

**PONTIFICIA UNIVERSIDAD
CATÓLICA DEL PERÚ**

Escuela de Posgrado



**IDENTIFICACIÓN DE EDIFICACIONES COLAPSADAS
MEDIANTE IMÁGENES SATELITALES, CURVAS DE
FRAGILIDAD, MAPAS DE DEMANDA Y REDES NEURONALES**

Tesis para obtener el grado académico de Maestro en Ingeniería Civil con
mención en Gestión de Riesgos Naturales que presenta:

Aymar Raúl Portillo Cazorla

Asesor:

Dr. Luis Angel Moya Huallpa

Co asesores:

Dr. Sabino Nicola Tarque Ruíz

Dra. Sandra Cecilia Santa Cruz Hidalgo

Lima, 2024

Informe de Similitud

Yo, Luis Angel Moya Huallpa, docente de la Escuela de Posgrado de la Pontificia Universidad Católica del Perú, asesor(a) de la tesis titulada(o) Identificación de Edificaciones Colapsadas Mediante Imágenes Satelitales, Curvas de Fragilidad, Mapas de Demanda y Redes Neuronales, de el autor Aymar Raúl Portillo Cazorla, dejo constancia de lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud de 12%. Así lo consigna el reporte de similitud emitido por el software *Turnitin* el 18/06/2024.
- He revisado con detalle dicho reporte y la Tesis o Trabajo de investigación, 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, 21 de junio de 2024.

Apellidos y nombres del asesor / de la asesora: <u>Moya Huallpa, Luis Angel</u>	
DNI: 43010087	Firma 
ORCID: 0000-0003-1764-3160	

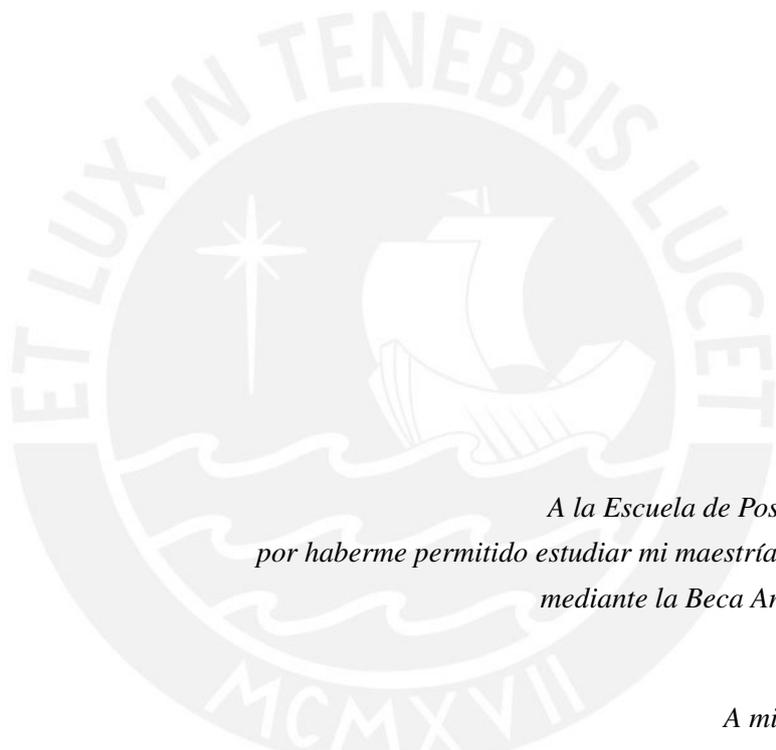
Dedicatorias



*A mis padres, por enseñarme con su ejemplo
el valor de la educación y el trabajo*

*A Stephany, por estar a mi lado en cada paso,
con un corazón lleno de amor
y una mano siempre dispuesta a ayudar.*

Agradecimientos



*A la Escuela de Posgrado de la PUCP,
por haberme permitido estudiar mi maestría a tiempo completo
mediante la Beca Angel San Bartolomé*

*A mi asesor Luis Moya,
por las enseñanzas, consejos, comprensión y el constante apoyo
durante el desarrollo de esta investigación*

*A mis co asesores Nicola Tarque y Sandra Santa Cruz,
por sus comentarios y consejos que han mejorado la calidad
de esta tesis*

*A Ed Castillo
por su invaluable amistad y sus numerosos comentarios
que enriquecieron esta tesis*

Investigaciones publicadas

Previo a la publicación de esta tesis, 2 trabajos de investigación académica fueron publicados en relación al método y a los casos de estudio presentados. A continuación se describen dichas publicaciones.

Título: *Seismic Risk Regularization for Urban Changes Due to Earthquakes: A Case of Study of the 2023 Turkey Earthquake Sequence*
Tipo de publicación: Revista indexada Q1
Revista: *Remote Sensing (MDPI)*
Fecha: 25 mayo del 2023
DOI: <https://doi.org/10.3390/rs15112754>

Título: *Semi-Supervised Classification of Collapsed Building Using Remote Sensing, In-Placed Sensors, and Fragility Functions*
Tipo de publicación: Conferencia indexada
Conferencia: *IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium*
Fecha: 2023
DOI: <https://doi.org/10.1109/IGARSS52108.2023.10281731>

Resumen

Esta tesis presenta un método innovador para identificar con rapidez las áreas afectadas por sismos. El método se distingue por su capacidad para operar con información limitada y aun así obtener resultados precisos. Utiliza una combinación de imágenes satelitales previas y posteriores al evento, inventarios de edificaciones, curvas de fragilidad, mapas de demanda sísmica y muestras etiquetadas recopiladas poco después del desastre. La característica central del método es su uso de redes neuronales que con una mínima cantidad de muestras etiquetadas, tan pocas como seis, como se demostró en el terremoto de Kumamoto de 2016, pueden clasificar grandes cantidades de datos sobre la fragilidad de las edificaciones en las áreas afectadas. Estas muestras se obtienen de fuentes verificables, se geolocalizan y se registran para su uso en la calibración de la red neuronal, lo que permite una evaluación rápida y precisa de áreas colapsadas.

Los resultados obtenidos con este enfoque han demostrado ser efectivos, alcanzando una precisión promedio del 87% en el terremoto de Kumamoto de 2016 y del 82% en el terremoto de Turquía-Siria de 2023. El método destaca por su capacidad para analizar áreas extensas de manera eficiente, lo que lo hace ideal para ser utilizado como parte de la respuesta inmediata tras sismos importantes.

Aunque el método es funcional y rápido, se han identificado oportunidades para mejoras futuras. Por ejemplo, es necesario optimizar la arquitectura de la red neuronal y evaluar el impacto del número de muestras etiquetadas utilizadas para la calibración. Además, probar el método en diversos contextos es crucial para validar su versatilidad y detectar posibles deficiencias que puedan ser corregidas posteriormente.

Abstract

This thesis presents an innovative method for rapidly identifying areas affected by earthquakes. The method is notable for its ability to operate with limited information while still delivering precise results. It combines pre- and post-event satellite images, building inventories, fragility curves, seismic demand maps, and labeled samples collected shortly after the disaster. The central feature of this method is its use of neural networks, which can classify large amounts of data on the fragility of buildings in affected areas with a minimal number of labeled samples— as few as six, as demonstrated in the 2016 Kumamoto earthquake. These samples are gathered from verifiable sources, geolocated, and recorded for use in calibrating the neural network, allowing for a swift and accurate assessment of collapsed areas.

The results obtained with this approach have proven to be effective, achieving an average accuracy of 87% in the 2016 Kumamoto earthquake and 82% in the 2023 Turkey-Syria earthquake. The method excels in its ability to efficiently analyze extensive areas, making it ideal for immediate response after significant seismic events.

While the method is functional and fast, opportunities for future improvements have been identified. For instance, optimizing the neural network architecture and evaluating the impact of the number of labeled samples used for calibration are necessary. Additionally, testing the method in various contexts is crucial to validate its versatility and to identify any potential deficiencies that could be addressed subsequently.

Indice General

Dedicatorias	ii
Agradecimientos	iii
Investigaciones publicadas	iv
Resumen	v
Abstract	vi
Indice General	vii
Lista de tablas	ix
Lista de figuras	x
1 Presentación del trabajo de investigación	1
1.1 Introducción	1
1.2 Antecedentes	2
1.2.1 Antecedente 1: An integrated method to extract collapsed buildings from satellite imagery, hazard distribution and fragility curves	2
1.2.2 Antecedente 2: Novel Unsupervised Classification of Collapsed Buildings Using Satellite Imagery, Hazard Scenarios and Fragility Functions	4
1.3 Justificación	6
1.4 Hipótesis	7
1.5 Objetivos de la investigación	7
1.5.1 Objetivo general	8
1.5.2 Objetivos específicos	8
1.6 Alcance	8
2 Marco teórico	9
2.1 Fundamentos geoespaciales y sistemas de coordenadas	9
2.1.1 Sistemas de coordenadas geodésicas	9
2.1.2 Sistemas de coordenadas proyectadas	10
2.1.3 Transformación de coordenadas	12

2.2	Sensores remotos	12
2.2.1	Plataformas de sensores remotos	13
2.2.2	Imágenes satelitales SAR	14
2.2.3	Otros tipos de sensores remotos	17
2.3	Herramientas de Machine learning	19
2.3.1	Principales modelos de machine learning	19
2.3.2	Redes neuronales profundas	19
2.4	Caracterización de la Demanda Sísmica y Fragilidad Estructural	24
2.4.1	Parámetros de demanda sísmica	24
2.4.2	Mapas de demanda	25
2.4.3	Curvas de fragilidad	27
3	Estado del arte	28
3.1	Detección de daños mediante imágenes satelitales	28
3.2	Método basado en umbrales	29
3.3	Métodos basados en machine learning	30
3.4	Métodos automáticos para identificación de daños	31
4	Metodología	33
4.1	Fundamentos del método	33
4.2	Descripción del método	34
4.3	Diagrama de Flujo del Método Propuesto	40
5	Evaluación experimental	42
5.1	Terremoto de Kumamoto-Japón 2016	42
5.1.1	Información disponible antes del evento	42
5.1.2	Información disponible después del evento	44
5.1.3	Resultados obtenidos	46
5.1.4	Discusión de resultados	48
5.2	Terremoto de Turquía-Siria 2023	49
5.2.1	Información disponible antes del evento	49
5.2.2	Información disponible después del evento	51
5.2.3	Resultados obtenidos	52
5.2.4	Discusión de resultados	55
6	Conclusiones y recomendaciones	57
	Referencias	60

Lista de tablas

1.1	Resumen de precisiones obtenidas para las diferentes curvas de fragilidad empleadas en el estudio. Adaptado de [1]	3
1.2	Resumen de precisiones obtenidas para las diferentes curvas de fragilidad empleadas en el estudio. Adaptado de [1]	6
2.1	Resumen de Parámetros de Demanda Sísmica	25
4.1	Base de datos que debe recopilarse antes de calibrar la función clasificadora y hacer predicciones. Se observa que la base de datos contiene las muestras etiquetadas y no etiquetadas	35
5.1	Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Kumamoto	44
5.2	Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Kumamoto	45
5.3	Comparación de predicciones hechas por el clasificador. Muestras colapsadas fueron etiquetadas por una fuente externa. Las muestras no colapsadas corresponden con área con muy bajo valor de PGV. C: colapsada, UC: no colapsada	47
5.4	User accuracy (UA), producer accuracy (PA), y F1 indicadores para las predicciones de la tabla 5.3	48
5.5	Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Turquía-Siria	50
5.6	Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Turquía-Siria	51
5.7	Comparación de las predicciones obtenidas por la función clasificadora con data previamente etiquetada. Las muestras colapsadas fueron etiquetadas por otro autor. Las muestras no colapsadas corresponden a muestras de ciudades con valores muy bajos de PGV. C: Colapsada, NC: No colapsada	55
5.8	User accuracy (UA), producer accuracy (PA), and F1 scores para las predicciones mostradas en la tabla 5.7	55

Lista de figuras

1.1	Esquema del procedimiento propuesto en la primera investigación. Adaptado de [1]	3
1.2	Diagramas de dispersión de las regiones clasificadas de las edificaciones en el espacio transformado para cada una de las funciones de fragilidad de referencia utilizadas. Fuente [1]	4
1.3	Funciones clasificadores no lineales en el espacio transformado para diferentes funciones de fragilidad. Fuente [2]	5
2.1	Meridianos y paralelos en una esfera. Adaptado de [3]	9
2.2	Sistema de coordenadas geodésicas WGS84. Adaptado de [4]	10
2.3	Esquema explicativo de proyecciones básicas más utilizadas. Adaptado de [5]	11
2.4	Universal Transverse Mercator (UTM). Adaptado de [6]	12
2.5	Esquema simplificado del proceso de remote sensing. Adaptado de [7]	13
2.6	Diagrama de plataformas usadas para poner en operación sensores remotos. Adaptado de [8]	14
2.7	Regiones que ocupan las bandas SAR dentro del espectro microondas. Adaptado de [9]	15
2.8	Esquema gráfico de una red neuronal profunda con 1 capa oculta. Adaptado de [10]	20
2.9	Función sigmoide. Adaptado de [11]	20
2.10	Función tangente hiperbólica. Adaptado de [11]	21
2.11	Función ReLU. Adaptado de [11]	21
2.12	Esquema del método de Descenso del gradiente. Adaptado de [12]	22
2.13	Mapa de demanda del terremoto de Pisco-Perú 2007. Fuente [13]	26
2.14	Curvas de fragilidad para edificaciones de albañilería confinada construídos de manera formal e informal en Lima considerando un nivel de daño de colapso, Perú. Adaptado de [14]	27
4.1	Patrón de distribución de edificaciones dañadas después de un terremoto. Elaboración propia	33
4.2	Esquema de creación de muestras no etiquetadas en base a inventario de edificaciones. En la imagen se puede observar que hay edificaciones que no estan inventariadas, lo cual indicaría una desactualización respecto al crecimiento urbano actual de la zona mostrada	35
4.3	Esquema de cálculo de las imágenes de coherencia pre y co-evento	36

4.4	Esquema de la arquitectura de la red neuronal diseñada para el método de identificación de edificaciones colapsadas. Elaboración propia.	37
4.5	Diagrama de rendimiento de los factores γ_R	39
4.6	Diagrama de la secuencia de procedimientos y línea de tiempo para la implementación del método propuesto. Elaboración propia.	41
5.1	Inventario de edificios empleado en el caso de estudio. Coordenadas del sistema japonés JGD2000 EPSG:2444. Elaboración propia	43
5.2	Funciones de fragilidad de edificaciones de madera con todo tipo de techos para el nivel de daño de colapso completo. Adaptado de [15].	44
5.3	Mapa de demanda de PGV empleada para el caso de estudio de Kumamoto. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].	45
5.4	Edificaciones etiquetadas como colapsadas empleadas para calibración de la red y evaluación de resultados. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].	46
5.5	Mapa de predicciones de colapso (marcadas en rojo) sobre el inventario de edificaciones, con coordenadas en WGS84 EPSG: 4326.	47
5.6	Inventario de edificios empleado en el caso de estudio. Coordenadas del sistema WGS84 EPSG:4326	49
5.7	Funciones de fragilidad de edificaciones de madera con todo tipo de techos para el nivel de daño de colapso completo. Adaptado de [17].	50
5.8	Mapa de demanda de PGV empleada para el caso de estudio de Turquía-Siria. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [18].	51
5.9	Edificaciones etiquetadas como colapsadas empleadas para calibración de la red y evaluación de resultados. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].	52
5.10	Diagrama de rendimiento de γ_R	53
5.11	Predicción de edificaciones colapsadas (en rojo) sobre el inventario de edificaciones analizado. Coordenadas en WGS84 EPSG: 4326. Píxeles rojos y blancos denotan respectivamente zonas identificadas como dañadas y no dañadas. Se muestra en cada subimagen un acercamiento a las ciudades de Adana, Aleppo, Antakya y Kahramanmaras en las subimágenes a,b,c,d respectivamente	54

Capítulo 1

Presentación del trabajo de investigación

1.1 Introducción

La aplicación de tecnologías de sensores remotos y técnicas de *machine learning* (ML) surge como una valiosa herramienta para la detección de áreas dañadas por desastres, las cuales pueden ser un eje principal para la toma de decisiones en lo que se refiere a la respuesta inmediata luego de un desastre de gran magnitud [19, 20]. Es particularmente interesante el uso de imágenes satelitales para evaluar daños en grandes áreas, gracias a su creciente disponibilidad y mejora constante en la calidad de resolución. Destaca el uso de imágenes de radar de apertura sintética (SAR), que, al generar las imágenes mediante ondas de radio, ofrecen resultados inafectados por las nubosidades, variaciones estacionales y la oscuridad nocturna [21, 22], características que sí limitan a las imágenes generadas a partir de la luz visible.

El uso combinado de imágenes satelitales y ML ha sido empleado previamente para la identificación de áreas dañadas después de un sismo [23, 24, 25]. La mayoría de los métodos se basan en la detección de cambios mediante la comparación de imágenes satelitales de una misma área. Sin embargo, el uso de metodologías de ML presenta complicaciones considerables. La principal dificultad radica en la necesidad de contar con una gran cantidad de información previamente clasificada para utilizar estas herramientas. Desafortunadamente, esta información solo está disponible varias semanas o incluso meses después del desastre, lo cual limita su aplicabilidad en situaciones de emergencia real [26]. Se ha propuesto el uso de información de desastres pasados como una solución aparente para superar esta limitación [27, 28]. Sin embargo, es importante destacar que la construcción de una base de datos de desastres pasados, que pueda ser utilizada para calibrar funciones de clasificación, implica considerar numerosas variables, como variaciones ambientales, diferencias geográficas, disparidades en la arquitectura urbana, entre otras. Además, no se garantiza la consistencia en la forma y rigurosidad con la que se registran los datos de los diferentes desastres sísmicos en todo el mundo.

En este documento se propone un nuevo método para la identificación de áreas dañadas de-

spués de un terremoto utilizando imágenes SAR, curvas de fragilidad, mapas de demanda y redes neuronales. Esta investigación es una continuación directa de dos estudios previos realizados por el Dr. Moya, los cuales fueron presentados en artículos científicos [1, 2]. El método propuesto en esta investigación mejora significativamente el enfoque previo al incorporar redes neuronales y la inclusión de un factor de regularización en la función de costo, lo cual permite incorporar información de edificios etiquetados como colapsados en el proceso de calibración de la red neuronal. El objetivo principal de esta investigación es seguir desarrollando y mejorando este método, con la esperanza de que en el futuro pueda implementarse en situaciones reales de desastre y contribuir a salvar vidas. En este sentido, el método se basa en la obtención de la menor cantidad posible de información adicional que deba ser recopilada después del evento sísmico analizado. Además, los casos de análisis presentados utilizan una cantidad de información mínima, lo cual simula las condiciones reales de operación en caso de utilizar el método en situaciones de emergencia.

1.2 Antecedentes

El presente trabajo es una continuación del trabajo realizado por Moya [1, 2] sobre un nuevo método planteado para la identificación rápida de áreas dañadas en casos de desastres como terremotos, tsunamis e inundaciones usando imágenes satelitales. El concepto fundamental es reemplazar la cuantiosa información previamente etiquetada que típicamente se usa para calibrar este tipo de clasificadores, por información sobre la fragilidad de las edificaciones, usando para ello mapas de la distribución de la demanda y funciones de fragilidad. La descripción del método y la evaluación de los resultados obtenidos de los casos de estudio analizados fueron publicados en los artículos científicos [1, 2].

1.2.1 Antecedente 1: An integrated method to extract collapsed buildings from satellite imagery, hazard distribution and fragility curves

En Moya [1] se planteó inicialmente un método sin plantear herramientas de optimización de técnicas de ML como el descenso del gradiente. El método consistía principalmente en transformar el espacio que definen las edificaciones del área de estudio a un espacio bidimensional determinado por 2 parámetros arbitrarios, para luego suponer una recta que divida a este nuevo espacio en dos grupos: uno de ellos se supone como edificaciones colapsadas y el otro como no colapsadas. Luego, se varía la posición de la recta hasta que la distribución espacial de las predicciones reproduzca una curva de fragilidad similar a la curva de fragilidad teórica/experimental disponible en la zona de estudio. La función de costo a optimizar es el error cuadrático medio entre la curva de fragilidad de referencia y la curva de generada a partir de la recta. En la figura (1.1) se muestra un esquema del procedimiento propuesto por el autor en la investigación en cuestión.

En esta investigación, se empleó como caso de estudio el Gran Tsunami del Este de Japón en 2011, para ello se emplearon imágenes satelitales obtenidas del TerraSAR-X, satélite que proporciona imágenes SAR de alta calidad y es gestionado por la Agencia Espacial Alemana (DLR).

