

**PONTIFICIA UNIVERSIDAD
CATÓLICA DEL PERÚ
ESCUELA DE POSGRADO**



**Monitoreo del crecimiento urbano en zonas vulnerables
empleando imágenes satelitales e inteligencia artificial**

Tesis para optar al grado académico de Maestro en Ingeniería Civil con
mención en Gestión de Riesgos Naturales, que presenta:

Javier Alonso Jaimes Cucho

Asesor:

Dr. Luis Angel Moya Huallpa

Lima, 2025

Informe de Similitud

Yo, Luis Angel Moya Huallpa, docente de la Escuela de Posgrado de la Pontificia Universidad Católica del Perú, asesor de la tesis titulado Monitoreo del crecimiento urbano en zonas vulnerables empleando imágenes satelitales e inteligencia artificial, del autor Javier Alonso Jaimes Cucho, dejo constancia de lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud de 19%. Así lo consigna el reporte de similitud emitido por el software *Turnitin* el **09/09/2025**.
- He revisado con detalle dicho reporte y la Tesis o Trabajo de Suficiencia Profesional, y no se advierte indicios de plagio.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lugar y fecha: Lima, 08 de octubre de 2025.

Apellidos y nombres del asesor: Moya Huallpa, Luis Angel DNI: 43010087 ORCID: 0000-0003-1764-3160	Firma: 
---	--

Dedicatoria



*A mi familia, por su apoyo
y compañía a lo largo de toda mi camino*

Agradecimientos



*A mi asesor Luis Moya,
por las enseñanzas, consejos y el constante apoyo
durante el desarrollo de esta investigación
A Concytec-Prociencia por financiar la presente investigación
en el marco del concurso “Tesis de Pregrado y Posgrado en Ciencia, Tecnología
e Innovación Tecnológica - Concurso E073-2024-01” [No. PE501091200-2024]*

Resumen

Las bases de datos de áreas urbanas desarrolladas a nivel mundial han demostrado su valor para el análisis del crecimiento urbano y usado como insumo para el desarrollo de diversas investigaciones que abordan los riesgos a los que están expuestas las diversas poblaciones. No obstante, estas bases de datos carecen de resolución temporal y espacial para el análisis a nivel local, especialmente en países en vías de desarrollo donde la información se encuentra desfasada. Esta tesis presenta un enfoque semisupervisado para la segmentación binaria del crecimiento urbano, orientado al monitoreo de la expansión no planificada en zonas vulnerables. Se destaca la necesidad urgente de contar con herramientas precisas, escalables y accesibles que permitan evaluar la exposición urbana en contextos caracterizados por la escasez de datos actualizados y la alta exposición a amenazas naturales. Se integran imágenes ópticas multitemporales del satélite Sentinel-2 con técnicas de aprendizaje débil y redes neuronales convolucionales (CNN), aprovechando información incompleta y de libre acceso para generar mapas de la huella urbana e identificar clusters de crecimiento urbano.

El marco teórico revisa el estado del arte en sensores remotos e inteligencia artificial, con énfasis en el potencial de las CNN para extraer características espaciales y espectrales relevantes a partir de imágenes satelitales. Sobre esta base, se plantea una metodología basada en el enfoque NNPU (Negative–Negative Positive-Unlabeled), una variante de aprendizaje débil diseñada para abordar tareas de segmentación binaria semisupervisada en escenarios con datos de referencia incompletos. El flujo de trabajo incluye el preprocesamiento de datos, la configuración de la arquitectura neuronal y el proceso de entrenamiento bajo supervisión débil.

La aplicación de esta metodología en Lima Metropolitana durante el período 2016–2025 permitió identificar una expansión urbana significativa en distritos como Carabaylo y Lurín. Se estimó un crecimiento de aproximadamente 8 km² en zonas clasificadas como altamente o muy altamente susceptibles a deslizamientos, y cerca de 4 km² en áreas propensas a inundaciones. Estos resultados reflejan una preocupante tendencia de ocupación urbana en sectores expuestos a múltiples amenazas naturales, lo que incrementa considerablemente la vulnerabilidad de la población.

El enfoque metodológico propuesto demuestra ser una herramienta eficaz y rentable para el monitoreo de la exposición urbana en entornos con restricciones técnicas y presupuestales. Su implementación puede fortalecer los sistemas de alerta temprana y apoyar la toma de decisiones en políticas de ordenamiento territorial y gestión del riesgo de desastres, promoviendo una respuesta más informada, proactiva y centrada en la reducción de la vulnerabilidad urbana.


Índice

Dedicatoria	i
Agradecimientos	ii
Resumen	iii
Indice	iv
Lista de tablas	vi
Lista de figuras	vii
1 Presentación del trabajo de investigación	1
1.1 Introducción	1
1.2 Antecedentes	2
1.3 Justificación	2
1.4 Hipótesis	3
1.5 Objetivos de la investigación	3
1.5.1 Objetivo general	3
1.5.2 Objetivos específicos	3
1.6 Alcance	4
2 Marco Conceptual	5
2.1 Crecimiento Urbano Global: Desigualdad, Morfología y Vulnerabilidad	5
2.1.1 Crecimiento urbano en el Perú	7
2.1.2 Crecimiento urbano en el Lima Metropolitana	8
2.2 Peligros Naturales en el Perú	9
2.2.1 Sismos	9
2.2.2 Susceptibilidad de movimiento de masas	10
2.3 Teledetección	11
2.3.1 Imágenes multiespectrales	11
2.3.2 Proyecto Sentinel	12
2.4 Redes Neuronales	13
2.4.1 Tipos de Redes Neuronales	14
2.4.2 Tipos de Aprendizaje	15

2.4.3	Métodos de Optimización Convencionales	15
2.4.4	Funciones de Activación	16
2.4.5	Hiperparámetros de una Red Neuronal	17
2.5	Redes Neuronales Profundas	18
2.5.1	Arquitectura de la red neuronal ResNet152	18
2.6	Métricas de Evaluación para la Validación de Modelos de Clasificación Basadas en la Matriz de Confusión	19
3	Estado del arte	21
4	Metodología	25
4.1	Enfoque propuesto para la segmentación semisupervisada	25
4.2	Arquitectura de la red neuronal	26
4.3	Flujo de trabajo	27
5	Evaluación experimental	29
5.1	Base de datos para la calibración de la red neuronal	29
5.2	Calibración de la red neuronal convolucional	32
5.3	Validación experimental	33
5.4	Evaluación experimental	35
5.5	Cuantificación del crecimiento de la exposición en Lima	42
5.6	Cuantificación del crecimiento urbano por nivel socioeconómico	47
5.7	Evaluación del crecimiento urbano en otras ciudades de la costa peruana	48
6	Conclusiones y recomendaciones	54
6.1	Conclusiones	54
6.2	Recomendaciones	54
	Referencias	57

Lista de tablas

2.1	Listado de terremotos y sismos en Perú (1970-2021)	10
2.2	Niveles de procesamiento de datos satelitales	12
2.3	Características de la arquitectura ResNet152	19
5.1	Imágenes ópticas de Sentinel-2 recopiladas para Lima Metropolitana	29
5.2	Resultados de validación comparando la clasificación basada en WSF2019 y CNN en diferentes áreas de Lima.	34
5.3	Maximo crecimiento urbano por periodo	40
5.4	Crecimiento urbano en las provincias de la costa peruana	49



Lista de figuras

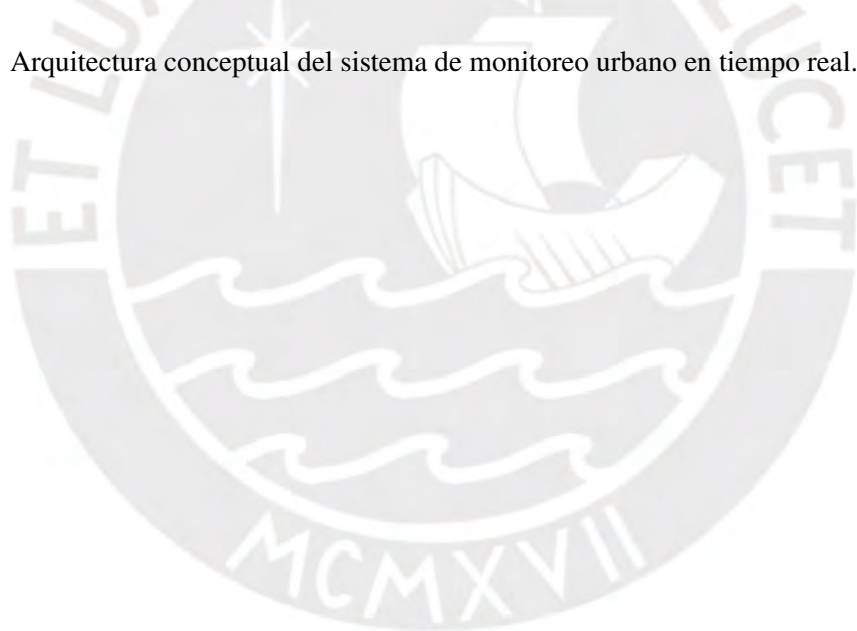
2.1	Esquema de los factores que configuran la vulnerabilidad urbana. Adaptado de [1]	6
2.2	<i>Susceptibilidad de movimiento de masas. Reelaborado de INGEMET [2]</i>	11
2.3	Esquema de una neurona artificial. Cada entrada x_i es ponderada por un peso sináptico w_i y sumada con un sesgo b . El resultado se transforma mediante una función de activación para producir la salida y .	13
2.4	Esquema de una red neuronal multicapa (MLP) con tres capas ocultas. Cada capa transforma las representaciones mediante combinaciones lineales y funciones de activación, generando finalmente la salida y .	14
2.5	Función de activación sigmoide.	16
2.6	Función tangente hiperbólica.	16
2.7	Función ReLU.	17
2.8	Función Swish.	17
2.9	Matriz de confusión para un problema de clasificación binaria.	19
3.1	<i>Segmentación urbana derivada de la capa real en 2019 (rojo), WSF2019 (azul) y Microsoft (verde) en 2021. Imagen de fondo corresponde a 2024.</i>	24
4.1	Arquitectura U-Net con codificador ResNet-152. La imagen de entrada se codifica progresivamente en características semánticas de alto nivel mediante bloques residuales y luego se decodifica para generar una máscara de segmentación detallada. Las líneas discontinuas indican conexiones de salto que fusionan los mapas de características del codificador y el decodificador para recuperar detalles espaciales.	27
4.2	<i>(a) Recolección de data de entrenamiento y descarga de imágenes. (b) Proceso de emparejamiento de imágenes de entrenamiento y máscara semántica, estandarización del tamaño de las imágenes de entrenamiento y entrenamiento de la red neuronal. (c) Localización de sitios de alto peligro de desastres, descarga de imágenes de alta resolución y estandarización.</i>	28
5.1	<i>Ubicación del área de estudio y conjunto de datos entrenamiento obtenidos. Los pixels en color rojo representan zonas urbanas; los pixels en color negro, las zonas no urbanas; y los pixels de color blanco, pixels sin clasificación</i>	30

5.2	Representación de algunas muestras de entrenamiento características de la base de datos (izquierda) y datos etiquetados disponibles de los mismos (derecha). (a) representa una muestra de área urbana en el centro de Lima Metropolitana, (b) y (c) representan muestras de la parte periférica de la ciudad, (d) representa una muestra totalmente no urbana y (e) representa una muestra no urbana en el océano	31
5.3	Flujo iterativo para el refinamiento de los resultados de la segmentación semisupervisada, adaptado de la metodología propuesta por Yokoya et. al. (2024) para el refinamiento de resultados de entrenamiento supervisado	32
5.4	<i>Curvas de entrenamiento y evaluación. Representan la evolución del costo en función del número épocas (Curvas derivadas con los siguientes hiperparámetros: 200 épocas, Tasa de aprendizaje de $5e-5$ y $\pi_p=0.35$)</i>	33
5.5	<i>La figura muestra las 20 muestras de validación de los resultados. Las subfiguras (a) hasta (j) representan las muestras periféricas, subfiguras (k) hasta (ñ) representan áreas urbanas centrales, subfiguras (o) hasta (q) representan áreas principalmente no urbanas y subfiguras (r) y (s) representan zonas del océano</i>	34
5.6	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Villa María del Triunfo. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	35
5.7	<i>La imagen muestra el crecimiento urbano en un sector del distrito de El Agustino. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	36
5.8	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Chorrillos. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	36
5.9	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Rimac. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	37
5.10	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Comas. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	37

5.11	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Lurigancho. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	38
5.12	<i>La imagen muestra el crecimiento urbano en un sector del distrito de Carabayllo. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024</i>	38
5.13	<i>Distribución espacial del crecimiento Urbano en Lima metropolitana desde el año 2016 al 2025, representada por la superficie de color rojo. La superficie de color azul representa la delimitación de áreas urbanas en el 2016</i>	39
5.14	<i>Crecimiento acumulado del área urbana por distrito en Lima Metropolitana desde el 2016 al 2025</i>	41
5.15	<i>(a) Zona de riesgo de inundación inducida por tsunamis tras un terremoto de 8,9 Mw. (b) Zona de susceptibilidad a deslizamientos de tierra. (c) Microzonificación sísmica. [2]</i>	42
5.16	<i>(a) Histograma del desarrollo de conglomerados urbanos de 2016 a 2025. (b) Expansión urbana en zonas de inundaciones propensas a tsunamis después de un terremoto de magnitud 8,8 (2016-2025). (c) Crecimiento urbano en áreas susceptibles a deslizamientos de tierra (2016-2025). (d) Desarrollo urbano en zonas de suelos sísmicamente peligrosos (2016-2025).</i>	43
5.17	<i>Crecimiento urbano del distrito de Carabayllo en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	43
5.18	<i>Crecimiento urbano del distrito de Lurín en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	44
5.19	<i>Crecimiento urbano del distrito de Pachacamac en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	44

5.20	<i>Crecimiento urbano del distrito de Punta Hermosa en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	44
5.21	<i>Crecimiento urbano del distrito de Villa María del Triunfo en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	45
5.22	<i>Crecimiento urbano del distrito de Ventanilla en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	45
5.23	<i>Crecimiento urbano del distrito de Cieneguilla en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	45
5.24	<i>Crecimiento urbano del distrito de Lurigancho en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	46
5.25	<i>Crecimiento urbano del distrito de San Juan de Lurigancho en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	46
5.26	<i>Crecimiento urbano del distrito de Puente Piedra en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento</i>	46
5.27	<i>Crecimiento Urbano disponible por Nivel Socioeconómico en Lima Metropolitana</i>	47
5.28	<i>Crecimiento de áreas urbanas en las ciudades de las costas del Perú en el periodo 2016-2025</i>	48
5.29	<i>Crecimiento acumulado de áreas urbanas en Arequipa por tipo de susceptibilidad a deslizamiento, en el periodo 2016-2025</i>	50

5.30	Crecimiento acumulado de áreas urbanas en Chimbote por tipo de susceptibilidad a deslizamiento, en el periodo 2016-2025	51
5.31	Crecimiento de áreas urbanas en Tacna. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.	51
5.32	Crecimiento de áreas urbanas en Moquegua. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.	52
5.33	Crecimiento de áreas urbanas en CAMANA. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.	52
5.34	Crecimiento de áreas urbanas en CAÑETE. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.	53
5.35	Crecimiento de áreas urbanas en TRUJILLO. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.	53
6.1	Arquitectura conceptual del sistema de monitoreo urbano en tiempo real.	55



Capítulo 1

Presentación del trabajo de investigación

1.1 Introducción

El crecimiento urbano constituye una de las dinámicas territoriales más complejas e influyentes del siglo XXI dado que cubre 3 pilares fundamentales del desarrollo sostenible: social, económica y ambiental [3]. Esta transición demográfica y espacial plantea desafíos sin precedentes en términos de planificación territorial, provisión de servicios básicos, gobernanza urbana y resiliencia frente a amenazas naturales y antrópicas. En este contexto, América Latina se presenta como una de las regiones más urbanizadas del planeta, con aproximadamente el 81% de su población residiendo en áreas urbanas.

En el caso particular del Perú, la urbanización ha sido impulsada, en gran medida, por intensos flujos migratorios desde zonas rurales durante el siglo XX, generando una presión significativa sobre la infraestructura urbana existente y evidenciando la incapacidad del mercado formal de vivienda para atender la demanda emergente. Esta situación propició la ocupación de suelos que no han sido designados para acomodarlos, generalmente de bajo valor económico y alta exposición a amenazas naturales, especialmente en las principales ciudades del país [4]. Lima, como capital y principal aglomeración urbana, concentra estas problemáticas de forma aguda, presentando una expansión metropolitana caracterizada por la informalidad, la desigualdad espacial y la creciente vulnerabilidad socioambiental. Frente a este escenario, se vuelve imperativo desarrollar mecanismos de monitoreo y análisis espacial del crecimiento urbano, con énfasis en las áreas de mayor peligro, a fin que las políticas públicas se adapten a las características específicas del crecimiento urbano identificado, con el propósito de diseñar políticas públicas más eficaces y sostenibles.

