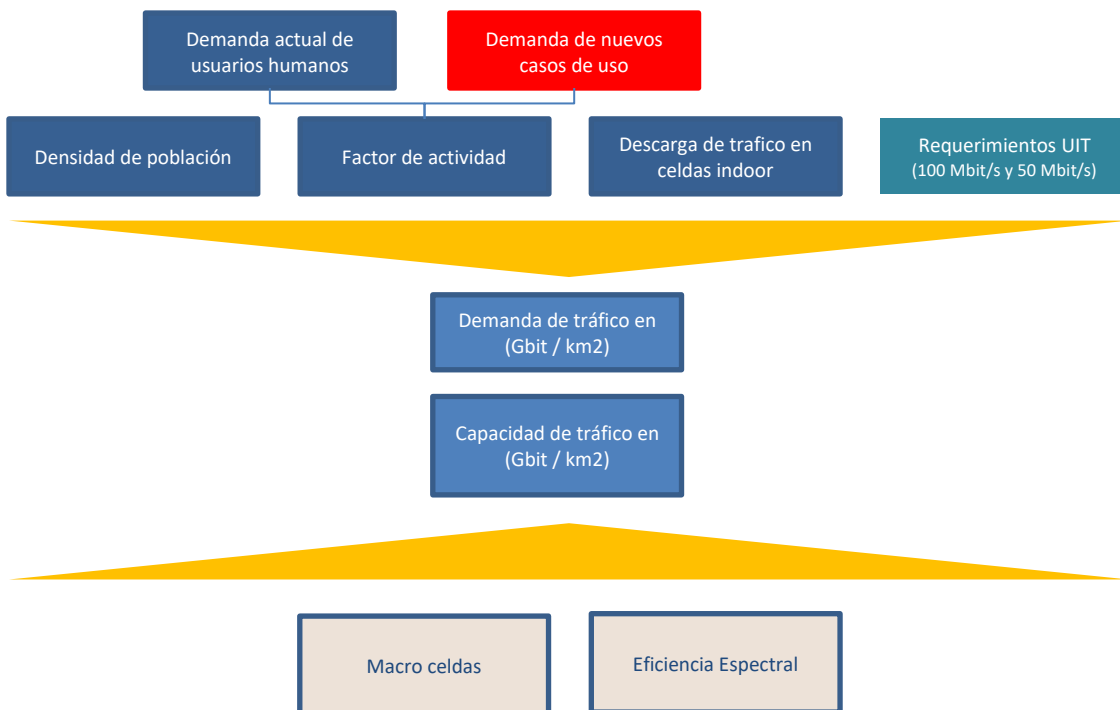
Hemos explorado las técnicas más avanzadas de aprendizaje automático y aprendizaje profundo y su aplicación a la clasificación de imágenes, además de profundizar en el concepto de aprendizaje por transferencia. En las próximas secciones, discutiremos más a fondo algunas de las aplicaciones prácticas de estas técnicas avanzadas en la clasificación de imágenes, desde la detección de objetos y materiales hasta la identificación de patrones en datos de teledetección, y cómo estas aplicaciones pueden utilizarse para estimar las necesidades de telecomunicaciones en un área geográfica.

2.5. Necesidades de Telecomunicaciones Inalámbricas

Por su parte, la demanda de telecomunicaciones inalámbricas ha sido un tema que ha tratado la UIT en diferentes recomendaciones técnicas iniciando con la recomendación ITU-R M. 1390 de 1999 el cual describe la metodología para el cálculo de las necesidades de espectro terrenal en las IMT. En resumen, la recomendación técnica detalla una metodología que consiste en determinar las necesidades individuales de espectro de todas las combinaciones representativas de

entornos y servicios concretos. Además, indica que los cálculos deben considerar diferentes densidades y necesidades de movilidad. Posteriormente, la UIT desarrolla una recomendación específica para la demanda de espectro en ITU-R M. 1768-1 “Methodology for calculation of spectrum requirements for the terrestrial component of International Mobile Telecommunications”, en cual se describen los tipos de servicio a ser modelados incluyendo nuevos servicios que aparecen con tecnologías 4G los datos de baja velocidad a los datos de super alta velocidad.

Figura 11: Modelo de demanda de tráfico y capacidad [59]



Como se puede observar en la Figura 11, expertos de la industria agregan los nuevos casos de uso como una entrada necesaria en la función de cálculo de la demanda de tráfico (ver recuadro resaltado en rojo en la Figura 11). Esta demanda determina las expectativas de inversión y la asignación por parte de los Gobiernos de los insumos necesarios como el espectro radioeléctrico.

Es así como la identificación del potencial de conectividad y/o la demanda de tráfico a través de fuentes convencionales puede ser mejorada con datos de sensores remotos para alcanzar una mayor precisión, mayor rentabilidad y mejor análisis de los cambios. De esta forma, tendría el potencial de convertirse en una estrategia verificable en el tiempo.

Respecto al uso de estas técnicas para la planeación de redes de telecomunicaciones, la literatura especializada plantea diferentes soluciones comerciales que facilitan la toma de decisiones de los operadores (Digital Globe, ATDI entre otros). También se identificaron investigaciones en donde se determina el LULC con imágenes de alta resolución que brindan información sobre densidad, así como una variedad de categorías de utilización de suelo. Por ejemplo, el conjunto de datos de *Euromap* se aplicó para toda Alemania con el objetivo de obtener 24 clases de densidad y uso urbanos para uso de planificación en telecomunicaciones móviles[30].

Capítulo 3

METODOLOGÍA

Para el desarrollo de las estimaciones de tráfico se desarrolló una arquitectura de i) adquisición de datos, ii) entrenamiento, iii) identificación del mejor desempeño, iv) identificación de áreas de interés en Colombia y v) predicción de coberturas para el área de interés de Colombia. Una vez obtenidas las categorías de cobertura de suelo se realizó una estimación de la demanda de espectro 5G para cada municipio de estudio.

Al realizar la predicción sobre las coberturas aplicadas a los municipios de estudio es posible determinar que sus características varían significativamente entre los usos del suelo principalmente diferenciado por la cantidad de Mts² utilizados para los diferentes usos, lo cual tiene repercusiones significativas en la planeación de redes de telecomunicaciones.

3.1 Diseño experimental y datos utilizados

EuroSAT¹⁵ es un conjunto de datos utilizado como conjunto de entrenamiento de aprendizaje profundo para la clasificación del uso y la cobertura del suelo. El conjunto de datos se basa en imágenes del satélite Sentinel-2 que cubren 13 bandas espectrales y constan de 10 clases con un total de 27.000 imágenes etiquetadas y georreferenciadas con la ayuda del European Urban Atlas^{16 17}. Esta base de datos fue presentada por Helber, Bischke, & Dengel [13] como un avance en la existencia de

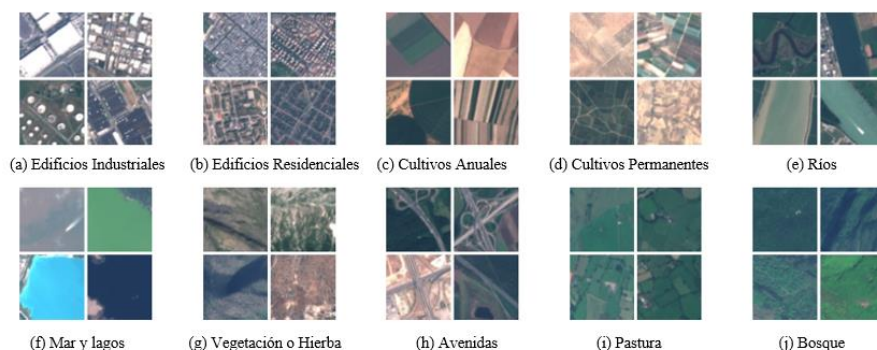
¹⁵ Base de datos se encuentra disponible en [13]

¹⁶ Iniciativa Europea con mapas de alta resolución de uso del suelo de más de 300 Grandes Zonas Urbanas y sus alrededores (más de 100.000 habitantes según la definición de la Auditoría Urbana)

¹⁷ European Urban Atlas es una iniciativa similar a National Land Cover Database por sus siglas en inglés NLCD y gestionado por el U.S Geological Survey (USGS)

conjuntos de datos para clasificación ya que mencionan los autores los conjuntos de datos existentes no eran públicos, o no podían ser replicados con fuentes de información de acceso libre. Además, los mismos fueron extractados de diferentes ciudades y países de Europa más específicamente 34 países¹⁸ europeos que traerá implicaciones para la comparación de resultados y su aplicación a Colombia.