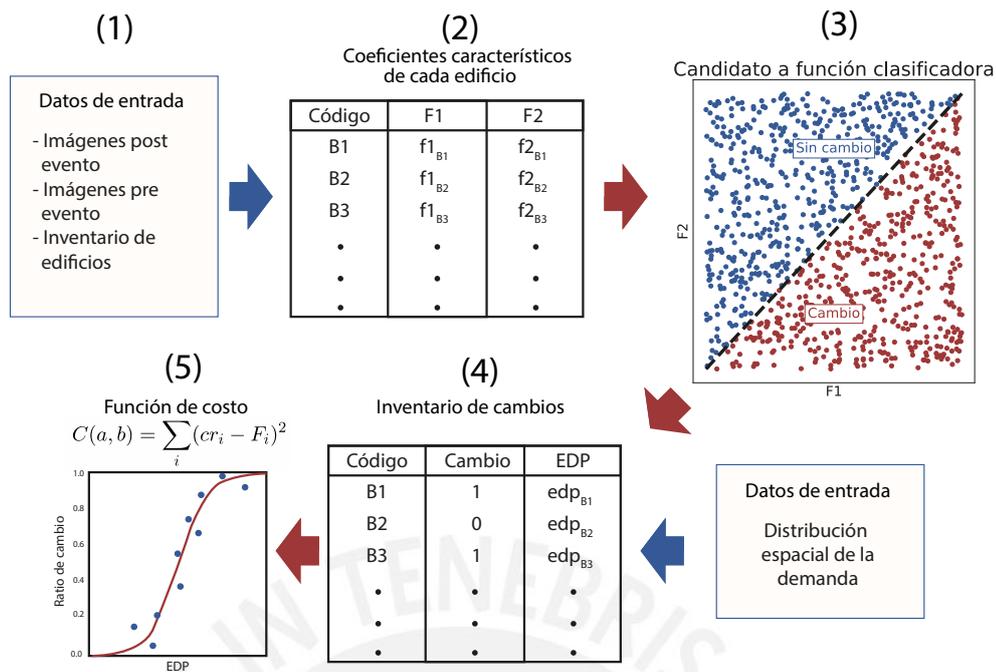


Figura 1.1: Esquema del procedimiento propuesto en la primera investigación. Adaptado de [1]

Se usaron imágenes con fechas de 21 de octubre del 2010 (pre-evento) y 13 de marzo del 2011 (post-evento). Así mismo, el parámetro de demanda es la altura de inundación y en consecuencia se utilizó en el análisis un mapa de distribución de la altura de inundación en el área de estudio. También, se emplearon hasta 4 funciones de fragilidad diferentes por separado para obtener los resultados de las áreas dañadas. En la figura 1.2 se muestran las regiones de edificaciones clasificadas como colapsadas y no colapsadas en el espacio transformado.

La evaluación de los resultados fue realizada a partir de datos de levantamiento de daños realizados en campo y facilitados por el Ministerio de Tierra, Infraestructura y Transporte de Japón. En la tabla 1.1 se presenta un resumen de resultados para cada función de fragilidad empleada en el estudio.

Tabla 1.1: Resumen de precisiones obtenidas para las diferentes curvas de fragilidad empleadas en el estudio. Adaptado de [1]

F. fragilidad de referencia	UA-C	UA-NC	PA-C	PA-NC	OA
Koshimura	61.2	96.4	92.7	76.9	81.4
Suppasri	69.8	92.3	81.8	86.1	84.9
Lineal	62.4	91.3	80.4	81.0	80.8
Logística	69.2	94.6	87.7	84.7	85.5

Este primer método obtuvo buenos resultados en lo referido a la precisión. No obstante, presenta algunas limitaciones importantes en cuanto a lo que se refiere a una versatilidad necesario para ser implementada en aplicaciones reales:

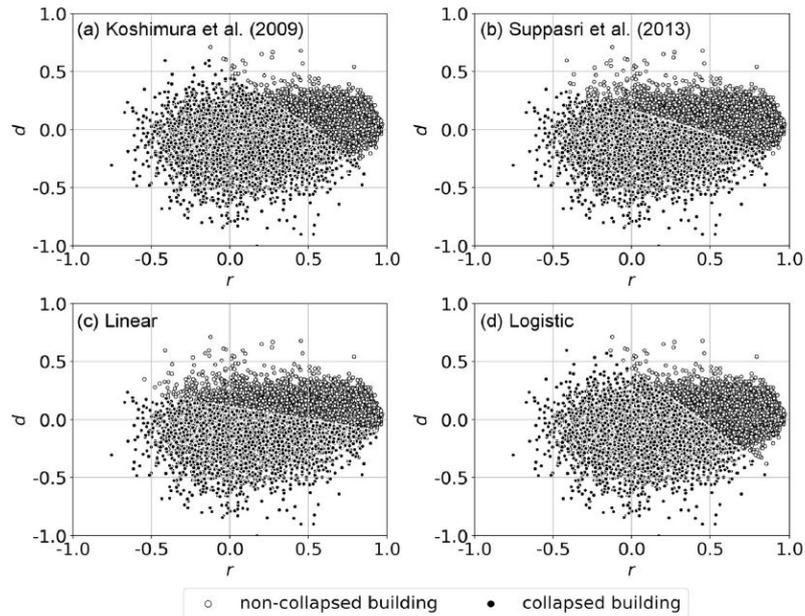


Figura 1.2: Diagramas de dispersión de las regiones clasificadas de las edificaciones en el espacio transformado para cada una de las funciones de fragilidad de referencia utilizadas. Fuente [1]

- El método está limitado a considerar únicamente 2 parámetros arbitrarios a partir de las imágenes satelitales.
- El ajuste de las rectas que dividen el espacio transformado en dos regiones se realizó mediante iteración de los parámetros que definen una recta en un espacio bidimensional: pendiente y término independiente.
- La función de costo empleada es el error cuadrático medio y la formulación de la misma hace que su diagrama al considerar diferentes posiciones de la recta sea escalonada y no suavizada, lo cual la imposibilita para aplicar métodos más sofisticados de optimización como el descenso del gradiente.

1.2.2 Antecedente 2: Novel Unsupervised Classification of Collapsed Buildings Using Satellite Imagery, Hazard Scenarios and Fragility Functions

En Moya [2] se mejoró el método previamente propuesto en [1] mediante la re-definición de la función clasificadora de un recta en un espacio bidimensional a un hiper plano para n dimensiones. De esta manera, es posible tomar en consideración n valores o características de cada edificación que sean calculadas a partir de las imágenes satelitales. Así mismo, se ha añadido también un operador logístico al final de la función clasificadora. Con esta última modificación se logran dos logros importantes:

- Se brindan capacidades no lineales a la función clasificadora.
- Se permite que los resultados de las predicciones tengan un rango continuo comprendido entre 0 y 1.

Otra mejora importante que se incorpora en esta investigación al método original, es el cambio de la función de costo mediante la cual se calibra la función clasificadora. Debido a que los resultados de la predicción son ahora continuos y limitados a un rango de entre 0 y 1. Se propone una nueva función de costo que permite utilizar métodos de optimización del ML como lo es el descenso del gradiente. La función de costo propuesta se origina a partir de la función de densidad de Bernoulli para eventos con solo 2 posibles resultados. En la ecuación 1.1 se muestra la función de costo utilizada en el estudio.

$$J(\theta) = -\frac{1}{N} \sum_{i=1}^N (p_i \cdot \ln(h_{\theta}(x_i)) + (1 - p_i) \cdot \ln(1 - h_{\theta}(x_i))) \quad (1.1)$$

En esta investigación se usó también como caso de estudio el Gran Terremoto y Tsunami en el Este de Japón del 2011 para aplicar la metodología propuesta. Para ello se usaron imágenes satelitales obtenidas del TerraSAR-X con fechas de 12 de octubre del 2010 (pre-evento) y 13 de marzo del 2011 (post-evento). Además, el parámetro de demanda es la altura de inundación debido a que fue el Tsunami el que produjo la mayor cantidad de daños a las edificaciones. Así mismo, en este estudio se emplearon 2 funciones de fragilidad diferentes para obtener la clasificación de edificaciones colapsadas. En la figura 1.3 se muestran los clasificadores calibrados y como dividen las muestras en el espacio transformado.

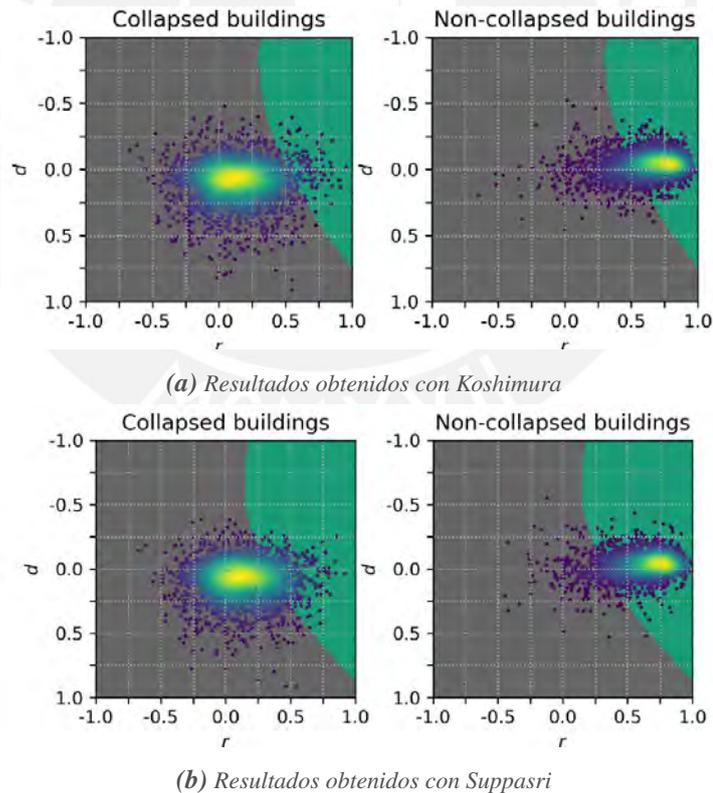


Figura 1.3: Funciones clasificadores no lineales en el espacio transformado para diferentes funciones de fragilidad. Fuente [2]

La evaluación de resultados fue realizada de forma análoga al estudio previo [1] usando la información proveída por el Ministerio de Tierra, Infraestructura y Transporte de Japón. En la

tabla (1.2) se presenta un resumen de las precisiones obtenidas en el presente estudio.

Tabla 1.2: Resumen de precisiones obtenidas para las diferentes curvas de fragilidad empleadas en el estudio. Adaptado de [1]

F. fragilidad de referencia	UA-C	UA-NC	PA-C	PA-NC	OA
Koshimura	60.7	96.5	93.0	76.4	81.1
Suppasri	75.4	92.6	81.7	89.5	87.3

Este segundo método, si bien no aumenta la precisión de los resultados con respecto al primer método, sí presenta mejoras sustanciales respecto a la metodología en sí pues transforma el método para caracterizar cada muestra con n variables (antes solo 2) y también cambia la función de costo a una función continua que puede ser optimizada usando métodos clásicos de ML como el descenso del gradiente.

El presente trabajo de investigación continua con la mejora del método descrito en [2] con el fin de que pueda mejorar su rendimiento y ser usado en mayor número de casos, y a que, como se vió durante el desarrollo de esta investigación. El método descrito en la segunda investigación, no es capaz de desempeñarse adecuadamente en casos donde la fragilidad de las edificaciones es bajas.

1.3 Justificación

El Perú se caracteriza por ser un país altamente sísmico debido a su ubicación en el Cinturón de Fuego del Pacífico, zona donde la Tierra libera más del 80% de la energía acumulada en su interior produciendo sismos y actividad volcánica [29]. La sismotectónica del Perú está determinada por una variedad de elementos estructurales que intervienen en los procesos de deformación a nivel regional y local. Uno de los principales factores es el proceso de subducción que ocurre en el borde occidental del país, resultado de la convergencia entre las placas de Nazca (oceánica) y Sudamérica (continental) [30].

A lo largo de su historia, el país ha experimentado numerosos terremotos devastadores. Uno de ellos fue el terremoto de Lima de 1940, con una magnitud estimada entre 8.0 y 9.0 en la escala de Mercalli modificada (MM), que se sintió en casi todo el país. Este terremoto provocó el colapso de numerosas edificaciones en Lima y Callao, cobrando la vida de 179 personas y dejando 3,500 heridos. Además, se estima que las pérdidas económicas ascendieron a 3.6 millones de soles oro. Otro evento catastrófico fue el terremoto de Ancash en 1970, con una magnitud de 7.9, que cobró la vida de 50,000 personas, dejó 20,000 desaparecidos y causó heridas a otras 150,000. La avalancha resultante del terremoto sepultó por completo el pueblo de Yungay, siendo responsable de la mayor cantidad de víctimas mortales [31].

A pesar de encontrarse en una región con alta actividad sísmica, en la actualidad, Perú atraviesa un periodo de silencio sísmico que ha durado décadas [32]. Este silencio sísmico implica una acu-

mulación constante de energía en las placas tectónicas, lo que podría desencadenar un terremoto de magnitud superior a 9.0Mw en el futuro si toda la energía se libera en un solo evento. Otro factor a considerar es la alta vulnerabilidad de las construcciones en el país. Aproximadamente el 70% de las viviendas son construidas de manera informal y sin asesoría técnica, lo que resulta en problemas de calidad y seguridad [33]. La falta de capacitación de la mano de obra se refleja en el asentamiento deficiente de ladrillos, dosificación incorrecta de materiales y ausencia de elementos estructurales adecuados. Estas viviendas son altamente vulnerables ante los sismos, lo cual se agrava en áreas de riesgo como los cerros de Lima.

Considerando el panorama sísmico en Perú, se han implementado diversas estrategias preventivas. Entre ellas, se ha promovido la educación en prevención sísmica y se han realizado simulacros de evacuación, con el propósito de preparar a la población para eventos de gran magnitud. En el ámbito tecnológico, el Ministerio de Transportes y Comunicaciones (MTC) ha desarrollado un sistema de alerta temprana denominado SISMATE, cuyo objetivo es proporcionar alertas a la población sobre la inminencia de un terremoto con al menos 10 segundos de anticipación [34]. No obstante, dada la posibilidad de un sismo de gran magnitud a corto plazo y la alta vulnerabilidad de las estructuras, es indispensable disponer de sistemas de respuesta eficaces post-sismo para proveer asistencia rápida y organizada a las áreas afectadas. Se debe tener en cuenta que, según el análisis de eventos sísmicos pasados en áreas urbanas, las primeras 48 horas después de un terremoto representan el período con mayor probabilidad de hallar supervivientes bajo los escombros. Pasado este lapso, la cantidad de sobrevivientes disminuye rápidamente, siendo poco común que individuos atrapados bajo edificios colapsados puedan sobrevivir más allá de 5 o 6 días después del evento [35].

En este contexto, la presente investigación surge como una respuesta a la necesidad de contar con herramientas eficaces tras la ocurrencia de un sismo de gran magnitud. Este método se presenta como una herramienta que podría ser fundamental para las entidades responsables de coordinar la distribución de ayuda y organizar equipos de búsqueda y rescate. Por ende, el objetivo principal de esta investigación se centra en lograr que el método sea capaz de operar con la menor cantidad de información disponible en períodos de tiempo muy reducidos, sin comprometer la obtención de resultados aceptables.

1.4 Hipótesis

En el campo del diagnóstico de zonas afectadas por sismos, se plantea que es posible emplear imágenes satelitales y redes neuronales para la identificación rápida de edificaciones colapsadas reemplazando la muestras etiquetadas por información sobre la fragilidad de las edificaciones para el entrenamiento de la función clasificadora.

1.5 Objetivos de la investigación

1.5.1 Objetivo general

El objetivo principal es desarrollar una metodología que implemente redes neuronales para la detección rápida de áreas dañadas después de un sismo de gran magnitud usando imágenes satelitales, mapas de demanda y curvas de fragilidad.

1.5.2 Objetivos específicos

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

- Revisar el estado del arte de imágenes satelitales, *Machine Learning* y análisis de riesgo con el fin de desarrollar adecuadamente la metodología.
- Proponer una metodología sobre la base de las investigaciones pasadas que implemente redes neuronales como función clasificadora.
- Elaborar un código informático lo más genérico posible que implemente la metodología propuesta.
- Probar la metodología propuesta y el código desarrollado para su aplicación en al menos 3 casos de estudio.
- Procesar las muestras con la función clasificadora calibrada para obtener los resultados de precisiones y elaborar mapas de daño y otros diagramas que sean útiles para interpretar los resultados

1.6 Alcance

El presente trabajo tiene como alcance desarrollar la tecnología propuesta y aplicarla a tres casos específicos para medir su eficacia. Más específicamente, se construirá una red neuronal capaz de identificar patrones, aislar unidades (píxeles, edificaciones, etc) y clasificarlas como colapsadas o no colapsadas. Así mismo, se usarán curvas de fragilidad y mapas de demanda teóricos o experimentales para la zona que será evaluada, los cuales serán obtenidos de investigaciones pasadas y que hayan estado disponibles antes de la ocurrencia del evento en cuestión. Por último, se elaborará un mapa de distribución del daño a partir de los resultados obtenidos y se compararán estos resultados con la data recolectada de levantamientos en campo de la zona de desastre evaluada para medir la precisión.

Capítulo 2

Marco teórico

2.1 Fundamentos geospaciales y sistemas de coordenadas

2.1.1 Sistemas de coordenadas geodésicas

Los sistemas de coordenadas geodésicas consideran el planeta como un elipsoide oblató, achatado en los polos y ensanchado en el ecuador. En este sistema, cualquier punto de la superficie terrestre es descrito mediante el uso de dos componentes angulares fundamentales: latitud y longitud. La latitud es el ángulo medido desde el plano ecuatorial terrestre y la longitud es el ángulo medido desde el meridiano de Greenwich hacia el punto de interés [36], tal y como se muestra en la figura (2.1). Los paralelos son círculos imaginarios que circundan la Tierra y son paralelos a la línea del ecuador, mientras que los meridianos son una serie de líneas que se intersectan en los polos y cruzan los paralelos con ángulos rectos [3]. A menudo, se complementa esta información con una tercera componente de ubicación que es la elevación, la cual se suele medir desde una superficie equipotencial aproximada al nivel medio del mar. El sistema de coordenadas geodésicas más utilizado alrededor del mundo es el WGS 84.

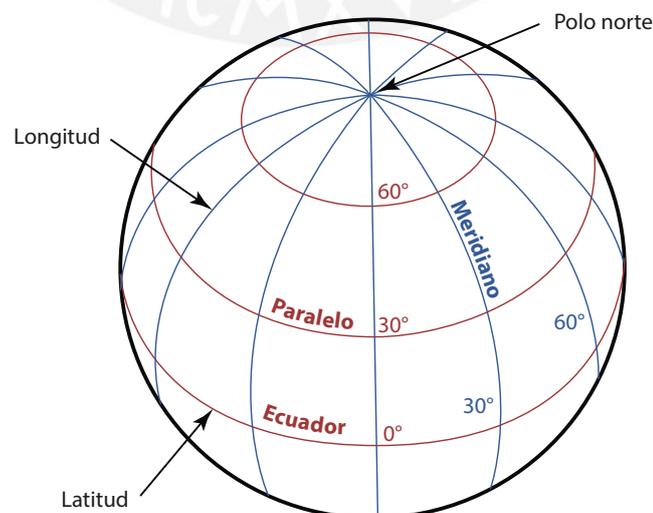


Figura 2.1: Meridianos y paralelos en una esfera. Adaptado de [3]

Aunque las coordenadas geodésicas ofrecen una representación precisa y coherente de la ubicación de puntos de interés en la superficie terrestre, su naturaleza curva implica errores considerables cuando se quieren medir distancia o áreas en zonas extensas de la superficie terrestre [3]. Por esta razón, en muchos contextos prácticos se recurren a sistemas de coordenadas proyectadas o cartográficas.

2.1.1.1 Sistema de coordenadas WGS 84

El sistema geodésico *World Geodetic System 1984* (WGS84) fue desarrollado en respuesta a la fragmentación de sistemas geodésicos locales, buscando un estándar global coherente. Esta iniciativa fue emprendida por el Departamento de Defensa de los Estados Unidos en la década de 1970. Una característica clave de WGS84 es su capacidad para integrar observaciones satelitales, lo que le otorga una precisión superior [4]. Su adopción masiva se vio fortalecida al ser el sistema base del Sistema de Posicionamiento Global (GPS) [37]. A pesar de su denominación, el WGS84 ha pasado por actualizaciones para mantenerse preciso y relevante en el contexto geodésico actual. En la figura (2.2), se muestra el sistema de coordenadas geodésicas WGS84.