El principal desafío para monitorear el crecimiento urbano en Lima, y otras ciudades del Perú, es la escasez de información georreferenciada actualizada. Uno de los principales enfoques para abordar este problema es el empleo de imágenes satelitales y técnicas de *machine learning*. Actualmente existen bases de datos de las zonas urbanas de todo el planeta generados usando técnicas de aprendizaje supervisado. La Agencia Aeroespacial Alemana ha generado mapas de crecimiento urbano desde 1985 hasta el año 2015 y mapa de áreas urbanas para los años 2015 y

2019 [5]. De forma análoga, Microsoft ha generado información vectorial de edificios de todo el planeta [6]. Aunque estos resultados son muy precisos a nivel global, no son satisfactorios para un análisis local. Debido a esto, en los últimos años se está generando mapas de uso de suelo a escalas nacionales, como en el caso de Japón [7]. Estos mapas son generados con algoritmos de inteligencia artificial calibrados con información local georreferenciada de alta resolución y debidamente etiquetada. Desafortunadamente, en el Perú existe escasez de base de datos que se puedan emplear para calibrar un clasificador de uso de suelos con base en técnicas de aprendizaje supervisado.

1.2 Antecedentes

Se han empleado técnicas de segmentación [8] para diferenciar áreas urbanas de no urbanas, facilitando la identificación de zonas vulnerables. La integración de datos geoespaciales [9] ha sido fundamental para delimitar estas áreas. Además, el procesamiento de imágenes satelitales de alta resolución [10] ha permitido analizar la evolución temporal del crecimiento urbano. La aplicación de algoritmos de inteligencia artificial, como las redes neuronales convolucionales (CNN) [11], ha demostrado ser efectiva en la detección automática de áreas urbanas. La validación de estos métodos se ha llevado a cabo mediante comparaciones con datos de campo y métricas de desempeño [12], garantizando su precisión y fiabilidad. La principal dificultad para emplear estos enfoques es la escasa información etiquetada disponible para su entrenamiento, debido a que el enfoque tradicional para su generación es la clasificación visual pixel por pixel de una imagen, lo cual demanda muchas horas para el etiquetado de una exigua data.

1.3 Justificación

La importancia de poder monitorear el crecimiento urbano descontrolado radica en los graves riesgos que el asentamiento en zonas susceptibles a peligros naturales representa para la población y el entorno. La segmentación binaria semisupervisada ofrece una vía prometedora para abordar este desafío al permitir la identificación de áreas urbanas y la generación de conjuntos de datos de entrenamiento masivos, los cuales son escasos a alta resolución, para algoritmos de inteligencia artificial. Si no se implementan medidas adecuadas de monitoreo y gestión del crecimiento urbano, las consecuencias podrían ser devastadoras. Los estudios muestran que el rápido desarrollo no planificado de las ciudades aumenta su exposición a desastres naturales, lo que puede resultar en pérdidas humanas y materiales significativas [4]. La falta de planificación urbana adecuada también puede exacerbar problemas como la saturación de la oferta de viviendas asequibles y alquileres accesibles, lo que contribuye a la creación de asentamientos informales en áreas de alto peligro [13]. Estos asentamientos carecen de servicios básicos y están expuestos a condiciones precarias de vida, aumentando la vulnerabilidad de la población a eventos adversos como inundaciones, deslizamientos de tierra y terremotos [14]. En este contexto, la incorporación de soluciones innovadoras para el monitoreo territorial en escenarios de escasez de información —como la segmentación binaria semisupervisada— no solo facilitaría una gestión más eficiente del crecimiento

urbano, sino que también contribuiría a comprender la morfología y las características del crecimiento urbano, generando insumos que podrían orientar la adopción de nuevas estrategias de planificación y gestión territorial.

1.4 Hipótesis

Se postula que mediante el empleo de técnicas de clasificación semisupervisada, es factible detectar y monitorear el crecimiento urbano en zonas vulnerables con un alto grado de precisión y eficacia, incluso cuando se dispone de pocos datos etiquetados y una gran cantidad de datos sin etiquetas. Se espera que enfoques semisupervisados novedosos y el uso de la inteligencia artificial permitan la identificación automatizada de áreas urbanas y la delimitación de zonas de expansión, aún en entornos complejos. Esta hipótesis se fundamenta en la capacidad demostrada de la inteligencia artificial para procesar grandes volúmenes de datos y reconocer patrones complejos con mínima supervisión. Además, la disponibilidad cada vez mayor de imágenes satelitales de mediana resolución proporciona una oportunidad sin precedentes para el monitoreo del crecimiento urbano, lo que potencia aún más la viabilidad de estos enfoques semisupervisados.

1.5 Objetivos de la investigación

1.5.1 Objetivo general

Cuantificar el crecimiento urbano, principalmente en áreas expuestas a peligros naturales y generación de datos de entrenamiento, mediante la aplicación especializada de la segmentación binaria semisupervisada en imágenes satelitales. Este enfoque permitirá entrenar un modelo con una discriminación clara entre áreas urbanas y no urbanas, empleando como datos de entrada imágenes satelitales. Los resultados obtenidos proporcionarán información crucial para la formulación de políticas y estrategias de gestión urbana que promuevan la sostenibilidad y la resiliencia en contextos urbanos vulnerables.

1.5.2 Objetivos específicos

Con el fin de lograr el objetivo general, se plantean los siguientes objetivos específicos:

- Identificar y delimitar las zonas de alto peligro dentro del área de estudio, aprovechando datos geoespaciales disponibles.
- Recopilar y procesar imágenes satelitales de mediana resolución correspondientes al área de estudio.
- Implementar algoritmos semisupervisados novedosos (NNPU) y redes neuronales profundas (DNN) para la discriminación automática de áreas urbanas
- Validar la precisión de la red neuronal calibrada en base a métricas de desempeño como precision, recall y accuracy.

- Analizar los resultados obtenidos para identificar patrones de crecimiento urbano en zonas vulnerables, así como para identificar áreas de riesgo y proporcionar recomendaciones para la planificación urbana y la mitigación de impactos sociales y ambientales.

1.6 Alcance

El proyecto desarrollado implicó la identificación y delimitación de la información geoespacial disponible en Lima Metropolitana durante el periodo 2016-2025. Posteriormente, se realizó la recopilación y el preprocesamiento de imágenes satelitales de alta resolución. A continuación, se aplicó un enfoque semisupervisado novedoso, basado en la adaptación del método NNPU, con el fin de detectar automáticamente las áreas urbanas. La exactitud de este enfoque fue verificada mediante la comparación de los resultados con la inspección visual de imágenes ópticas, así como con información geoespacial adicional, y a través de la evaluación de métricas de rendimiento comparadas a las obtenidas con la base de datos World Settlement Footprint (WSF2019). Finalmente, se analizaron los hallazgos obtenidos para identificar tendencias en el crecimiento urbano, detectar zonas de riesgo y proponer recomendaciones orientadas a la planificación urbana sostenible. Adicionalmente, se extendió el análisis a las principales provincias costeras del Perú, con el fin de validar la aplicabilidad del enfoque en otros contextos urbanos.



Capítulo 2

Marco Conceptual

2.1 Crecimiento Urbano Global: Desigualdad, Morfología y Vulnerabilidad

El presente apartado se basa en los hallazgos del *World Cities Report 2024* de ONU-Hábitat [1], así como en investigaciones recientes sobre eficiencia del uso del suelo urbano y morfología intraurbana a escala global [15, 16]. Estos aportes permiten construir una visión integrada sobre el crecimiento urbano contemporáneo, articulando procesos de expansión física con fenómenos de informalidad, desigualdad y vulnerabilidad climática.

La urbanización constituye uno de los principales motores de transformación del territorio en el siglo XXI. Desde 1985, el mundo ha experimentado una rápida expansión de áreas urbanas, muchas veces sin la planificación adecuada para garantizar eficiencia espacial, equidad social o resiliencia ambiental. Esta situación ha generado impactos significativos en el uso del suelo, el consumo de recursos y la exposición de las poblaciones a riesgos naturales y climáticos [1].

La relación entre urbanización y cambio climático es bidireccional. Las ciudades concentran una gran proporción de la población mundial y de las emisiones de gases de efecto invernadero, pero también son altamente vulnerables a fenómenos como inundaciones, olas de calor, deslizamientos y escasez hídrica. El informe de ONU-Hábitat destaca que el cambio climático puede erosionar décadas de progreso urbano, afectando con mayor severidad a las poblaciones en situación de pobreza o marginalidad. Esta “urbanización del riesgo climático” se ha vuelto más evidente en contextos donde la expansión informal ocurre sobre zonas expuestas y sin infraestructura adecuada [1].

Más de mil millones de personas viven actualmente en asentamientos informales, lo que representa una cuarta parte de la población urbana mundial. Estos espacios suelen carecer de servicios básicos, seguridad jurídica de tenencia, acceso a infraestructura resiliente o representación política efectiva. A partir de datos globales, se ha observado una fuerte correlación entre la proporción de informalidad urbana y la vulnerabilidad climática ($\rho = 0.82$), así como una correlación negativa con los niveles de preparación frente al cambio climático ($\rho = -0.64$). Esto revela que las poblaciones más excluidas no solo enfrentan mayores riesgos, sino que disponen de menor capacidad para adaptarse o recuperarse [1].

A nivel global, el crecimiento urbano entre 1985 y 2015 ha sido ineficiente en términos del uso del suelo. Un análisis reciente, basado en imágenes satelitales de alta resolución y datos poblacionales, demostró que las áreas urbanas nuevas albergan menos personas por hectárea que las zonas ya urbanizadas previamente. Esto implica una tendencia hacia una urbanización más dispersa, de baja densidad, que requiere más infraestructura per cápita y genera mayores emisiones. Según estimaciones, si se hubiera mantenido una eficiencia similar a la de las zonas urbanas preexistentes, se podrían haber alojado 1,466 millones de personas adicionales sin necesidad de consumir más suelo [15].

La morfología urbana juega un papel clave en este proceso. Mediante técnicas de aprendizaje profundo, se ha logrado clasificar 138 patrones morfológicos alrededor del mundo. Los resultados indican que predominan los patrones dispersos y fragmentados, con tejidos urbanos característicos de urbanizaciones periféricas o suburbanas. Solo una minoría de ciudades presenta morfologías compactas y mixtas, que son las más deseables desde una perspectiva de sostenibilidad, movilidad y eficiencia energética [16].

La forma en que se estructura el espacio urbano tiene implicancias directas sobre el acceso a servicios, la movilidad, la segregación residencial y la exposición a peligros. Por ejemplo, los patrones dispersos dificultan la provisión de transporte público eficiente, aumentan la dependencia del automóvil y fragmentan el tejido social. Al mismo tiempo, las ciudades con expansión informal tienden a ocupar terrenos de alto peligro, como riberas, laderas o zonas inundables, aumentando la exposición de la población vulnerable a desastres naturales. En la Figura 2.1 se muestran los principales factores de la vulnerabilidad urbana.




Figura 2.1: Esquema de los factores que configuran la vulnerabilidad urbana. Adaptado de [1]

2.1.1 Crecimiento urbano en el Perú

El crecimiento urbano en el Perú ha sido un fenómeno de gran intensidad durante las últimas décadas, caracterizado principalmente por su aceleración, informalidad y expansión periférica. Estudios recientes han revelado que, entre los años 2001 y 2018, las 43 ciudades más grandes del país sumaron aproximadamente 68,000 hectáreas de nuevo suelo urbano, lo que representa un incremento del 47% sobre el suelo urbano existente al año 2000 [17]. Este proceso ha albergado a 3.5 millones de personas en cerca de 940,000 viviendas nuevas, revelando tanto la magnitud del fenómeno como sus implicancias en términos de planificación territorial, acceso a servicios y sostenibilidad urbana.

Una de las características más preocupantes del proceso de expansión ha sido su carácter predominantemente informal. Se estima que el 93% del nuevo suelo urbano generado desde el año 2001 corresponde a urbanizaciones informales, es decir, asentamientos que carecen de habilitación urbana completa [17]. Esta informalidad se manifiesta no solo en la precariedad de las condiciones físicas del entorno construido, sino también en la falta de acceso a servicios básicos: aproximadamente el 54.4% del área urbana que creció entre 2007 y 2017 no cuenta con sistema de alcantarillado, el 49.5% carece de acceso a agua potable por red pública, y más del 62% de las viviendas no poseen título de propiedad en el año 2023 [18].

La informalidad urbana también genera distorsiones económicas relevantes. A través de la inversión pública en infraestructura y servicios, el Estado termina subsidiando indirectamente a los hogares que adquieren lotes en urbanizaciones informales, lo cual incrementa el precio del suelo urbanizado informalmente y eleva la rentabilidad de los promotores informales, afectando la viabilidad económica de los proyectos de urbanización formal [17]. Además, las familias ubicadas en estos contextos soportan costos acumulados significativos debido a la espera prolongada —en promedio 14 años— para acceder a servicios básicos, lo que puede equivaler a la inversión inicial en la adquisición del lote.

El patrón de expansión urbana en el Perú también se caracteriza por su dispersión y baja densidad, en contraposición a los principios del desarrollo urbano compacto y policéntrico que promueve una mayor sostenibilidad. La baja densidad está asociada a una menor eficiencia en el uso del suelo y de los servicios públicos, una mayor dependencia del transporte motorizado, y una mayor presión sobre ecosistemas frágiles, especialmente en ciudades que han ocupado zonas de ladera o peligro geotécnico. Por ejemplo, en Lima se registraron más de 188,000 viviendas ubicadas en zonas de pendiente entre 35% y 52%, y más de 63,000 en pendientes aún más pronunciadas [18].

A nivel nacional, el crecimiento urbano en la década intercensal 2007–2017 fue de aproximadamente 24%, concentrándose en mayor medida en la costa (43%), seguida de la sierra (37%) y la selva (21%) [18]. Este patrón muestra cómo la expansión urbana está fuertemente ligada a dinámicas demográficas y económicas regionales, y plantea desafíos para la implementación de políticas públicas orientadas a la contención de la expansión informal y la promoción de ciudades inclusivas, resilientes y sostenibles.

En comparación con otras ciudades de América Latina, donde la expansión promedio es del orden del 30%, el caso peruano destaca por su ritmo acelerado y su débil capacidad institucional para orientar dicho crecimiento [17]. Ciudades como Tacna, Yurimaguas y Arequipa han duplicado

su superficie urbana en el periodo 2000–2018, mientras que Lima ha liderado el crecimiento en términos absolutos, añadiendo 25,000 hectáreas de suelo urbano nuevo [17].

2.1.2 Crecimiento urbano en el Lima Metropolitana

El crecimiento urbano de Lima Metropolitana se ha caracterizado por una expansión acelerada y predominantemente informal, estructurada en fases históricas vinculadas a procesos sociales, normativas estatales, presiones demográficas y eventos naturales. Según datos del Ministerio de Vivienda, Construcción y Saneamiento, entre los años 2007 y 2017 se registraron importantes procesos de expansión urbana en diversos distritos de la ciudad, destacando San Juan de Lurigancho con 468 ha, Lurigancho con 343 ha, Lurín con 1951 ha, Ate con 196 ha, Carabayllo con 118.7 ha y Puente Piedra con 243 ha. Este patrón de crecimiento ha estado impulsado tanto por la migración interna como por la falta de acceso a vivienda formal, lo que ha llevado a una ocupación progresiva del territorio sin una planificación adecuada [18].

La evolución del crecimiento urbano en Lima puede dividirse en cuatro grandes fases, cada una con dinámicas específicas que reflejan la transformación del territorio metropolitano. La primera fase, correspondiente al inicio de la expansión urbana entre 1900 y 1960, se origina con la demolición de las murallas de la ciudad en 1868. Durante esta etapa surgieron los primeros espacios autoproducidos en zonas periféricas al centro histórico de Lima y al puerto del Callao, como Armatambo (1924), Puerto Nuevo (1928), Mendocita (1931) y Leticia (1933), motivados por el hacinamiento, la expansión industrial y factores ambientales como las inundaciones[13]. La segunda fase, entre 1940 y 1953, estuvo marcada por un agudo proceso de autoproducción urbana como respuesta al terremoto de 1940. Este fenómeno dio origen a asentamientos populares como San Cosme (1946), El Agustino (1947) y 27 de Noviembre (1949), denominados “barriadas” y reconocidos institucionalmente durante el gobierno de Manuel Odría, lo que permitió su formalización progresiva mediante asociaciones con fines de lucro y promovió un mercado informal de lotes[13].

La tercera fase, que se desarrolla entre 1954 y 1960, corresponde a un periodo de expansión hacia áreas cada vez más distantes del centro urbano, como Arenales del Sur, Ciudad de Dios y Comas. Esta dinámica motivó al Estado a promulgar la Ley 13517 en 1961, mediante la cual se reconoció legalmente la urbanización autoproducida. Dicha ley estipulaba la compensación a propietarios legítimos y el saneamiento físico-legal de los asentamientos, aunque debido a las limitaciones presupuestarias, la intervención estatal se limitó a la entrega de títulos de propiedad sin mayores inversiones en infraestructura. Finalmente, la cuarta fase, que abarca desde 1961 hasta el año 2020, refleja la consolidación de una política estatal centrada en la formalización de la propiedad informal, liderada principalmente por la Comisión de Formalización de la Propiedad Informal (COFOPRI). Esta institución otorgó titularidad incluso en zonas no aptas para la urbanización, delegando a las municipalidades la responsabilidad de emitir informes técnicos de riesgo. La promulgación de la Ley 28923 durante el segundo gobierno de Alan García consolidó este modelo, estableciendo un régimen extraordinario que favoreció la masificación de la titulación. Sin embargo, dicho proceso fue aprovechado por traficantes de terrenos y promotores informales, quienes formaron organizaciones sociales ficticias para acceder a bonos estatales de vivienda como

“Techo Propio”. Se estima que hasta el 90% de las invasiones recientes en Lima y la costa norte tienen origen en estas redes ilegales, lo que evidencia una relación directa entre la política de formalización y la mercantilización informal del suelo urbano [13].