Figura 12: Ejemplo de las categorías de la base de datos EuroSAT [13]



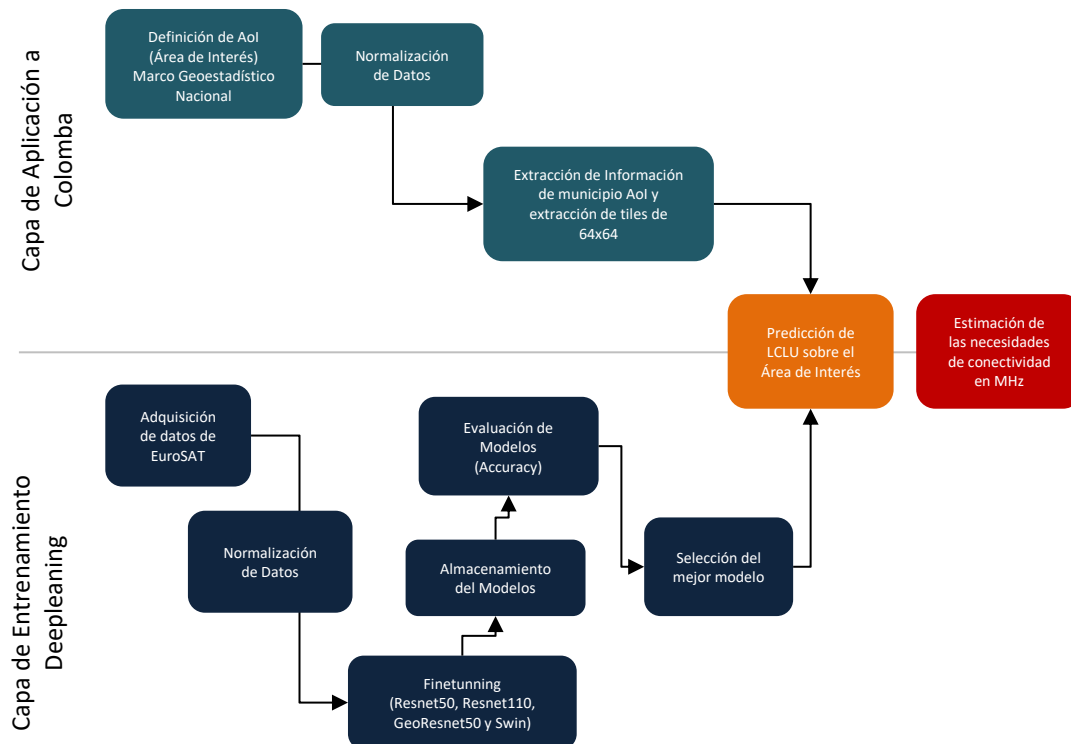
Entre las 10 categorías previamente determinadas y etiquetadas de la Figura 12, se encuentran i) edificios industriales, ii) edificios residenciales, iii) cultivos interanuales iv) cultivos permanentes, v) ríos, vi) mares, vii) hierba, viii) avenidas, ix) pastizales y x) bosques. Estas categorías y su relevancia con los diferentes usos y necesidades de telecomunicaciones hicieron de este conjunto de datos el principal elemento de entrenamiento sin que este sea a futuro el único elemento de entrada de datos, ya que como lo evidenciamos existen diferentes conjuntos de datos que podrían ser usados en su conjunto para enriquecer el análisis.

¹⁸ Las ciudades cubiertas se distribuyen por los 34 países europeos: Austria, Bielorrusia, Bélgica, Bulgaria, Chipre, República Checa (Czechia), Dinamarca, Estonia, Finlandia, Francia, Alemania, Grecia, Hungría, Irlanda, Islandia, Italia / Santa Sede, Letonia, Lituania, Luxemburgo, Macedonia, Malta, República de Moldavia, Noruega, Países Bajos, Polonia, Portugal, Rumanía, Eslovaquia, Eslovenia, España, Suecia, Suiza, Ucrania y Reino Unido

3.2 Arquitectura de la aplicación

Para el entrenamiento se realizó una arquitectura que separa las funcionalidades del entrenamiento y la predicción, además se determinó una serie de algoritmos para la adquisición de datos para Colombia mediante la plataforma de Google Earth Engine seleccionando las coberturas del Margo Geoestadístico Nacional distribuido por el DANE[60]. Finalmente, ambas funcionalidades se unen para la predicción de un área geográfica específica de Colombia.

Figura 13: Arquitectura de entrenamiento y predicción para concluir en las necesidades de telecomunicaciones



Fuente: Elaboración propia

El procedimiento está centrado en el uso del conjunto de datos de EuroSat y el posterior entrenamiento utilizando 4 arquitecturas de redes neuronales

convolucionales como los son Resnet50, Resnet101, GeoResnet50 y Swin Transformer.

En primera medida, se realizó una separación funcional dividiendo la fase de entrenamiento de la parte de predicción y aplicación a Colombia en un municipio específico o Área de Interés (AoI). Esta separación funcional fue considerada por facilitar el entendimiento del código implementado y posterior elaboración de modelos, así como la reducción de costos y tiempo computacional al separar el entrenamiento de la predicción de cobertura de uso.

Respecto a la fase de entrenamiento, esta consistió en incorporar un conector para adquirir la base de imágenes EuroSat. Posteriormente, estas imágenes fueron transformadas (normalización) a escala (1,0) para el desarrollo correcto del entrenamiento y así eliminar el posible efecto de valores considerablemente más altos dadas las características geográficas como vegetación, humedad, entre otros. Con este conjunto de entrenamiento normalizado se procedió al entrenamiento o “*fine tuning*” el cual considera el ajuste de la última capa de salida de la red convolucional en las 4 arquitecturas (SWIN, Resnet50, Resnet101 y GeoResnet50). Finalmente, las mismas se compararon mediante métricas de evaluación de “*accuracy*” para determinar el mejor modelo con la base de datos fuera de muestra.

Por otro lado, la capa de aplicación a Colombia consistió en el uso del marco geoestadístico nacional MGN publicado por el Departamento Nacional de Estadística (DANE). Una vez obtenido el polígono del municipio se procedió a realizar la división de este en “tiles” de 64x64 píxeles para realizar la extracción de la información contenida por Sentinel-2 a través de la plataforma Google Earth Engine. Finalmente, y una vez realizado el paso 1 y paso 2 la unión de los algoritmos consiste en evaluar la información geográfica de Colombia en los modelos entrenados

(particularmente el que alcanzó máximo desempeño). Así, se obtiene la predicción de cobertura para cada uno de los “tiles” del municipio de estudio. Finalmente, mediante una revisión de literatura y elaboración de supuestos de consumo por tecnología se obtiene la cantidad de MHz en cada uso.

3.3 Medidas de evaluación sobre los datos de entrenamiento fuera de muestra

Para determinar el modelo de mejor desempeño para realizar la predicción sobre las áreas geográficas colombianas se consideró utilizar una división del EuroSAT en (80% *train dataset* / 20% *test dataset*, ~21,000 imágenes entrenamiento y ~5,400 de prueba) seleccionada aleatoriamente con una semilla para su posterior replicación. Posteriormente, y por tratarse de un problema de clasificación, la selección del mejor modelo se obtuvo por la medida de evaluación “accuracy”. Esta métrica mide la cantidad de aciertos sin distinguir los falsos positivos o los verdaderos negativos en un ejercicio de múltiples clases (dada la evaluación de negocio y las múltiples clases no es posible determinar cuál tipo de error debe pesar más que el otro).

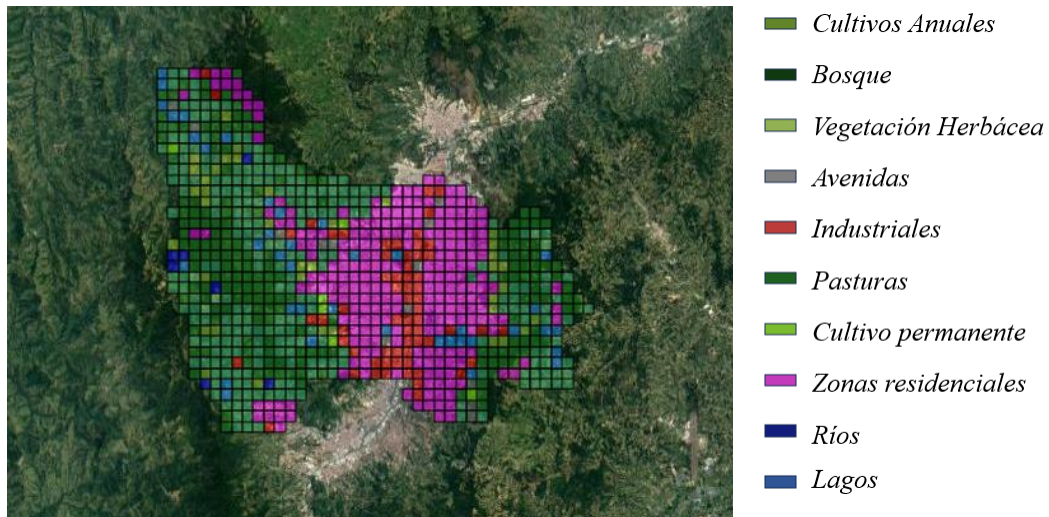
$$(1) \textit{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$$

3.4 Aplicación y *tunning* de los modelos a la demanda de telecomunicaciones móviles

Utilizando el mejor modelo el cual fue determinado como el Swin Transformer[61] se procede a la predicción de áreas de interés dentro de Colombia[62]. Posterior a la determinación de las áreas geográficas se realiza una predicción de dichas áreas las cuales deben ser divididas en una cuadrícula de 64 Pixeles x 64 Pixeles. Estos *tiles* de las regiones geográficas colombianas son utilizados como entrada de la red

neuronal y mediante un proceso iterativo se obtienen las clasificaciones del modelo para cuantos tiles sean objeto de estudio y/o estén incorporados dentro de la región geográfica.