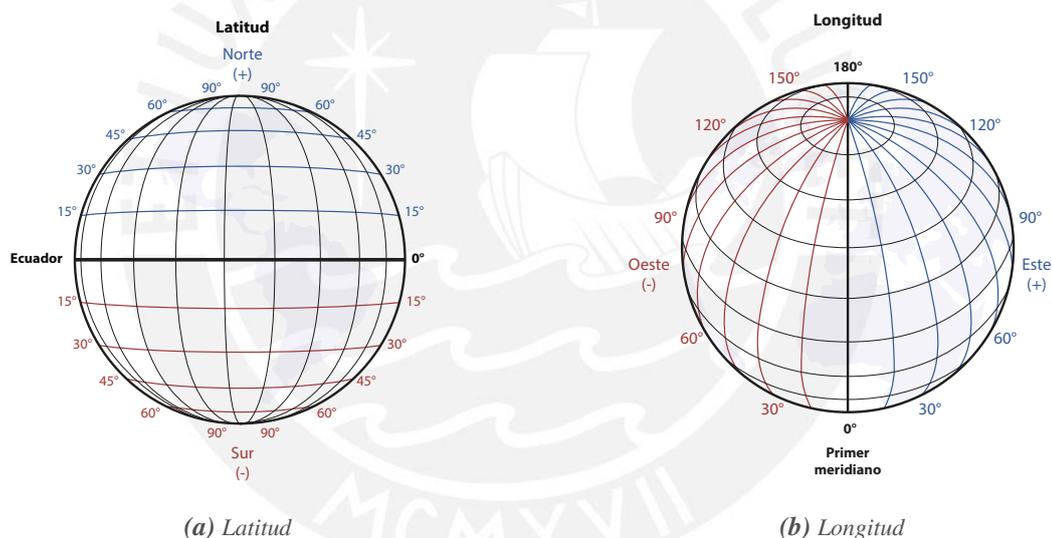


Figura 2.2: Sistema de coordenadas geodésicas WGS84. Adaptado de [4]

2.1.2 Sistemas de coordenadas proyectadas

El planeta Tierra, al ser un objeto tridimensional, no puede representarse en un plano bidimensional sin algún grado de distorsión. Esto fue demostrado en [38] por Carl Friedrich Gauss con el teorema *egregium*. Los sistemas de proyección son técnicas matemáticas que convierten la información de la superficie esférica (o elipsoide) de la Tierra a un plano. Estas transformaciones siempre conllevan a distorsiones en la representación de área, distancia, dirección y forma [39].

En la literatura se reconocen 3 grandes grupos de proyecciones básicas [40]:

- **Proyecciones cilíndricas:** La superficie terrestre se proyecta sobre un cilindro. Un ejemplo común es la proyección Mercator, que preserva las direcciones y es muy utilizada en

navegación, aunque distorsiona significativamente las áreas en latitudes altas.

- **Proyecciones cónicas:** Un cono se coloca sobre la esfera terrestre, y generalmente se utiliza para mapas de áreas de tamaño medio, como países o estados. Un buen ejemplo es la proyección conforme de Lambert, que se utiliza comúnmente para mapas aeronáuticos debido a sus propiedades conformes, donde los ángulos se mantienen.
- **Proyecciones azimutadas o planas:** Estas proyectan la superficie de la Tierra sobre un plano tangente. Se utilizan comúnmente para las regiones polares. Un ejemplo es la proyección estereográfica, que representa un punto de la superficie terrestre en la posición en la que un rayo de luz, desde ese punto, impactaría el plano

En la figura (2.3) se muestran los esquemas explicativos las proyecciones anteriormente descritas.

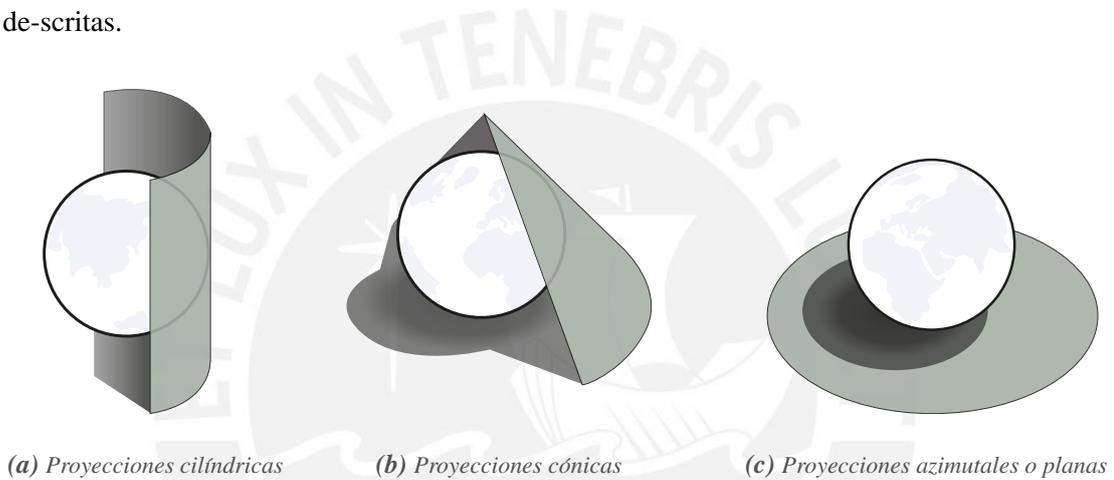


Figura 2.3: Esquema explicativo de proyecciones básicas más utilizadas. Adaptado de [5]

2.1.2.1 Universal Transverse Mercator (UTM)

El UTM (*Universal Transverse Mercator*) es un sistema global de proyección cartográfica y coordenadas basado en la proyección cilíndrica transversa de Mercator. Este sistema es uno de los más empleados en todo el mundo. Divide la Tierra en 60 zonas de 6 grados longitudinales, abarcando desde 80°S hasta 84°N, excluyendo las regiones polares cubiertas por el UPS. Las coordenadas se expresan en metros, con ajustes para asegurar valores positivos. Destaca por su precisión en áreas y distancias dentro de zonas específicas y su aplicación universal, facilitando la interoperabilidad de datos geoespaciales [39]. Sin embargo, no es ideal para regiones que cruzan múltiples zonas o áreas cercanas a los polos. Es esencial en campos como la ingeniería y la cartografía. En la figura (2.4), se muestra un esquema del sistema UTM.

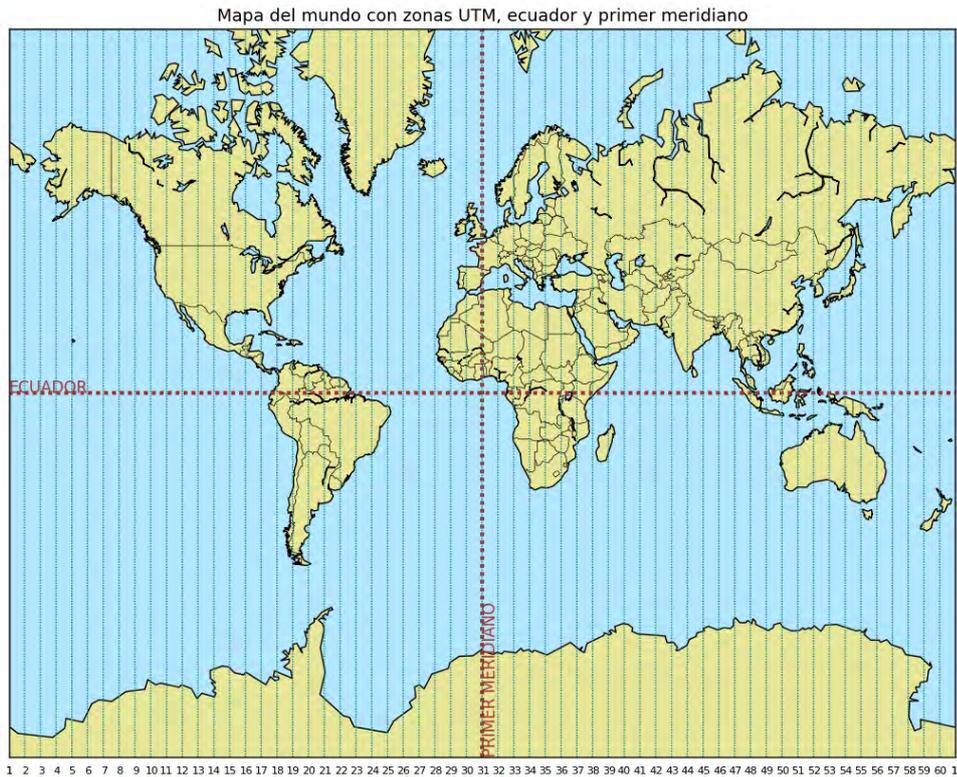


Figura 2.4: Universal Transverse Mercator (UTM). Adaptado de [6]

2.1.3 Transformación de coordenadas

La **transformación de coordenadas** en el ámbito geográfico se refiere al proceso matemático de convertir un conjunto de coordenadas de un sistema o marco de referencia a otro. Esta operación es esencial al manejar datos geoespaciales de distintas fuentes o al representar dichos datos en diferentes proyecciones o marcos de referencia [3]. En la actualidad, la transformación de coordenadas se realiza por medio del uso de programas GIS que usan sistemas como el EPSG para identificar y relizar estos procesos.

El EPSG (*European Petroleum Survey Group*) fue establecido por un comité científico en la industria petrolera y gasífera, evolucionando hasta ser un referente en definiciones geodésicas y proyecciones cartográficas. Su base de datos geodésica, que incluye sistemas de coordenadas, datum y elipsoides, es esencial para aplicaciones geoespaciales y GIS, facilitando la referencia precisa y transformaciones entre diferentes sistemas mediante códigos EPSG [41], como el *EPSG:4326* para WGS 84 y *EPSG:3857* para Web Mercator [42].

2.2 Sensores remotos

El científico Evelyn Pruitt, perteneciente a la Oficina de Investigación de la Marina de los Estados Unidos, introdujo el término *remote sensing* en los 60s. Observó que el concepto de *aerial photography* no abarcaba adecuadamente las avanzadas técnicas de captura de imágenes, en especial aquellas que utilizan radiación electromagnética fuera del espectro visible. *Remote sensing* es la

técnica de recolectar datos sobre objetos físicos a través de sensores sin tener contacto directo con ellos. Aunque originalmente sus aplicaciones estaban enfocadas en áreas como el uso de suelo, geología y vegetación, en la actualidad también se emplea para evaluar regiones afectadas por desastres naturales como tsunamis, inundaciones y terremotos [7]. En la figura (2.5), se muestra un esquema simplificado del proceso de *remote sensing*.

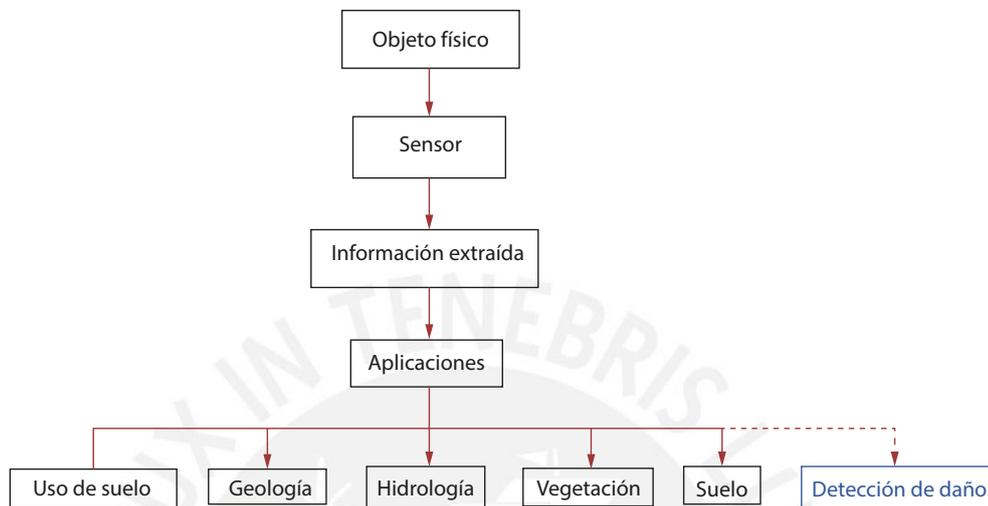


Figura 2.5: Esquema simplificado del proceso de remote sensing. Adaptado de [7]

El auge y evolución del remote sensing ha estado estrechamente ligado al desarrollo de la tecnología satelital y aeroespacial. Desde los primeros satélites de observación de la Tierra en la década de 1960, se ha avanzado hacia una era en la que se cuenta con una constelación de satélites que capturan imágenes con alta resolución, abarcando diferentes bandas del espectro electromagnético y proporcionando datos en tiempo casi real [43].

2.2.1 Plataformas de sensores remotos

Los sensores usados para recoger información sobre la Tierra pueden ser montados en una variedad de plataformas. Estas pueden ubicarse a diferentes altitudes, desde algunos pocos centímetros sobre el suelo hasta altitudes que sobrepasan la atmósfera terrestre, como en aeronaves y satélites. Aunque la mayoría de los sensores se instalan en plataformas móviles, hay casos donde se utilizan plataformas estacionarias. Un ejemplo de esto es el montaje de un espectrómetro en un polo terrestre para monitorear la variación de la reflectancia en un área específica a lo largo del día [44]. La elección de la plataforma está determinada por factores como la escala, resolución y el propósito específico del sensor. En la figura (2.6), se presenta un diagrama que ilustra las distintas plataformas utilizadas en sensores remotos de acuerdo a su altitud de operación. Las principales plataformas de despliegue de sensores se listan a continuación:

- Satélites
- Aeronaves (aviones y helicópteros)
- Drones o Vehículos Aéreos no Tripulados (UAVs)

- Globos Aerostáticos y Dirigibles
- Plataformas Terrestres y Móviles

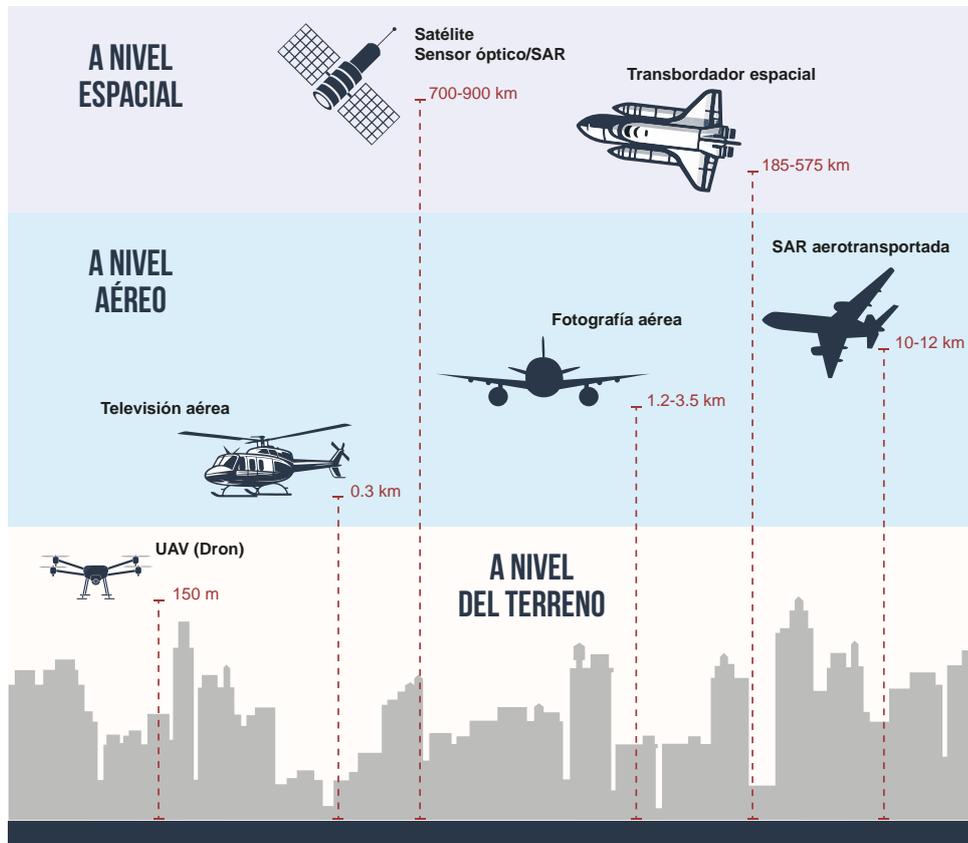


Figura 2.6: Diagrama de plataformas usadas para poner en operación sensores remotos. Adaptado de [8]

2.2.2 Imágenes satelitales SAR

La tecnología SAR, conocida por sus siglas en inglés como *Synthetic Aperture Radar*, es una técnica avanzada de *remote sensing* que utiliza señales de radar para producir imágenes de alta resolución de la superficie terrestre. A diferencia de otras técnicas de *remote sensing* que dependen de la luz solar, el SAR tiene la capacidad de emitir su propia señal, lo que le permite operar de día y de noche y en todas las condiciones climáticas [45]. Estas imágenes de radar se adquieren principalmente desde plataformas aéreas, como aviones, y satélites. Ejemplos notables son los satélites Sentinel-1 [46] de la Agencia Espacial Europea y el TerraSAR-X [47] operado por Alemania. La resolución de las imágenes SAR puede variar según el sensor y la plataforma, pero con la tecnología moderna, algunas alcanzan resoluciones de hasta un metro o incluso menos en sistemas comerciales.

Los sensores SAR tienen la ventaja distintiva de emitir su propia señal, lo que le permite funcionar de manera ininterrumpida, tanto de día como de noche, y bajo cualquier condición atmosférica. Las frecuencias utilizadas en SAR se categorizan en diferentes bandas, cada una con propiedades específicas de penetración y resolución. Estas bandas, que varían desde la *Banda P* con alta penetración pero baja resolución, hasta la *Banda Ka* con alta resolución pero baja pene-

tración, se seleccionan según el objetivo de la investigación. La versatilidad de las bandas SAR permite adaptar la teledetección a diversos estudios y aplicaciones, optimizando los resultados según las necesidades específicas del análisis. En la figura (2.7), se muestra un diagrama de las regiones que ocupan cada banda dentro del rango de microondas.

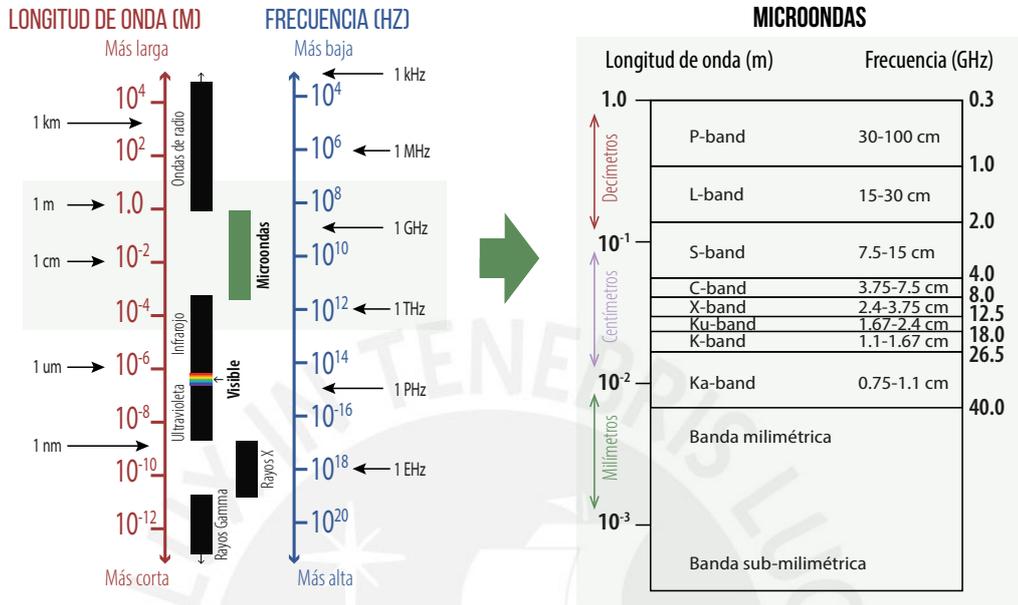


Figura 2.7: Regiones que ocupan las bandas SAR dentro del espectro microondas. Adaptado de [9]

Un aspecto importante al hablar de las imágenes SAR es la polarización. Esta se refiere a la orientación de la onda electromagnética emitida por el radar. Dependiendo de su polarización, ya sea horizontal o vertical, y cómo se recibe este reflejo, se pueden deducir diferentes características del objeto o superficie bajo estudio. Existen cuatro posibles combinaciones entre las polarizaciones transmitidas y recibidas [45]:

- **HH** - transmisión horizontal y recepción horizontal
- **VV** - transmisión vertical y recepción vertical
- **HV** - transmisión horizontal y recepción vertical
- **VH** - transmisión vertical y recepción horizontal

La elección de la polarización depende en gran medida de los objetivos de la observación y de las características específicas del área de interés. Por ejemplo, si el objetivo es estudiar la estructura de la vegetación, una combinación de polarizaciones que incluya HV o VH sería más adecuada. En cambio, para detectar derrames de petróleo en el océano, una polarización VV podría ser más eficaz.

Otro aspecto importante sobre las imágenes SAR son las trayectorias. Estas se refieren a la dirección en la que el satélite se desplaza respecto a la superficie terrestre durante la adquisición de datos. En el contexto de las imágenes SAR, las trayectorias más comunes son las llamadas ascending (ascendente) y descending (descendente)

- **Ascending (Ascendente):**

- El satélite se mueve de sur a norte.
- Observa el área desde el oeste, desplazando sombras y características hacia el este en la imagen.
- Ideal para estudiar fenómenos o estructuras de sur a norte.

- **Descending (Descendente):**

- El satélite se mueve de norte a sur.
- Observa el área desde el este, desplazando sombras y características hacia el oeste en la imagen.
- Útil para observar fenómenos de norte a sur o para obtener una perspectiva alterna de un área.

La elección entre pasada ascendente o descendente puede influir en la interpretación de las imágenes SAR. Algunas características o anomalías pueden ser más evidentes en una trayectoria que en otra.