Actualmente, el crecimiento urbano de Lima continúa orientado hacia las periferias, con patrones de ocupación de baja densidad, acceso limitado a servicios básicos y trazado urbano irregular. Esta expansión, en su mayoría sin planificación, implica importantes desafíos para la sostenibilidad urbana, la mitigación de riesgos y la equidad en el acceso al territorio urbano formalizado [18].

2.2 Peligros Naturales en el Perú

2.2.1 Sismos

El mapa de sismicidad global indica que más del 80% de la energía acumulada en el interior de la Tierra se libera en la región conocida como el “Cinturón de Fuego del Pacífico”. Como consecuencia de esta ubicación geotectónica, el Perú se encuentra en una zona de alto riesgo sísmico, además de ser vulnerable a fenómenos asociados como tsunamis, licuefacción de suelos y deslizamientos de tierra y rocas. En particular, la región costera del país representa la mayor amenaza sísmica debido a su proximidad a la superficie de fricción interplacal, donde interactúan las Placas de Nazca y Sudamericana. Esta interacción es responsable de generar sismos de gran magnitud, superiores a los ocho grados, frecuentemente acompañados por tsunamis [14].

Según Tavera (2014), la repetición de eventos sísmicos en una determinada región sugiere que el comportamiento del suelo ante futuros sismos será similar. Por lo tanto, los niveles de sacudimiento del suelo en escenarios sísmicos futuros pueden ser estimados utilizando mapas de intensidades máximas históricas. Estos niveles de sacudimiento dependen en gran medida de la composición geológica del suelo, siendo los suelos menos compactos los más susceptibles a la amplificación de las ondas sísmicas. Esta amplificación aumenta el riesgo de daños estructurales y compromete la seguridad de las personas.

Asimismo, la distribución espacial de las zonas de ruptura permite identificar la presencia de lagunas sísmicas, las cuales son definidas como áreas donde han ocurrido grandes sismos pero que no han experimentado una recurrencia similar, lo que incrementa su probabilidad de ocurrencia futura. Un ejemplo relevante es la región central del país, identificada como una laguna sísmica debido a que, desde el terremoto de 1746 con una intensidad de XI en la escala de Mercalli, no ha ocurrido otro evento de magnitud comparable (8.8 Mw). Esto sugiere que la energía acumulada en esta área no ha sido completamente liberada, lo que incrementa el riesgo de un sismo de magnitud similar en el futuro. La Tabla 2.1 presenta un resumen de los principales eventos sísmicos ocurridos en el Perú desde 1970 hasta la fecha.

Según INDECI, un terremoto de 8.8 Mw, similar a lo ocurrido en 1746, podría generar un tsunami con olas de 24 metros de altura, licuación de suelos, derrumbes, volcamiento de suelo y roca, 623 882 viviendas inhabitables y 110313 fallecidos [19]. Las poblaciones más afectadas serán las que son más vulnerables y se encuentren en zonas de mayor peligro de desastre.

Año	Descripción	Magnitud
1970	Terremoto y Alud-aluvi3n en Ancash	7.9 Mw
1974	Terremoto de Lima	8.4 Mw
1986	Terremoto de Cusco	5.8 MI
1990	Terremoto en el nororiente peruano	5.8 MI
1991	Terremoto en el nororiente peruano	6.9 Mw
1996	Terremoto en Nazca	7.7 Mw
1999	Terremoto en Chuschi, Ayacucho	4.5 Mw
2001	Terremoto en el sur del pa3s	8.4 Mw
2003	Sismo en Capacmarca, Cusco	4.5 MI
2005	Sismo en Moquegua	5.4 MI
2005	Terremoto de Lamas	7.5 Mw
2005	Sismo de Ayacucho	5.8 MI
2007	Terremoto de Pisco	8.0 Mw
2008	Sismo de Pasco	5.3 Mw
2013	Terremoto de Acar3	7.0 Mw
2018	Terremoto de Arequipa	7.1 Mw
2019	Sismo de Lagunas	8.0 Mw
2021	Sismo en Loreto	7.5 Mw
2021	Sismo en Piura	6.2 Mw

Tabla 2.1: Listado de terremotos y sismos en Per3 (1970-2021)

2.2.2 Susceptibilidad de movimiento de masas

El territorio peruano, caracterizado por su compleja geolog3a y relieve accidentado, presenta un alto peligro ante los movimientos de masas. Entre estos fen3menos se encuentran los deslizamientos, flujos de lodo, desprendimientos de rocas y hundimientos, los cuales ponen en riesgo tanto la infraestructura como las zonas pobladas. Fen3menos naturales como la actividad s3smica, las precipitaciones intensas y la composici3n geol3gica del suelo, sumados a intervenciones humanas como la deforestaci3n y la urbanizaci3n en 3reas de riesgo, favorecen el desencadenamiento de movimientos de masa.

El Instituto Geol3gico, Minero y Metal3rgico (INGEMET) desempe3a un rol clave en la identificaci3n y reducci3n de estos riesgos. Esta entidad desarrolla mapas de susceptibilidad tanto a nivel nacional como regional, permitiendo reconocer 3reas propensas a estos fen3menos y proporcionando informaci3n esencial para la gesti3n del riesgo de desastres. Dichos mapas, elaborados mediante el an3lisis de datos geol3gicos y clim3ticos con tecnolog3as SIG y teledetecci3n, facilitan la toma de decisiones informadas por parte de autoridades y comunidades, contribuyendo a minimizar los impactos de los movimientos de masas en el pa3s. En la Figura 2.2 se muestra un mapa de susceptibilidad a movimiento de masas elaborado por INGEMET y distribuido por SIGRID.




Figura 2.2: Susceptibilidad de movimiento de masas. Reelaborado de INGEMET [2]

2.3 Teledetección

La teledetección puede ser conceptualizada, de acuerdo con Bakker et al. [20] y Khorram et al. [21], como el proceso de adquisición de información geoespacial a distancia mediante el uso de sensores, ya sean satelitales o aerotransportados, que detectan señales electromagnéticas emitidas por la superficie terrestre, considerando un tamaño de píxel o resolución específicos. Su objetivo es, a partir de mediciones indirectas cuantitativas [22], identificar y caracterizar objetos a distancia [23]. Esta técnica tiene una amplia gama de aplicaciones en diversas disciplinas, incluyendo ingeniería, arquitectura, arqueología, medicina, control de calidad industrial y robótica, así como en el mapeo de cuerpos extraterrestres.

En función de la fuente de energía utilizada, los sensores se clasifican en dos categorías:

- **Sensores pasivos:** Captan ondas electromagnéticas provenientes de una fuente de energía natural, como el sol. Su principal desventaja radica en que su rendimiento está condicionado por la intensidad de la radiación recibida de la fuente emisora.
- **Sensores activos:** Conocidos como sistemas de radar, estos sensores emiten y reciben su propia energía, lo que les permite operar independientemente de la luz solar.

2.3.1 Imágenes multiespectrales

Las imágenes multiespectrales se definen como representaciones visuales de la superficie terrestre obtenidas mediante la captura de datos en múltiples bandas del espectro electromagnético. A

diferencia de las imágenes convencionales, que generalmente se limitan a una sola banda (como el visible), las imágenes multiespectrales abarcan una gama más amplia de longitudes de onda, incluyendo, pero no limitándose a, el infrarrojo cercano y el infrarrojo térmico. Esta capacidad de capturar información en diversas longitudes de onda permite la identificación y análisis de características específicas de la superficie terrestre, como la composición del suelo, la cobertura vegetal y los cuerpos de agua, proporcionando información valiosa en campos como la agricultura, la gestión de recursos naturales, la planificación urbana y la evaluación ambiental. Las imágenes multiespectrales son obtenidas mediante sensores especializados montados en plataformas satelitales o aéreas, los cuales permiten la detección de diferentes características del entorno mediante la reflexión y absorción de la radiación electromagnética en función de las propiedades físicas y químicas de los objetos en la superficie.

2.3.2 Proyecto Sentinel

El proyecto multisatelital impulsado por la Agencia Espacial Europea (ESA), en el marco del programa Copernicus, constituye uno de los esfuerzos más ambiciosos a nivel global en materia de observación de la Tierra. Su principal objetivo es el monitoreo continuo de cambios en la superficie terrestre, los océanos y la atmósfera, así como el apoyo a la gestión de desastres naturales y antrópicos. Para ello, se emplean sensores de última generación, tanto de radar de apertura sintética (SAR) como multiespectrales, capaces de adquirir información en diferentes rangos del espectro electromagnético con alta resolución espacial y temporal. Las misiones de las constelaciones Sentinel son:

Sentinel 1(A-B): Radares gemelos empleados para respuesta ante emergencias. Están desfazados 180° por lo que el periodo de monitoreo de toda la superficie es de 6 días. Trabaja en la banda C por lo que las ondas electromagnéticas emitidas tienen longitudes de onda alrededor de 4cm.

Sentinel 2(A-B): Sistemas de teledetección óptica que permite el monitoreo de la superficie terrestre con 13 bandas espectrales con resolución de hasta 10m. Son empleados para el control de desastres naturales mediante la inspección visual de un desastre, a partir de la comparación entre imágenes previas y posteriores al evento. En la Tabla 2.2 se presentan los productos y niveles de procesamiento de los datos proveídos por la constelación Sentinel 2.

Tabla 2.2: Niveles de procesamiento de datos satelitales

Producto	Descripción
Level 0	Datos originales comprimidos sin procesar.
Level 1A	Datos en bruto sin compresión ni modificaciones.
Level 1B	Imágenes calibradas radiométricamente, expresadas en valores de radiancia.
Level 1C	Ortoimágenes georreferenciadas en el sistema de coordenadas UTM.
Level 2A	Versión mejorada del nivel 1C, con correcciones atmosféricas aplicadas para obtener imágenes con valores de reflectancia superficial reales.

Sentinel 3-6: Empleados para el monitoreo del agua y océanos. Algunas de sus aplicaciones son: Estudio de temperatura y color de los océanos, vigilancia de incendios forestales, seguimiento

de la dinámica marina (corrientes, clorofila), balance energético y climático global, medición del aumento del nivel del mar, estudios sobre dinámica oceánica y cambio climático y validación de modelos climáticos y pronósticos meteorológicos

Sentinel 4-5: Empleados para el monitoreo de la atmósfera. Algunas de sus aplicaciones son: Detección de contaminantes atmosféricos (NO_2 , SO_2 , ozono, aerosoles), control de calidad del aire, apoyo en políticas de mitigación del cambio climático, vigilancia de gases de efecto invernadero (CO_2 , CH_4), seguimiento del ozono estratosférico y análisis de dispersión de contaminantes a escala global.

2.4 Redes Neuronales

Las redes neuronales artificiales (RNA) son modelos computacionales ampliamente utilizados en tareas de aprendizaje supervisado y no supervisado, cuyos fundamentos se inspiran en el funcionamiento del sistema nervioso biológico, particularmente en la manera en que las neuronas del cerebro procesan y transmiten información.

Una red neuronal está compuesta por un conjunto de unidades básicas denominadas *neuronas artificiales*, las cuales se organizan en capas: una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona recibe un conjunto de señales de entrada ponderadas por un conjunto de pesos sinápticos, realiza una operación de agregación (generalmente una suma ponderada), y aplica una función de activación no lineal para generar una salida.

La capacidad de aprendizaje de una red neuronal se basa en el ajuste iterativo de los pesos sinápticos mediante algoritmos de optimización, tales como el descenso de gradiente estocástico, con el objetivo de minimizar una función de pérdida que cuantifica el error entre las salidas predichas y las deseadas.

A continuación, se presenta un esquema de una neurona artificial típica, que ilustra el proceso de agregación y activación:




Figura 2.3: Esquema de una neurona artificial. Cada entrada x_i es ponderada por un peso sináptico w_i y sumada con un sesgo b . El resultado se transforma mediante una función de activación para producir la salida y .

2.4.1 Tipos de Redes Neuronales

Redes Neuronales Densas (Feedforward)

Las redes neuronales densas, también conocidas como perceptrones multicapa (MLP) (Se muestra un esquema en la Figura 2.4), consisten en una arquitectura secuencial de capas completamente conectadas, donde cada neurona de una capa está conectada a todas las de la siguiente. Este tipo de red es adecuado para problemas donde las características no poseen una estructura espacial o secuencial explícita.

Capa de entrada Capa oculta 1 Capa oculta 2 Capa oculta 3 Capa de salida

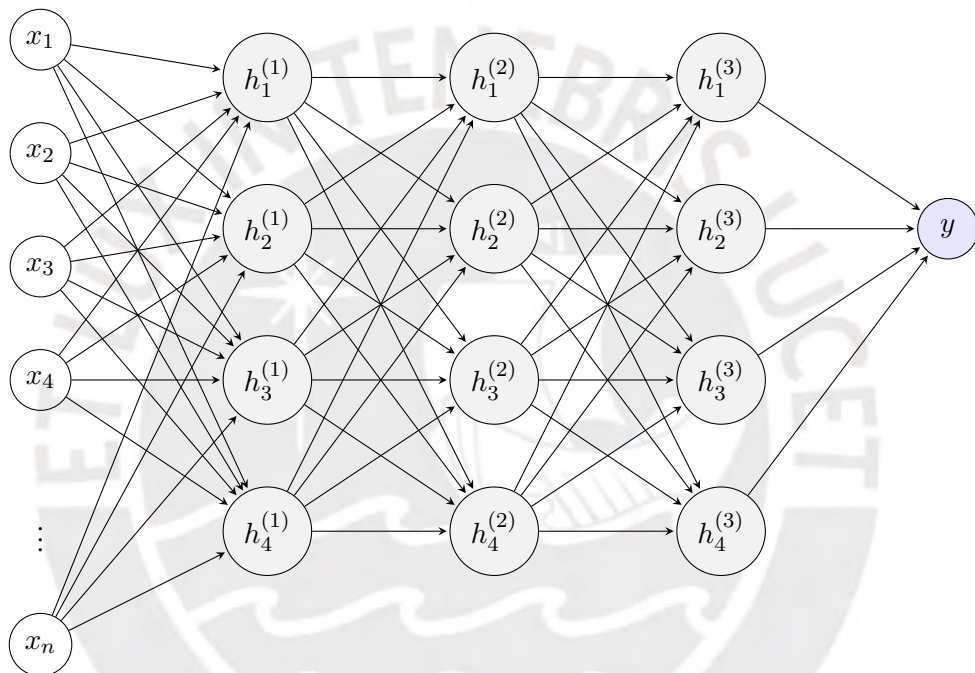


Figura 2.4: Esquema de una red neuronal multicapa (MLP) con tres capas ocultas. Cada capa transforma las representaciones mediante combinaciones lineales y funciones de activación, generando finalmente la salida y .

Redes Neuronales Convolucionales (CNN)

Las CNN son arquitecturas especializadas en la extracción jerárquica de características espaciales a partir de datos como imágenes o series temporales multivariadas. Utilizan filtros convolucionales que se deslizan sobre los datos para capturar patrones locales.

- **Operador de convolución 2D:**

$$S(i, j) = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (2.1)$$

donde:

- $S(i, j)$: valor resultante de la convolución en la posición (i, j) de la imagen de salida.

- $I(i - m, j - n)$: valor del píxel de la imagen de entrada I , desplazado según los índices (m, n) .
- $K(m, n)$: valor del núcleo o filtro de convolución (kernel) en la posición (m, n) .
- (i, j) : coordenadas espaciales de la posición donde se calcula la convolución en la salida.

- **Tamaño de kernel:** Define la dimensión de los filtros. Un tamaño común es 3×3 o 5×5 .
- **Padding:** Técnica para preservar dimensiones espaciales al aplicar convoluciones.

Redes Generativas Adversarias (GANs)

Las GANs están compuestas por dos redes enfrentadas: un generador G , que busca producir datos indistinguibles de los reales, y un discriminador D , que intenta distinguir entre muestras reales y sintéticas. Esta formulación se plantea como un juego minimax:

$$\min_G \max_D E_{x \sim p_{\text{datos}}} [\log D(x)] + E_{z \sim p_z} [\log(1 - D(G(z)))] \quad (2.2)$$

2.4.2 Tipos de Aprendizaje

Aprendizaje Supervisado

En este enfoque, el modelo se entrena con datos etiquetados (x, y) , aprendiendo una función de mapeo entre entradas y salidas. Es común en clasificación, regresión y detección de objetos.

Aprendizaje No Supervisado

El modelo explora la estructura interna de los datos sin etiquetas explícitas. Se aplica en reducción de dimensionalidad, clustering (e.g., k-means) y detección de anomalías.

Aprendizaje Semisupervisado

Combina una pequeña cantidad de datos etiquetados con una gran cantidad de datos no etiquetados, aprovechando técnicas de regularización, propagación de etiquetas y autoentrenamiento.

2.4.3 Métodos de Optimización Convencionales

Descenso de Gradiente

Método iterativo que ajusta los pesos para minimizar la función de pérdida L mediante el gradiente:

$$w = w - \eta \frac{\partial L}{\partial w} \quad (2.3)$$

Descenso de Gradiente Estocástico (SGD)

Variante que actualiza los pesos en cada paso utilizando un subconjunto de muestras (mini-lote), reduciendo el costo computacional y mejorando la generalización.