Figura 14: Predicción modelo SWIN Transformer sobre la superficie de Medellín – Antioquia



Fuente: Elaboración propia

La predicción de los 10 tipos de coberturas determinadas en la Tabla 2 obtienen valor desde un punto de planeación de telecomunicaciones en la medida que es posible identificar el uso predominante en dicho *tile* y por tanto considerar su necesidad de telecomunicaciones restringido a cierta zona geográfica de acuerdo con al tipo de uso del suelo. Es de mencionar que cada *tile* representa 640m x 640m considerando que cada píxel de Sentinel-2 corresponde a 10m.

Capítulo 4

RESULTADOS Y DISCUSIÓN: Aplicación al Contexto de las Telecomunicaciones 5G

De la evaluación de esta medida sobre el 20% de la muestra separada antes del entrenamiento en un subconjunto “*test dataset*” podemos obtener las siguientes medidas de evaluación.

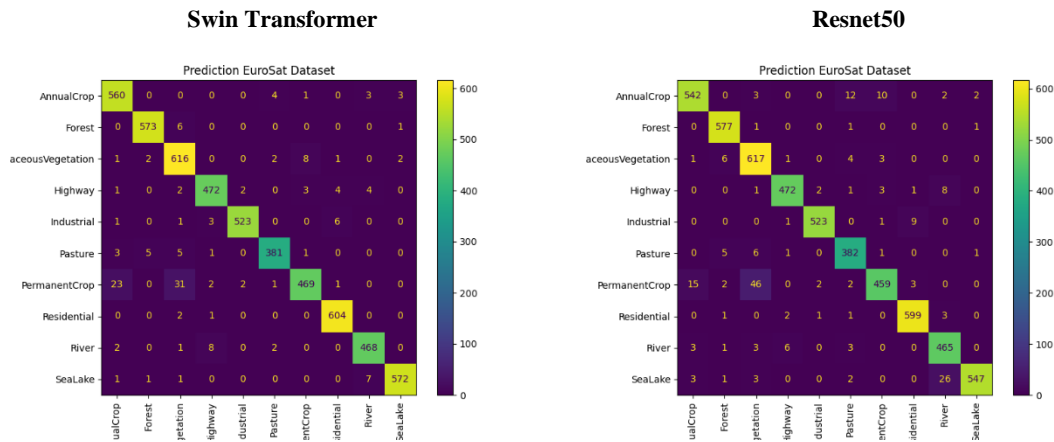
Tabla 2: Tabla de Evaluación de Medidas modelos entrenados con 80/20 Eurosat

	Resnet50	Resnet101	SWIN	GeoResnet50
Accuracy	0.959	0.97	0.97	0.77

Fuente: Elaboración propia

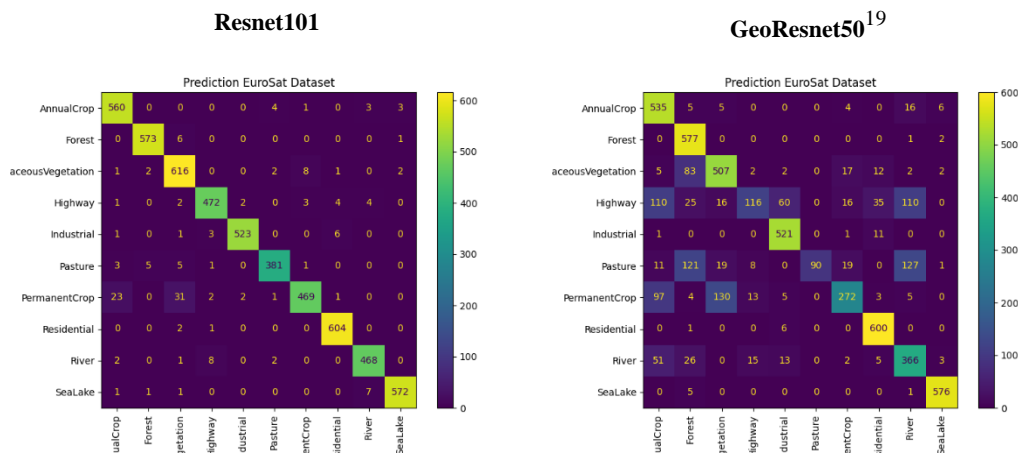
De la anterior tabla se puede evidenciar que la arquitectura que mejor se desempeñó fuera de muestra fue la arquitectura ResNet101 y SWIN que se comportaron frente a esta métrica de una forma similar obteniendo 0.97. En tercer lugar, tenemos la arquitectura Resnet50 con un desempeño de 0.959 en *Accuracy*. Finalmente, la Arquitectura GeoResnet50 obtenida de la librería *Torchgeo* la cual preentrega sus modelos con datos multiespectrales obtuvo el peor desempeño con 0.77. En este caso, cabe señalar que se considera que la misma se encuentra optimizada para los 13 sensores y no desempeña bien en imágenes RGB.

Figura 15: Matriz de Confusión modelos Swin Transformer y Resnet50



Fuente: Elaboración propia

Figura 16: Matriz de Confusión modelos Resnet101 y GeoResnet50



Fuente: Elaboración propia

¹⁹ Arquitectura Resnet50 de la librería TorchGeo las cuales son entrenadas con imágenes multiespectrales.

Una vez entrenado y seleccionado el algoritmo de clasificación a utilizar mediante la medida de desempeño de “*accuracy*” se procede a determinar los municipios de estudio²⁰ para lo cual el algoritmo consulta el Marco Geoestadístico Nacional con el fin de identificar el polígono de selección. Posteriormente se realiza una solicitud de los píxeles del municipio a la plataforma de Google Earth Engine (GEE) la cual almacena los datos de diferentes misiones de exploración espacial con metadatos como la cobertura de las nubes la cual fue establecida en su nivel más bajo.

Cómo se mencionó en un capítulo 3, la determinación de la geografía y tipología geográfica de una región son determinantes para el cálculo de las necesidades de telecomunicaciones. Mencionan diferentes organismos y empresas consultoras que la 5G debe ofrecer una velocidad de datos móviles experimentada por el usuario de 100 Mbit/s en el enlace descendente y de 50 Mbit/s en el ascendente[4], [59], y dar cabida a 1 millón de conexiones por km². Sin embargo, dichas recomendaciones varían dependiendo de la región y sus características urbanas.

Para tal fin, el uso del mejor modelo (SWIN) entrenado mediante un proceso de *fine-tuning* detallados en el capítulo 3 para identificar 10 tipos de coberturas determinadas en la Tabla 3 obtienen valor desde un punto de planeación de telecomunicaciones en la medida que es posible inferir un uso principal en determinada zona geográfica de acuerdo con al tipo de uso del suelo. Así mismo, se determina un color por tipo de cobertura que permita un ejercicio de visualización por caso de negocio.

²⁰ Los municipios fueron seleccionados aleatoriamente entre tres categorías de clasificación previamente establecidas en ejercicios de la Agencia Nacional del Espectro utilizando categorías previas de denso, urbano y rural

Tabla 3: Coberturas por Usos

Tipo de Cobertura	Uso (5G)	Color
Cosecha Anual	mIoT ²¹	Verde
Bosque	NA	Gris
Vegetación Herbácea	NA	Gris
Carreteras	NA	Gris
Industrial	uRLL ²² , eMBB ²³	Rojo
Pasto	mIoT	Verde
Cultivos Permanentes	mIoT	Verde
Residencial	FWA ²⁴ , mIoT, eMBB	Amarillo
Ríos	NA	Gris
Océano y Lagos	NA	Gris

Fuente: Elaboración propia

Con el fin de determinar la aplicación de este análisis se determinaron 3 municipios de estudio, esto sin perjuicio de que los resultados pudieran realizarse para todo Colombia o para una zona geográfica específica. Estos municipios fueron seleccionados con unas características típicas de un ejercicio de dimensionamiento de red como lo son Denso, Urbano y Rural mediante una clasificación sobre la población cubierta en la cabecera²⁵. De acuerdo con dicha clasificación fueron seleccionados: Medellín en el departamento de Antioquia²⁶, Cartago²⁷ en el Valle del Cauca y El Calvario en departamento del Meta²⁸

²¹ mIoT se refiere a Massive IoT

²² uRLL se refiere a Ultra Reliability Low Latency – Tecnología para aplicaciones industriales

²³ eMBB se refiere a banda ancha mejorada – Dispositivos móviles con anchas más ancho de banda.