2.2.2.1 Procesamiento de imágenes satelitales SAR

Antes de ser empleadas para propósitos específicos, las imágenes SAR requieren pasar por varias etapas de preprocesamiento. Durante este proceso, el uso de *rasters* cobra relevancia. Un *raster* se define como una estructura de datos en forma de matriz compuesta por celdas (también conocidas como píxeles) dispuestas en filas y columnas. Cada celda alberga un valor, el cual puede representar distintos tipos de información, como la intensidad del radar. En el ámbito de las imágenes SAR, los *rasters* son fundamentales debido a que proporcionan una estructura organizada para la representación, análisis y almacenamiento de la información contenida en las imágenes de radar.

A continuación, se presentan algunos de los procedimientos básicos que constituyen el preprocesamiento de una imagen SAR antes de su utilización en una tarea particular. Estos procedimientos son los recomendados específicamente para las imágenes adquiridas por Sentinel-1 [48, 49].

- **Aplicación del archivo de órbita:** Corrige la precisión de la órbita del satélite actualizando los vectores de estado de la órbita en los metadatos del producto SAR.
- **Eliminación de ruido térmico:** Reduce el ruido térmico en la imagen, particularmente en el canal de polarización cruzada, normalizando la señal de retrodispersión.
- **Eliminación de ruido de borde:** Corrige artefactos radiométricos en los bordes de la imagen, eliminando ruido de baja intensidad y datos no válidos en los bordes.
- **Calibración:** Convierte valores de píxeles digitales en retrodispersión SAR radiométricamente calibrada.

- **Filtrado de speckle:** Mejora la calidad de la imagen reduciendo el ruido granular conocido como speckle. Se pueden usar varios filtros dependiendo de las características deseadas.
- **Corrección de terreno Range Doppler:** Corrige distorsiones geométricas relacionadas con la topografía utilizando un modelo de elevación digital, geolocalizando la imagen en una geometría real.
- **Conversión a dB:** Transforma el coeficiente de retrodispersión a decibelios (dB) mediante una transformación logarítmica.

2.2.2.2 Coherencia interferométrica

La coherencia interferométrica en imágenes SAR es una medida cuantitativa que refleja la similitud o consistencia de fase entre dos imágenes SAR adquiridas en diferentes momentos. Esta se calcula como el valor absoluto del promedio de productos cruzados de estas imágenes, normalizado por el producto de sus magnitudes.

$$\gamma = \frac{\sum_{(i,j)} I_{i,j}^A I_{i,j}^{B*}}{\sqrt{\sum_{(i,j)} I_{i,j}^A I_{i,j}^{A*} I_{i,j}^B I_{i,j}^{B*}}} \quad (2.1)$$

La coherencia varía entre 0 y 1, donde un valor de 1.0 indica perfecta similitud entre las fases de las dos imágenes, y un valor cercano a 0 sugiere una baja similitud o una alta variabilidad en la respuesta del radar entre las dos adquisiciones. Una coherencia alta es comúnmente observada en áreas estables como terrenos desnudos o cuerpos de agua, mientras que una baja coherencia puede resultar de cambios en la superficie o de interferencias, como en áreas con vegetación densa o zonas urbanas en construcción.

La coherencia interferométrica es una herramienta esencial en la interferometría SAR (InSAR), técnica que permite estimar cambios topográficos y deformaciones en la superficie terrestre. La interpretación de la coherencia es crucial en estudios de desplazamiento y subsistencia, así como en la evaluación de la calidad y fiabilidad de los resultados interferométricos.

2.2.3 Otros tipos de sensores remotos

2.2.3.1 Satélites Multiespectrales

Los satélites multiespectrales son herramientas diseñadas para capturar información de la Tierra en diversas bandas del espectro electromagnético, lo que les brinda la capacidad de observar variados aspectos, desde la vegetación hasta la atmósfera. Estos satélites tienen sensores que detectan radiación en diferentes longitudes de onda, desde el ultravioleta hasta el infrarrojo térmico. Sus aplicaciones incluyen monitoreo de vegetación, estudios ambientales, predicciones meteorológicas, agricultura de precisión, cartografía, planificación urbana y observación de desastres naturales. Por ejemplo, en [50], se usó imágenes multiespectrales en conjunto con redes neuronales convolucionales para detectar y caracterizar retrocesos de deshielo en el Ártico.

Dos programas prominentes de satélites multiespectrales son **Landsat** y **Sentinel-2**. Landsat, una colaboración entre la NASA y el USGS, se lanzó por primera vez en la década de 1970 y ha proporcionado datos valiosos para aplicaciones como la monitorización de cambios en el uso del suelo y la detección de incendios [51]. Por otro lado, Sentinel-2 es una iniciativa de la Agencia Espacial Europea (ESA) y forma parte del programa Copernicus de la Unión Europea, lanzado en la década de 2010, centrándose en aplicaciones como la agricultura de precisión y la gestión forestal [52]. Ambos programas ofrecen datos de acceso gratuito para investigadores y público en general.

2.2.3.2 Satélites Hiperespectrales

Los satélites hiperespectrales capturan imágenes y datos de alta resolución en una extensa cantidad de bandas espectrales, superando a los satélites multiespectrales que tienen un rango limitado. Estas bandas cercanas entre sí permiten distinguir con gran precisión las diferencias en la reflectancia espectral de la Tierra. Gracias a su alta resolución espectral, estos satélites identifican con exactitud materiales y sustancias en la Tierra, sirviendo en áreas como monitorización ambiental, agricultura de precisión, estudios atmosféricos y geología. Por ejemplo, en [53], se usaron imágenes hiperespectrales para medir parámetros de calidad del agua no ópticamente activos como el oxígeno disuelto (DO) y el fósforo total (TP).

Uno de los satélites que usa tecnología hiperespectral es AVIRIS (Airborne Visible/Infrared Imaging Spectrometer). Diseñado para vuelos aéreos, AVIRIS captura datos en el espectro visible e infrarrojo cercano. Con una resolución espectral que abarca 224 bandas, este instrumento mide con precisión la radiación reflejada o emitida por la Tierra [54]. Aunque tiene una resolución espacial más baja que los satélites en órbita, AVIRIS sigue siendo valioso en aplicaciones como geología, agricultura, monitorización ambiental y más. Se ha utilizado en aviones y drones, siendo esencial para quienes requieren datos hiperespectrales de alta calidad.

2.2.3.3 Lidar (Light Detection and Ranging)

Lidar es una tecnología que usa pulsos de luz láser para determinar distancias e información tridimensional sobre la Tierra y la atmósfera. Se basa en medir el tiempo que la luz tarda en reflejarse de un objeto a un receptor. Esta técnica tiene múltiples aplicaciones: desde topografía, detección de vegetación y monitorización atmosférica hasta navegación de vehículos autónomos y arqueología. Por ejemplo, en [55], se propuso un nuevo método para extraer instantáneamente las líneas de costa usando imágenes LIDAR.

Un proyecto específico que utiliza Lidar es el GEDI (Global Ecosystem Dynamics Investigation) de la NASA, alojado en la Estación Espacial Internacional (EEI). GEDI se centra en el estudio tridimensional de bosques y ecosistemas terrestres globales. Mide con precisión la altura y estructura de la vegetación, siendo vital para entender la dinámica de ecosistemas, la biomasa forestal y los cambios en la cobertura forestal [56].

2.3 Herramientas de Machine learning

2.3.1 Principales modelos de machine learning

Un modelo de machine learning es una estructura matemática capaz de identificar patrones, realizar predicciones y/o tomar decisiones basadas en datos. Su habilidad para aprender de un conjunto de datos y mejorar con la experiencia lo distingue de un algoritmo tradicional, que sigue instrucciones y permanece inalterable independientemente de la información adicional.

La elección de un modelo de machine learning no sigue una regla única, sino que depende de la naturaleza del problema a resolver. Por ejemplo, mientras que los modelos lineales pueden ser suficientes para datos menos complejos y más pequeños, los retos que involucran grandes volúmenes de información o patrones complejos pueden beneficiarse de modelos más sofisticados, como las redes neuronales. A continuación se enumeran algunos de los principales modelos de machine learning:

- **Regresión Lineal:** Es uno de los modelos más simples y ampliamente utilizados en ML. Se utiliza para predecir valores numéricos continuos basados en la relación lineal entre variables independientes y la variable dependiente.
- **Regresión Logística:** A pesar de su nombre, es un modelo de clasificación que predice la probabilidad de que una instancia pertenezca a una clase en lugar de otra, especialmente útil en problemas de clasificación binaria.
- **Máquinas de Soporte Vectorial (SVM):** Diseñadas para la clasificación, las SVM pueden también ser adaptadas para regresiones. Su objetivo es encontrar el margen máximo entre las clases de datos, lo que las hace efectivas en espacios de alta dimensionalidad.
- **Redes Neuronales Artificiales (ANN):** Comprenden capas de neuronas interconectadas que trabajan conjuntamente para aprender de los datos. Las ANN son adaptables a una amplia gama de problemas, desde clasificación hasta regresión.

2.3.2 Redes neuronales profundas

Las redes neuronales artificiales son sistemas que imitan cómo las neuronas del cerebro interactúan entre sí, permitiendo realizar cálculos complejos. Estos modelos computacionales han demostrado ser altamente efectivos en múltiples tareas de aprendizaje automático desde su desarrollo inicial en el siglo XX [10]. Estas funcionan conectando simples operaciones matemáticas, como sumas ponderadas, con transformaciones no lineales llamadas funciones de activación. Estos cálculos se organizan en capas sucesivas, donde cada capa toma la salida de la anterior, la procesa y la pasa a la siguiente. Los parámetros de estas sumas ponderadas son los que se varían durante el entrenamiento para obtener el resultado deseado. En la figura (2.8), se muestra la arquitectura de una red neuronal profunda.

Las redes neuronales profundas son una extensión de las redes neuronales tradicionales que se distinguen por incluir, además de una capa de entrada y una de salida, múltiples capas intermedias conocidas como capas ocultas. Estas capas intermedias facilitan el aprendizaje jerárquico de características en diversos niveles de abstracción.

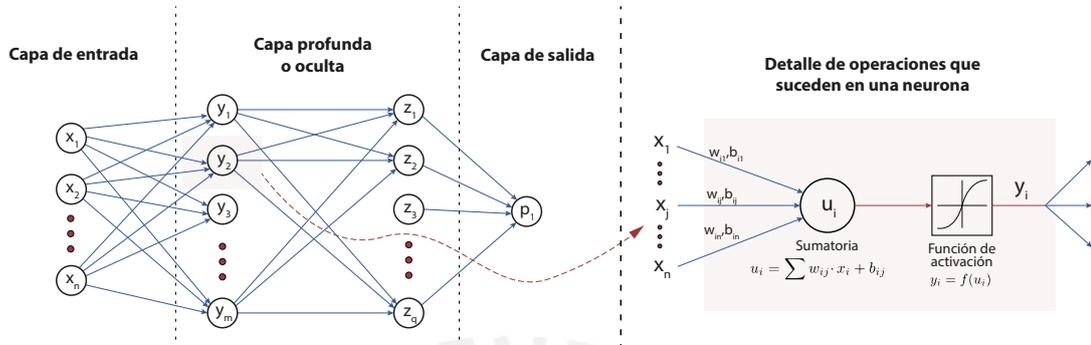


Figura 2.8: Esquema gráfico de una red neuronal profunda con 1 capa oculta. Adaptado de [10]

2.3.2.1 Funciones de activación

Las funciones de activación en las redes neuronales introducen no linealidad en el modelo. Estas funciones determinan la salida de una neurona basándose en sus entradas, lo que permite que la red maneje datos complejos y relaciones no lineales entre características. Esta no linealidad es esencial, ya que sin ella, incluso múltiples capas de neuronas se reducirían a una única capa lineal, incapaz de aprender de la complejidad inherente a muchos conjuntos de datos [57].

Las funciones de activación más usadas son las siguientes:

- Sigmoide: Esta función toma cualquier valor como entrada y lo devuelve en un rango entre 0 y 1. Es especialmente útil para modelos que requieren una salida en forma de probabilidad.

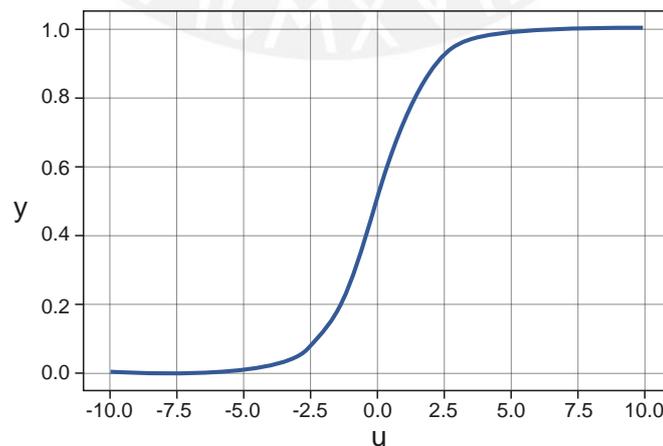


Figura 2.9: Función sigmoide. Adaptado de [11]

- Tanh (Tangente hiperbólica): Similar a la función sigmoide, pero devuelve valores en un

rango entre -1 y 1. Ofrece una salida centrada en cero, lo que la hace más eficiente en algunos casos.

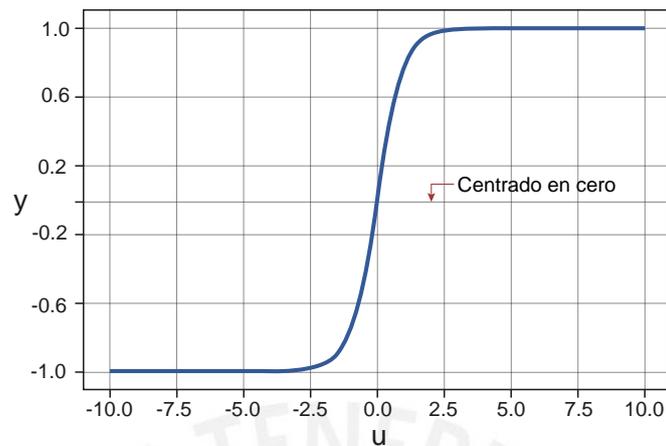


Figura 2.10: Función tangente hiperbólica. Adaptado de [11]

- ReLU (Rectified Linear Unit): Es una función simple que devuelve el valor si es positivo, y cero en caso contrario. Se ha convertido en la función de activación más popular en redes neuronales profundas debido a su eficiencia computacional.

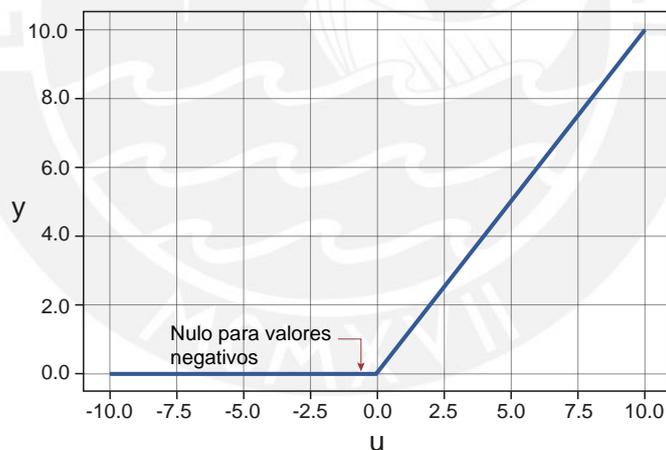


Figura 2.11: Función ReLU. Adaptado de [11]

La elección de la función de activación es clave en el diseño de redes neuronales, ya que cada función tiene sus pros y contras y puede influir significativamente en el rendimiento del modelo para tareas concretas. La investigación activa en este campo busca continuamente nuevas funciones que mejoren este rendimiento [58].

2.3.2.2 Funciones de costo o de pérdida

Las funciones de costo o pérdida en redes neuronales son herramientas esenciales que cuantifican el error entre las predicciones y los valores reales durante el entrenamiento. Su propósito es

guiar el proceso de aprendizaje hacia la minimización de estos errores. Sin embargo, no todos los errores son iguales, y las funciones de costo pueden ser diseñadas para reflejar las consecuencias desiguales de distintos tipos de errores, como es crítico en aplicaciones como el diagnóstico médico. En esencia, la función de costo evalúa la precisión de un modelo y su elección adecuada es crucial, pues afecta directamente a la eficacia del modelo en aprender y realizar predicciones acertadas [57].

2.3.2.3 Métodos de optimización: Descenso del gradiente

La optimización en redes neuronales es esencial para el ajuste eficiente de los parámetros del modelo. Un enfoque predominante para tal propósito es el método del gradiente. Básicamente, este método emplea información del gradiente para actualizar los pesos del modelo en dirección del gradiente negativo, lo que se denomina “descenso de gradiente”. Cada actualización consideraba un “ratio de aprendizaje”, que determina el tamaño del paso tomado en esa dirección [57]. En términos más técnicos, si consideramos w como el vector de pesos, la actualización en cada iteración es:

$$w_{(\tau+1)} = w_{(\tau)} - \eta \nabla E(w_{(\tau)}) \quad (2.2)$$

donde η es el ratio de aprendizaje y ∇E representa el gradiente de la función de error respecto a w . No obstante, es importante señalar que cada actualización requiere la evaluación del gradiente en relación con el conjunto de entrenamiento completo. Existe además, una variante del método conocida como “descenso de gradiente estocástico”, este actualiza los pesos basándose en un solo grupo de datos a la vez, siendo especialmente útil para conjuntos de datos grandes. En la figura (2.12), se muestra un esquema simplificado del método de descenso del gradiente.

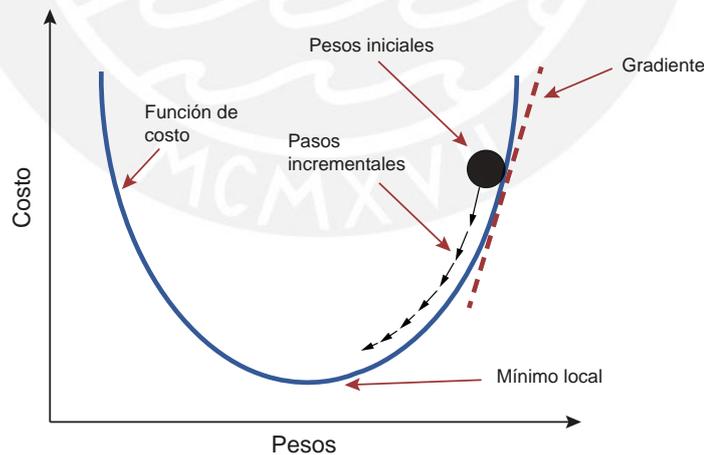


Figura 2.12: Esquema del método de Descenso del gradiente. Adaptado de [12]

2.3.2.4 Backpropagation

El algoritmo de *backpropagation*, inicialmente descrito en [59], es una técnica esencial en redes neuronales para optimizar los parámetros del modelo. Esta técnica se basa en el método del gradiente y es fundamentalmente un procedimiento iterativo que ajusta los pesos en dirección del

gradiente negativo.

El proceso comienza con una propagación hacia adelante en la red neuronal, donde la entrada se pasa a través de cada capa de la red hasta obtener una salida. Luego, se calcula el error entre la salida obtenida y la salida deseada mediante el uso de una función de costo. Este error se propaga hacia atrás, desde la última capa hasta la primera, ajustando los pesos en función de su contribución al error. El *backpropagation*, en esencia, calcula la derivada de una función de costo con respecto a cada parámetro utilizando la regla de la cadena del cálculo, permitiendo así actualizaciones eficientes de los pesos [58].

El algoritmo de *backpropagation* es descrito por las siguientes cuatro ecuaciones [60]:

1. Error en la capa de salida (δ^L):

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad (2.3)$$

Aquí, $\nabla_a C$ es el gradiente del costo respecto a la activación, σ' es la derivada de la función de activación, y z^L son las entradas a las neuronas en la capa de salida antes de la activación.

2. Error en las capas ocultas (δ^l):

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad (2.4)$$

En esta ecuación, $(w^{l+1})^T$ es la transpuesta de la matriz de pesos de la capa $l + 1$, y δ^{l+1} es el error de la capa siguiente.

3. Gradiente del sesgo ($\frac{\partial C}{\partial b_j^l}$):

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad (2.5)$$

Esta es la derivada parcial del costo respecto al sesgo b_j^l de la neurona j en la capa l , y es simplemente el error δ_j^l de esa neurona.

4. Gradiente del peso ($\frac{\partial C}{\partial w_{jk}^l}$):

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad (2.6)$$

Aquí, a_k^{l-1} es la activación de la neurona k en la capa $l - 1$, y δ_j^l es el error de la neurona j en la capa l .

2.3.2.5 Hiper parámetros de una red neuronal

Los hiperparámetros en una red neuronal son configuraciones que se establecen antes del proceso de entrenamiento y no se modifican durante el mismo. Estos pueden incluir la tasa de aprendizaje, la cantidad de capas y neuronas en la red, el número de épocas de entrenamiento, y la elección de la función de activación, entre otros. A diferencia de los parámetros del modelo, que se aprenden de los datos durante el entrenamiento, los hiperparámetros se utilizan para controlar el comportamiento del algoritmo de aprendizaje y tienen un impacto significativo en el rendimiento del modelo entrenado [58].