2.4.4 Funciones de Activación

Función Sigmoide

Convierte cualquier valor real en un rango entre 0 y 1. Utilizada históricamente en problemas de clasificación binaria:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.4)$$

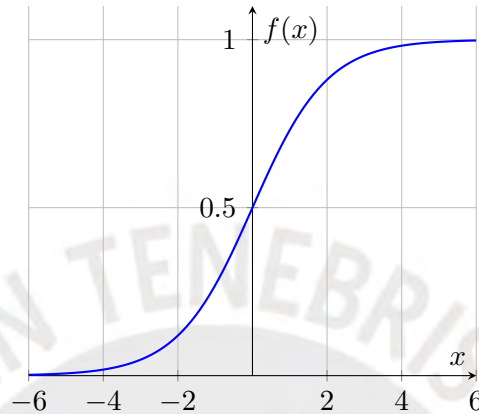


Figura 2.5: Función de activación sigmoide.

Tangente Hiperbólica

Escala los valores al rango $(-1, 1)$, centrando los datos alrededor del cero:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$




Figura 2.6: Función tangente hiperbólica.

ReLU (Rectified Linear Unit)

Aproximación lineal a trozos que activa solo valores positivos:

$$f(x) = \max(0, x) \quad (2.6)$$




Figura 2.7: Función ReLU.

Swish

Función no monótona propuesta por Google, combina linealidad y suavidad:

$$f(x) = x \cdot \sigma(x) \tag{2.7}$$




Figura 2.8: Función Swish.

2.4.5 Hiperparámetros de una Red Neuronal

Tasa de Aprendizaje (η)

Controla el paso con que los pesos se actualizan. Un valor pequeño puede ralentizar la convergencia, mientras que uno grande puede causar inestabilidad.

Momento

Acumula el gradiente para estabilizar la dirección del descenso:

$$v_t = \beta v_{t-1} + (1 - \beta) \nabla L, \quad w = w - \eta v_t \tag{2.8}$$

donde $\beta \in [0, 1]$ es el coeficiente de momento.

Número de Épocas

Número total de veces que el modelo recorre el conjunto completo de entrenamiento. Es clave para asegurar la convergencia del modelo, evitando tanto el subajuste como el sobreajuste.

2.5 Redes Neuronales Profundas

Las redes neuronales profundas (DNN, por sus siglas en inglés) han revolucionado el campo del aprendizaje automático y la visión por computadora debido a su capacidad para modelar relaciones complejas en los datos. Estas arquitecturas se basan en capas de neuronas interconectadas que extraen características a diferentes niveles de abstracción. Con el incremento en la profundidad de las redes, se ha demostrado que pueden aprender representaciones cada vez más complejas, permitiendo avances en tareas como clasificación de imágenes, segmentación semántica y reconocimiento de patrones en datos multiespectrales.

Sin embargo, el aumento en la profundidad de las redes neuronales conlleva desafíos significativos, como la degradación del gradiente y el sobreajuste. Para abordar estos problemas, se han desarrollado arquitecturas especializadas como ResNet (Redes Residuales), las cuales introducen conexiones de acceso directo (skip connections) que facilitan el flujo de la información a través de la red. Estas conexiones permiten que los modelos profundos converjan de manera más eficiente y evitan la desaparición del gradiente, lo que mejora la estabilidad del entrenamiento.

2.5.1 Arquitectura de la red neuronal ResNet152

ResNet152 es una de las arquitecturas más avanzadas de las redes residuales, caracterizada por su gran profundidad con 152 capas, lo que la hace adecuada para tareas de clasificación y segmentación de imágenes de alta complejidad. Su diseño se basa en bloques residuales, los cuales incluyen conexiones de acceso directo que permiten el aprendizaje de funciones de identidad. Esto facilita la optimización del modelo al permitir que los gradientes se propaguen sin obstáculos a través de la red, mitigando así el problema del desvanecimiento del gradiente.

Además de su estructura residual, ResNet152 incorpora capas convolucionales profundas con normalización por lotes y funciones de activación no lineales como ReLU, lo que mejora la estabilidad del entrenamiento y acelera la convergencia. Gracias a estas características, ResNet152 ha demostrado un rendimiento sobresaliente en competiciones como ImageNet y ha sido utilizada en diversas aplicaciones de teledetección y análisis de imágenes satelitales, donde la capacidad de extraer características detalladas es fundamental para la segmentación y clasificación de estructuras urbanas y naturales.

Tabla 2.3: Características de la arquitectura ResNet152

Característica	Descripción
Número de capas	152
Tipo de bloques	Bloques residuales
Función de activación	ReLU
Normalización	Batch Normalization
Tipo de capas principales	Convolucionales 2D, Pooling, Fully Connected
Número de parámetros	~ 60 millones
Conjunto de datos de referencia	ImageNet
Propósito principal	Clasificación y segmentación de imágenes

2.6 Métricas de Evaluación para la Validación de Modelos de Clasificación Basadas en la Matriz de Confusión

La matriz de confusión es una herramienta fundamental para evaluar el desempeño de modelos de clasificación. Esta matriz resume la cantidad de predicciones realizadas por el modelo, discriminadas según su coincidencia con las clases reales. En el caso de un problema de clasificación binaria con clases C_1 y C_2 , la estructura general de la matriz se muestra en la Figura 2.9.

		Clase predicha	
		C_1	C_2
Clase real	C_1	TP	FN
	C_2	FP	TN

Figura 2.9: Matriz de confusión para un problema de clasificación binaria.

Los elementos de la matriz se interpretan como sigue:

- TP (True Positives): número de instancias correctamente clasificadas como C_1 ,
- TN (True Negatives): número de instancias correctamente clasificadas como C_2 ,
- FP (False Positives): número de instancias de clase C_2 clasificadas erróneamente como C_1 ,
- FN (False Negatives): número de instancias de clase C_1 clasificadas erróneamente como C_2 .

A partir de esta matriz, se pueden derivar múltiples métricas para evaluar cuantitativamente el rendimiento del modelo:

Exactitud global (Overall Accuracy). Representa la proporción de predicciones correctas con respecto al total de predicciones:

$$\text{Accuracy}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \delta(y_i, \hat{y}_i), \quad \text{donde} \quad \delta(y_i, \hat{y}_i) = \begin{cases} 1 & \text{si } y_i = \hat{y}_i, \\ 0 & \text{si } y_i \neq \hat{y}_i. \end{cases} \quad (2.9)$$

Precisión (Precision). Mide la proporción de predicciones correctas dentro de todas las instancias predichas como pertenecientes a una clase específica j :

$$\text{Precision}_j = \frac{TP_j}{TP_j + FP_j} \quad (2.10)$$

Sensibilidad (Recall). Corresponde a la proporción de instancias correctamente identificadas entre todas las verdaderamente pertenecientes a la clase j :

$$\text{Recall}_j = \frac{TP_j}{TP_j + FN_j} \quad (2.11)$$

Medida F1 (F1 Score). Se define como la media armónica entre la precisión y el recall, ofreciendo un balance entre ambas métricas, especialmente útil en problemas con clases desbalanceadas:

$$F1_j = 2 \cdot \frac{\text{Precision}_j \cdot \text{Recall}_j}{\text{Precision}_j + \text{Recall}_j} \quad (2.12)$$

Estas métricas pueden extenderse al caso multiclase mediante técnicas de promediado (macro, micro, o ponderado), según la naturaleza del problema y la distribución de clases. La adecuada elección y análisis de estas métricas permite una comprensión más profunda del comportamiento del modelo más allá de una simple tasa de aciertos.

Capítulo 3

Estado del arte

El uso combinado de la teledetección y el aprendizaje automático se ha consolidado como una herramienta indispensable para el monitoreo urbano, facilitando el análisis a gran escala de imágenes satelitales y aéreas [9, 24, 25]. Estos enfoques han demostrado ser especialmente eficaces en el mapeo de asentamientos informales, los cuales presentan desafíos sustanciales debido a su crecimiento no planificado y la limitada disponibilidad de datos oficiales. En este contexto, diversas investigaciones han desarrollado estrategias que integran datos abiertos con algoritmos de aprendizaje supervisado y no supervisado, permitiendo la detección, caracterización y seguimiento de estas zonas para apoyar el desarrollo de políticas públicas más inclusivas.

Gram-Hansen et al. [26] proponen un enfoque dual que utiliza datos multiespectrales de baja resolución de Sentinel-2 junto con un clasificador espectral supervisado para discriminar entre asentamientos informales y su entorno. Además, incorporan una técnica de segmentación semántica basada en redes neuronales profundas con imágenes de muy alta resolución (VHR), adecuada para contextos en los que no se observan patrones espectrales claros. En una línea similar, Tingzon et al. [27] emplean series temporales de Sentinel-2 junto con clasificadores como regresión logística, SVM lineal y random forest para localizar nuevos asentamientos generados por la migración venezolana. Por otro lado, Assarkhaniki et al. [9] destacan la utilidad de datos VHR abiertos y enfoques basados en objetos (OBIA) para capturar patrones estructurales característicos. Fallatah et al. [24] integran algoritmos como LandTrendr y LandsatLinkr con imágenes Landsat para realizar análisis temporales, logrando una precisión del 95% en la identificación de asentamientos mediante Random Forest. Complementariamente, World Settlement Footprint (WSF) [25] implementa un enfoque sistemático a escala global que combina clasificadores RF, datos de OSM y predicción de caminos ausentes, demostrando la eficacia de los datos espaciales abiertos y multiescalares para una toma de decisiones robusta.

En ciudades con crecimiento acelerado como Lima, donde la expansión urbana informal ocurre frecuentemente en zonas expuestas a amenazas naturales, estas tecnologías permiten mapear de manera detallada tanto los asentamientos informales como las áreas de alto riesgo. Li et al. [28] utilizan redes neuronales convolucionales optimizadas mediante agentes para detectar construcciones ilegales, relevantes tanto en términos de seguridad como de planificación urbana. Kim et al. [29] implementan modelos explicables de inteligencia artificial (XGBoost + SHAP) para predecir la expansión urbana no planificada en Corea del Sur, alcanzando una precisión del

82.54%. En India, Das et al. [30] combinan Landsat multitemporal, lógica difusa y SVM para identificar pérdida de espacios verdes y expansión desordenada. Mansour et al. [31] aplican autómatas celulares y algoritmos genéticos para modelar el crecimiento urbano bajo reglas de transición optimizadas por factores socioambientales. En Indonesia, Prasetyadi et al. [32] integran Random Forest y Google Earth Engine para monitorear cambios en áreas construidas en regiones sísmicamente activas, destacando la utilidad de combinar GIS, RS y ML en contextos de riesgo geológico. Finalmente, Kesavan et al. [33] desarrollan un marco de planificación resiliente basado en IA para evaluar riesgos de inundación a nivel de edificio, integrando modelos digitales de elevación, redes viales y cobertura vegetal mediante análisis multicriterio.

Estos trabajos ponen de manifiesto cómo la fusión de datos multifuente (DEM, Landsat, Sentinel, OSM) con modelos avanzados (CNN, XAI, SVM, RF, CA-GA) permite afrontar los retos de la expansión urbana en territorios vulnerables, proporcionando herramientas cruciales para una planificación sostenible e inclusiva.

En particular, las redes neuronales convolucionales (CNNs) han mostrado una eficacia notable en el análisis de imágenes de sensores remotos, gracias a su capacidad para extraer automáticamente características discriminativas y reconocer patrones espaciales complejos. Estas arquitecturas han sido empleadas exitosamente en tareas clave como la clasificación de cobertura del suelo, segmentación semántica y detección de cambios en entornos urbanos densamente poblados. Por ejemplo, en [8], se utilizó una arquitectura U-Net para mapear cambios en el uso del suelo en el distrito de Ate (Lima) entre 2002 y 2023, revelando un incremento del 10.3% en la exposición a inundaciones. Wei et al. [11] propusieron el modelo CLP-CNN para segmentar edificaciones con precisión comparable a la delineación manual, reduciendo significativamente el esfuerzo de anotación. Geis et al. [12] introdujeron una técnica de *relearning* profundo donde una segunda CNN mejora las representaciones espaciales reutilizando salidas previas, logrando mejoras de hasta 2.09% (92.43% a 94.52%). Por su parte, Ding et al. [34] combinaron segmentación basada en objetos y datos viales para detectar expansión urbana con imágenes VHR en ciudades chinas. En el ámbito de la cartografía submétrica, Yokoya et al. [10] desarrollaron un enfoque con intervención humana mínima que, utilizando una pequeña muestra adicional de etiquetas, mejoró la clasificación en Japón en 16 puntos porcentuales. Finalmente, Qiao et al. [35] demostraron que la integración del Segment Anything Model (SAM) con segmentadores semánticos permite corregir bordes imprecisos sin necesidad de reentrenamiento, con mejoras entre 0.6% y 1.3% en desempeño.

En general, los métodos de clasificación de imágenes comparten una secuencia común de etapas: se decide si se aplicará análisis visual o procesamiento digital; se seleccionan las fuentes de datos (imágenes satelitales o combinadas con fotografía aérea); se determina la escala de trabajo y el sensor adecuado, junto con las fechas de adquisición. Posteriormente, los datos se corrigen radiométrica y geoméricamente, se definen etiquetas o índices según el objetivo del estudio, y se realiza la clasificación. Finalmente, se validan los resultados y se genera un inventario cartográfico [36]. Entre los enfoques supervisados más empleados se encuentran el método de Máxima Verosimilitud Gaussiana, las Máquinas de Vectores de Soporte (SVM) y las redes neuronales, los cuales requieren datos etiquetados, selección de características relevantes,

calibración de parámetros y validación del desempeño.

No obstante, la mayoría de estos enfoques se basa en aprendizaje supervisado completo, el cual exige conjuntos extensos de datos etiquetados con alta precisión. En muchos países del Sur Global, incluyendo Perú, la generación de estas anotaciones a nivel de píxel resulta limitada por falta de recursos o infraestructura técnica [37]. Aunque los modelos supervisados pueden alcanzar alta precisión, su dependencia de datos densamente etiquetados limita su aplicabilidad en contextos con escasez de datos o cobertura heterogénea.

Adicionalmente, iniciativas globales impulsadas por instituciones como Microsoft, NASA y el Centro Aeroespacial Alemán (DLR) buscan mapear el asentamiento humano a nivel mundial. Sin embargo, estas aproximaciones a menudo no logran capturar con precisión la morfología urbana, especialmente en zonas periféricas o de urbanización reciente en América Latina. La Figura 3.1 muestra la comparación entre una máscara urbana de referencia en Lima y las delimitaciones generadas por los productos World Settlement Footprint 2019 (WSF2019) y Microsoft Urban Footprint, evidenciando omisiones significativas en áreas construidas.

Ante las limitaciones que presenta el aprendizaje supervisado —particularmente su alta dependencia de grandes volúmenes de datos etiquetados— han emergido enfoques alternativos basados en aprendizaje semisupervisado y aprendizaje débilmente supervisado, los cuales buscan reducir los costos de anotación sin comprometer la precisión del análisis. En el contexto de imágenes de percepción remota, se han propuesto diversas estrategias innovadoras para aprovechar de forma efectiva los datos no etiquetados. Por ejemplo, el método Reliable Contrastive Learning (RCL) incorpora funciones de pérdida contrastiva centradas en las regiones de cambio, y emplea medidas de incertidumbre para seleccionar pseudolabels confiables en el proceso de entrenamiento semisupervisado [38]. De forma complementaria, el enfoque basado en Certainty-Aware Consistency Training (CACT) introduce mecanismos de corrección y umbral adaptativo balanceado por clase, con el fin de mitigar la ambigüedad semántica derivada de predicciones inciertas [39]. Por otro lado, la red tipo *adaptive ladder* permite una búsqueda arquitectónica incremental con mínima dependencia de etiquetas reales, generando pseudolabels más fiables a partir de la combinación de técnicas semisupervisadas y no supervisadas [40]. Finalmente, estrategias fundamentadas en redes neuronales convolucionales sobre grafos (GCN) han demostrado ser eficaces para propagar información a partir de pocas etiquetas distribuidas espacialmente, aprovechando la homogeneidad espectral y espacial de los objetos multitemporales [41]. Estas estrategias no solo permiten reducir la carga de anotación manual, sino que también mejoran la robustez del modelo frente a variaciones temporales y espaciales complejas.

En particular, los marcos de aprendizaje débil ofrecen una vía prometedora para abordar esta problemática mediante el uso de datos parcialmente etiquetados, etiquetas inexactas o incluso etiquetas ruidosas [42, 43]. Una de las técnicas más destacadas en este campo es el aprendizaje positivo-no etiquetado (PU learning), que permite entrenar modelos usando únicamente ejemplos positivos y datos no etiquetados. Existen dos estrategias principales: (1) identificar ejemplos negativos dentro del conjunto no etiquetado y tratarlos como tales en el entrenamiento, lo cual depende fuertemente de heurísticas; o (2) asumir que los datos no etiquetados son negativos, pero asignándoles un peso reducido. Ambas estrategias presentan limitaciones, ya sea por sesgos




Figura 3.1: Segmentación urbana derivada de la capa real en 2019 (rojo), WSF2019 (azul) y Microsoft (verde) en 2021. Imagen de fondo corresponde a 2024.

o por la necesidad de cómputo intensivo. Para superar estas dificultades, se ha desarrollado el aprendizaje PU no sesgado (Unbiased PU learning), que considera los datos no etiquetados como muestras ponderadas tanto de positivos como de negativos, y permite estimadores de riesgo sin sesgo. Dentro de esta línea, el método NNPU learning ha emergido como uno de los enfoques más robustos, introduciendo formulaciones convexas estables que mitigan el sobreajuste y aumentan la confiabilidad del modelo [44].