²⁴ FWA se refiere a Acceso fijo inalámbrico – Servicio de internet al hogar.

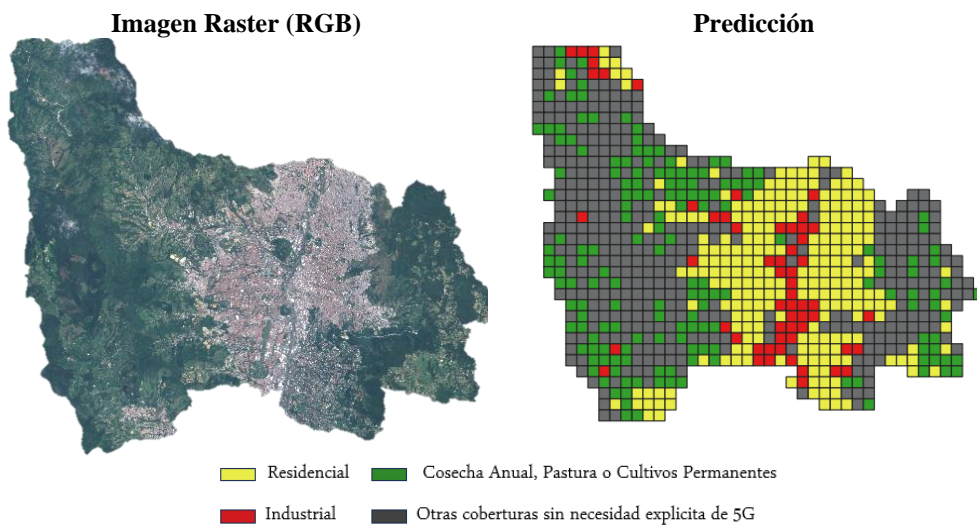
²⁵ Los municipios densos son aquellos en los cuales la población de la cabecera es superior a la rural y cuenta con más de 100.000 habitantes, Los municipios urbanos son aquellos en los cuales la población de la cabecera es mayor a la rural, pero tiene menos de 100.000 habitantes. Finalmente, la población tipología rural son aquellos municipios en los cuales la población rural supera la población de la cabecera.

²⁶ Municipio identificado con el Código DANE - 05001

²⁷ Municipio identificado con el Código DANE - 76147


²⁸ Municipio identificado con el Código DANE - 50226

Figura 17: Agrupación de usos según necesidad de telecomunicaciones - Medellín



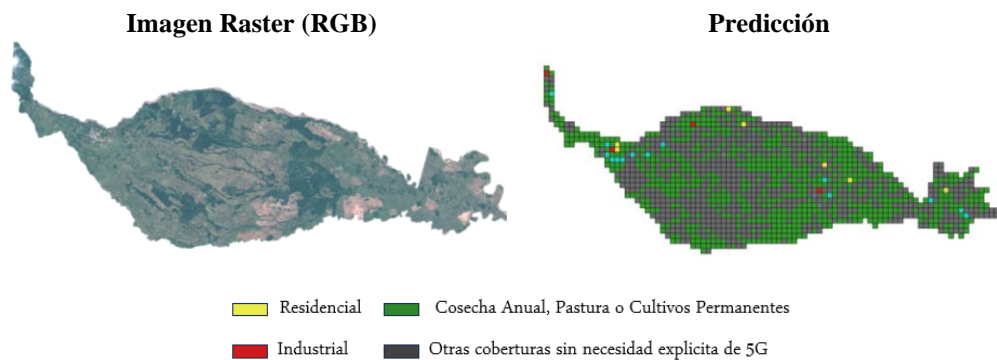
Fuente: Elaboración propia

Figura 18: Agrupación de usos según necesidad de telecomunicaciones - Cartago



Fuente: Elaboración propia

Figura 19: Agrupación de usos según necesidad de telecomunicaciones - Calvario



Fuente: Elaboración propia

Por otra parte, con el fin de dimensionar la capacidad de la red requerida para satisfacer la demanda de tráfico de los usuarios y dispositivos para los diferentes usos mencionados, en primer lugar, de deben establecer como datos de entrada la eficiencia espectral (b/s/Hz/sector) de 5G.

Autores han manifestado dudas frente a los objetivos trazados de eficiencia espectral para la tecnología 5G, teniendo en cuenta que las tecnologías inalámbricas podrían estar alcanzando el límite de Shannon[63], lo cual generaría importantes obstáculos tecnológicos para obtener las mejoras previstas de eficiencia espectral para la tecnología 5G. Ahora bien, simulaciones realizadas sobre la tecnología 5G han permitido obtener las siguientes eficiencias espectrales promedio:

Tabla 4: Eficiencia Espectral Promedio Obtenida Tecnología 5G [64] [65]

	Eficiencia Espectral Promedio	
	Uplink	Downlink
Denso / Urbano	5,4 b/s/Hz	7,8 b/s/Hz
Rural	1,6 b/s/Hz	3,3 b/s/Hz

Una vez definidos estos parámetros de entrada (Eficiencia espectral de Uplink, Eficiencia espectral de Downlink, se procede a calcular la cantidad de dispositivos por metro cuadrado(m²) y su consumo promedio para una calidad optima. Para esto se realizó una revisión de diferentes proyectos de automatización industrial tanto rural como urbana y sus métricas asociadas con el fin de estimar una densidad de dispositivos por m² plausible para cada caso de uso.

Para el primer caso, se consideraron los dispositivos utilizados para automatización en ambientes urbanos, especialmente aquellos comúnmente clasificados como dispositivos para ciudades inteligentes. Así, la literatura especializada[66], estima que en zonas urbanas se instalarán 0.3023 dispositivos por m², calculado como la suma de los usos descritos en Tabla 5.

Tabla 5: Densidad de Dispositivos por Mt2 – Ciudades Inteligentes [66]

mIoT Ciudades Inteligentes ²⁹	
Tipo	Densidad por Metro Cuadrado
Medidores de Agua	0,1
Medidores de Electricidad	0,1
Medidores de Gas	0,1
Peajes Urbanos	0,00225

Posteriormente, y debido a la diversidad de casos de uso o aplicaciones de internet de las cosas en sitios rurales y aplicaciones de agricultura inteligente, se consultaron proyectos e implementaciones a nivel global de los cuales se identificaron 5 casos que incluyen ganadería, riego y manejo de aguas. Luego, se identificó la densidad de dispositivos utilizando un promedio de la densidad de dispositivos.

Tabla 6: Densidad de Dispositivos por Mt2 – Agricultura Inteligente

mIoT Agricultura Inteligente				
Caso	Num Hectáreas	Dispositivos del Proyecto	Metros de Proyecto	Densidad por metro cuadrado
Cognag[67]	100	2000	1'000.000	0,002
Iberdrola[68]	3000	600	30'000.000	0,00002
One Water[69]	100	3000	1'000.000	0,003

²⁹ EMC Challenges of the Internet of Things

mIoT Agricultura Inteligente				
Saga Robotics[69]	500	100	5'000.000	0,00002
Desamis[70]	1000	3000	10'000.000	0,0003
Densidad Dispositivos Total				0,0003

Para el caso de uso industrial se consideró el caso de uso de AMAZON quienes realizan operaciones logísticas en bodegas[71]. Para este caso y de acuerdo con la revisión del caso se consideró 1 elemento robótico cada 8 m² para una densidad uRLL de 0.1250 por metro cuadrado.

Finalmente, la densidad eMBB y FWA es calculada con el numero de hogares del municipio y con el número de habitantes determinado por el Departamento Administrativo Nacional de Estadística (DANE) dividido la cantidad de metros calculados mediante los usos del suelo. Este cálculo permite modelar la existencia de diferentes densidades correspondientes a diferentes tipos de municipio o geotipos que también se encuentra en la literatura de telecomunicaciones.

Respecto a las predicciones LU/LC, se realiza la predicción del uso del suelo y se determinan la cantidad de *tiles* por uso del suelo para cada uno de los municipios seleccionados. Este resultado se ilustra en la Tabla 7.

Tabla 7: Cantidad de Tiles por LU

Tipo de Cobertura	Medellín	Cartago	El Calvario
Cosecha Anual	5	35	149
Bosque	82	0	4
Vegetación Herbácea	230	76	86
Carreteras	13	1	14
Industrial	58	15	4
Pasto	144	218	439
Cultivos Permanentes	19	97	78
Residencial	233	23	7
Ríos	36	22	159
Oceano y Lagos	1	34	423

Fuente: Elaboración propia con base en modelo entrenado.

Posteriormente, se agrupan los cuadros de acuerdo con los casos de uso determinados en la Tabla 3, correspondiente a mIoT, uRLL y FWA. Es importante reconocer que

la implementación de este estudio permite la superposición de capas de conectividad en la cual dos diferentes usos pueden y deben convivir para así sumar sus necesidades de conectividad.

Tabla 8: Cantidad de Tiles determinados por uso

Ciudad	mIoT + Rural (Tiles)	mIoT + Urban (Tiles) ³⁰	URLL (Tiles)	FWA (Tiles)	eMBB (Tiles) ³¹
Medellín	168	233	58	233	291
Cartago	350	23	15	23	37
El Calvario	666	7	4	7	11

Fuente: Elaboración propia con base en modelo entrenado.