2.3.2.6 Términos de regularización

La regularización en redes neuronales es una técnica empleada para prevenir el sobreajuste (*overfitting*), una condición en la cual el modelo aprende el ruido de los datos de entrenamiento hasta el punto de perder capacidad de generalización [60]. Se introduce una penalización en la función de coste del modelo para controlar la magnitud de los parámetros, limitando de este modo la complejidad del modelo.

Matemáticamente, la regularización se añade como un término adicional $R(\theta)$ en la función de coste J que se minimiza durante el entrenamiento [10]:

$$J(\theta) = \text{Coste}(\theta) + \lambda R(\theta) \quad (2.7)$$

donde θ son los parámetros del modelo, λ es el coeficiente de regularización que ajusta la intensidad de la penalización, y $R(\theta)$ es una norma de los parámetros como la norma L1 o L2. La norma L2, también conocida como regularización de Tikhonov o Ridge, penaliza la suma de los cuadrados de los parámetros, y la norma L1, o Lasso, penaliza la suma de los valores absolutos de los parámetros.

Al introducir la regularización, se busca mejorar la capacidad del modelo para generalizar, aunque pueda sacrificar algo de precisión en los datos de entrenamiento. Sin embargo, un exceso de regularización puede llevar a un modelo demasiado simplificado que no captura adecuadamente la estructura de los datos, fenómeno conocido como infraajuste (*underfitting*).

2.4 Caracterización de la Demanda Sísmica y Fragilidad Estructural

2.4.1 Parámetros de demanda sísmica

Los parámetros de demanda sísmica son indicadores cuantitativos del movimiento del suelo durante un terremoto. Estos parámetros se utilizan para desarrollar curvas de fragilidad y modelos de respuesta estructural que predicen el rendimiento de las estructuras bajo cargas sísmicas específicas. Estas herramientas son fundamentales en la evaluación del riesgo sísmico y en la toma de decisiones para la mitigación de riesgos y la planificación de la respuesta ante desastres [61]. En la tabla (2.1), se muestran los parámetros de demanda existentes, así como su significado y uso.

Tabla 2.1: Resumen de Parámetros de Demanda Sísmica

Parámetro	Significado	Uso
PGA	Aceleración Pico del Suelo	Diseño sísmico de estructuras bajas; mapas de peligro sísmico [62].
PGV	Velocidad Pico del Suelo	Estimación de daños en estructuras altas; evaluación de la deformación estructural [63].
PGD	Desplazamiento Pico del Suelo	Evaluación de efectos a largo plazo en estructuras extensas como puentes y presas [64].

2.4.2 Mapas de demanda

Los mapas de demanda sísmica generados a partir de un evento sísmico ya ocurrido, a menudo denominados *shake maps*, representan la distribución espacial de la intensidad del movimiento del suelo durante un terremoto específico. Estos mapas son utilizados para evaluar el impacto inmediato de un terremoto, facilitando la respuesta de emergencia y la evaluación rápida de daños en infraestructuras. Son creados utilizando datos de estaciones sismológicas, observaciones de intensidades del terremoto y modelos de atenuación del movimiento del suelo [65]

Por otro lado, existen también los mapas de peligro sísmico o *ground motion maps* generados por métodos probabilísticos, como el Análisis de Peligro Sísmico Probabilístico (PSHA), estiman la probabilidad de exceder ciertos niveles de movimiento del suelo dentro de un período de tiempo dado y en una ubicación particular. Estos mapas se basan en la historia sísmica de una región, la sismotectónica y la geología local [61]. Son fundamentales para el diseño sísmico a largo plazo y la planificación urbana, ya que proporcionan estimaciones del riesgo sísmico basadas en la probabilidad. En la figura (2.13) se muestra un ejemplo de un mapa de demanda de un evento en específico.

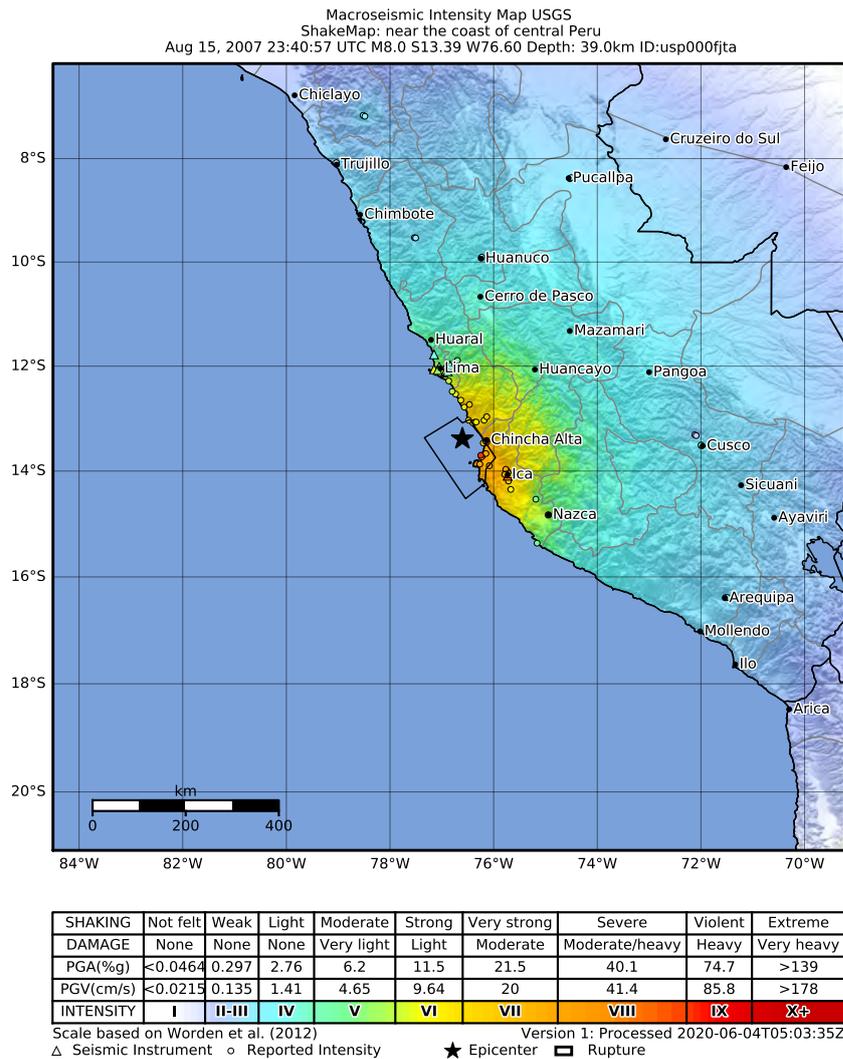


Figura 2.13: Mapa de demanda del terremoto de Pisco-Perú 2007. Fuente [13]

Los mapas de demanda sísmica en la actualidad se generan mediante sistemas avanzados que integran registros sísmicos observados y modelos geotécnicos del subsuelo para producir estimaciones rápidas y detalladas del movimiento del suelo. Un ejemplo de tal sistema es *QuiQuake*, desarrollado por el *Geological Survey of Japan*, AIST [66]. Este sistema emplea un enfoque automatizado para generar mapas de movimiento fuerte del suelo, que incluyen datos como la aceleración máxima del suelo (PGA), la velocidad máxima del suelo (PGV) y la intensidad sísmica instrumental, tras un evento sísmico.

El proceso comienza con la activación automática del sistema inmediatamente después de un terremoto. *QuiQuake* utiliza un mapa predefinido de capacidad de amplificación basado en el Mapa de Clasificación Geomorfológica de Ingeniería de Japón, que incorpora datos del promedio de velocidad de onda cortante (V_{s30}) para modelar las condiciones geotécnicas que afectan la amplificación del movimiento sísmico. Esta información geomorfológica se combina con registros sísmicos en tiempo real recogidos de una red de estaciones de observación para interpolar los valores de movimiento del suelo en toda la región afectada. El sistema lleva a cabo una serie de

cálculos de interpolación espacial, teniendo en cuenta la atenuación característica del movimiento sísmico con la distancia a la fuente, y aplica técnicas de cómputo paralelo para acelerar este proceso. La capacidad de generar estos mapas rápidamente es crucial para la evaluación de los efectos del terremoto y la respuesta a emergencias.

2.4.3 Curvas de fragilidad

Las curvas o funciones de fragilidad son modelos matemáticos que describen la probabilidad de que un componente estructural o un sistema falle al alcanzar un estado límite predefinido cuando está sujeto a un rango de acción sísmica [67]. Estas curvas se definen en función de una medida de intensidad del movimiento del suelo como el PGA, PGV o PGD y son fundamentales para evaluar la vulnerabilidad de edificios, líneas vitales, redes de transporte y facilidades críticas ante terremotos y para predecir los daños potenciales que podrían resultar de estos eventos [68]. La fragilidad se refiere a la probabilidad de un resultado indeseable como una función de excitación, como la que se experimentaría durante un terremoto [69].

Existen diversas maneras de elaborar curvas de fragilidad. Los métodos empíricos generalmente se basan en informes de daños de terremotos anteriores para desarrollar las curvas de fragilidad, como en el caso del terremoto de Maule de 8.8 Mw [70]. Los métodos analíticos, por otro lado, utilizan simulaciones numéricas de la respuesta sísmica utilizando componentes de movimiento del suelo de estaciones que registraron el terremoto. En la figura (2.14), se muestra un ejemplo de curvas de fragilidad obtenidos de manera analítica para edificaciones de albañilería confinada en Lima, Perú.

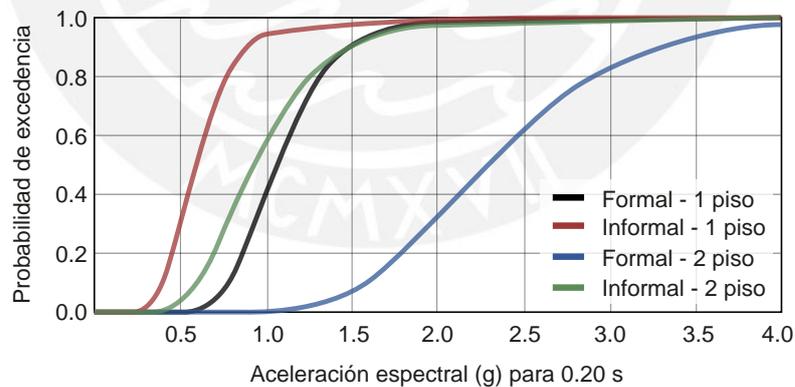


Figura 2.14: Curvas de fragilidad para edificaciones de albañilería confinada construidos de manera formal e infor-mal en Lima considerando un nivel de daño de colapso, Perú. Adaptado de [14]

Capítulo 3

Estado del arte

3.1 Detección de daños mediante imágenes satelitales

La detección de daños mediante imágenes satelitales es un proceso que usualmente requiere del análisis de imágenes capturadas antes y después de eventos disruptivos. Esta técnica se basa en la identificación de cambios estructurales y anomalías entre las imágenes de referencia que puedan indicar daños en infraestructuras. Se emplean principalmente imágenes de alta resolución espacial que permiten discernir detalles necesarios para la evaluación precisa del estado de las estructuras. Los daños que se pueden analizar con estas imágenes incluyen los causados por terremotos, tsunamis, inundaciones y conflictos armados.

El uso de imágenes satelitales proporciona una fuente de información valiosa para la evaluación de daños en áreas afectadas por desastres. No obstante, la cantidad de datos a inspeccionar hace que la evaluación manual sea impracticable. Por lo tanto, para abordar este problema frecuentemente se usan modelos de aprendizaje de ML para la detección de daños a gran escala [71].

El análisis detallado de daños estructurales a consecuencia de desastres naturales mediante imágenes satelitales constituye una de las contribuciones más significativas de la teledetección a la ingeniería civil y la gestión de emergencias. El avance tecnológico en este campo ha permitido desarrollar metodologías que facilitan la evaluación rápida y precisa de los daños en infraestructuras. Un ejemplo de ello es la investigación llevada a cabo por Yamazaki et al. [72] tras el terremoto de Bam en Irán puso de manifiesto la utilidad de las imágenes de alta resolución del satélite QuickBird. La comparación visual de imágenes pre y post-desastre, fundamentada en la Escala Macrosísmica Europea (EMS-98), permitió la clasificación detallada de 12,063 edificaciones, subrayando la eficacia de estas tecnologías para la detección de daños.

La capacidad de las imágenes satelitales para cubrir amplias zonas geográficas en un solo momento proporciona una ventaja única en comparación con otras técnicas de observación, permitiendo así una evaluación extensiva y sistemática de los daños. Esta ventaja se ve complementada por el uso de imágenes SAR en la evaluación de desastres, como se observa en el estudio de

Wen Liu y su equipo [73] sobre el terremoto y tsunami de Tohoku-oki en 2011. La metodología aplicada en este caso se centró en la evaluación de la retrodispersión de imágenes SAR de alta resolución para la identificación de áreas inundadas y daños en construcciones, alcanzando una precisión general de más del 90% en la clasificación de daños .

El reconocimiento rápido de daños en edificaciones es vital para la respuesta inmediata tras un desastre. EN 2020, Moya [74] introdujo un procedimiento basado en la correlación de fase y modelos estadísticos dispersos para detectar cambios en áreas urbanas afectadas por el terremoto-tsunami de Sulewesi en Indonesia. Este enfoque logró reproducir con eficiencia el 85% del inventario de daños, demostrando así su utilidad en la evaluación rápida de daños y la relevancia de una respuesta temprana .

Yanbing Bai y su equipo [75] avanzaron en el uso de redes neuronales convolucionales profundas para el reconocimiento de daños en edificaciones, aprovechando la precisión y eficiencia en la extracción de regiones afectadas que ofrecen estas herramientas computacionales . Además, la adaptabilidad del aprendizaje automático a problemas de múltiples dimensiones y el empleo de funciones discriminantes no lineales destacan dentro de los avances más recientes en el campo [2].

En conjunto, estos estudios reflejan el desarrollo progresivo y la integración de herramientas avanzadas para la detección y clasificación de daños estructurales. Desde la interpretación visual de imágenes hasta el procesamiento de datos mediante algoritmos sofisticados, el uso de imágenes satelitales ha demostrado ser un recurso indispensable para la gestión eficiente de desastres naturales. La consolidación de estas técnicas promete mejorar aún más la capacidad de respuesta rápida ante emergencias, contribuyendo significativamente a la minimización de impactos en el entorno urbano y la salvaguarda de vidas humanas.

3.2 Método basado en umbrales

En la identificación de estructuras colapsadas mediante imágenes satelitales, el método basado en umbrales se ha consolidado como un enfoque fundamental en el procesamiento de datos de teledetección. Este enfoque implica definir un valor límite que permita la clasificación de los píxeles de la imagen para discernir entre áreas dañadas y no dañadas. La eficacia de este método radica en su simplicidad y en la capacidad de adaptarse a diferentes contextos y objetivos de evaluación de daños.

La metodología de umbral ha sido aplicada para detectar varios tipos de daños en edificaciones. Por ejemplo, en [76] se utilizaron características en 2D y 3D para detectar cambios significativos en altura y área, así como en la textura de las imágenes post-desastre . La precisión de esta técnica ha demostrado ser superior en la detección automática de daños en edificios, siendo una herramienta valiosa para las acciones de respuesta a emergencias.

El análisis de fenología de cultivos mediante imágenes satelitales también se ha beneficiado del método de umbral. En [77], se realizó la identificación del inicio y fin de la temporada de crecimiento en diversas zonas agrícolas. Aunque el método de umbral requiere la recalibración periódica, su aplicación ha resultado en una precisión mejorada en la detección de eventos fenológicos.

En el contexto de la detección de objetivos para búsqueda y rescate, la aplicación de conocimientos morfológicos combinados con umbrales ha permitido la segmentación eficaz de la imagen y la mejora en la eficiencia de los equipos de rescate [78]. La utilización de esta técnica morfológica basada en umbrales ha demostrado ser prometedora para acelerar la localización de objetivos en situaciones de desastre.

La detección de daños en carreteras mediante imágenes satelitales de alta resolución también ha sido abordada a través de modelos de conocimiento que utilizan umbrales para definir características relevantes como el brillo y la desviación estándar [79]. La aplicación de estos modelos ha logrado una alta precisión en la identificación de carreteras dañadas, lo que es crucial para la logística de respuesta ante desastres.

El método basado en umbrales no solo ha servido para mejorar la detección de daños en edificaciones al fusionar características de imágenes de teledetección pre y post-desastre, sino que también ha jugado un papel importante en la evaluación de daños sísmicos en estructuras urbanas [23]. La combinación de técnicas de visión por computadora y aprendizaje automático ha resultado en métodos de evaluación rápida y precisa, fundamentales para la gestión de emergencias.

El enfoque de Aprendizaje de Rastreo y Detección (TLD) aplicado a la detección de daños en carreteras representa otra faceta innovadora del método basado en umbrales [80]. Este método se caracteriza por su autoadaptación y actualización continua, demostrando ser efectivo y práctico para uso en situaciones de emergencia.

Por último, la extracción de información sobre la extensión de inundaciones en tierras agrícolas ha sido posible gracias a la combinación de datos de radar y ópticos, aplicando umbrales en plataformas como Google Earth Engine [81]. Este método ha facilitado una respuesta rápida y precisa, esencial para la restauración de tierras agrícolas y la mitigación de inundaciones.

3.3 Métodos basados en machine learning

En la detección de daños a edificaciones mediante imágenes satelitales, los modelos de ML han demostrado ser herramientas valiosas, ofreciendo enfoques innovadores que superan las limitaciones de los métodos tradicionales. Gaffinet et al. [82] exploraron el uso de redes neuronales profundas, específicamente una combinación de SENet y UNet, para la detección de la extensión de inundaciones en imágenes de satélite ópticas. Su modelo, entrenado con datos de las inun-

daciones en Pakistán de 2022, demostró una alta precisión, con una Intersección sobre la Unión (IoU) del 93.5%, y una notable transferibilidad geográfica con una IoU del 83.8%.

Abdi et al. [83] se centraron en la adaptación de ResNet-34 para la identificación de edificaciones dañadas post-desastre, utilizando un enfoque de aprendizaje profundo por transferencia que permitió lograr una precisión general de más del 91%. Este enfoque demostró la eficacia del marco de detección de daños y su capacidad de generalización a diferentes tipos de desastres.

Zhang et al. [84] introdujeron un enfoque de aprendizaje métrico profundo para la detección de daños multi-riesgo en imágenes de teledetección. Utilizando una red de tripletes y datos pre y post evento, su metodología abordó las variaciones inter e intra-clase en imágenes del entorno construido, proporcionando una precisión promedio de detección de más del 89%.

Moya et al. [85] propusieron un método de selección de muestras de entrenamiento basado en la intensidad del desastre para la clasificación del daño en edificios, evitando la necesidad de recopilación manual de datos y ofreciendo una precisión que varía entre 0.85 y 0.89. Este método fue validado en varios desastres naturales, incluyendo terremotos y tsunamis.

En conjunto, estos estudios demuestran el potencial y la eficacia de los métodos de machine learning en la tarea crítica de identificar edificaciones colapsadas tras desastres naturales. No obstante, suponen aún una herramienta poco aplicable para la evaluación rápida de áreas afectadas por desastres debido a la necesidad de muestras etiquetadas para calibrar los modelos de ML usados para clasificación.

3.4 Métodos automáticos para identificación de daños

Las recientes investigaciones han proporcionado un avance significativo en la identificación automática de daños utilizando aprendizaje automático y teledetección. En el trabajo de Philippe Aparicio [86], se presentó una metodología que, tras el terremoto de Haití en 2010, permite la clasificación automática de edificios en categorías de daños usando imágenes satelitales y LiDAR. Este enfoque innovador se centra en la capacidad de mapear automáticamente los daños, lo cual es esencial para la gestión eficiente de desastres.

Chengzhe Sun y colaboradores [87] propusieron el método *"SemiBuildingChange"*, que utiliza un generador de datos pseudo bitemporales (PITA) y aprendizaje profundo para superar la escasez de datos anotados de alta calidad. Este enfoque ha demostrado mejorar el rendimiento de la detección de cambios en edificios, incluso con un conjunto limitado de datos etiquetados, proporcionando una alta precisión en la localización de edificios post-terremoto y la evaluación de daños.

A. Cerbelaud et al. [88] desarrollaron métodos de clasificación supervisada para detectar automáticamente daños causados por fuertes lluvias. Utilizando imágenes ópticas de alta resolución

multitemporales y datos auxiliares, su método ha demostrado ser eficaz para identificar áreas recientemente inundadas y se ha beneficiado de la verificación de una amplia muestra de verdades de campo, demostrando la aplicabilidad en diferentes climas y topografías.

Estas investigaciones subrayan la relevancia de los métodos automáticos y el uso de algoritmos de aprendizaje automático en la teledetección para una rápida identificación de daños en edificios. La combinación de enfoques manuales y automáticos se sugiere como una solución óptima para la mejora continua en la detección de daños, lo que es crucial para los esfuerzos de rescate y reconstrucción post-desastre. La integración de estas metodologías en prácticas de ingeniería civil y gestión de desastres promete mejorar significativamente la rapidez y la precisión en la respuesta a emergencias.