En suma, el uso de técnicas semisupervisadas y débilmente supervisadas representa un cambio de paradigma en la clasificación urbana basada en teledetección. Estas metodologías permiten realizar análisis efectivos del crecimiento urbano y la exposición al peligro incluso en entornos donde la disponibilidad de datos etiquetados es limitada, contribuyendo así a una planificación urbana más inclusiva, precisa y sostenible.

Capítulo 4

Metodología

4.1 Enfoque propuesto para la segmentación semisupervisada

El método propuesto aprovecha Redes Neuronales Convolucionales (CNNs, por sus siglas en inglés) adaptadas para escenarios de supervisión débil, integrando estrategias de autoentrenamiento y generación de etiquetas ficticias (pseudoetiquetado) con el fin de manejar la escasez de etiquetas. Definimos la imagen de entrada como una observación multiespectral $X \in R^{w \times h \times c}$, donde w , h y c representan las dimensiones espaciales y espectrales. Cada píxel se representa como $X_{ij} = x \in R^c$, y la correspondiente salida de segmentación como $Y_{ij} = y \in \{-1, 0, +1\}$, indicando zona no urbana, no etiquetada y zona urbana, respectivamente.

La distribución conjunta de los píxeles en un conjunto de imágenes y etiquetas se denota como $p(x, y)$, con las densidades condicionales para las clases positiva y negativa definidas como:

$$p_p(x) = p(x|Y = +1), \quad p_n(x) = p(x|Y = -1), \quad (4.1)$$

y las probabilidades a priori dadas por:

$$\pi_p = p(Y = +1), \quad \pi_n = 1 - \pi_p. \quad (4.2)$$

En este estudio, se asume que π_p es conocida o estimada a partir de los datos.

Para guiar el proceso de aprendizaje, se define una familia de funciones de costo. Primero, para la modificación NNPU (Non Negative Positive Unlabeled):

$$\tilde{R}_{pu}(g) = \frac{\pi_p}{n_p} \sum_{(i,j) \in I_p} l(t_{ij}, +1) + \max \left\{ 0, \frac{1}{n_u} \sum_{(i,j) \in I_u} l(t_{ij}, -1) - \frac{\pi_p}{n_p} \sum_{(i,j) \in I_p} l(t_{ij}, -1) \right\}, \quad (4.3)$$

donde n_p y n_u representan el número de píxeles urbanos y no etiquetados en una muestra, respectivamente, t_{ij} representa un píxel y $l(\cdot)$ es la función de costo.

De manera similar, la función de riesgo NPNU (Non Positive Negative Unlabeled) se define como:

$$\tilde{R}_{nu}(g) = \frac{\pi_n}{n_n} \sum_{(i,j) \in I_n} l(t_{ij}, -1) + \max \left\{ 0, \frac{1}{n_u} \sum_{(i,j) \in I_u} l(t_{ij}, +1) - \frac{\pi_n}{n_n} \sum_{(i,j) \in I_n} l(t_{ij}, +1) \right\}, \quad (4.4)$$

donde n_n denota el número de píxeles no urbanos en una muestra.

Para su implementación, se adopta la siguiente función de riesgo compuesta con el objetivo de mejorar la discriminación entre clases:

$$\tilde{R} = \max \left\{ \tilde{R}_{nu}, \tilde{R}_{pu} \right\}. \quad (4.5)$$

Esta formulación aprovecha la disponibilidad de muestras etiquetadas de ambas clases e introduce una pérdida basada en competencia, incentivando al modelo a aprender a partir de la señal de riesgo más informativa. Para garantizar la estabilidad numérica y la estandarización, la función de pérdida se acota en el intervalo $[0, 1]$ y se define como:

$$l(t_{ij}, y) = \frac{1}{1 + e^{\delta y t_{ij}}}, \quad \text{donde } \text{Ran}(l) \in [0.007, 0.993]. \quad (4.6)$$

Esta función de pérdida basada en la sigmoide proporciona un gradiente suave y una penalización consistente en los límites entre clases, favoreciendo un entrenamiento eficaz en contextos con incertidumbre en las etiquetas.

4.2 Arquitectura de la red neuronal

La arquitectura del modelo, en el cual se aplicó la formulación descrita en la sección anterior como función de costo para el entrenamiento, sigue la estructura U-NET [45], como se muestra en la Figura 4.1, en el cual la red ResNet-152 [46] actúa como el codificado (encoder). ResNet-152 es una red neuronal convolucional compuesta de 152 capas ocultas, con conexiones residuales (Las cuales se muestran con líneas discontinuas en la Figura 4.1). Las conexiones residuales reintroducen información espacial que de otro modo podría perderse, mejorando enormemente la delimitación de los límites precisos de los objetos [46].

La imagen de entrada, que contiene cuatro canales espectrales (RGB e infrarrojo), se procesa primero mediante una capa convolucional inicial que emplea un kernel 7×7 con paso 2, lo que resulta en una reducción de las dimensiones espaciales (altura y anchura) a la mitad y la producción de 64 salidas. A continuación, se realiza la normalización por lotes para estabilizar el entrenamiento y una función de activación no lineal (ReLU) para introducir diversidad de características. Una capa de agrupación máxima (MaxPool) con paso 2 reduce la resolución espacial, preservando las características más destacadas. El núcleo del codificador consta de cuatro etapas principales, cada una construida a partir de bloques de cuello de botella (bottleneck): bloques residuales especializados que comprimen y expanden las dimensiones de las características para mantener la eficiencia computacional. En estos bloques de cuello de botella, se profundiza progresivamente en la jerarquía de características, capturando información semántica cada vez más abstracta con salidas de 256, 512, 1024 y 2048 mapas de características, respectivamente. En la parte inferior del

diagrama, el decodificador aumenta progresivamente la resolución espacial de las características profundas y produce máscaras de segmentación píxel por píxel.




Figura 4.1: Arquitectura U-Net con codificador ResNet-152. La imagen de entrada se codifica progresivamente en características semánticas de alto nivel mediante bloques residuales y luego se decodifica para generar una máscara de segmentación detallada. Las líneas discontinuas indican conexiones de salto que fusionan los mapas de características del codificador y el decodificador para recuperar detalles espaciales.

4.3 Flujo de trabajo

El flujo de trabajo para la detección del crecimiento urbano en zonas vulnerables (exposición) se organiza en una serie de etapas interconectadas. En primer lugar, se recopila información geoespacial de áreas urbanas disponibles, tanto en formato ráster como vectorial, junto con un conjunto de imágenes satelitales temporales del área de interés. Dependiendo del tipo de imagen, será necesario aplicar distintos procesos de preprocesamiento y corrección, asegurando la delimitación espacial y temporal de la información geoespacial 4.2(a).

Posteriormente, toda la información recopilada se reproyecta a un sistema de coordenadas geográficas común y se estandariza en formato ráster, con el fin de generar las etiquetas para el conjunto de datos de entrenamiento. Luego, se entrenan algoritmos de detección utilizando técnicas de aprendizaje semi-supervisado, ajustando sus parámetros de acuerdo con los datos disponibles 4.2(b).

Una vez completado el entrenamiento, los algoritmos se aplican a las imágenes satelitales preprocesadas para la detección automática de áreas urbanas. Los resultados se validan mediante comparaciones con datos de referencia utilizando métricas de desempeño, realizando los ajustes necesarios. Además, se implementa un proceso de retroalimentación, incorporando manualmente nuevos datos de entrenamiento en las zonas donde el desempeño del modelo haya sido deficiente [7]. Finalmente, se emplea la información georreferenciada proveniente de estudios de peligros para cuantificar el crecimiento urbano en dichas zonas 4.2(c).




Figura 4.2: (a) Recolección de data de entrenamiento y descarga de imágenes. (b) Proceso de emparejamiento de imágenes de entrenamiento y máscara semántica, estandarización del tamaño de las imágenes de entrenamiento y entrenamiento de la red neuronal. (c) Localización de sitios de alto peligro de desastres, descarga de imágenes de alta resolución y estandarización.

Capítulo 5

Evaluación experimental

5.1 Base de datos para la calibración de la red neuronal

El conjunto de datos se ha recopilado a partir de bases de datos de libre acceso, incluyendo imágenes satelitales de Sentinel-2 y datos geográficos auxiliares utilizados para recopilar etiquetas de entrenamiento. En la Tabla 5.1 se muestran las imágenes ópticas de Sentinel 2 recopiladas para Lima Metropolitana. Para el entrenamiento del modelo se emplearon las imágenes satelitales de los años 2021 y 2024, dado que se tenían disponible imágenes de alta resolución en esas fechas e información geoespacial.

Tabla 5.1: Imágenes ópticas de Sentinel-2 recopiladas para Lima Metropolitana

Plataforma	Fecha de adquisición	Órbita	Identificador de escena
S2A	2016-03-27	N0500	T18LTM_20231012T151933
S2A	2017-02-20	N0500	T18LTM_20230917T180851
S2A	2019-04-11	N0500	T18LTM_20221207T083055
S2A	2021-04-20	N0500	T18LTM_20230512T122652
S2A	2024-02-14	N0510	T18LTM_20240214T202045
S2B	2018-04-11	N0500	T18LTM_20230726T101155
S2B	2020-04-20	N0500	T18LTM_20230522T004632
S2B	2022-04-30	N0400	T18LTM_20220430T193732
S2B	2023-01-25	N0509	T18LTM_20230125T190933
S2B	2025-01-14	N0511	T18LTM_20250114T203300

La figura 5.1 presenta la fusión de información geoespacial proveniente de fuentes de libre acceso, integrada a partir de diversos orígenes: datos abiertos extraídos de OpenStreetMap (OSM) mediante el complemento QuickOSM en QGIS [47], desarrollos de lotes urbanos proporcionados por INDECI [48], y los 25 conglomerados de crecimiento urbano identificados en el estudio de Moya et. al. (2024) [49]. Para la generación de los datos de entrenamiento correspondientes al año 2021, se consideró únicamente la información geoespacial proporcionada por INDECI; en cambio, para el año 2024 se integró toda la información disponible. Finalmente, toda la data fue estandarizada para entrenar la CNN: Toda la data fue convertida en un mismo formato raster,

reproyectada para uniformizar el sistema de coordenadas y reescalada para asegurar la consistencia en las dimensiones de todos los pixels.





Figura 5.1: Ubicación del área de estudio y conjunto de datos entrenamiento obtenidos. Los pixels en color rojo representan zonas urbanas; los pixels en color negro, las zonas no urbanas; y los pixels de color blanco, pixels sin clasificación

La Figura 5.2 muestra algunas de las muestras de entrenamiento generadas a partir de imágenes de los años 2021 y 2024, con un tamaño de 512×512 píxeles. Figura 5.2 b-d representa algunas de estas muestras de entrenamiento. Las muestras están formadas por 3 clases de píxeles: píxeles clasificados como urbanos(rojo), no etiquetados(blanco) y no urbanos(negro). Es importante reconocer que dado las limitaciones de disponibilidad de datos correctamente etiquetada y la media resolución de las imágenes nosotros adoptamos la definición de áreas urbanas como aquellas caracterizadas por modificaciones humanas urbanas. Estas incluyen principalmente las manzanas y carreteras, dado que la mayor cantidad de datos de entrenamiento [50] está compuesto principalmente por información urbana a nivel de manzana, las cuales incluyen internamente algunas pistas. Adicionalmente, los clusters de crecimiento informal delimitados en el estudio de Moya et. al. (2024) no proporcionan etiquetamiento a nivel de edificaciones individuales; los clusters comprenden un agregado de estructuras. En contraste, áreas no urbanas son definidas como zonas sin intervención humana o áreas verdes.



(a) Muestra totalmente no urbana en el océano.

Figura 5.2: Representación de algunas muestras de entrenamiento características de la base de datos (izquierda) y datos etiquetados disponibles de los mismos (derecha). (a) representa una muestra de área urbana en el centro de Lima Metropolitana, (b) y (c) representan muestras de la parte periférica de la ciudad, (d) representa una muestra totalmente no urbana y (e) representa una muestra no urbana en el océano

5.2 Calibración de la red neuronal convolucional

Para abordar la tarea de segmentación binaria, se utilizó una red neuronal convolucional basada en la arquitectura U-Net, con un codificador ResNet-152 preentrenado en ImageNet. Esta configuración permitió aprovechar el poder de extracción de características profundas de ResNet-152 y la capacidad de reconstrucción espacial precisa del decodificador U-Net. Se adaptó la arquitectura para aceptar cuatro canales de entrada (RGB + infrarrojo) y una única clase de salida, aplicando una función de activación \tanh que permite interpretar los resultados como una máscara continua.

Después de definir la arquitectura de la red neuronal, debemos configurar los hiperparámetros del modelo, los cuales gobiernan el proceso de aprendizaje durante el entrenamiento. A diferencia de los parámetros internos de la arquitectura, los cuales se calibran automáticamente, los hiperparámetros se calibran bajo un enfoque empírico de ensayo y error. Los hiperparámetros que se calibraron son: La tasa de aprendizaje, la cual controla la magnitud de optimización de los parámetros internos de la arquitectura (valores altos pueden ocasionar una falta de convergencia y valores bajos pueden generar un lento proceso de aprendizaje); El tamaño del lote, el cual determina cuantas muestras seran procesadas antes de actualizar los parámetros; El número de épocas, el cual especifica cuantas iteraciones de toda la data de entrenamiento se pasaran por la red neuronal; y la probabilidad a priori π_p , el cual controla el balance entre las etiquetas etiquetadas y no etiquetadas durante el entrenamiento.

Con el objetivo de mejorar la precisión en la tarea de segmentación, se incorporaron muestras adicionales bien etiquetadas que permiten refinar el proceso de aprendizaje [7], en la Figura 5.3 se ilustra este flujo. En particular, se incluyeron 600 datos etiquetados manualmente mediante polígonos (Los cuales representan el 0.5% de los pixels disponibles en la base de entrenamiento), empleando imágenes Sentinel-2 correspondientes a los años 2021 y 2024 para el entrenamiento del modelo. En total, se generaron 12,000 muestras semi-etiquetadas, de las cuales el 70 % se utilizó para calibrar la función de riesgo y el 30 % restante para evaluar su tendencia. Las muestras para calibrar y evaluar se seleccionan de forma aleatoria.

El entrenamiento final se llevó a cabo durante 500 épocas, con un tamaño de lote de 32, probabilidad a priori $\pi_p = 0.35$ y una tasa de aprendizaje de 5×10^{-5} . En la Figura 5.4 se presentan las curvas de entrenamiento y evaluación, en las cuales se observa una tendencia decreciente y una convergencia hacia valores cercanos a cero en ambas curvas a medida que avanza el entrenamiento. Este comportamiento sugiere que la función de costo se comporta de manera coherente tanto en los datos de entrenamiento como en los datos externos, lo que constituye un indicio de que el modelo está logrando una adecuada generalización, sin incurrir en sobreajuste.




Figura 5.3: Flujo iterativo para el refinamiento de los resultados de la segmentación semisupervisada, adaptado de la metodología propuesta por Yokoya et. al. (2024) para el refinamiento de resultados de entrenamiento supervisado




Figura 5.4: Curvas de entrenamiento y evaluación. Representan la evolución del costo en función del número épocas (Curvas derivadas con los siguientes hiperparámetros: 200 épocas, Tasa de aprendizaje de $5e-5$ y $\pi_p=0.35$)

5.3 Validación experimental

Para evaluar nuestros resultados, nosotros comparamos los resultados de nuestros modelos con la base de datos WSF2019, una base de datos a nivel global de 10 m de resolución binaria que delimita asentamientos humanos. Este dataset fue generado usando imágenes multitemporales de Sentinel-1 (S1) y Sentinel-2 (S2) del año 2019 y usando un clasificador Random Forest. Para evaluar los resultados, se seleccionaron aleatoriamente 20 muestras de la región de Lima correspondientes al año 2019: 10 provenientes de zonas periféricas, 5 de áreas urbanas centrales, 3 de zonas no urbanas y 2 de regiones oceánicas. En la Figura 5.5 se presentan las 20 muestras de evaluación. La máscara de referencia fue elaborada manualmente a partir de la interpretación visual de imágenes satelitales disponibles en Google Earth. Es importante notar que la base de datos WSF2019 tuvo un extenso proceso de postprocesamiento para remover pistas y carreteras; Por tal motivo, nosotros excluiríamos estos pixels para el proceso de validación.

La evaluación se presenta en la Tabla 5.2, utilizando métricas estándar derivadas de la matriz de confusión: Precisión, Recall (Sensibilidad), F1-Score y Exactitud. Cada una de estas métricas se calcula tanto para la línea base WSF2019 como para el enfoque propuesto, basado en redes neuronales convolucionales (CNN). Estas métricas fueron computadas de forma separada pro clases urbanas y no urbanas. Ambos modelos exitosamente clasificaron los pixels de los oceanos como no urbanos. Usando la métrica F1 para la evauación, nosotros observamos que en las áreas urbanas nuestro modelo tiene un desempeño menor del 1.5% al modelo base. No obstante, en áreas periféricas este sobrepasa al modelo base en 2% y en zonas remotas por un 11.74%. Estos




Figura 5.5: La figura muestra las 20 muestras de validación de los resultados. Las subfiguras (a) hasta (j) representan las muestras periféricas, subfiguras (k) hasta (ñ) representan áreas urbanas centrales, subfiguras (o) hasta (q) representan áreas principalmente no urbanas y subfiguras (r) y (s) representan zonas del oceano

Tabla 5.2: Resultados de validación comparando la clasificación basada en WSF2019 y CNN en diferentes áreas de Lima.