Con el fin de determinar la cantidad de MHz requeridos por *tile* realizamos la operación de la ecuación (2) y (3). Para esto es necesario determinar algunos supuestos de densidad de dispositivos por uso y el consumo esperado de los mismos. También se determina la distancia entre macro-celdas el cual corresponde a una cada 500Mts².

Supuestos de Consumo por Tipo de Uso					
Uso	Consumo (Mbps) DL	Consumo (Mbps) UL	Disp x Mt2	Disp x EB	Distancia entre EB en Mts ² ³²
FWA	100	100	0,0167	8,3333	500
uRRL	100	100	0,1250	62,5000	500
mIoT + Urban	10	5	0,3023 ³³	151,1250	500
mIoT + Rural	10	5	0,0003 ³⁴	0,1500	22.500 ³⁵
eMBB	100	50	0,2105	105,2707	500

³⁰ Es equivalente al área determinada como residencial por LU ya que incluye sensores de ciudad como medidores de agua inteligentes, contadores eléctricos inteligentes, medidores de gas y peajes electrónicos, así como elementos asociados a ciudades inteligentes.

³¹ Se determina con la suma de dos tipos de cobertura Residencial e Industrial ya que las mismas necesidades se superponen en una misma área geográfica.

³² La UIT determina que la cobertura al nivel de macroceldas para 5G estará limitada a una cobertura de 500mts

³³ Suma de 4 casos de uso como medidores inteligentes, medidores eléctricos inteligentes, medidores de gas inteligentes y peajes electrónicos.

³⁴ Promedio de 5 proyectos como Cognag, Iberdrola, One Water, Saga Robotics y Desamis.

³⁵ Se utilizó la relación cobertura urbana a rural en la banda de 2600MHz - APT 700MHz Best Choice for nationwide coverage – Esta relación es 45/1 respecto a sectores urbanos.

La tabla anterior indica la cantidad de consumo la distancia en metros y la cantidad de dispositivos por cada tipo de tile para lo cual se realiza la operación de la ecuación (1) con el fin de determinar el Throughput (DL y UL) de cada tile.

$$(1) \text{ Capacidad (DL y UL)} = \text{Consumo}_{DL \text{ y } UL} \times (\text{Dispositivos}_{Mt2} * \text{Distancia Cubierta})$$

Así, se determina que la capacidad requerida downlink (DL) y uplink (UL) depende del consumo por dispositivo multiplicado por la cantidad de dispositivos por mt2 multiplicado por la distancia cubierta de las estaciones base (EB).

Así, y posterior a la determinación de los supuestos es posible calcular la ecuación 2 y 3 para la determinación de la cantidad de MHz requeridos por cada tipo de *tile*.

$$(2) \text{ BW (MHz)}_{DL} = \frac{\text{Capacidad}_{DL \text{ Tile}} \text{ (Mbps)}}{EB_{\text{Tile}} \times EE_{DL} \left(\frac{\text{Mbps}}{\text{MHz}} \right) \times \left(\frac{\text{Sector}}{\text{Sites}} \right)^{36}}$$

$$(3) \text{ BW (MHz)}_{UL} = \frac{\text{Capacidad}_{UL \text{ Tile}} \text{ (Mbps)}}{EB_{\text{Tile}} \times EE_{UL} \left(\frac{\text{Mbps}}{\text{MHz}} \right) \times \left(\frac{\text{Sector}}{\text{Sites}} \right)^{37}}$$

Las ecuaciones anteriormente señaladas determinan que el ancho de banda en cantidad de MHz (BW) tanto para downlink (DL) y uplink (UL) están determinadas por la capacidad requerida para el *tile* específico o capacidad (DL y UL) en Mbps dividido por el factor o cantidad de estaciones base (EB) de cada tile multiplicado por la eficiencia espectral y la cantidad de sectores en cada sitio.

³⁶ Se asumen 3 sectores por Estación Base EB debido a que cada sector genera 120° y para dar cobertura total o 360° se requieren al menos 3.

³⁷ Ibidem

Posterior a la aplicación de las fórmulas anteriores se obtiene información respecto al Downlink y Uplink de los diferentes *tiles* en la cual es necesario considerar que las diferentes capas están superpuestas en relación con su uso. Esta relación total de MHz requeridos por tile se detalla en las diferentes tablas para cada uno de los municipios sujetos de estudio.

Tabla 9: MHz requeridos por tipo de uso para los diferentes municipios seleccionados

Medellín								
Uso	#Tiles	Downlink 7,8 Mbps/MHz/Sector			Uplink 5,4 Mbps/MHz/Sector			Total MHz
		Throughput DL (Mbps)	Mbps cursados por sector (DL)	MHz requerido ³⁸ s EB (DL)	Throughput UL (Mbps)	Mbps cursados por sector (UL)	MHz requeridos EB (UL)	
FWA	233	4486	575	192	4486	831	277	469
uRRL	58	6250	801	267	6250	1157	386	653
mIoT Urban	233	1511	194	65	756	140	47	111
mIoT Rural	168	67.5	8.65	2.88	33.75	6.25	2.08	5
eMBB	291	10777	1382	461	5388	998	333	793

Cartago								
Uso	#Tiles	Downlink 7,8 Mbps/MHz/Sector			Uplink 5,4 Mbps/MHz/Sector			Total MHz
		Throughput DL (Mbps)	Mbps cursados por sector (DL)	MHz requerido ³⁹ s EB (DL)	Throughput UL (Mbps)	Mbps cursados por sector (UL)	MHz requeridos EB (UL)	
FWA	23	2477	318	106	2477	459	153	259
uRRL	15	6250	801	267	6250	1157	386	653
mIoT Urban	23	1511	194	65	756	140	47	111
mIoT Rural	350	67.5	8.65	2.88	33.75	6.25	2.08	5
eMBB	38	4498	577	192	2249	416	139	331

³⁸ Posterior a la aplicación de la ecuación de necesidades de espectro

³⁹ Posterior a la aplicación de la ecuación de necesidades de espectro

Calvario								
Uso	#Tiles	Downlink 7,8 Mbps/MHz/Sector			Uplink 5,4 Mbps/MHz/Sector			Total MHz
		Throughput DL (Mbps)	Mbps cursados por sector (DL)	MHz requerido ⁴⁰ s EB (DL)	Throughput UL (Mbps)	Mbps cursados por sector (UL)	MHz requeridos EB (UL)	
FWA	7	98	13	4	98	18	6	10
uRRL	4	6250	801	267	6250	1157	386	653
mIoT + Urba	7	1511	194	65	756	140	47	111
mIoT + Rural	666	67.5	8.65	2.88	33.75	6.25	2.08	5
eMBB	11	188	24	8	94	17	6	14

Asimismo, se identifican y se superponen diferentes tipos de uso dependiendo que la particularidad geográfica. El mismo análisis determina la cantidad de MHz requeridos ya que no se considera un solo uno y por el contrario se consideran múltiples usos en una misma área geográfica. En la siguiente tabla se identifican los usos para las diferentes regiones de estudio.

Tabla 10: MHz requeridos por Tile

Medellín - Antioquia					
Usos		FWA			
	uRRL				
		mIoT - Urbano			mIoT - Rural
		eMBB			
Superposición	uRRL + eMBB	FWA + eMBB + mIoT Urbano			mIoT Rural
Cantidad de MHz requeridos para la combinación de usos	1446	1372	1372	1372	5

Cartago - Valle					
Usos		FWA			
	uRRL				
		mIoT - Urbano			mIoT - Rural
		eMBB			
Superposición	uRRL + eMBB	FWA + eMBB + mIoT Urbano			mIoT Rural
Cantidad de MHz requeridos para la combinación de usos	984	700	700	700	5

⁴⁰ Posterior a la aplicación de la ecuación de necesidades de espectro

Calvario - Meta					
Usos		FWA			
	uRRL				
		mIoT - Urbano		mIoT - Rural	
		eMBB			
Superposición	uRRL + eMBB	FWA + eMBB + mIoT Urbano		mIoT Rural	
Cantidad de MHz requeridos para la combinación de usos	667	135	135	135	5

De la tabla anterior podemos observar que el requerimiento de conectividad varia considerablemente para cada geotipo dada la cantidad de metros cuadrados relevantes identificados y las necesidades de conectividad y cubrimiento de la población. Sin embargo, tanto para los usos uRLL y mIoT se considera que no son concluyentes ya que la cantidad de espectro dependerá drásticamente del tipo de instalación que uRLL requiera y pueden no ser homogéneas en el país. Así mismo, por la baja densidad de dispositivos y el poco consumo en Mbps del cálculo de demanda de espectro asigna casi 0 a mIoT rural sin embargo esta parece no ser una recomendación adecuada ya que también dependerá de la infraestructura instalada y la cobertura de la macrocelda.