Capítulo 4

Metodología

4.1 Fundamentos del método

La metodología que se propone se fundamenta en el patrón reconocido de distribución de daño tras terremotos, ilustrado en la figura (4.1). Los sismos generan ondas que se propagan en todas direcciones, disminuyendo su amplitud con la distancia desde el epicentro, pero pudiendo amplificarse localmente debido a las características mecánicas del terreno. El daño suele concentrarse en las zonas de alta demanda sísmica, aunque hay estructuras que resisten sin daños notables. En contraste, las áreas de baja intensidad sísmica muestran edificaciones sin afectaciones. Con la expansión del área de estudio, se incluyen más edificaciones indemnes debido a la atenuación sísmica.

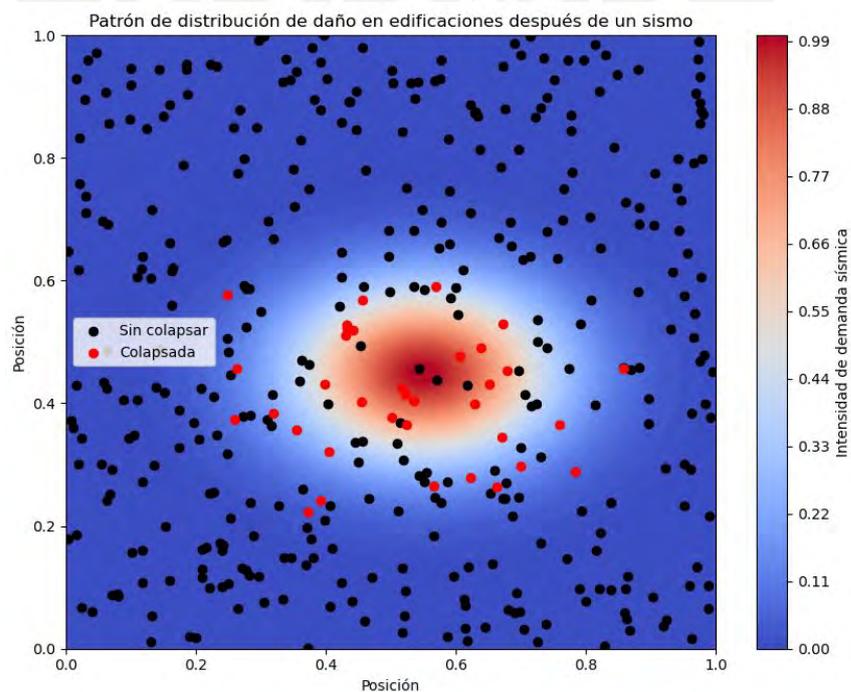


Figura 4.1: Patrón de distribución de edificaciones dañadas después de un terremoto. Elaboración propia

Aunque pueda parecer trivial, este patrón de daño es crucial, ya que los mapas de demanda sísmica se publican rápidamente tras un terremoto y proporcionan una guía preliminar para al-

goritmos de *machine learning* encargados de detectar estructuras colapsadas. No obstante, la presencia de edificaciones intactas en zonas de alta demanda sísmica refleja la variabilidad en la vulnerabilidad sísmica de cada edificio, condicionada por el diseño de ingeniería sismorresistente. Esto introduce una complejidad adicional, ya que el comportamiento sísmico de una edificación varía de acuerdo al nivel de seguridad estructural de dicha edificación. Los edificios antiguos, por ejemplo, suelen no cumplir con las normativas modernas de resistencia sísmica y, por ende, son más propensos al daño.

Las curvas de fragilidad son un concepto bien establecido en ingeniería sísmica, estas permiten relacionar la probabilidad de daño de una estructura con el nivel de intensidad sísmica. Combinando los mapas de demanda con las curvas de fragilidad se puede estimar la probabilidad de fallo o colapso de un edificio, información que en este método reemplaza parcialmente la necesidad de usar muestras etiquetadas para el entrenamiento de una función clasificadora de ML. El uso de curvas de fragilidad para los fines descritos es especialmente conveniente, ya que existen numerosas investigaciones que elaboran dichas funciones de fragilidad para distintos tipos de estructuras y en distintas ubicaciones, razón por la cual es posible emplear funciones elaboradas previamente.

La fusión de estos datos con la información visual obtenida de imágenes satelitales nos proporciona una herramienta más precisa para la identificación de edificios colapsados post-terremotos, integrando tanto el análisis visual como el conocimiento estructural de las edificaciones en la zona de interés y prescindiendo en gran medida de la necesidad de muestras etiquetadas.

4.2 Descripción del método

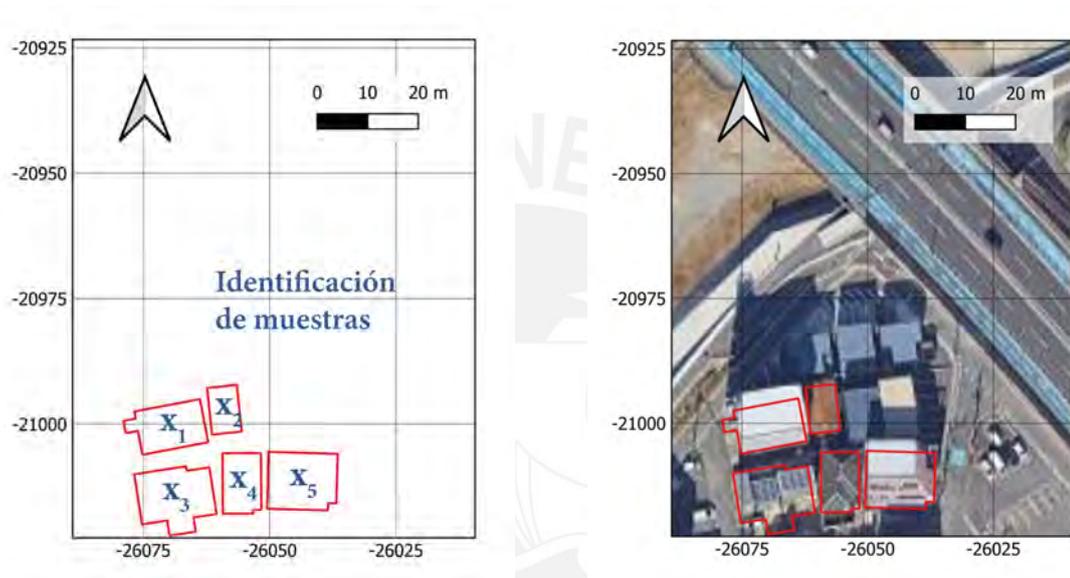
Este trabajo propone un enfoque semi-supervisado que mejora la clasificación de edificaciones post-sismo. El método se basa en la metodología de aprendizaje no supervisado previamente descrita en [2].

Después de la ocurrencia de un sismo, se identifican las ciudades o zonas urbanas más próximas al epicentro para ser evaluadas. Como primer requisito, es imperativo contar con un inventario de las edificaciones existentes, el cual es crucial para determinar el conjunto de muestras a analizar. Como información fundamental, dicho inventario debe incluir las ubicaciones georreferenciadas de las edificaciones, así mismo, es deseable que contenga información sobre la tipología estructural de cada edificio, como número pisos, material, año de construcción, etc. Aunque esto último no es obligatorio para el correcto funcionamiento del método.

Aunque en muchos países y municipios los registros catastrales proporcionan una documentación exhaustiva del crecimiento urbano. Estos no siempre están disponibles o podrían no ser públicos. En tales circunstancias, una alternativa viable es recurrir a mapas de uso de suelo de áreas urbanas proporcionados por entidades internacionales, como es el caso del *World Settlement Footprint* (WSF) de la Agencia Espacial Alemana (DLR) [89]. A pesar de que el uso de mapas genéricos

como el WSF puede introducir desviaciones menores debido a la posible desactualización frente al desarrollo urbano reciente, el método propuesto sigue siendo efectivo.

Usando el inventario de edificaciones se determina el número de muestras no etiquetadas u , como se muestra en el esquema de la figura 4.2. Así mismo, en paralelo y luego de ocurrido el evento, es posible obtener un conjunto de muestras etiquetadas o edificaciones colapsadas en las horas subsiguientes al evento. Estas pueden ser identificadas mediante reportes de noticias o redes sociales, proporcionando un conjunto etiquetado de muestras ℓ , denotadas por $\{x_i, y_i\}_{i=1}^{\ell}$, donde x_i es la muestra y y_i su correspondiente etiqueta.



(a) Creación de u muestras no etiquetadas en base al inventario de edificaciones.

(b) Inventario de edificios superpuesto con imágenes satelitales de google maps

Figura 4.2: Esquema de creación de muestras no etiquetadas en base a inventario de edificaciones. En la imagen se puede observar que hay edificaciones que no están inventariadas, lo cual indicaría una desactualización respecto al crecimiento urbano actual de la zona mostrada

Cada una de las muestras $\{x_i\}_{i=1}^{\ell+u}$ debe ser asociada con la siguiente información: x_i^1 , x_i^2 , d_i y r_i , los cuales corresponde a los valores de coherencia pre-evento, coherencia co-evento, demanda y fragilidad respectivamente. La elaboración de esta base de datos es fundamental para la calibración de la función clasificadora y la elaboración posterior de las predicciones.

Muestra (x_i)	Coh. pre (x_i^1)	Coh. post (x_i^2)	Demanda (d_i)	Fragilidad (r_i)
x_1	x_1^1	x_1^2	d_1	r_1
x_2	x_2^1	x_2^2	d_2	r_2
		.		
		.		
$x_{\ell+u}$	$x_{\ell+u}^1$	$x_{\ell+u}^2$	$d_{\ell+u}$	$r_{\ell+u}$

Tabla 4.1: Base de datos que debe recopilarse antes de calibrar la función clasificadora y hacer predicciones. Se observa que la base de datos contiene las muestras etiquetadas y no etiquetadas

Las imágenes satelitales pre-evento consisten de dos imágenes SAR, adquiridas con parámetros idénticos en fechas diferentes, siendo recomendable que una de ellas se haya capturado lo más cercano posible al evento. Estas imágenes, una vez adquiridas, deben ser procesadas para obtener la coherencia interferométrica, resultando en una imagen *raster* denominada pre-evento. De manera análoga, después del evento, es factible adquirir una imagen SAR de la zona de interés. Esta debe mantener las características de adquisición consistentes de las imágenes pre-evento previamente adquiridas. El tiempo requerido para obtener esta imagen post-evento puede variar, dependiendo de la frecuencia con la que el satélite sobrevuela la ubicación especificada. Al procesar la imagen SAR post-evento, se debe procesar en conjunto con una imagen pre-evento para generar un nuevo *raster* correspondiente a la coherencia interferométrica de ambas, conocido como co-evento. En la figura 4.3, se muestra un esquema del cálculo necesario para obtener las imágenes de coherencia pre y co-evento.

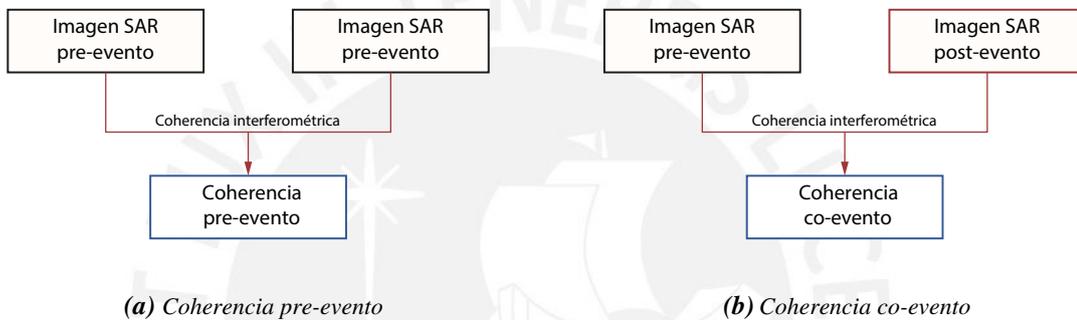


Figura 4.3: Esquema de cálculo de las imágenes de coherencia pre y co-evento

Una vez procesadas las imágenes SAR y obtenidos los valores de coherencia interferométrica pre y post evento. A cada muestra $\{\mathbf{x}_i\}_{i=1}^{\ell+u}$ se le asigna sus correspondientes valores de coherencia pre y post evento. Esto último se realiza usando las posiciones georeferenciadas de cada una de las muestras. Para una muestra cualquiera i , estos indicadores se denominan \mathbf{x}_i^1 y \mathbf{x}_i^2 , denotando la coherencia pre y co-evento respectivamente.

En cuanto a los valores de demanda, estos se obtienen de un mapa de demanda. Aunque no todos los países cuentan con instituciones que lleven a cabo esta tarea, existen organizaciones internacionales, como el Servicio Geológico de los Estados Unidos (USGS), que proporcionan mapas de demanda para eventos sísmicos en todo el mundo. Una vez adquirido, el mapa de demanda debe ser procesado y correlacionado con el inventario de edificaciones para determinar los valores de demanda específicos para cada estructura o muestra en estudio. Es decir, para cada muestra $\{\mathbf{x}_i\}$ se corresponde con un valor de demanda d_i . Es crucial considerar que la demanda se utiliza para calcular la fragilidad mediante las funciones correspondientes. Por ende, es esencial que el mapa de demanda utilizado coincida con el parámetro de intensidad que se emplea en la definición de las curvas de fragilidad seleccionadas, ya sea PGA, PGV o PGD.

Para calcular los valores de fragilidad r_i es necesario hacer uso de curvas de fragilidad. Las funciones de fragilidad son un componente crítico en el análisis de riesgo y han sido extensiva-

mente estudiadas por académicos que desarrollan curvas específicas para distintos tipos de estructuras en sus países. En ese sentido, si se dispone de un inventario detallado del tipo de edificaciones en las zonas de estudio, es posible aplicar las curvas de fragilidad más apropiadas para las tipologías identificadas. En ausencia de información detallada sobre las tipologías estructurales, se recomienda seleccionar un conjunto limitado de tipologías que representen la fragilidad predominante en dichas áreas. Aunque esta aproximación puede comprometer la precisión del método, los casos de estudio presentados en esta investigación demuestran que es posible obtener resultados satisfactorios al emplear una única curva de fragilidad para todas las zonas evaluadas. En ese sentido, continuando con el procedimiento, se calcula la fragilidad asociada a cada muestra $\{x_i\}$ mediante el uso de las funciones de fragilidad de referencia seleccionadas Φ como se muestra a continuación

$$r_i = \Phi(d_i), \quad (4.1)$$

La función clasificadora es una red neuronal y se denota como f . La arquitectura de esta red en la metodología actual se basa en un proceso iterativo de prueba y error, asegurando una configuración fija en las capas de entrada y salida. Esta configuración consta de dos neuronas en la capa de entrada, que reciben los valores de coherencia pre-evento y co-evento (x_i^1 y x_i^2), y una neurona en la capa de salida. A esta última se le aplica la función de activación sigmoide, obteniendo como resultado una predicción $f(x_i)$ que se encuentra en el intervalo $[0.0, 1.0]$. La Figura 4.4 ilustra el esquema de la arquitectura de red neuronal sugerida para el método de identificación de estructuras colapsadas.

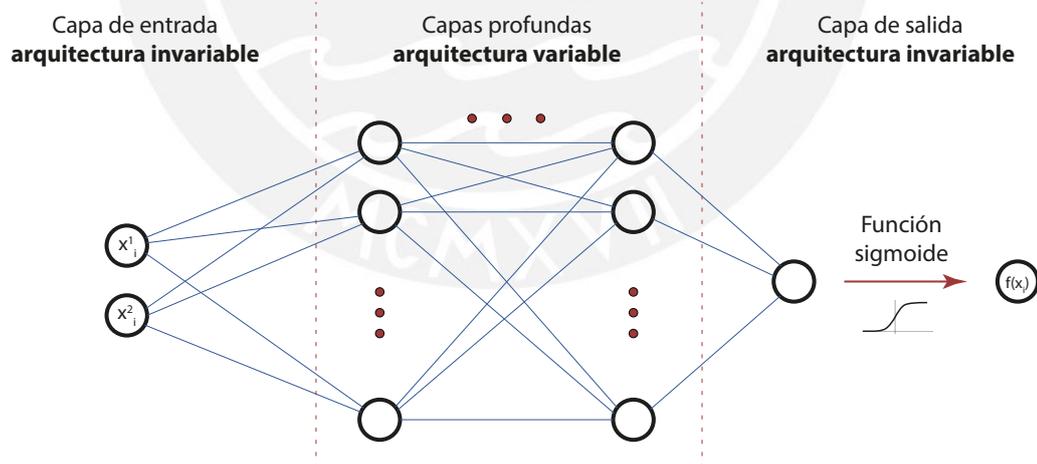


Figura 4.4: Esquema de la arquitectura de la red neuronal diseñada para el método de identificación de edificaciones colapsadas. Elaboración propia.

La selección de la arquitectura de la red es, hasta cierto punto, arbitraria y se basa en la experiencia y el juicio del investigador. Por lo tanto, definir de manera más objetiva y sistemática la configuración óptima para la red clasificadora representa una línea futura de investigación.

La función clasificadora, denotada como f , se optimiza mediante una función de pérdida reg-

ularizada, definida por:

$$\mathcal{L} = \sum_{i=1}^{\ell} V(\mathbf{x}_i, y_i, f) + \gamma_R \mathcal{R}(f), \quad (4.2)$$

donde V es una función de costo que mide el error de las muestras etiquetadas y $\mathcal{R}(f)$ es un término de regularización que considera la complejidad en la distribución espacial de la demanda y la severidad del sismo en cada muestra. El término γ_R actúa como un factor de regularización, ajustable según el análisis.

La función de regularización $\mathcal{R}(f)$ se calcula a través de una adaptación de la entropía cruzada:

$$\mathcal{R}(f) = -1 \sum_{i=1}^{\ell+u} (r_i \log f(\mathbf{x}_i) + (1 - r_i) \log(1 - f(\mathbf{x}_i))), \quad (4.3)$$

Cabe destacar que para las muestras etiquetadas como colapsadas, el valor de r_i se considera igual a 1.0, sobrescribiendo cualquier valor que podría obtenerse mediante $r_i = \Phi(d_i)$.

$$\forall x_i, i \in [1, \ell] \rightarrow \quad (4.4)$$

$$r_i = 1.0 \quad (4.5)$$

Entonces, V se calcula de manera similar a $\mathcal{R}(f)$ pero modificando el valor de r_i

$$V(\mathbf{x}_i, y_i, f) = -(\log f(\mathbf{x}_i)), \quad (4.6)$$

Con la arquitectura de la red neuronal ya establecida y la función de pérdida definida, el siguiente paso es determinar el factor de regularización γ_R . Se propone un enfoque sistemático para encontrar el valor óptimo de este parámetro crucial. Dado que γ_R actúa como un hiperparámetro de la red, su valor no varía durante el entrenamiento y ejerce una influencia significativa en los resultados finales.

Disponemos de un conjunto de muestras colapsadas ℓ y un conjunto mucho mayor u de muestras no clasificadas. Se establece un tamaño de *batch* b , considerablemente menor que u , ($b \ll u$), para utilizar el método de *Stochastic Gradient Descent*. Para la calibración, se emplean $\ell-1$ muestras etiquetadas, reservando una para validación, y se fija un número de épocas n_e . La función de costo en cada iteración se describe como:

$$\mathcal{R}(f) = - \sum_{i=1}^{b+\ell-1} (r_i \log f(\mathbf{x}_i) + (1 - r_i) \log(1 - f(\mathbf{x}_i))), \quad (4.7)$$

$$r_i = \Phi(d_i), \quad (4.8)$$

$$V(\mathbf{x}_i, y_i, f) = -\log f(\mathbf{x}_i), \quad (4.9)$$

$$\mathcal{L} = \sum_{i=1}^{l-1} V(\mathbf{x}_i, y_i, f) + \gamma_R \mathcal{R}(f). \quad (4.10)$$

Cada muestra para validación se utiliza secuencialmente, realizando l pruebas por cada valor de γ_R . El resultado de cada prueba, denotado por p_i , se registra como 1.0 si es correcto, o como 0.0 si es incorrecto. La eficiencia S_R de γ_R se calcula entonces como:

$$S_R = \frac{\sum_{i=1}^l p_i}{l}. \quad (4.11)$$

Para cada valor de S_R se requieren l calibraciones completas. Este procedimiento se repite para diversos valores de γ_R , permitiendo trazar una curva de eficiencia como la ilustrada en la Figura 4.5.