Tipo	Modelo	Precision			Recall			F1-Score		
		U	NU	Av.	U	NU	Av.	U	NU	Av.
Periférico	WSF19	0.7295	0.9180	0.8238	0.6061	0.9515	0.7788	0.6621	0.9345	0.7983
	CNN	0.5810	0.9881	0.7846	0.9526	0.8518	0.9022	0.7218	0.9149	0.8183
Urbano	WSF19	0.8483	0.7833	0.8158	0.8174	0.8187	0.8180	0.8326	0.8006	0.8166
	CNN	0.7680	0.9066	0.8373	0.9464	0.6454	0.7959	0.8479	0.7540	0.8010
Remoto	WSF19	0.3989	0.9928	0.6958	0.1605	0.9979	0.5792	0.2289	0.9953	0.6121
	CNN	0.3132	0.9994	0.6563	0.9268	0.9824	0.9546	0.4682	0.9908	0.7295
Oceano	WSF19	-	1	-	-	1	-	-	1	-
	CNN	-	1	-	-	1	-	-	1	-

resultados indican que el modelo propuesto es particularmente efectivo para detectar zonas de crecimiento urbano, los cuales soportan nuestro objetivo del estudio: Cuantificar la expansión urbana.

5.4 Evaluación experimental

Las Figuras 5.6 hasta 5.12 ilustran el contraste en la dinámica del crecimiento urbano a lo largo del tiempo en ciertos distritos de Lima, seleccionados por contar con imágenes satelitales de alta resolución (2 m.) que permitieron realizar una evaluación visual detallada. La figura ubicada a la izquierda muestra una capa de color púrpura que representa el área urbanizada hasta el año 2021. En cambio, la figura de la derecha incorpora dos capas: una púrpura, correspondiente al mismo periodo, y una capa adicional en rojo, la cual destaca las áreas que experimentaron expansión urbana entre los años 2021 y 2024. En ambas visualizaciones, se observa una delimitación precisa de los bordes urbanos en los respectivos periodos, lo que facilita el análisis comparativo del crecimiento espacial. Las Figuras 5.6, 5.7, 5.8, 5.10, 5.11 y 5.12 muestran los crecimientos urbanos en un sector de los distritos de Villa Maria del Triunfo, El Agustino, Chorrillos, Comas, Lurigancho y Carabaylo respectivamente. El crecimiento de estos distritos está caracterizado por aglomeración de las áreas urbanas en los bordes de las áreas urbanas existentes y edificaciones informales. En la Figura 5.9 se muestra el crecimiento urbano en un sector del distrito de Rimac. Se puede apreciar que el crecimiento se dio por la construcción de un conjunto de edificios residenciales en este sector.

Los resultados de segmentación para la detección de áreas urbanas en el periodo comprendido entre 2016 y 2025 (Capa en color rojo) se presentan en la Figura 5.13. Estos mapas ilustran la expansión progresiva de los asentamientos urbanos dentro del área de estudio a lo largo de los años. El modelo de segmentación logra delinear con éxito los límites urbanos, capturando tanto la densificación de las zonas ya consolidadas como la aparición de nuevos desarrollos. Se observa que el crecimiento urbano se concentró principalmente en las zonas periféricas de Lima.




Figura 5.6: La imagen muestra el crecimiento urbano en un sector del distrito de Villa Maria del Triunfo. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024

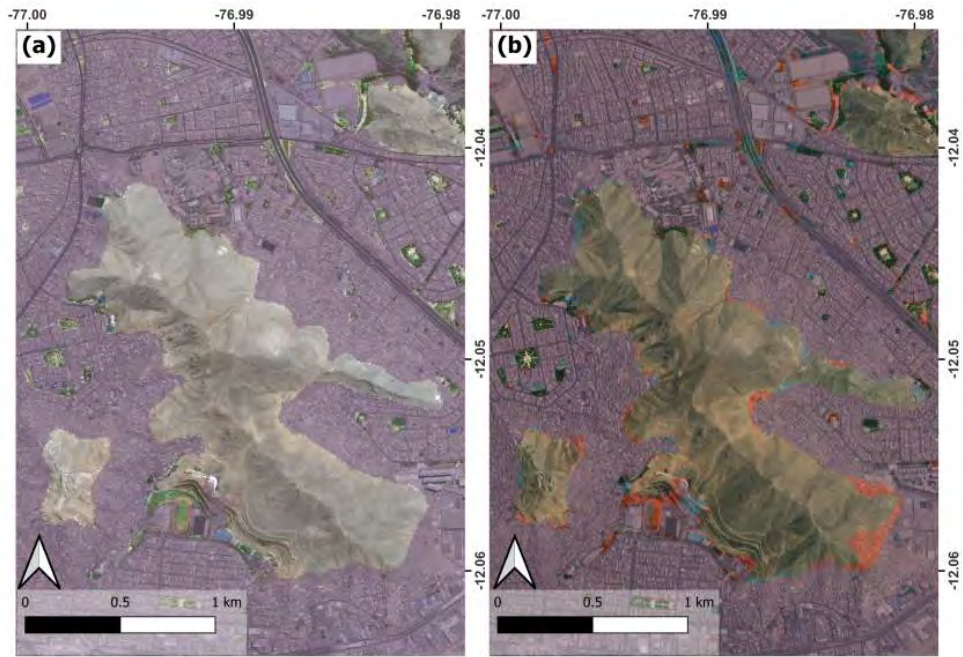


Figura 5.7: La imagen muestra el crecimiento urbano en un sector del distrito de El Agustino. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.8: La imagen muestra el crecimiento urbano en un sector del distrito de Chorrillos. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.9: La imagen muestra el crecimiento urbano en un sector del distrito de Rimac. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.10: La imagen muestra el crecimiento urbano en un sector del distrito de Comas. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.11: La imagen muestra el crecimiento urbano en un sector del distrito de Lurigancho. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.12: La imagen muestra el crecimiento urbano en un sector del distrito de Carabayllo. En la subfigura (a), correspondiente al año 2021, se muestra una superficie en púrpura que representa la delimitación de la zona urbana y subfigura (b), correspondiente al año 2024, se muestra una superficie en rojo que representa las zonas de crecimiento urbana durante el 2021 al 2024




Figura 5.13: Distribución espacial del crecimiento Urbano en Lima metropolitana desde el año 2016 al 2025, representada por la superficie de color rojo. La superficie de color azul representa la delimitación de áreas urbanas en el 2016

La Figura 5.14 presenta la expansión urbana acumulada en diversos distritos de Lima a lo largo de varios periodos, desde 2016 hasta 2025. El gráfico de barras apiladas ilustra el crecimiento urbano incremental en cada distrito, utilizando colores más claros para representar los periodos más antiguos y tonos más oscuros para indicar las expansiones más recientes. Destacan los distritos de Carabayllo, Lurín y Pachacámac, los cuales exhiben el mayor crecimiento acumulado, siendo Carabayllo el que alcanza la expansión más significativa. Esta visualización permite identificar la distribución espacial y temporal del desarrollo urbano, evidenciando que ciertos distritos han experimentado un crecimiento continuo a lo largo del tiempo, mientras que en otros se observan incrementos más esporádicos. Los patrones identificados sugieren una concentración del proceso de urbanización en distritos periféricos, posiblemente impulsada por el crecimiento poblacional y la disponibilidad de suelo.

La Tabla 5.3 presenta los distritos de Lima que experimentaron el mayor crecimiento urbano durante cada uno de los periodos analizados entre 2016 y 2025. Carabayllo mostró la expansión más significativa en múltiples intervalos de tiempo, en particular entre 2016 y 2017, con un crecimiento máximo de 2.6916 km² representando el 0.8% de la superficie de la región. Sin embargo, otros distritos también evidenciaron tendencias notables de urbanización. Por ejemplo, Lurín registró el mayor crecimiento entre 2020 y 2022 (1.3565 km²). Estos resultados ponen de manifiesto la variabilidad espacial de la expansión urbana en Lima, con ciertos distritos experimentando de manera consistente tasas elevadas de crecimiento a lo largo del tiempo.

Tabla 5.3: Maximo crecimiento urbano por periodo

Periodo	Distrito	Área (Km²)
2016-03-27 al 2017-02-20	Carabayllo	2.6916
2017-02-20 al 2018-04-11	Carabayllo	2.1363
2018-04-11 al 2019-04-11	Carabayllo	1.4172
2019-04-11 al 2020-04-20	Carabayllo	0.9914
2020-04-20 al 2021-04-20	Lurin	0.7252
2021-04-20 al 2022-04-30	Lurín	0.6313
2022-04-30 al 2023-01-25	Callao	0.9773
2023-01-25 al 2024-02-14	Carabayllo	1.4402
2024-02-14 al 2025-01-14	Carabayllo	1.3171





Figura 5.14: Crecimiento acumulado del área urbana por distrito en Lima Metropolitana desde el 2016 al 2025

5.5 Cuantificación del crecimiento de la exposición en Lima

Las áreas urbanas detectadas se analizan en relación con zona y factores de peligro predefinidas, incluyendo regiones propensas a inundaciones, áreas con susceptibilidad a deslizamientos y la microzonificación sísmica. Al examinar los patrones de expansión urbana entre 2016 y 2025, el estudio evalúa en qué medida los nuevos desarrollos urbanos se desarrollan en áreas peligrosas. En la Figura 5.15 se presenta diversos mapas de peligro, extraídos de la base de datos del SIGRID, usados para cuantificar el crecimiento urbano en estas áreas.




Figura 5.15: (a) Zona de riesgo de inundación inducida por tsunami tras un terremoto de 8,9 Mw. (b) Zona de susceptibilidad a deslizamientos de tierra. (c) Microzonificación sísmica. [2]

La Figura 5.16(a) muestra un histograma del desarrollo de conglomerados urbanos, donde el eje x representa el tamaño del conglomerado en hectáreas. Se observa una clara relación inversa entre el tamaño del conglomerado y su frecuencia, lo cual puede explicarse por la formación anual de nuevos conglomerados pequeños, mientras que los conglomerados más antiguos tienden a crecer, resultando en un número reducido de conglomerados, pero de mayor tamaño. La Figura 5.16(b) ilustra la expansión urbana en zonas de inundación propensas a tsunamis bajo un escenario de sismo de magnitud 8.8, con un incremento estimado de aproximadamente 4 km^2 en áreas peligrosas. La Figura 5.16(c) presenta el crecimiento en zonas con susceptibilidad a deslizamientos, evidenciando un aumento significativo de alrededor de 30 km^2 en áreas con susceptibilidad media a alta. La Figura 5.16(d) muestra un incremento de aproximadamente 4 km^2 en el desarrollo urbano dentro de zonas de suelos sísmicamente peligrosos, consideradas no aptas para la construcción (Tipo IV y V). Es importante destacar la actual carencia de estudios detallados en muchas de estas áreas de alto peligro donde se ha producido crecimiento urbano, lo que limita la capacidad para evaluar más del 60% de la expansión en relación con dicha exposición.

En las Figuras 5.17-5.26 se presentan el crecimiento urbano, clasificado por tipo de susceptibilidad a deslizamiento, en los 10 distritos con mayor crecimiento en Lima Metropolitana durante los años 2016-2025, los cuales aparecen representados en la Figura 5.14 (mayor a 3 km^2).




Figura 5.16: (a) Histograma del desarrollo de conglomerados urbanos de 2016 a 2025. (b) Expansión urbana en zonas de inundaciones propensas a tsunamis después de un terremoto de magnitud 8,8 (2016-2025). (c) Crecimiento urbano en áreas susceptibles a deslizamientos de tierra (2016-2025). (d) Desarrollo urbano en zonas de suelos sísmicamente peligrosos (2016-2025).

Susceptibilidad a Deslizamientos de suelo en el distrito de CARABAYLLO (2016-2025)




Figura 5.17: Crecimiento urbano del distrito de Carabayllo en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de LURIN (2016-2025)

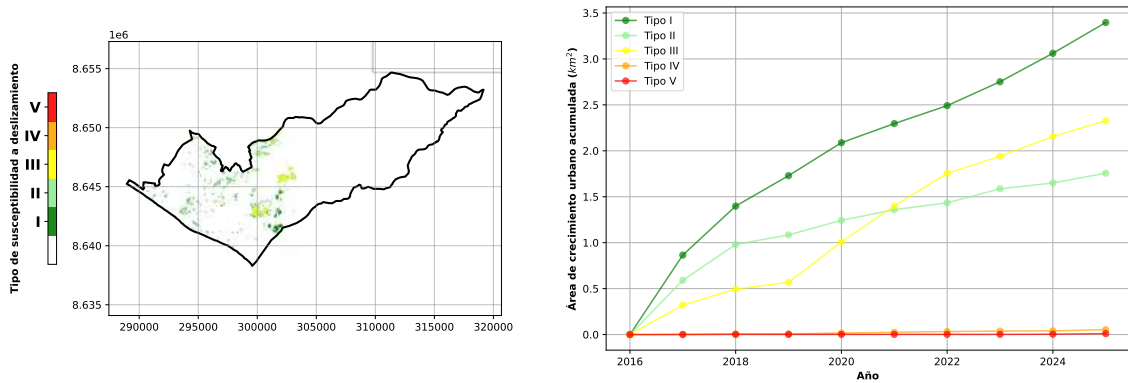


Figura 5.18: Crecimiento urbano del distrito de Lurín en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de PACHACAMAC (2016-2025)

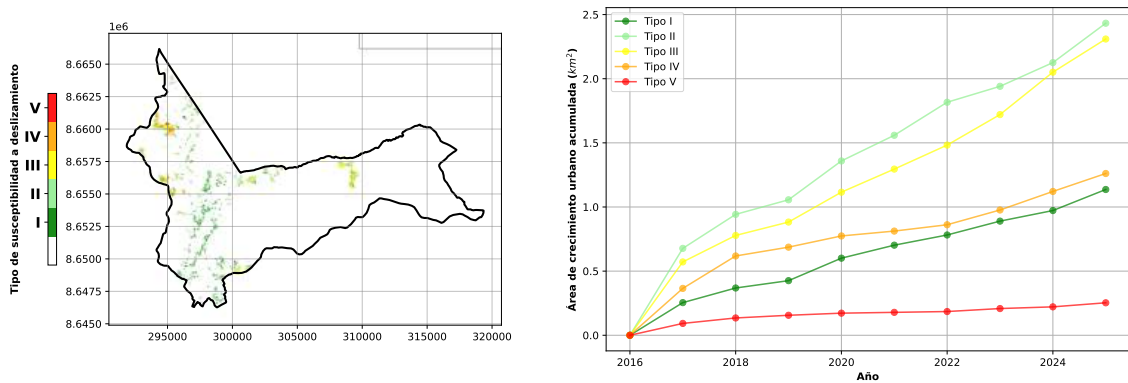


Figura 5.19: Crecimiento urbano del distrito de Pachacamac en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de PUNTA HERMOSA (2016-2025)




Figura 5.20: Crecimiento urbano del distrito de Punta Hermosa en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de VILLA MARIA DEL TRIUNFO (2016-2025)




Figura 5.21: Crecimiento urbano del distrito de Villa María del Triunfo en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de VENTANILLA (2016-2025)




Figura 5.22: Crecimiento urbano del distrito de Ventanilla en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de CIENEGUILLA (2016-2025)

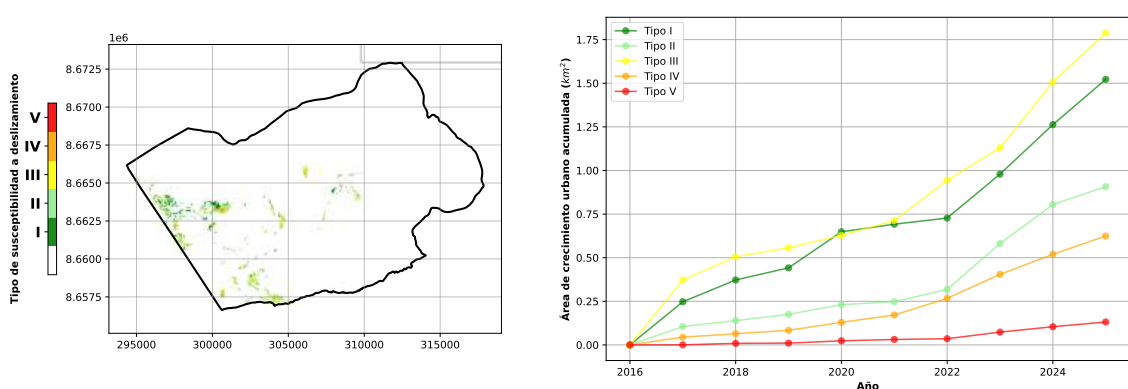


Figura 5.23: Crecimiento urbano del distrito de Cieneguilla en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de LURIGANCHO (2016-2025)




Figura 5.24: Crecimiento urbano del distrito de Lurigancho en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de SAN JUAN DE LURIGANCHO (2016-2025)




Figura 5.25: Crecimiento urbano del distrito de San Juan de Lurigancho en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Susceptibilidad a Deslizamientos de suelo en el distrito de PUENTE PIEDRA (2016-2025)




Figura 5.26: Crecimiento urbano del distrito de Puente Piedra en el periodo del 2016 al 2025. En la gráfica de la derecha se muestra la distribución espacial del crecimiento urbano en el distrito y clasificación por susceptibilidad a deslizamiento del suelo asentado. En la gráfica de la izquierda se muestra el crecimiento acumulado anualmente por tipo de susceptibilidad a deslizamiento

Como se observa en las Figuras 5.17–5.26, el patrón de crecimiento urbano varía significativamente entre distritos. Esta variabilidad está condicionada por factores como la fragilidad estructural asociada al tamaño del distrito, así como por la geolocalización de las zonas de peligro. Por ejemplo: En el distrito de Villa María del Triunfo se presente el mayor crecimiento acumulado de áreas susceptibles a deslizamiento de suelos (Figura 5.21) mientras que el distrito de Carabaylo (Figura 5.17) es el distrito, que a pesar de concentrar el mayor crecimiento urbano acumulado de la ciudad, presenta un crecimiento acumulado inferior a la mitad que el distrito de Villa Maria del Triunfo. Además, en la Figura 5.16(c) se aprecia una morfología particular que difiere del comportamiento observado a escala distrital. En consecuencia, resulta fundamental implementar un monitoreo localizado en las áreas con mayor exposición al riesgo.