4.1 Ventajas, limitaciones y retos del cálculo de MHz mediante LC/LU.

Como se puede observar en la tabla de resultados de las tablas Tabla 9 y Tabla 10 es posible identificar la cantidad de Kmts² por uso en cada municipio o zona de estudio para así determinar los requerimientos de conectividad de cada uno de ellos relacionado a los diferentes usos. Así mismo fue posible identificar rangos similares a los descritos por la UIT en los requerimientos de espectro IMT a 2020, quienes llegan a la siguiente conclusión plasmada en el Reporte UIT-R M.2290 de 2013:

Tabla 11: Demanda de espectro por densidad de usuarios

	Tecnologías pre-IMT, IMT-2000	Tecnologías IMT-Avanzada	Total
Baja densidad de usuarios	440 MHz	900MHz	1340 MHz
Alta densidad de usuarios	540MHz	1420MHz	1960 MHz

Fuente: UIT[10]

También, concuerda en los rangos de valor determinados por GSMA en los cuales se identifica que para el 2030 se requerirán 2GHz de espectro en bandas medias con el fin de cubrir todas las necesidades de conectividad de la población (GSMA, New Spectrum for 5G: Adding Up the Mid-Band Maths, s.f.). Esto contrasta con los 480MHz que actualmente están asignado en Colombia y abre un espacio de reflexión a la próxima subasta de 5G en la cual se consideran 400MHz adicionales y 40MHz de espectro remanente en diferentes bandas.

Sin embargo, vemos limitaciones en el enfoque en la medida que la identificación de zonas industriales de momento no provee suficiente información del tipo de despliegue que se requeriría en dicha zona ya que los mismos pueden variar considerablemente entre geotipos. Es decir, una zona industrial en Bogotá con una automatización será diferente a un desarrollo industrial agrícola o de una zona urbana no densa.

También, a través de una aproximación visual es posible evidenciar que estos tiles son de gran tamaño para una región ya que constan de 640m x 640m considerando que cada pixel de Sentinel-2 corresponde a 10m. Esto puede ser problemático ya que pueden existir 2 usos diferentes en el mismo tile. Aun así, consideramos que esto será parte del trabajo futuro con una consideración técnica para la reducción de pixeles.

A pesar de las dificultades que trae la identificación utilizada en este trabajo se abre la puerta a análisis que no dependen o están limitados a un municipio específico y por el contrario permiten hacer desagregaciones locales a regiones, tiles o incluso pixeles que tienen diferentes necesidades de conectividad. Para así generar políticas más eficientes de asignación e incluso valoración del bien.

Capítulo 5

CONCLUSIONES Y TRABAJOS FUTUROS

Los resultados de nuestro trabajo ponen de manifiesto el valor de integrar bases de datos etiquetadas sobre el uso del suelo y la cobertura terrestre (LU/LC) con técnicas de transferencia de aprendizaje para mitigar las deficiencias de la información geoespacial en Colombia. Esta conclusión es particularmente relevante dada la existencia de un vacío en la recopilación y distribución de datos geoespaciales precisos y fiables en Colombia. En este sentido, el empleo de técnicas de transferencia de aprendizaje se presenta como un enfoque eficaz para adaptar modelos de aprendizaje profundo previamente entrenados a nuevos conjuntos de datos regionales.

A través de nuestra investigación, se ha evidenciado el potencial de las técnicas de aprendizaje profundo en el procesamiento de imágenes satelitales, especialmente en lo que respecta a la clasificación de la cobertura terrestre. Pese a que varias arquitecturas de aprendizaje profundo han demostrado ser valiosas para este propósito, en el análisis del conjunto de datos del Sentinel-2, las arquitecturas *Transformer*, específicamente las *SWIN Transformer*, han mostrado un rendimiento superior y más eficaz.

Las arquitecturas SWIN y Resnet, con su habilidad para gestionar efectivamente las dependencias a largo plazo y centrar su atención en las características más pertinentes de la imagen, parecen ser especialmente aptas para la tarea de interpretar y analizar imágenes satelitales. Esto sugiere que estas arquitecturas podrían ser la elección predilecta en la mayoría de los casos, especialmente al tratar con conjuntos de datos de gran complejidad y volumen, como los empleados en este estudio.

En este trabajo, se ha demostrado que la integración del procesamiento de imágenes satelitales con algoritmos de aprendizaje profundo constituye una herramienta

poderosa para la planificación y optimización de las redes 5G. Al identificar y clasificar diferentes tipos de uso del suelo y cobertura terrestre, se pueden proyectar las necesidades de espectro para diversos tipos de aplicaciones (IoT, uRLL, FWA, entre otros). Adicionalmente, este enfoque permite la identificación de zonas específicas que pueden requerir atención prioritaria en el despliegue de la infraestructura de la red 5G lo que podría ser instrumental para lograr una implementación eficiente y efectiva de las redes 5G en el país.

En el transcurso de este proyecto, se corroboró que la estimación de espectro obtenida mediante nuestra metodología concuerda con las recomendaciones internacionales existentes para la planificación del espectro 5G. Esta conformidad con las directrices globales, incluyendo las establecidas por la Unión Internacional de Telecomunicaciones (UIT) y la GSMA, respalda la efectividad de nuestra metodología de procesamiento de imágenes satelitales y uso de algoritmos de aprendizaje profundo.

No obstante, cabe subrayar que nuestro método aporta un grado de desagregación superior, permitiendo una identificación más detallada y precisa de las necesidades de espectro. Al clasificar detalladamente los usos del suelo y la cobertura terrestre en diferentes áreas geográficas, logramos determinar las necesidades de espectro con una especificidad muy alta, tanto en términos de casos de uso como de ubicación geográfica.

Hemos observado que, coherente con lo sugerido en el Reporte UIT-R M.2290 de 2013 y en los cálculos proporcionados por la GSMA, la demanda de espectro para tecnologías IMT avanzadas identificada tiende a situarse en el rango de 1446MHz a 667MHz, en función del geotipo. No obstante, el valor añadido de nuestra metodología radica en su capacidad para desagregar estos datos generales, identificar

necesidades puntuales por *tile* facilitando un análisis más preciso de las necesidades de espectro en función de factores urbanísticos, geográficos y de uso. Esta cifra contrasta con los 480MHz que actualmente están asignados en Colombia y plantea importantes cuestiones para la próxima subasta de 5G, en la que se consideran 400MHz adicionales y 40MHz de espectro remanente en diferentes bandas.

A lo largo de este trabajo, nos encontramos con ciertas limitaciones inherentes a las fuentes de datos disponibles actualmente. Las imágenes de bases de datos abiertas utilizadas, como las del Sentinel-2, presentan una resolución espacial relativamente baja. Este hecho nos ha permitido realizar un análisis a una escala más amplia, aunque con un nivel de detalle más limitado. Un pixel de las imágenes del Sentinel-2 equivale a un área de 10 metros cuadrados, lo que significa que cada tile o mosaico de la imagen abarca un área considerable de 640 x 640 metros. Tal resolución, a pesar de ser útil para un análisis a gran escala, puede presentar desafíos al intentar identificar usos de suelo distintos dentro de un mismo mosaico.

Además, observamos que la clasificación de ciertas zonas, como las industriales, no proporciona suficiente información sobre el tipo de despliegue de 5G que se requeriría. Por ejemplo, el despliegue necesario para una zona industrial altamente automatizada en Bogotá podría ser considerablemente diferente al requerido para un desarrollo industrial agrícola o una zona urbana no densa.

Por lo tanto, se hace necesario explorar el uso de otras fuentes de imágenes, como las imágenes aéreas u otras fuentes de mayor resolución. Este enfoque permitiría un nivel de desagregación superior y una clasificación más precisa de los diferentes usos del suelo, lo que a su vez facilitaría la estimación más exacta de las necesidades de tráfico 5G.

Adicionalmente, se ha demostrado que la metodología propuesta para el procesamiento de imágenes satelitales y el uso de algoritmos de aprendizaje profundo puede aplicarse efectivamente en la estimación de la demanda de tráfico 5G, teniendo en cuenta el uso del suelo y la cobertura terrestre. Sin embargo, el alcance y el potencial de este enfoque podría exceder el ámbito de las telecomunicaciones.

Es prometedor explorar cómo la clasificación de uso del suelo y cobertura terrestre (LU/LC) puede ser útil en otros contextos y aplicaciones. Manteniendo la mayor parte de la metodología que hemos propuesto, es factible extender su uso a diversas disciplinas y sectores. Los datos que pueden obtenerse a partir de la interpretación de las imágenes satelitales y su posterior análisis mediante aprendizaje profundo pueden proporcionar información crucial para la planificación y la toma de decisiones en una gran variedad de campos.

Por ejemplo, este enfoque podría aplicarse en la planificación urbana y rural, en la gestión de los recursos naturales, en la monitorización del cambio climático y en la mitigación de desastres, entre otros. La capacidad para identificar y categorizar de manera precisa y eficiente las diferentes formas de uso del suelo y cobertura terrestre puede proveer una valiosa información para la planificación y gestión a escala nacional.