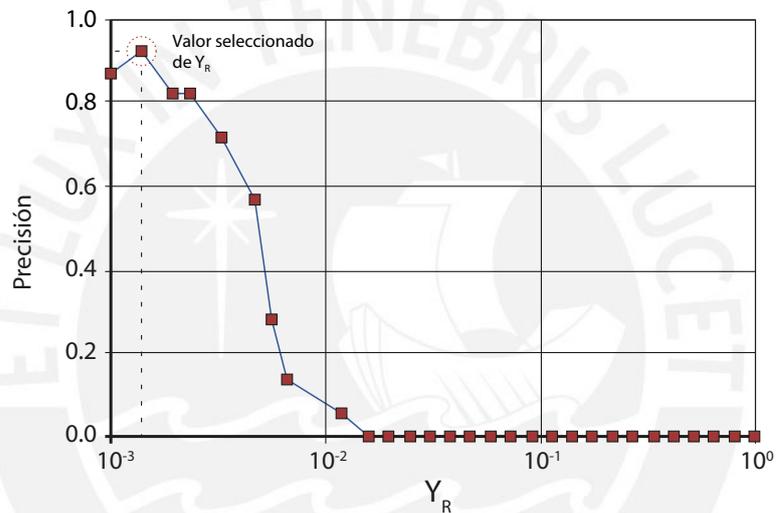


Figura 4.5: Diagrama de rendimiento de los factores γ_R

Luego, se elige el valor de γ_R con el mejor desempeño y se reentrena la red con este parámetro seleccionado.

Es crucial recordar que el valor de γ_R tiene una correlación directa con el tamaño de *batch* b utilizado en la calibración. Por tanto, este último debe mantenerse constante a lo largo del proceso de calibración.

Es importante notar que cuando $\gamma_R \rightarrow \infty$, se tiene que:

$$\frac{\mathcal{L}}{\gamma_R} \approx \mathcal{R}(f), \quad (4.12)$$

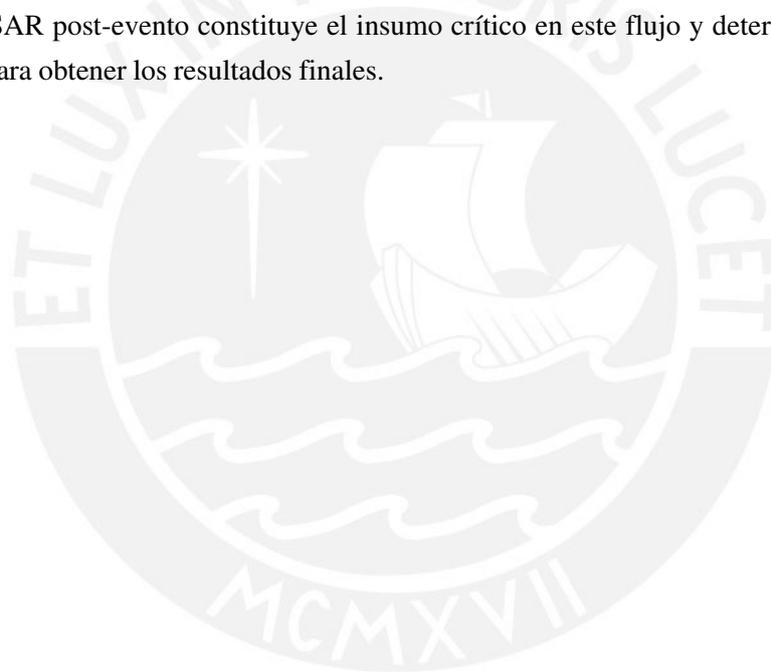
y la función de costo se asemeja al modelo presentado en [2], correspondiente a un enfoque de aprendizaje no supervisado. En contraste, cuando $\gamma_R \rightarrow 0$, la función de pérdida se alinea con un modelo de aprendizaje supervisado. Además, si $\gamma_R = 1$ y el área de estudio es extensa, la clasificadora f tiende a etiquetar todas las muestras como no colapsadas, dado que $u \gg l$ y la

mayoría de estas muestras no presentan daño y tienen una baja demanda sísmica. Este comportamiento establece un límite superior útil para γ_R , indicando que $\gamma_R < 1$, razón por la cual no se normalizan las muestras.

4.3 Diagrama de Flujo del Método Propuesto

El método propuesto busca identificar zonas afectadas por un sismo de manera rápida, con el objetivo de facilitar la toma de decisiones en la distribución de ayuda humanitaria, provisión de víveres y coordinación de equipos de rescate. La celeridad en el procesamiento es, por lo tanto, un aspecto crítico. La figura 4.6 ilustra de forma esquemática los pasos requeridos para alcanzar los resultados deseados, distribuidos en una línea de tiempo.

Como se observa en la figura 4.6, varios de los procedimientos pueden ejecutarse de manera paralela, dependiendo de los recursos operativos disponibles. Es notorio que la disponibilidad de la imagen SAR post-evento constituye el insumo crítico en este flujo y determina el tiempo total requerido para obtener los resultados finales.



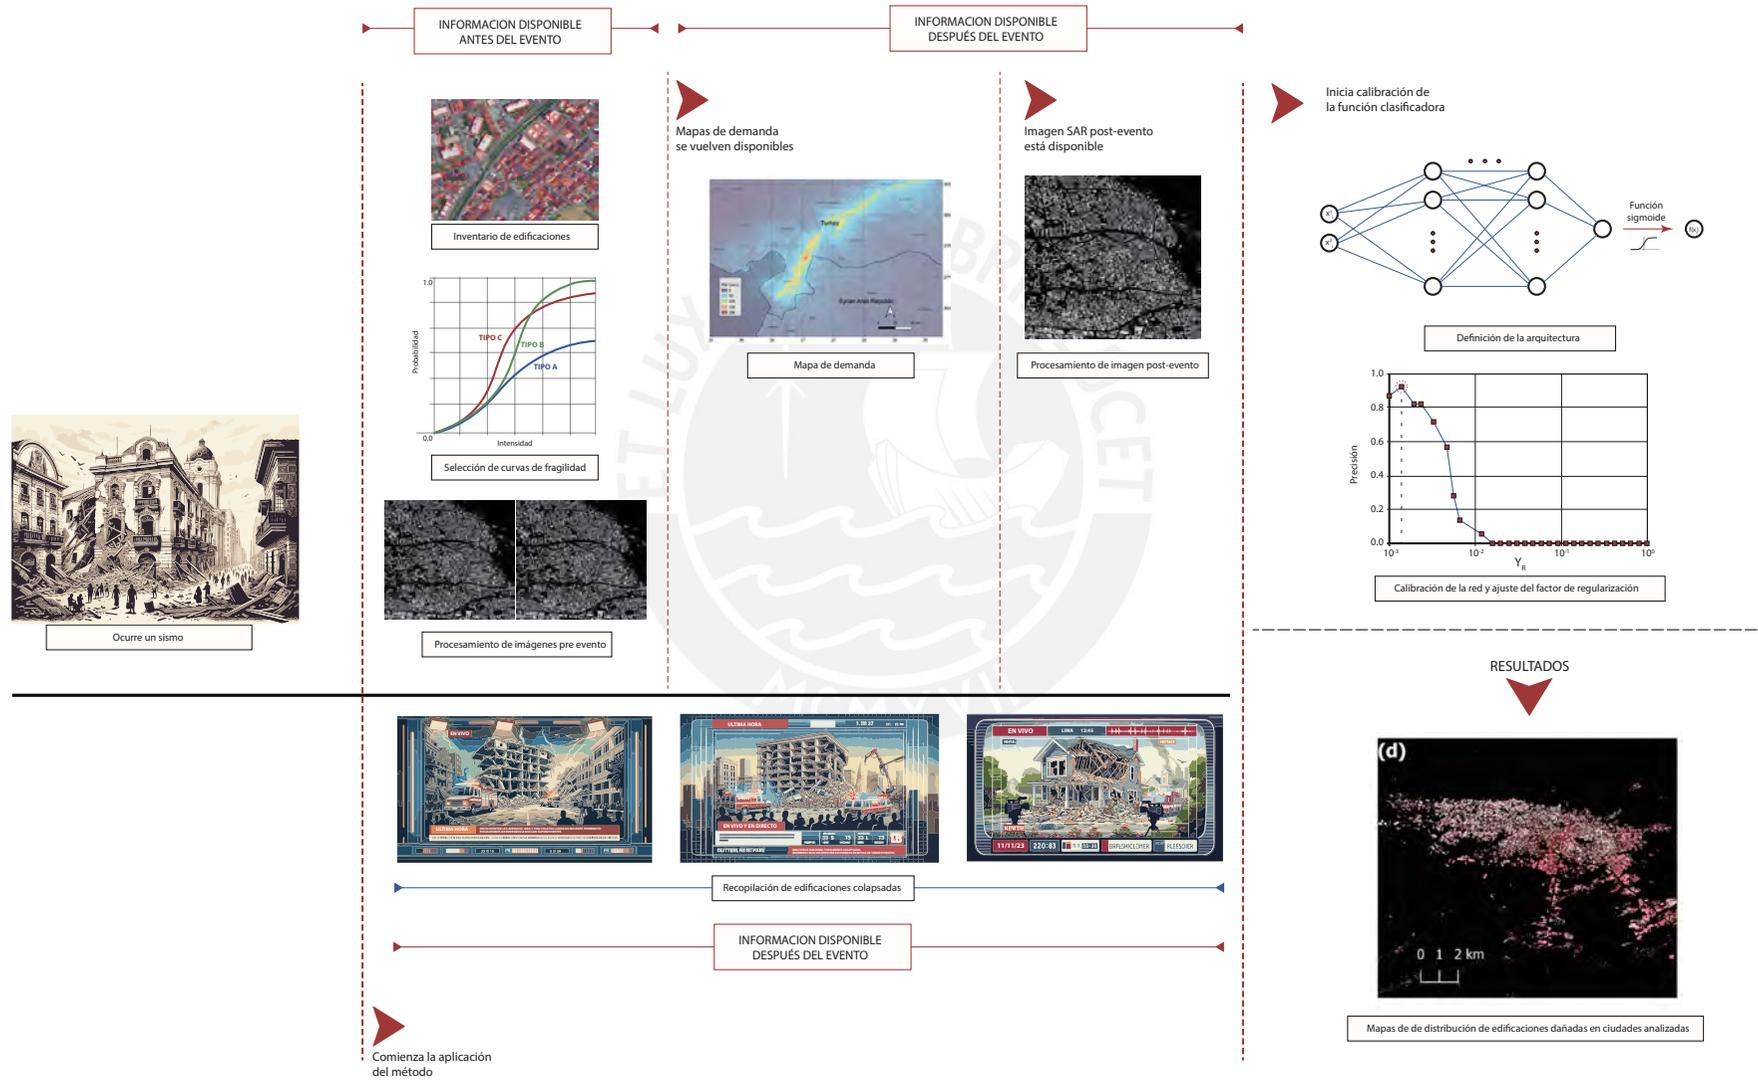


Figura 4.6: Diagrama de la secuencia de procedimientos y línea de tiempo para la implementación del método propuesto. Elaboración propia.

Capítulo 5

Evaluación experimental

5.1 Terremoto de Kumamoto-Japón 2016

El terremoto de Kumamoto de 2016 se presentó como una serie de eventos sísmicos iniciando con un temblor preliminar de magnitud momento (M_w) de 6.2 el 14 de abril en la Falla de Hinagu, seguido por otro temblor previo de M_w 6.0 en la misma falla el 15 de abril. El evento principal, un terremoto significativo de M_w 7.0, tuvo lugar el 16 de abril bajo la ciudad de Kumamoto en la prefectura de Kumamoto en la isla de Kyushu, Japón, a una profundidad de aproximadamente 10 kilómetros.

El terremoto principal fue el resultado de fallas de deslizamiento lateral a poca profundidad. La Agencia Meteorológica de Japón (JMA) registró una magnitud de MJ 7.0, equivalente a una magnitud de momento de 7.0. La actividad tectónica indicó deslizamiento en una falla lateral izquierda hacia el noroeste o en una falla lateral derecha hacia el noreste. Este evento condujo a una devastación severa en muchas áreas dentro de la Prefectura de Kumamoto y afectó parcialmente a la Prefectura de Oita en la Región de Kyushu. El terremoto moderado que sacudió la región el 14 de abril, con una magnitud de MJ 6.5, se originó en el segmento norte de la falla de Hinagu.

Japón es una de las regiones más activas sísmicamente del mundo, ubicada sobre la convergencia de varias placas tectónicas de la Tierra. Este constante movimiento tectónico hace que Japón sea propenso a terremotos frecuentes y a veces muy poderosos. Los efectos catastróficos de los terremotos de Kumamoto 2016 son un testimonio de la vulnerabilidad del país ante tales desastres naturales.

5.1.1 Información disponible antes del evento

5.1.1.1 Inventario de edificaciones existentes

En este caso de estudio se utilizó un inventario de edificios detallado con información sobre los edificios, su forma y sus posiciones geolocalizadas. El inventario fue obtenido de la base de datos de *OpenStreetMap*. Sin embargo, se debe resaltar que mapas de uso de suelo pueden ser usados

satisfactoriamente en caso de ausencia de inventarios precisos de edificaciones. En la figura 5.1, se muestra a manera demostrativa los polígonos de edificaciones de la base de datos empleada, así mismo se muestra también en la misma figura una superposición con una vista satelital de la zona de google maps.



(a) Polígonos georreferenciados del inventario de edificios

(b) Inventario de edificios empleado superpuesto con imágenes satelitales de google maps

Figura 5.1: Inventario de edificios empleado en el caso de estudio. Coordenadas del sistema japonés JGD2000 EPSG:2444. Elaboración propia

En la figura 5.1, se observa que al comparar las imágenes con detenimiento, existen algunos polígonos que describen edificaciones que en la vista actual satelital de google maps ya no están. Estos edificios habrían sido destruidos durante el terremoto y no fueron reconstruidos.

5.1.1.2 Curvas de fragilidad seleccionadas

Debido a la falta de disponibilidad de información sobre la tipología estructural de las edificaciones de la zona de estudio, una única función de fragilidad fue empleada para este caso de estudio. Esta función de fragilidad fue seleccionada bajo la suposición de que las estructuras de madera de baja altura o *low-rise wooden buildings* son la tipología prevaleciente en la ciudad de Kumamoto. Se debe hacer notar que la función de fragilidad adoptada, originalmente propuesta en [15], corresponde al colapso completo para edificios de madera de todo tipo de techos. Esta función fue obtenida mediante el levantamiento de las edificaciones colapsadas durante el terremoto de Kobe. En la figura 5.2, se muestran las curvas de fragilidad para diferentes años de construcción. La línea de mayor espesor corresponde a la curva promedio, la cual fue adoptada como función de fragilidad de referencia para ser empleada en la detección de edificaciones colapsadas.

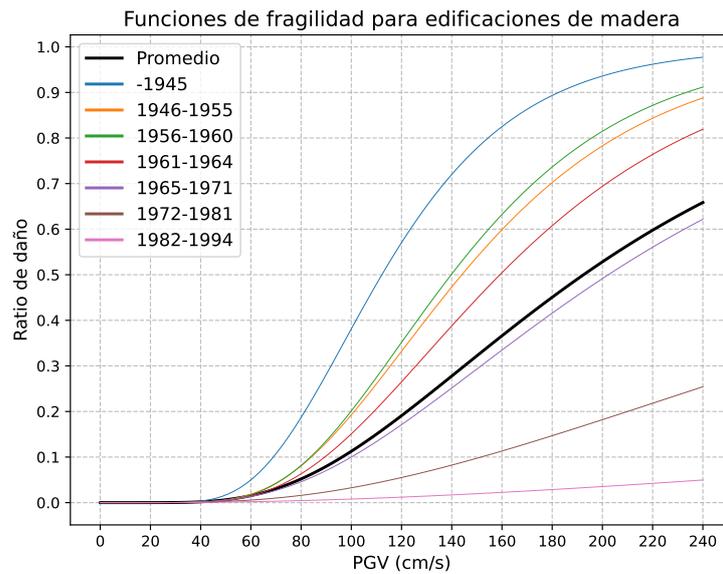


Figura 5.2: Funciones de fragilidad de edificaciones de madera con todo tipo de techos para el nivel de daño de colapso completo. Adaptado de [15].

5.1.1.3 Imágenes SAR pre-evento

En este estudio se usaron 2 imágenes SAR Banda-L del satélite ALOS-2. Las imágenes fueron tomadas en trayectoria ascendente y antes del evento, la primera el 30 de noviembre de 2015 y la otra el 7 de marzo de 2016. Ambas imágenes son del tipo *Single Look Complex* (SLC) obtenidos con polarización horizontal-horizontal (HH). Los parámetros de adquisición de ambas imágenes se muestran en la tabla 5.1.

Tabla 5.1: Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Kumamoto

Sensor	Fecha de adquisición	Trayectoria	Polarización	Banda	Tipo de producto	Modo de Adquisición
ALOS-2	30 Noviembre 2015	Ascendente	HH	L	SLC	IW
ALOS-2	7 Marzo 2016	Ascendente	HH	L	SLC	IW

A partir de las imágenes SAR pre-evento, fue calculada la coherencia interferométrica pre-evento mediante el uso del *software* SNAP, el cual fue desarrollado por la Agencia Espacial Europea (ESA)

5.1.2 Información disponible después del evento

5.1.2.1 Mapa de demanda

El mapa de demanda de la Velocidad Pico del Suelo (PGV en inglés) fue obtenida de los repositorios de las redes de sensores KiK-net y K-net [16]. EL PGV fue escogido especialmente debido a que este es el parámetro utilizado para definir la curva de fragilidad que se usa como referencia.

No obstante, se debe notar que es posible utilizar el PGA si la función de fragilidad la emplea como parámetro de demanda. En la figura 5.3 se muestra el mapa de demanda de PGV utilizado.

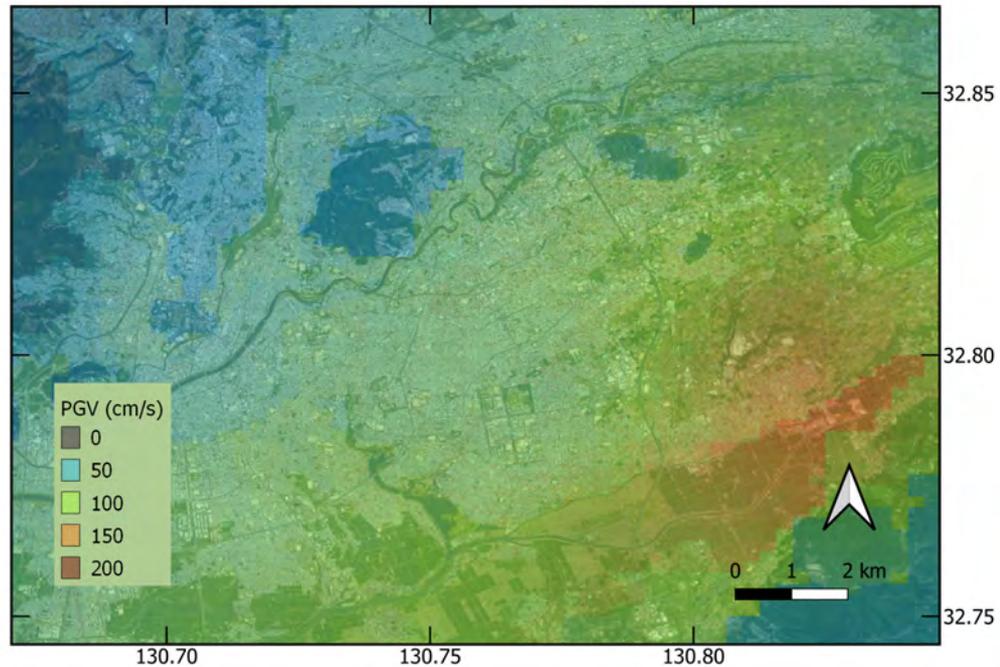


Figura 5.3: Mapa de demanda de PGV empleada para el caso de estudio de Kumamoto. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].

En la figura 5.3, se observa que el cuadrante inferior derecha existe una mayor demanda, por lo tanto, se espera que en esta zona se identifiquen una mayor cantidad de edificaciones colapsadas.

5.1.2.2 Imagen SAR post-evento

Una imagen post evento SAR banda-L del satélite ALOS-2, con fecha del 18 de abril del 2016, fue obtenida con parámetros de adquisición idénticos a las imágenes SAR pre evento. Dichos parámetros se muestran en la tabla 5.2

Tabla 5.2: Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Kumamoto

Sensor	Fecha de adquisición	Trayectoria	Polarización	Banda	Tipo de producto	Modo de Adquisición
ALOS-2	18 Abril 2016	Ascendente	HH	L	SLC	IW

A partir de las imágenes SAR pre y post evento del 7 de marzo y 18 de abril respectivamente, fue calculada la coherencia interferométrica co-evento mediante el uso del *software* SNAP.

5.1.2.3 Edificaciones Etiquetadas como Colapsadas

Este caso de estudio se dispone de una base de datos que comprende 1755 edificaciones, las cuales han sido etiquetadas manualmente como colapsadas. Este etiquetado se basa en el análisis de imágenes Lidar, según lo documentado por [90]. Para replicar condiciones operativas realistas, únicamente se seleccionaron 6 edificaciones de esta base de datos para calibrar el algoritmo clasificador. Es importante mencionar que la elección de estas edificaciones fue aleatoria. Las edificaciones restantes se utilizan para validar y evaluar el rendimiento del clasificador. En la Figura 5.4, se presenta un mapa que ilustra la distribución geográfica de las edificaciones seleccionadas para este estudio.