5.6 Cuantificación del crecimiento urbano por nivel socioeconómico

En la Figura 5.27 se muestra que el crecimiento urbano horizontal ha estado principalmente asociado a sectores socioeconómicos más vulnerables (75%) tal cual se indica en [18]. Es importante recalcar que estos resultados representan solo el 35% del crecimiento urbano durante este periodo debido a la falta de estudios de niveles socioeconómicos en estas nuevas áreas de crecimiento en los años 2016-2020.

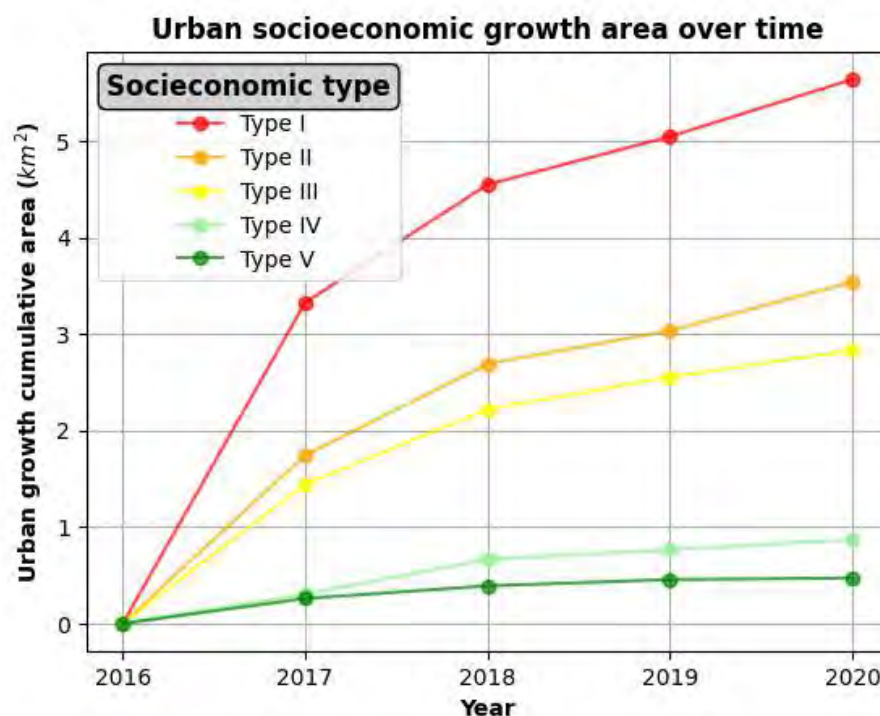


Figura 5.27: Crecimiento Urbano disponible por Nivel Socioeconómico en Lima Metropolitana

5.7 Evaluación del crecimiento urbano en otras ciudades de la costa peruana

En la Figura 5.28 se presenta georeferenciado las áreas de crecimiento urbano en las ciudades de las costas del Perú durante el periodo 2016-2025. En la Tabla 5.4 se presenta un resumen del crecimiento urbano registrado en las principales provincias de la costa peruana durante el periodo de estudio. Este análisis se obtuvo a partir de la red calibrada y reentrenada inicialmente con datos de Lima, incorporando información adicional de las principales zonas urbanas de estas ciudades, así como la clasificación de áreas con vegetación como no urbanas. Los resultados muestran un crecimiento urbano significativo en varias provincias, exceptuando Lima Metropolitana (ya evaluada previamente). Destacan los incrementos en Arequipa con 42.47 km^2 , Trujillo con 32.57 km^2 , Ica con 29.76 km^2 , Chiclayo con 29.26 km^2 y Tacna con 22.68 km^2 . Este patrón podría explicarse por la concentración de actividades socioeconómicas y la alta densidad poblacional que caracterizan a estas provincias.



Figura 5.28: Crecimiento de áreas urbanas en las ciudades de las costas del Perú en el periodo 2016-2025

Tabla 5.4: Crecimiento urbano en las provincias de la costa peruana

Provincia	Intervalo	Área (hm^2)
AREQUIPA	20160510:20240418	4247.17
ASCOPE	20160502:20240121	435.78
BARRANCA	20160509:20241113	594.25
CAMANA	20160510:20250118	548.02
CASMA	20160618:20240207	166.67
CHEPEN	20160721:20250120	303.69
CHICLAYO	20160721:20250120	2926.8
CHINCHA	20160426:20240315	991.87
CHOTA	20160721:20250120	18.45
CONTRALMIRANTE VILLAR	20161121:20240722	65.2
CONTUMAZA	20160810:20240604	81.47
FERREÑAFE	20160721:20250120	282.5
GRAN CHIMU	20160810:20240604	27.02
HUARAL	20180419:20240313	398.04
HUARMEY	20160509:20241113	195.83
HUAURA	20180419:20240313	1115.51
ICA	20161122:20240330	2976.57
ISLAY	20160510:20240418	368.59
JORGE BASADRE	20160914:20240430	55.73
LAMBAYEQUE	20160721:20250120	1195.56
NASCA	20160722:20240511	418.53
OCROS	20160509:20241113	8.22
OTUZCO	20160810:20240604	2.06
PACASMAYO	20160502:20240121	603.67
PAITA	20160515:20250118	1275.47
PALPA	20161122:20240330	47.99
PISCO	20160426:20240325	362.17
PIURA	20160823:20250118	2879.89
SANTA	20160618:20240207	1051.4
SULLANA	20160823:20250118	568.47
TACNA	20160914:20240430	2268.63
TARATA	20160914:20240430	14.43
TRUJILLO	20160810:20240604	3257.05
TUMBES	20161121:20240722	133.68
VIRU	20161125:20241113	311.56

En las Figuras 5.29 y 5.30 se muestran las gráficas del crecimiento urbano acumulado anual entre 2016 y 2025, considerando la susceptibilidad a deslizamientos en las ciudades de Arequipa y Chimbote, respectivamente. En el caso de Arequipa, se observa que más de $5 km^2$ de áreas

urbanas se desarrollan en zonas de tipo V y más de 18km^2 en zonas de tipo IV, ambas clasificadas como susceptibles a deslizamiento. En contraste, en Chimbote el crecimiento urbano en conjunto en estas dos categorías no supera el 5% del total. Esta diferencia puede atribuirse, principalmente, a las condiciones morfológicas más accidentadas que caracterizan a la ciudad de Arequipa, en oposición al relieve relativamente menos accidentado de Chimbote.

En las figuras 5.31, 5.32, 5.33, 5.34 y 5.35 se presentan figuras en mayor detalle del crecimiento urbanos de algunas ciudades de la costa del Perú. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.

**Temporal Evolution of Urban Growth in Landslide Susceptibility Zones
Arequipa**




Figura 5.29: Crecimiento acumulado de áreas urbanas en Arequipa por tipo de susceptibilidad a deslizamiento, en el periodo 2016-2025

**Temporal Evolution of Urban Growth in Landslide Susceptibility Zones
Chimbote**

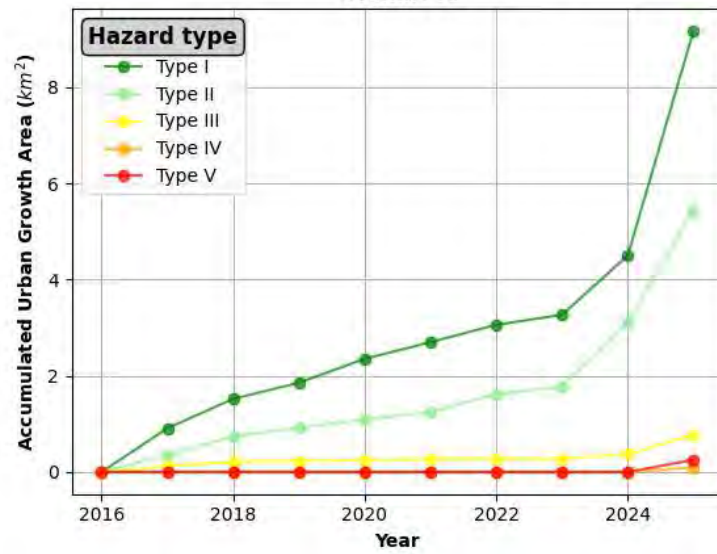


Figura 5.30: Crecimiento acumulado de áreas urbanas en Chimbote por tipo de susceptibilidad a deslizamiento, en el periodo 2016-2025




Figura 5.31: Crecimiento de áreas urbanas en Tacna. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.




Figura 5.32: Crecimiento de áreas urbanas en Moquegua. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.




Figura 5.33: Crecimiento de áreas urbanas en CAMANA. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.




Figura 5.34: Crecimiento de áreas urbanas en CAÑETE. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.




Figura 5.35: Crecimiento de áreas urbanas en TRUJILLO. La capa purpura muestra la delimitación de áreas urbanas para el año 2016 y la capa roja representa la delimitación del crecimiento urbano entre 2016 al 2025.

Capítulo 6

Conclusiones y recomendaciones

6.1 Conclusiones

En este estudio se utilizó un enfoque de segmentación semisupervisado para la detección de áreas urbanas, incorporando técnicas de aprendizaje débil y empleando ResNet-152 como arquitectura base. La metodología propuesta permitió identificar y mapear las principales zonas de crecimiento urbano en la ciudad de Lima Metropolitana entre 2016 y 2025, revelando un incremento de áreas urbanas de 76 km^2 concentrándose en los sectores periféricos como Carabaylo, Lurín y Pachacamac, proporcionando información valiosa sobre la expansión de los asentamientos, en particular en regiones expuestas a peligros naturales.

La evaluación de los resultados y comparación con la base de datos de WSF2019 permitió contrastar y demostrar la capacidad del modelo para generalizar, a pesar de las limitaciones asociadas a datos de entrenamiento incompletos, lo que resalta su aplicabilidad para el monitoreo urbano a gran escala. Esto se pudo evidenciar al evaluar el crecimiento urbano en las principales provincias del Perú, en las cuales se encontraron que el crecimiento se desarrolló en las principales ciudades de la costa del Perú como Lima, Arequipa (42.47 km^2), Trujillo (32.57 km^2) e Ica (22.68 km^2).

No obstante, persiste la necesidad de realizar evaluaciones de peligros de manera continua, ya que la información obtenida en este estudio no es suficiente por sí sola para supervisar de forma integral todas las zonas vulnerables. Muchos sectores de expansión urbana aún enfrentan una exposición significativa a amenazas ambientales, lo que hace imprescindible mantener un análisis constante y adoptar estrategias de planificación urbana proactivas que contribuyan a mitigar los riesgos potenciales.

6.2 Recomendaciones

Se recomienda la implementación de un sistema de monitoreo en tiempo real basado en una arquitectura servidor-cliente, que permita la recepción continua de imágenes satelitales actualizadas —por ejemplo, mediante fuentes abiertas como Sentinel-2 o datos de radar de Sentinel-1—. Este sistema debería integrar modelos de segmentación entrenados previamente, capaces de detectar nuevas áreas urbanas y comparar los resultados con mapas de peligros existentes. Al identificar

que el crecimiento urbano se produce en zonas clasificadas como de alto riesgo (inundaciones, deslizamientos o suelos sísmicamente inestables), el sistema deberá generar alertas automáticas y reportes críticos para su análisis por parte de autoridades urbanísticas y de gestión del riesgo.

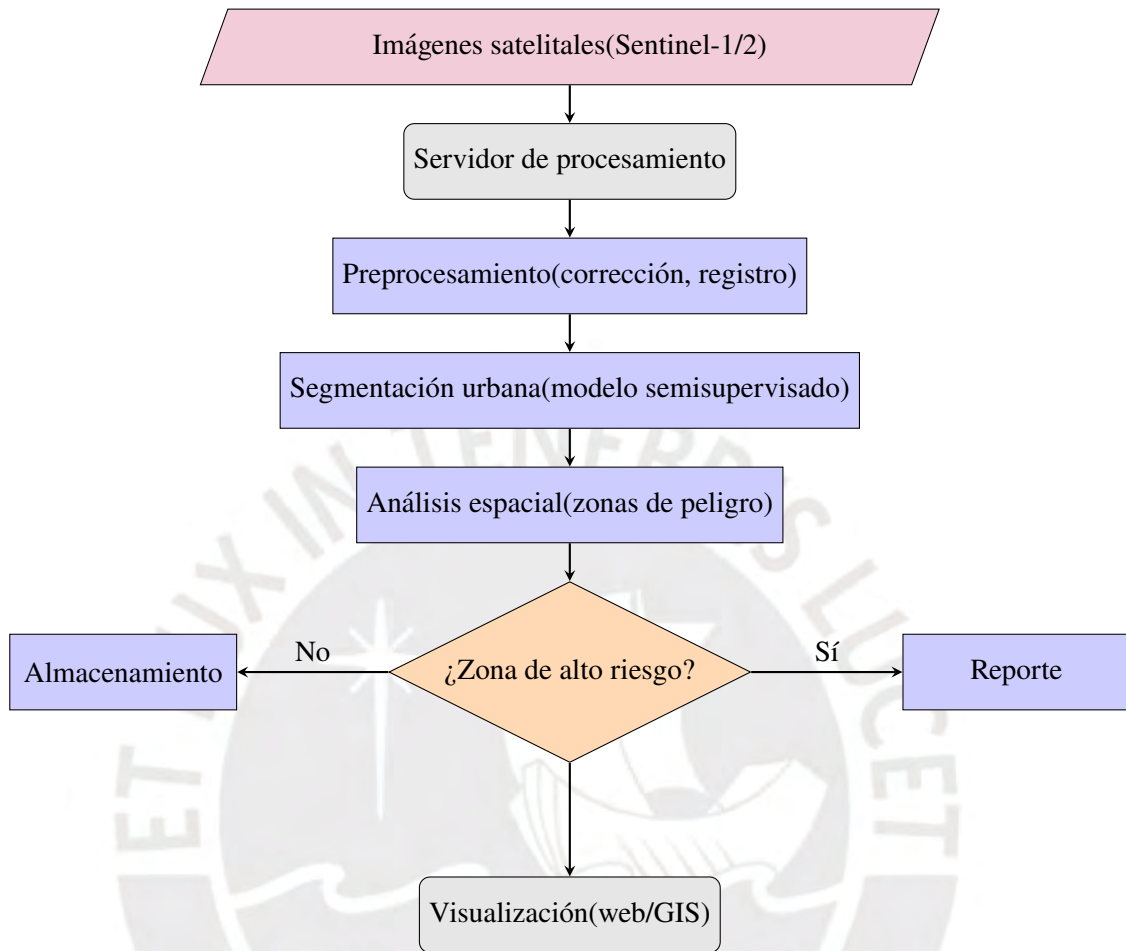


Figura 6.1: Arquitectura conceptual del sistema de monitoreo urbano en tiempo real.

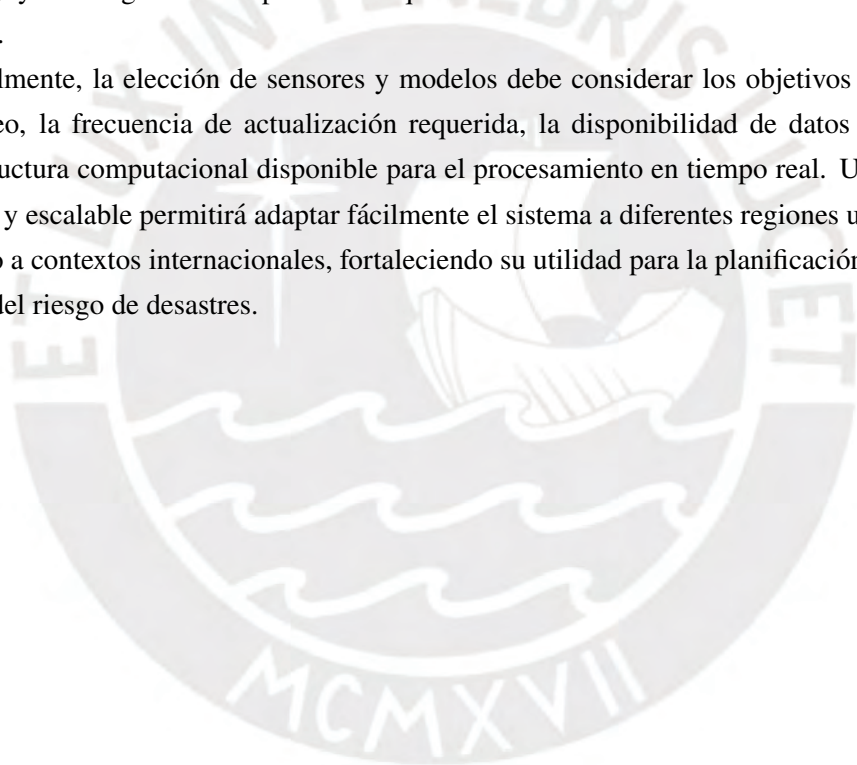
La Figura 6.1 muestra una arquitectura conceptual propuesta para el monitoreo urbano en tiempo real. Este sistema se alimenta de imágenes satelitales (ópticas y de radar) que son recibidas por un servidor centralizado. Las imágenes pasan por un proceso de preprocesamiento y segmentación urbana utilizando modelos semisupervisados. Posteriormente, se realiza un análisis espacial cruzando los resultados con mapas de peligros. Si se detecta crecimiento urbano en zonas de alto riesgo, el sistema genera reportes críticos y alertas. Todos los resultados son almacenados y visualizados a través de una interfaz interactiva tipo GIS o portal web.