Por lo tanto, aunque nuestro trabajo ha estado orientado hacia el sector de las telecomunicaciones, creemos que los resultados y las conclusiones de nuestra investigación tienen un alto potencial de aplicabilidad en otros campos. Este es un aspecto que merece ser explorado más a fondo en investigaciones futuras, dado que podría contribuir significativamente al avance de múltiples disciplinas y al mejoramiento de las estrategias de planificación y gestión a nivel nacional.

Adicionalmente, los trabajos futuros podrían extender este enfoque para abordar otros aspectos relacionados con el despliegue de las redes 5G, como la identificación de ubicaciones óptimas para desarrollar programas de política pública o imponer obligaciones de cobertura.

REFERENCIAS

- [1] X. Lin, «An Overview of 5G Advanced Evolution in 3GPP Release 18», ene. 2021.
- [2] H. Holma, A. Toskala, y T. Nakamura, *5G Technology: 3GPP New Radio / Wiley*. Accedido: 19 de junio de 2023. [En línea]. Disponible en: <https://www.wiley.com/en-us/5G+Technology%3A+3GPP+New+Radio-p-9781119236290>
- [3] ITU, «5G - Fifth generation of mobile technologies», *ITU*. <https://www.itu.int:443/en/mediacentre/backgrounders/Pages/5G-fifth-generation-of-mobile-technologies.aspx> (accedido 19 de junio de 2023).
- [4] ITU, «ITU towards “IMT for 2020 and beyond”». <https://www.itu.int/en/ITU-R/study-groups/rsg5/rwp5d/imt-2020/Pages/default.aspx> (accedido 19 de noviembre de 2022).
- [5] ITU, «IMT-2020 BACKGROUND». Accedido: 19 de junio de 2023. [En línea]. Disponible en: <https://www.itu.int/en/ITU-R/study-groups/rsg5/rwp5d/imt-2020/Documents/060R1e.pdf>
- [6] M. Contento, «Massive IoT and 5G: What’s Next for Large-Scale Cellular IoT», *Telit*, 9 de septiembre de 2022. <https://www.telit.com/blog/massive-iot-5g-whats-next/> (accedido 13 de noviembre de 2022).
- [7] CISCO, «What Is Low Latency? Ultra-low Latency Use Cases», *Cisco*, 13 de noviembre de 2022. <https://www.cisco.com/c/en/us/solutions/data-center/data-center-networking/what-is-low-latency.html> (accedido 13 de noviembre de 2022).
- [8] C. Kim, «5G and Massive IoT: legacy technologies will bridge the gap for now :: Omdia», 13 de noviembre de 2022. <https://omdia.tech.informa.com/OM004695/5G-and-Massive-IoT-legacy-technologies-will-bridge-the-gap-for-now> (accedido 13 de noviembre de 2022).
- [9] D. Schulz, «5G for digital industries | ABB», *News*, 13 de noviembre de 2022. <https://new.abb.com/news/detail/74698/5g-for-digital-industries> (accedido 13 de noviembre de 2022).
- [10] ITU-R, «Future spectrum requirements estimate for terrestrial IMT (M. 2290-0)», 2013.
- [11] ITU, «Guidelines on cost modelling», 2021. [En línea]. Disponible en: https://www.itu.int/dms_pub/itu-d/opb/stg/D-STG-SG01.04_CST_MOD-2021-PDF-E.pdf
- [12] NASA, «Data | Landsat Science», 30 de noviembre de 2021. <https://landsat.gsfc.nasa.gov/data/> (accedido 19 de junio de 2023).
- [13] P. Helber, B. Bischke, A. Dengel, y D. Borth, «EuroSAT: A Novel Dataset and Deep Learning Benchmark for Land Use and Land Cover Classification». Zenodo, Valencia, Spain, 22 de julio de 2018. doi: 10.5281/zenodo.7711810.

- [14] Y. Grinberger, M. Minghini, L. Juhász, y G. Yeboah, «The Academic Study of the OpenStreetMap Project, Data, Contributors, Community, and Applications», mar. 2022, Accedido: 20 de junio de 2023. [En línea]. Disponible en:
https://www.researchgate.net/publication/359625703_OSM_Science-The_Academic_Study_of_the_OpenStreetMap_Project_Data_Contributors_Community_and_Applications
- [15] NIREOS, «What Is Hyperspectral Imaging?»,
<https://www.nireos.com/hyperspectral-imaging/> (accedido 13 de noviembre de 2022).
- [16] N. Erdogan, E. Nurlu, A. Guvensen, y Ü. Erdem, «Land use/land cover change detection for environmental monitoring in Turkey: A case study in Karaburun Peninsula», *J. Environ. Prot. Ecol.*, vol. 16, pp. 252-263, ene. 2015.
- [17] A. Chatziantoniou, E. Psomiadis, y G. P. Petropoulos, «Co-Orbital Sentinel 1 and 2 for LULC Mapping with Emphasis on Wetlands in a Mediterranean Setting Based on Machine Learning», *Remote Sens.*, vol. 9, n.º 12, Art. n.º 12, dic. 2017, doi: 10.3390/rs9121259.
- [18] P. Fisher, A. Comber, y R. Wadsworth, «Land use and land cover: contradiction or complement», 2005, pp. 85-98.
- [19] P. C. Pandey, N. Koutsias, G. P. Petropoulos, P. K. Srivastava, y E. Ben Dor, «Land use/land cover in view of earth observation: data sources, input dimensions, and classifiers—a review of the state of the art», *Geocarto Int.*, vol. 36, n.º 9, Art. n.º 9, may 2021, doi: 10.1080/10106049.2019.1629647.
- [20] A. Whyte, K. P. Ferentinos, y G. P. Petropoulos, «A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms», *Environ. Model. Softw.*, vol. 104, pp. 40-54, jun. 2018, doi: 10.1016/j.envsoft.2018.01.023.
- [21] W. L. Stefanov, M. S. Ramsey, y P. R. Christensen, «Monitoring urban land cover change: An expert system approach to land cover classification of semiarid to arid urban centers», *Remote Sens. Environ.*, vol. 77, n.º 2, pp. 173-185, ago. 2001, doi: 10.1016/S0034-4257(01)00204-8.
- [22] G. P. Petropoulos, K. P. Vadrevu, y C. Kalaitzidis, «Spectral angle mapper and object-based classification combined with hyperspectral remote sensing imagery for obtaining land use/cover mapping in a Mediterranean region», *Geocarto Int.*, vol. 28, n.º 2, pp. 114-129, abr. 2013, doi: 10.1080/10106049.2012.668950.
- [23] P. Smith *et al.*, «Global Change Pressures on Soils from Land Use and Management», *Glob. Change Biol.*, vol. 22, pp. 1008-1028, mar. 2016, doi: 10.1111/gcb.13068.
- [24] Q. Liu, M. Kampffmeyer, R. Jessen, y A.-B. Salberg, «Dense Dilated Convolutions Merging Network for Land Cover Classification», *IEEE Trans.*

- Geosci. Remote Sens.*, vol. 58, n.º 9, pp. 6309-6320, sep. 2020, doi: 10.1109/TGRS.2020.2976658.
- [25] H. Zhai *et al.*, «Understanding Spatio-Temporal Patterns of Land Use/Land Cover Change under Urbanization in Wuhan, China, 2000–2019», *Remote Sens.*, vol. 13, n.º 16, Art. n.º 16, ene. 2021, doi: 10.3390/rs13163331.
- [26] N. Kabisch, P. Selsam, T. Kirsten, A. Lausch, y J. Bumberger, «A multi-sensor and multi-temporal remote sensing approach to detect land cover change dynamics in heterogeneous urban landscapes», *Ecol. Indic.*, vol. 99, pp. 273-282, abr. 2019, doi: 10.1016/j.ecolind.2018.12.033.
- [27] ESA, «Earth Online». <https://earth.esa.int/eogateway> (accedido 8 de junio de 2023).
- [28] «Banda Pancromática Y El Uso En Las Imágenes Satelitales». <https://eos.com/es/make-an-analysis/panchromatic/> (accedido 8 de junio de 2023).
- [29] E. Gidey, O. Dikinya, R. Sebege, E. Segosebe, y A. Zenebe, «Cellular automata and Markov Chain (CA_Markov) model-based predictions of future land use and land cover scenarios (2015–2033) in Raya, northern Ethiopia», *Model. Earth Syst. Environ.*, vol. 3, n.º 4, pp. 1245-1262, dic. 2017, doi: 10.1007/s40808-017-0397-6.
- [30] R. Richter, U. Weingart, y T. Wever, «Urban Clutter Data for the Telecommunications Industry». 2018.
- [31] R. Hillson *et al.*, «Estimating the size of urban populations using Landsat images: a case study of Bo, Sierra Leone, West Africa», *Int. J. Health Geogr.*, vol. 18, n.º 1, p. 16, jul. 2019, doi: 10.1186/s12942-019-0180-1.
- [32] M. S. Regasa, M. Nones, y D. Adeba, «A Review on Land Use and Land Cover Change in Ethiopian Basins», *Land*, vol. 10, n.º 6, Art. n.º 6, jun. 2021, doi: 10.3390/land10060585.
- [33] J. Heaton, «Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618», *Genet. Program. Evolvable Mach.*, vol. 19, oct. 2017, doi: 10.1007/s10710-017-9314-z.
- [34] T. M. Mitchell, *Machine Learning*. McGraw-Hill, 1997.
- [35] Y. LeCun, Y. Bengio, y G. Hinton, «Deep learning», *Nature*, vol. 521, n.º 7553, Art. n.º 7553, may 2015, doi: 10.1038/nature14539.
- [36] J. Schmidhuber, «Deep Learning in Neural Networks: An Overview», *Neural Netw.*, vol. 61, pp. 85-117, ene. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [37] M. Rimol y S. Alaybeyi, «Understand 3 Key Types of Machine Learning», *Gartner*. <https://www.gartner.com/smarterwithgartner/understand-3-key-types-of-machine-learning> (accedido 20 de junio de 2023).
- [38] J. Brownlee, «What Is Semi-Supervised Learning», *MachineLearningMastery.com*, 8 de abril de 2021. <https://machinelearningmastery.com/what-is-semi-supervised-learning/> (accedido 20 de junio de 2023).

- [39] F. Chollet, «Deep Learning with Python», *Manning Publications*. <https://www.manning.com/books/deep-learning-with-python> (accedido 8 de junio de 2023).
- [40] A. Krizhevsky, I. Sutskever, y G. E. Hinton, «ImageNet classification with deep convolutional neural networks», *Commun. ACM*, vol. 60, n.º 6, pp. 84-90, may 2017, doi: 10.1145/3065386.
- [41] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, y Z. Wojna, «Rethinking the Inception Architecture for Computer Vision». arXiv, 11 de diciembre de 2015. doi: 10.48550/arXiv.1512.00567.
- [42] «ImageNet Benchmark (Image Classification) | Papers With Code». <https://paperswithcode.com/sota/image-classification-on-imagenet> (accedido 8 de junio de 2023).
- [43] K. He, X. Zhang, S. Ren, y J. Sun, «Deep Residual Learning for Image Recognition». arXiv, 10 de diciembre de 2015. doi: 10.48550/arXiv.1512.03385.
- [44] Z. Liu *et al.*, «Swin Transformer: Hierarchical Vision Transformer using Shifted Windows». arXiv, 17 de agosto de 2021. doi: 10.48550/arXiv.2103.14030.
- [45] A. J. Stewart, C. Robinson, I. A. Corley, A. Ortiz, J. M. Lavista Ferres, y A. Banerjee, «TorchGeo: Deep Learning With Geospatial Data», *Proceedings of the 30th International Conference on Advances in Geographic Information Systems*. en SIGSPATIAL '22. Association for Computing Machinery, Seattle, Washington, pp. 1-12, noviembre de 2022. doi: 10.1145/3557915.3560953.
- [46] S. Sood, H. Singh, M. Malarvel, y R. Ahuja, «Significance and Limitations of Deep Neural Networks for Image Classification and Object Detection», en *2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, oct. 2021, pp. 1453-1460. doi: 10.1109/ICOSEC51865.2021.9591759.
- [47] S. Mukherjee, «The Annotated ResNet-50. Explaining how ResNet-50 works and why». <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758> (accedido 20 de junio de 2023).
- [48] A. Dosovitskiy *et al.*, «An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale». arXiv, 3 de junio de 2021. doi: 10.48550/arXiv.2010.11929.
- [49] J. Loy, «A Comprehensive Guide to Microsoft's Swin Transformer», *Medium*, 2 de agosto de 2022. <https://towardsdatascience.com/a-comprehensive-guide-to-swin-transformer-64965f89d14c> (accedido 12 de junio de 2023).
- [50] Y. Wang y A. Stewart, «SSL4EO-S12 Dataset». Zhu Lab, 5 de junio de 2023. Accedido: 9 de junio de 2023. [En línea]. Disponible en: <https://github.com/zhu-xlab/SSL4EO-S12>

- [51] Andrew Ng, «Transfer Learning», *Nerd For Tech*, 25 de febrero de 2021. <https://medium.com/nerd-for-tech/transfer-learning-7914c6ab2b56> (accedido 12 de junio de 2023).
- [52] J. Yosinski, J. Clune, Y. Bengio, y H. Lipson, «How transferable are features in deep neural networks?» arXiv, 6 de noviembre de 2014. doi: 10.48550/arXiv.1411.1792.
- [53] M. Long, Y. Cao, J. Wang, y M. I. Jordan, «Learning Transferable Features with Deep Adaptation Networks». arXiv, 27 de mayo de 2015. doi: 10.48550/arXiv.1502.02791.
- [54] integrate.ai, «Transfer Learning Explained», *the integrate.ai blog*, 12 de septiembre de 2018. <https://medium.com/the-official-integrate-ai-blog/transfer-learning-explained-7d275c1e34e2> (accedido 20 de junio de 2023).
- [55] W. M. Kouw y M. Loog, «An introduction to domain adaptation and transfer learning». arXiv, 14 de enero de 2019. doi: 10.48550/arXiv.1812.11806.
- [56] Z. Wang, Z. Dai, B. Póczos, y J. Carbonell, «Characterizing and Avoiding Negative Transfer», en *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, CA, USA: IEEE, jun. 2019, pp. 11285-11294. doi: 10.1109/CVPR.2019.01155.
- [57] Z. Ke, B. Liu, N. Ma, H. Xu, y L. Shu, «Achieving Forgetting Prevention and Knowledge Transfer in Continual Learning». arXiv, 5 de diciembre de 2021. doi: 10.48550/arXiv.2112.02706.
- [58] J. Lin, R. Ward, y Z. J. Wang, «Deep Transfer Learning for Hyperspectral Image Classification», en *2018 IEEE 20th International Workshop on Multimedia Signal Processing (MMSP)*, ago. 2018, pp. 1-5. doi: 10.1109/MMSP.2018.8547139.
- [59] GSMA y Coleago Consulting, «Estimating-Mid-Band-Spectrum-Needs.pdf», 2021. Accedido: 13 de noviembre de 2022. [En línea]. Disponible en: <https://www.gsma.com/spectrum/wp-content/uploads/2021/07/Estimating-Mid-Band-Spectrum-Needs.pdf>
- [60] DANE, «Geoportal DANE - Descarga del Marco Geoestadístico Nacional (MGN)». <https://geoportal.dane.gov.co/servicios/descarga-y-metadatos/descarga-mgn-marco-geoestadistico-nacional/> (accedido 12 de junio de 2023).
- [61] PyTorch, «Models and pre-trained weights — Torchvision 0.15 documentation». Linux Foundation, 2017. Accedido: 12 de junio de 2023. [En línea]. Disponible en: <https://pytorch.org/vision/stable/models.html>
- [62] M. L. Casado, «geotorch: Constrained Optimization and Manifold Optimization in Pytorch». Accedido: 8 de junio de 2023. [OS Independent]. Disponible en: <https://github.com/Lezcano/geotorch>
- [63] W. Webb, «The 5G Myth: When Vision Decoupled from Reality», en *The 5G Myth*, DeG Press, 2018. doi: 10.1515/9781547401185.

- [64] B. Anass, K. Koshiro, y A. Hiroyuki, «IMT-2020 Radio Interface Standardization Trends in ITU-R», *NTT DOCOMO Tech. J. Vol 19 No3*, pp. 55-63, ene. 2018.
- [65] E. Mohyeldin, «Minimum Technical Performance Requirements for IMT-2020 radio interface(s)», 2016.
- [66] Ericsson, «Ericsson Mobility Report». noviembre de 2016. Accedido: 21 de agosto de 2023. [En línea]. Disponible en: <https://displaydaily.com/wp-content/uploads/2016/11/ericsson-mobility-report-november-2016.pdf>
- [67] Peter, «Fraunhofer Lighthouse Project “Cognitive Agriculture (COGNAC)” - Fraunhofer IESE». <https://www.iese.fraunhofer.de/en/project/cognitive-agriculture.html> (accedido 21 de agosto de 2023).
- [68] Iberdrola, «Smart Farming y Agricultura de Precisión - Iberdrola». <https://www.iberdrola.com/innovacion/smart-farming-agricultura-precision> (accedido 21 de agosto de 2023).
- [69] World Bank Group, «Climate-Smart Agriculture», *World Bank*. <https://www.worldbank.org/en/topic/climate-smart-agriculture> (accedido 21 de agosto de 2023).
- [70] Desamis, «U-motion® - Monitor your herd's behavior». <http://desamis.co.jp/en/> (accedido 21 de agosto de 2023).
- [71] W. Knight, «Amazon's New Robots Are Rolling Out an Automation Revolution», *WIRED*, 26 de junio de 2023. Accedido: 21 de agosto de 2023. [En línea]. Disponible en: <https://www.wired.com/story/amazons-new-robots-automation-revolution/>