Cabe resaltar que la metodología propuesta es altamente adaptable a distintos tipos de sensores satelitales, tanto ópticos como de radar, incluyendo imágenes de muy alta resolución espacial (VHR, por sus siglas en inglés). En el caso de imágenes ópticas como las proporcionadas por Sentinel-2, se dispone de información multiespectral útil para identificar patrones urbanos; sin embargo, su calidad puede verse comprometida por condiciones atmosféricas adversas, como la presencia de nubosidad o sombras. Para superar esta limitación, es posible incorporar imágenes VHR provenientes de satélites comerciales (como WorldView, Pleiades o similares), las cuales no solo ofrecen una mayor precisión espacial para la delimitación de objetos urbanos, sino que,

en algunos casos, están disponibles en franjas temporales que permiten evitar áreas cubiertas por nubes. Alternativamente, también pueden emplearse datos de radar de apertura sintética (SAR), como los del satélite Sentinel-1, que permiten obtener imágenes independientemente de las condiciones climáticas y de iluminación. Esta flexibilidad en la selección de sensores permite optimizar el desempeño del sistema según las condiciones geográficas, climáticas y técnicas del área de estudio.

Además, la aplicabilidad del sistema a otras regiones fuera de la costa del Perú requiere una etapa previa de adaptación del modelo de segmentación. Esto se debe a que los modelos entrenados en un contexto urbano específico tienden a especializarse en las texturas, colores y geometrías particulares de dicho entorno. Por tanto, es necesario reentrenar o ajustar los modelos con muestras representativas de las nuevas áreas de estudio, asegurando que se incluyan variaciones locales en la morfología urbana, materiales de construcción, densidad habitacional y características del terreno. Este proceso puede apoyarse en técnicas de aprendizaje por transferencia (transfer learning) y estrategias semisupervisadas que reduzcan la necesidad de anotaciones manuales extensas.

Finalmente, la elección de sensores y modelos debe considerar los objetivos específicos del monitoreo, la frecuencia de actualización requerida, la disponibilidad de datos históricos y la infraestructura computacional disponible para el procesamiento en tiempo real. Una arquitectura modular y escalable permitirá adaptar fácilmente el sistema a diferentes regiones urbanas del país e incluso a contextos internacionales, fortaleciendo su utilidad para la planificación territorial y la gestión del riesgo de desastres.



Referencias

- [1] United Nations Human Settlements Programme (UN-Habitat), *World Cities Report 2024: Cities and Climate Action*. Nairobi: UN-Habitat, 2024. [Online]. Available: <https://unhabitat.org/world-cities-report-2024-cities-and-climate-action>
- [2] CENEPRED, “Cartografía de peligros - sigrid,” 2025, accessed on February, 2025. [Online]. Available: https://sigrid.cenepred.gob.pe/arcgis/rest/services/Cartografia_Peligros/MapServer
- [3] ONU, “Las ciudades seguirán creciendo, sobre todo en los países en desarrollo,” 2018.
- [4] UN-Habitat, “Informal settlements,” *HABITAT III*, pp. 1–8, 2015.
- [5] German Aerospace Center (DLR), “World settlement footprint (wsf) evolution - landsat-5/-7 - global,” 2023, accessed on March 11, 2024. [Online]. Available: https://download.geoservice.dlr.de/WSF_EVO/
- [6] Microsoft, “Building footprints: An ai-assisted mapping deliverable with the capability to solve for many scenarios.” 2023, accessed on March 11, 2024. [Online]. Available: <https://planetarycomputer.microsoft.com/dataset/ms-buildings>
- [7] N. Yokoya, J. Xia, and C. Broni-Bediako, “Submeter-level land cover mapping of japan,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 127, p. 103660, 2024.
- [8] Bruno Adriano, Luis Moya, Erick Mas, Hiroyuki Miura, Masashi Matsuoka, and Shunichi Koshimura, “Urban Vulnerability Analysis in the Tributary Basin of the Rimac River, Peru Using High-Resolution Remote Sensing Imagery.” [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/10642715>
- [9] Z. Assarkhaniki, S. Sabri, and A. Rajabifard, “Using open data to detect the structure and pattern of informal settlements: an outset to support inclusive SDGs’ achievement,” *Big Earth Data*, vol. 5, no. 4, pp. 497–526, Nov. 2021, publisher: Taylor & Francis eprint: <https://doi.org/10.1080/20964471.2021.1948178>. [Online]. Available: <https://doi.org/10.1080/20964471.2021.1948178>
- [10] N. Yokoya, J. Xia, and C. Broni-Bediako, “Submeter-level land cover mapping of Japan,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 127, p.

- 103660, Mar. 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1569843224000141>
- [11] S. Wei, T. Zhang, and S. Ji, "A Concentric Loop Convolutional Neural Network for Manual Delineation-Level Building Boundary Segmentation From Remote-Sensing Images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–11, 2022, conference Name: IEEE Transactions on Geoscience and Remote Sensing. [Online]. Available: <https://ieeexplore.ieee.org/document/9610052/keywords#keywords>
- [12] C. Geiß, Y. Zhu, C. Qiu, L. Mou, X. X. Zhu, and H. Taubenböck, "Deep Relearning in the Geospatial Domain for Semantic Remote Sensing Image Segmentation," vol. 19. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/9247397>
- [13] D. Torres, D. Perleche, and A. Aiquipa, *La producción del espacio urbano en Lima Metropolitana y el Callao: Entre las informalidades y la regulación (1961-2020)*, 1st ed. Lima: Urbes Lab, 2021.
- [14] H. Tavera, *Evaluación del peligro asociado a los sismos y efectos secundarios en Perú*, 1st ed. Lima: IGP, 2014.
- [15] H. Taubenböck, J. Mast, R. Lemoine Rodríguez, H. Debray, M. Wurm, and C. Geiß, "Was global urbanization from 1985 to 2015 efficient in terms of land consumption?" *Habitat International*, vol. 160, p. 103397, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0197397525001134>
- [16] H. Debray, M. Gassilloud, R. Lemoine-Rodríguez, M. Wurm, X. Zhu, and H. Taubenböck, "Universal patterns of intra-urban morphology: Defining a global typology of the urban fabric using unsupervised clustering," *International Journal of Applied Earth Observation and Geoinformation*, vol. 141, p. 104610, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1569843225002572>
- [17] A. Espinoza and R. Fort, "Mapeo y tipología de la expansión urbana en el Perú," GRADE, Tech. Rep., 2019.
- [18] Ministerio de Vivienda, Construcción y Saneamiento, "Crecimiento urbano en ciudades del Perú," accedido el 31 de mayo de 2025. [Online]. Available: <https://dportalgis.vivienda.gob.pe/dportal/apps/Cascade/index.html?appid=bd40e02be3a648a296871b264f3a9441>
- [19] INDECI-DIPRE, "Escenario sísmico para lima metropolitana y callao: Sismo 8.8mw," Instituto Nacional de Defensa Civil (INDECI), Tech. Rep., 2017, Perú.
- [20] W. Bakker, W. Feriga, A. Gieske, B. Gorte, K. Grabmaier, C. Hecker, J. Horn, G. Huurneman, L. Janssen, K. Norman, F. V. der Meer, G. Parodi, C. Pohl, C. Reeves, F. V. Ruitenbeek, E. Schetselaar, K. Tempfli, M. Weir, E. Westinga, and T. Woldai, *Principles of Remote Sensing*. Enschede: The International Institute for Geo-Information Science and Earth Observation, 2009.

- [21] S. Khorram, F. H. Koch, C. F. V. der Wiele, and S. A. C. Nelson, *Remote Sensing*. Raleigh: Springer, 2012.
- [22] E. A. Ustinov, *Sensitivity Analysis in Remote Sensing*. Springer, 2015.
- [23] IGN, *El programa Copernicus aplicado a la producción y gestión de la información geoespacial*. Madrid, 2022.
- [24] A. Fallatah, S. Jones, L. Wallace, and D. Mitchell, “Combining Object-Based Machine Learning with Long-Term Time-Series Analysis for Informal Settlement Identification,” *Remote Sensing*, vol. 14, no. 5, p. 1226, Jan. 2022, number: 5 Publisher: Multidisciplinary Digital Publishing Institute. [Online]. Available: <https://www.mdpi.com/2072-4292/14/5/1226>
- [25] M. Marconcini, “Understanding current trends in global urbanisation - the world settlement footprint suite,” vol. Volume 9,, pp. 33–38, 2021, online available: <https://austriaca.at/?arp=0x003c9b4c> - Last access:12.5.2025. [Online]. Available: <https://austriaca.at/?arp=0x003c9b4c>
- [26] B. Gram-Hansen, P. Helber, I. Varatharajan, F. Azam, A. Coca-Castro, V. Kopackova, and P. Bilinski, “Mapping Informal Settlements in Developing Countries using Machine Learning and Low Resolution Multi-spectral Data,” in *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society*, Jan. 2019, pp. 361–368, arXiv:1901.00861 [cs]. [Online]. Available: <http://arxiv.org/abs/1901.00861>
- [27] I. Tingzon, N. Dejito, R. A. Flores, R. D. Guzman, L. Carvajal, K. Z. Erazo, I. E. C. Cala, J. Villaveces, D. Rubio, and R. Ghani, “Mapping New Informal Settlements using Machine Learning and Time Series Satellite Images: An Application in the Venezuelan Migration Crisis,” in *2020 IEEE / ITU International Conference on Artificial Intelligence for Good (AI4G)*, Sep. 2020, pp. 198–203, arXiv:2008.13583 [cs]. [Online]. Available: <http://arxiv.org/abs/2008.13583>
- [28] B. S. Li and C. N. Liu, “RESEARCH ON INTELLIGENT RECOGNITION OF VIOLATION BASED ON BIG DATA OF URBAN CONSTRUCTION,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-3-W10, pp. 721–724, Feb. 2020, conference Name: ISPRS WG III/5
International Conference on Geomatics in the Big Data Era (Volume XLII-3/W10) - 15–17 November 2019, Guilin, Guangxi, China Publisher: Copernicus GmbH. [Online]. Available: <https://isprs-archives.copernicus.org/articles/XLII-3-W10/721/2020/isprs-archives-XLII-3-W10-721-2020.html>
- [29] M. Kim and G. Kim, “Modeling and Predicting Urban Expansion in South Korea Using Explainable Artificial Intelligence (XAI) Model,” *Applied Sciences*, vol. 12, no. 18, p. 9169, Jan. 2022, number: 18 Publisher: Multidisciplinary Digital Publishing Institute. [Online]. Available: <https://www.mdpi.com/2076-3417/12/18/9169>

- [30] T. Das, Shahfahad, M. W. Naikoo, S. Talukdar, A. Parvez, A. Rahman, S. Pal, M. S. Asgher, A. R. M. T. Islam, and A. Mosavi, “Analysing Process and Probability of Built-Up Expansion Using Machine Learning and Fuzzy Logic in English Bazar, West Bengal,” *Remote Sensing*, vol. 14, no. 10, p. 2349, Jan. 2022, number: 10 Publisher: Multidisciplinary Digital Publishing Institute. [Online]. Available: <https://www.mdpi.com/2072-4292/14/10/2349>
- [31] S. Mansour, E. Ghoneim, A. El-Kersh, S. Said, and S. Abdelnaby, “Spatiotemporal Monitoring of Urban Sprawl in a Coastal City Using GIS-Based Markov Chain and Artificial Neural Network (ANN),” *Remote Sensing*, vol. 15, no. 3, p. 601, Jan. 2023, number: 3 Publisher: Multidisciplinary Digital Publishing Institute. [Online]. Available: <https://www.mdpi.com/2072-4292/15/3/601>
- [32] A. Prasetyadi, A. Gunawan, W. Hendriawan, A. Bisri, N. Rahma, and A. Fakhru, “Integrating Remote Sensing and Machine Learning for Monitoring Urban Growth in Seismically Active Regions: A Case Study of the Lembang Fault Zone, West Java, Indonesia.” Bandung, Indonesia: IEEE, 2024. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/10732244>
- [33] H. Kesavan, S. Choudhary, S. Khan, S. R, and A. Sharma, “AI Based Urban Resilience Planning: Opportunities and Challenges,” *Journal of Environmental & Earth Sciences*, vol. 6, no. 2, pp. 200–214, Jul. 2024, number: 2. [Online]. Available: <https://journals.bilpubgroup.com/index.php/jees/article/view/6681>
- [34] L. Ding, H. Zhang, and D. Li, “Monitoring and Analysis of Urban Sprawl Based on Road Network Data and High-Resolution Remote Sensing Imagery: A Case Study of China’s Provincial Capitals,” *Photogrammetric Engineering & Remote Sensing*, vol. 88, no. 7, pp. 479–486, Jul. 2022.
- [35] Y. Qiao, B. Zhong, B. Du, H. Cai, J. Jiang, and Q. Liu, “SAM Enhanced Semantic Segmentation for Remote Sensing Imagery without Additional Training.” [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/10857947>
- [36] J. A. Richards, *Remote Sensing Digital Image Analysis*, 5th ed. Berlin: Springer, 2013.
- [37] M. Kuffer, K. Pfeffer, and R. Sliuzas, “Slums from Space—15 Years of Slum Mapping Using Remote Sensing,” *Remote Sensing*, vol. 8, no. 6, p. 455, Jun. 2016, number: 6 Publisher: Multidisciplinary Digital Publishing Institute. [Online]. Available: <https://www.mdpi.com/2072-4292/8/6/455>
- [38] J.-X. Wang, T. Li, S.-B. Chen, J. Tang, B. Luo, and R. Wilson, “Reliable Contrastive Learning for Semi-Supervised Change Detection in Remote Sensing Images,” vol. 60. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/9978928>
- [39] Y. Guo, F. Wang, Y. Xiang, and H. You, “Semisupervised Semantic Segmentation With Certainty-Aware Consistency Training for Remote Sensing Imagery,” vol. 16. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/10066529>

- [40] J. Shi, T. Wu, A. K. Qin, Y. Lei, and G. Jeon, “Semisupervised Adaptive Ladder Network for Remote Sensing Image Change Detection,” vol. 60. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/9732943>
- [41] S. Saha, L. Mou, X. X. Zhu, F. Bovolo, and L. Bruzzone, “Semisupervised Change Detection Using Graph Convolutional Network,” vol. 18. [Online]. Available: <https://ieeexplore.pucp.elogim.com/document/9069898>
- [42] M. Sugiyama, H. Bao, T. Ishida, N. Lu, T. Sakai, and G. Niu, *Machine Learning from Weak Supervision: An Empirical Risk Minimization Approach*. Cambridge, MA: MIT Press, Aug. 2022, original publication date: August 23, 2022. [Online]. Available: <https://mitpress.mit.edu/9780262047660/>
- [43] J. Yue, L. Fang, P. Ghamisi, W. Xie, J. Li, J. Chanussot, and A. J. Plaza, “Optical Remote Sensing Image Understanding with Weak Supervision: Concepts, Methods, and Perspectives,” *IEEE Geoscience and Remote Sensing Magazine*, vol. 10, no. 2, pp. 250–269, Jun. 2022, arXiv:2204.09120 [cs]. [Online]. Available: <http://arxiv.org/abs/2204.09120>
- [44] R. Kiryo, G. Niu, M. C. d. Plessis, and M. Sugiyama, “Positive-Unlabeled Learning with Non-Negative Risk Estimator,” Nov. 2017, arXiv:1703.00593 [cs]. [Online]. Available: <http://arxiv.org/abs/1703.00593>
- [45] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, ser. Lecture Notes in Computer Science, vol. 9351. Springer, 2015, pp. 234–241. [Online]. Available: <http://lmb.informatik.uni-freiburg.de/people/ronneber/u-net>
- [46] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2016, pp. 770–778. [Online]. Available: <https://doi.org/10.1109/CVPR.2016.90>
- [47] QuickOSM, “Quickosm plugin for qgis,” 2025, available at: <https://plugins.qgis.org/plugins/QuickOSM/> (last access: February 2025).
- [48] Instituto Nacional de Defensa Civil (INDECI), “Base de datos de peligros y vulnerabilidades en el Perú,” 2025. [Online]. Available: <https://www.gob.pe/indeci>
- [49] L. Moya, M. Vilela, J. Jaimes, B. Espinoza, J. Pajuelo, N. Tarque, S. Santa-Cruz, P. Vega-Centeno, and F. Yamazaki, “Vulnerabilities and exposure of recent informal urban areas in Lima, Peru,” *Progress in Disaster Science*, vol. 23, p. 100345, Oct. 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2590061724000358>
- [50] INEI, “Manzanas,” <https://ide.inei.gob.pe/>, 2013.