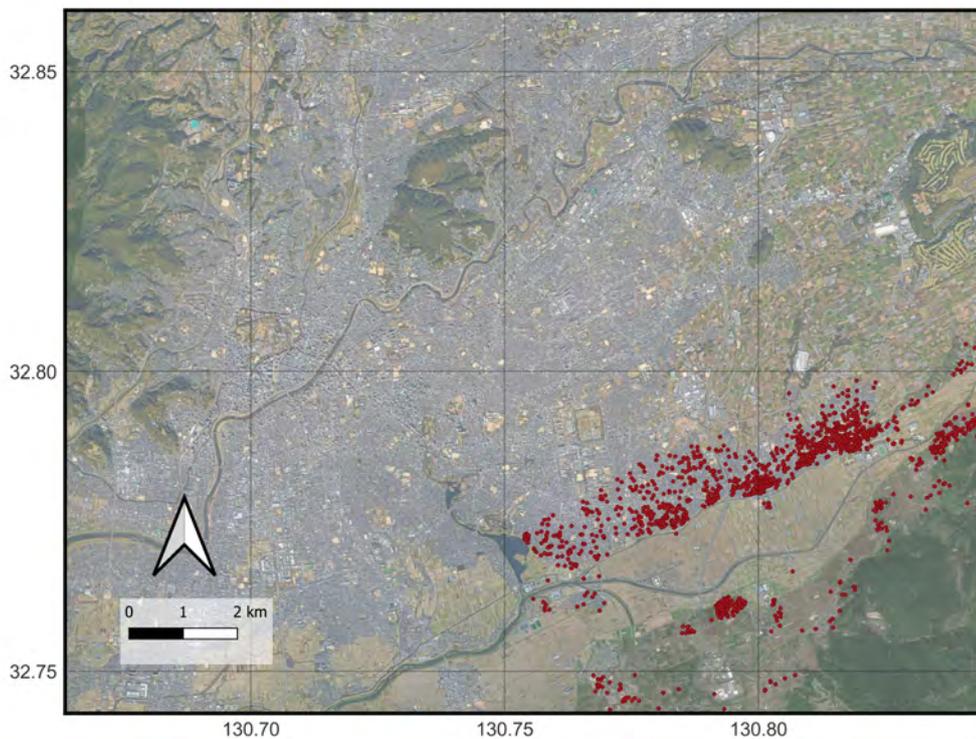


Figura 5.4: Edificaciones etiquetadas como colapsadas empleadas para calibración de la red y evaluación de resultados. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].

5.1.3 Resultados obtenidos

Se implementó una red neuronal tipo perceptrón con una arquitectura 2-10-10-1 para la clasificación. La calibración de este modelo se llevó a cabo utilizando un conjunto de 6 muestras etiquetadas, aplicando un factor de regularización $\gamma_R = 0.013$. El entrenamiento de la red se extendió a lo largo de 200 épocas. La Figura 5.5 ilustra las predicciones realizadas sobre el conjunto de edificaciones analizado.

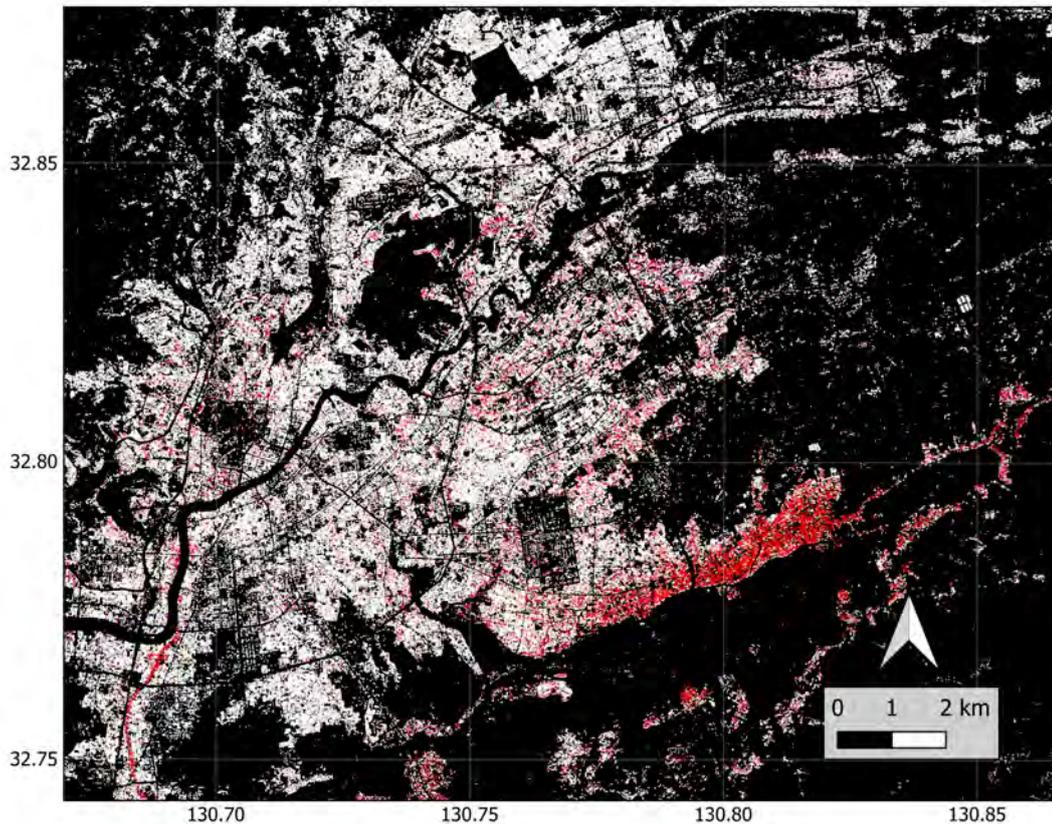


Figura 5.5: Mapa de predicciones de colapso (marcadas en rojo) sobre el inventario de edificaciones, con coordenadas en WGS84 EPSG: 4326.

Para la validación de los resultados, se utilizaron dos bases de datos: una con 1749 muestras etiquetadas como colapsadas, provenientes de [90] y clasificadas manualmente a partir de imágenes Lidar, y otra con 1749 edificaciones consideradas no colapsadas, ubicadas en áreas con niveles bajos de Velocidad Pico del Suelo (PGV) y seleccionadas de manera aleatoria. El análisis de estos datos de referencia revela una precisión promedio del 84%. La correlación entre las predicciones y las bases de datos de referencia se detalla en la Tabla 5.3, mientras que los indicadores de precisión se exponen en la Tabla 5.4.

Tabla 5.3: Comparación de predicciones hechas por el clasificador. Muestras colapsadas fueron etiquetadas por una fuente externa. Las muestras no colapsadas corresponden con área con muy bajo valor de PGV. C: colapsada, UC: no colapsada

		Observada		
		C	UC	Total
Predicción	C	1253	56	1309
	UC	496	1693	2189
	Total	1749	1749	3498

Tabla 5.4: User accuracy (UA), producer accuracy (PA), y F1 indicadores para las predicciones de la tabla 5.3

	UA	PA	F1
C	0.96	0.72	0.84
UC	0.77	0.97	0.87
Promedio	0.87	0.85	0.84

5.1.4 Discusión de resultados

La validación de la clasificación realizada con dos bases de datos distintas, una con edificaciones colapsadas y otra con edificaciones no colapsadas, proporciona una medida fiable de la precisión del modelo clasificador. Al analizar los resultados numéricos, se observa una tendencia del modelo calibrado a categorizar las muestras como no colapsadas. Una explicación para esto podría ser el uso de una única función de fragilidad para calibrar el modelo, lo cual constituye una limitación técnica. Si se dispusiera de información detallada sobre la tipología estructural de las edificaciones, sería factible incorporar un mayor número de curvas de fragilidad ajustadas a las características específicas de la zona de estudio, lo cual indudablemente mejoraría el nivel de precisión que alcanza el método. Otra fuente de error, inherente al método, es que las edificaciones con daños estructurales significativos o colapsos parciales pueden ser clasificadas como no colapsadas si los signos de daño no son visibles en imágenes satelitales. Signos de colapso como la explosión del concreto en columnas, grandes grietas en elementos importantes, son difícilmente apreciables desde una vista satelital, aunque seguramente podrían ser etiquetados como edificios colapsados por un ingeniero que realiza la inspección.

El mapa de daño ilustrado en la Figura 5.5 demuestra la utilidad de herramientas visuales como los mapas de áreas afectadas para identificar rápidamente las zonas más dañadas, facilitando la toma de decisiones en la distribución de recursos. Por ejemplo, el mapa muestra una alta concentración de edificaciones colapsadas en el sudeste de la ciudad. Es importante destacar que información generada por el modelo clasificador es extensa y se puede segmentar de acuerdo a diversas unidades geográficas (calles, manzanas, urbanizaciones, etc.) para presentarla de manera más objetiva y útil para los tomadores de decisiones.

En la calibración del modelo se utilizaron solo 6 edificaciones colapsadas, lo cual es un número viable en contextos reales post-desastre para etiquetar muestras durante la fase de calibración. Esta limitada cantidad de muestras de calibración no disminuye la validez del método, que ha demostrado ser eficaz para la identificación rápida de áreas afectadas por sismos.

En base a los resultados, se concluye que la implementación de una red neuronal con arquitectura 2-10-10-1 ha sido efectiva para distinguir entre edificaciones colapsadas y no colapsadas en las zonas estudiadas. Sin embargo, esta arquitectura puede no ser óptima para todos los casos de estudio, lo que sugiere la necesidad de adaptar la arquitectura del modelo según el contexto

específico. La definición racional y eficiente de la arquitectura de la red sigue siendo un área de investigación futura, especialmente para mejorar su aplicación en respuestas rápidas a desastres en tiempo real.

Determinar el número de personas atrapadas bajo los escombros sería vital para optimizar la distribución de los recursos disponibles en las operaciones de rescate. Investigaciones pre-vias, como la de [91], han utilizado información GIS sobre la distribución de edificaciones y la población para desarrollar modelos que estimen cuántas personas pueden quedar atrapadas tras un desastre. El método propuesto en esta tesis también tiene el potencial de estimar el número de personas atrapadas utilizando información GIS sobre la distribución de la población, que puede obtenerse de fuentes como los censos, los cuales están disponibles en todas las regiones. Esta línea de investigación se explorará en trabajos futuros.

5.2 Terremoto de Turquía-Siria 2023

5.2.1 Información disponible antes del evento

5.2.1.1 Inventario de edificaciones existentes

En este caso de estudio se analizan grandes áreas de terreno de aproximadamente $270\,000\text{ km}^2$ que abarcan territorios de Turquía y Siria, razón por la cual fue difícil recabar inventarios detallados de edificaciones para todas las ciudades dentro de la zona de estudio. En su lugar, se usó los mapas de uso de suelo que provee la Agencia Espacial Alemana llamados *World Settlement Footprint*

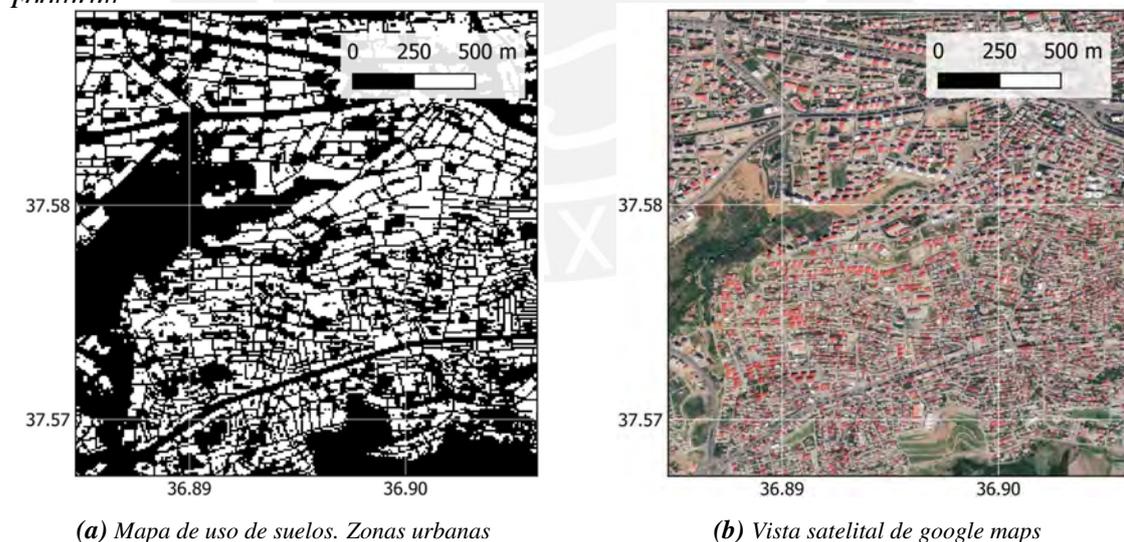


Figura 5.6: Inventario de edificios empleado en el caso de estudio. Coordenadas del sistema WGS84 EPSG:4326

5.2.1.2 Curvas de fragilidad seleccionadas

Debido a la falta de disponibilidad de información sobre la tipología estructural de las edificaciones de la zona de estudio, una única función de fragilidad fue empleada para este caso de estudio. Esta función de fragilidad fue seleccionada bajo la suposición de que las estructuras de

concreto de mediana altura con muros de relleno *low-rise with infill walls* son la tipología más prevaleciente en las zonas afectadas. Esta función de fragilidad [17] fue obtenida mediante simulación numérica, cuyos modelos consideran las propiedades mecánicas recolectadas de edificaciones después de la ocurrencia de 2 terremotos en 1999 en la ciudad de Duzce, estas edificaciones consideradas fueron construidas entre los años 1962 y 1999. En la figura 5.7, se muestran las curvas de fragilidad obtenidas para distintos tipos estructurales que fueron obtenidos por el mismo autor. La línea de mayor espesor corresponde a la curva adoptada como función de fragilidad de referencia para ser empleada en la detección de edificaciones colapsadas.

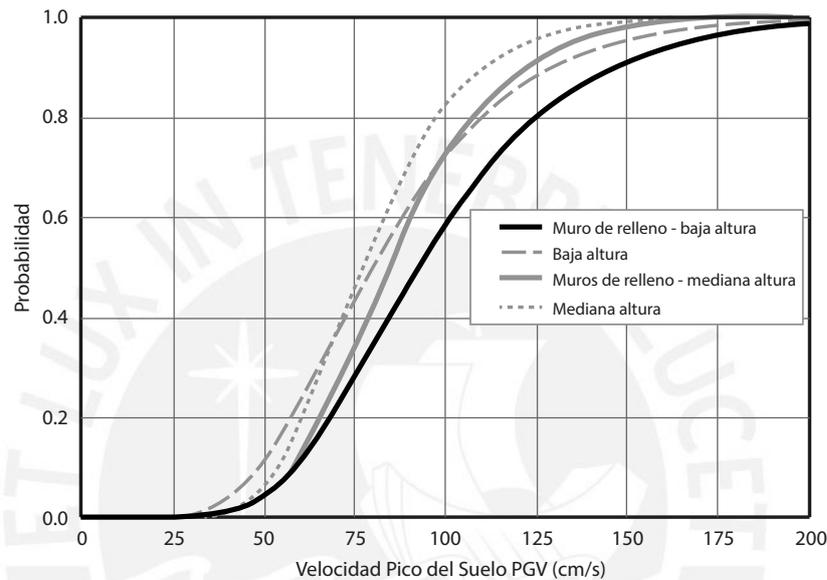


Figura 5.7: Funciones de fragilidad de edificaciones de madera con todo tipo de techos para el nivel de daño de colapso completo. Adaptado de [17].

5.2.1.3 Imágenes SAR pre-evento

En este estudio se usaron 2 imágenes SAR Banda-C del satélite Sentinel-1. Las imágenes fueron tomadas en trayectoria ascendente y antes del evento, la primera el 16 de enero de 2023 y la otra el 28 de enero de 2023. Ambas imágenes son del tipo *Single Look Complex* (SLC) obtenidos con polarización vertical-vertical (VV). Debido a la gran extensión del área a analizar, 2 escenas fueron necesarias para cubrir el área de estudio. Los parámetros de adquisición de ambas imágenes se muestran en la tabla 5.5.

Tabla 5.5: Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Turquía-Siria

Sensor	Fecha de adquisición	Trayectoria	Polarización	Banda	Tipo de producto	Modo de Adquisición
Sentinel-1	16 Enero 2023	Ascendente	VV	C	SLC	IW
Sentinel-1	28 Enero 2023	Ascendente	VV	C	SLC	IW

A partir de las imágenes SAR pre-evento, fue calculada la coherencia interferométrica pre-

evento mediante el uso del *software* SNAP, el cual fue desarrollado por la Agencia Espacial Europea (ESA).

5.2.2 Información disponible después del evento

5.2.2.1 Mapa de demanda

El mapa de demanda de la Velocidad Pico del Suelo (PGV en inglés) fue obtenida del repositorio de *United States Geological Service* (USGS) [18]. El PGV fue escogido especialmente debido a que este es el parámetro utilizado para definir la curva de fragilidad que se usa como referencia. En la figura 5.8 se muestra el mapa de demanda de PGV utilizado.

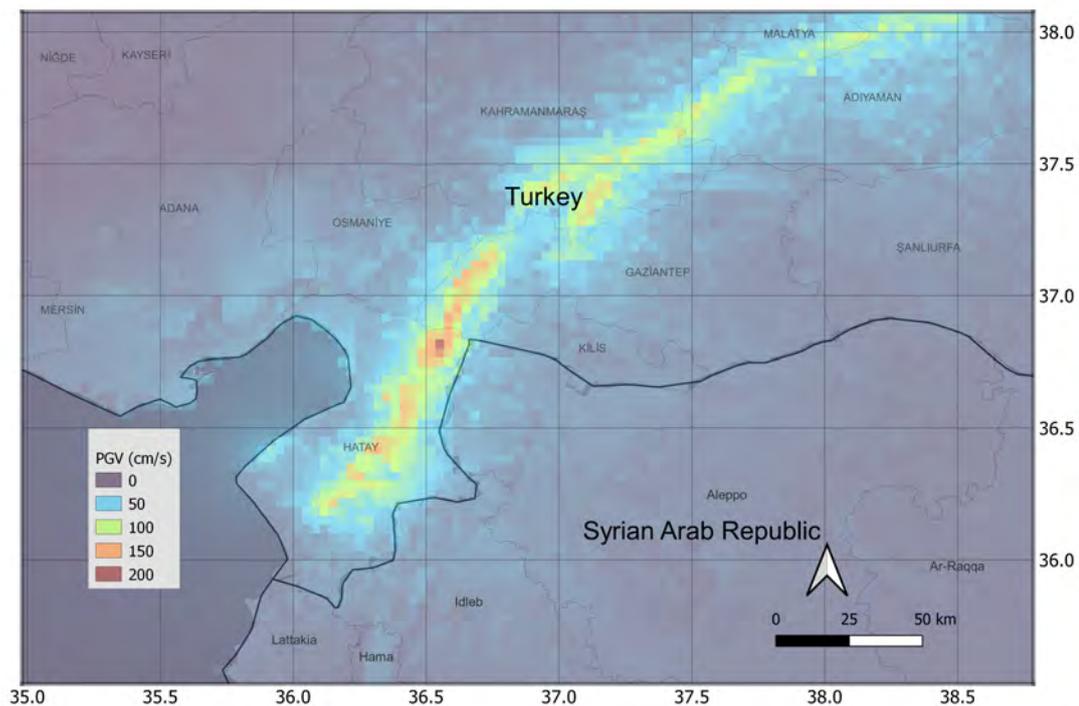


Figura 5.8: Mapa de demanda de PGV empleada para el caso de estudio de Turquía-Siria. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [18].

5.2.2.2 Imagen SAR post-evento

Una imagen post evento SAR banda-C del satélite Sentinel-1, con fecha del 9 de febrero del 2023, fue obtenida con parámetros de adquisición idénticos a las imágenes SAR pre evento. Dichos parámetros se muestran en la tabla 5.6

Tabla 5.6: Parámetros de adquisición de las imágenes SAR pre-evento adquiridas para la evaluación experimental del caso de estudio de Turquía-Siria

Sensor	Fecha de adquisición	Trayectoria	Polarización	Banda	Tipo de producto	Modo de Adquisición
Sentinel-1	9 Febrero 2023	Ascendente	VV	C	SLC	IW

A partir de las imágenes SAR pre y post evento del 28 de enero y 9 de febrero respectivamente, fue calculada la coherencia interferométrica co-evento mediante el uso del *software* SNAP, el cual fue desarrollado por la Agencia Espacial Europea (ESA)

5.2.2.3 Muestras etiquetadas como colapsadas

En este caso de estudio, se obtuvieron las ubicaciones de 35 edificaciones colapsadas a partir de la información de medios de noticias de un video de la grabación de un vuelo de dron que sobrevoló la ciudad de Hatay y que fue publicada por un periodico online [92]. Adicionalmente, se obtuvieron la ubicación de 4 edificaciones colapsadas extraídas del reporte de respuesta rápida de StEER. En la figura 5.9, se muestra un mapa de la distribución de las edificaciones etiquetadas empleadas en este caso de estudio.

Para propósitos de evaluación de resultados, se incorporan al análisis muestras colapsadas documentadas en *OpenStreetMap* actualizado hasta el 6 de Marzo de 2023.

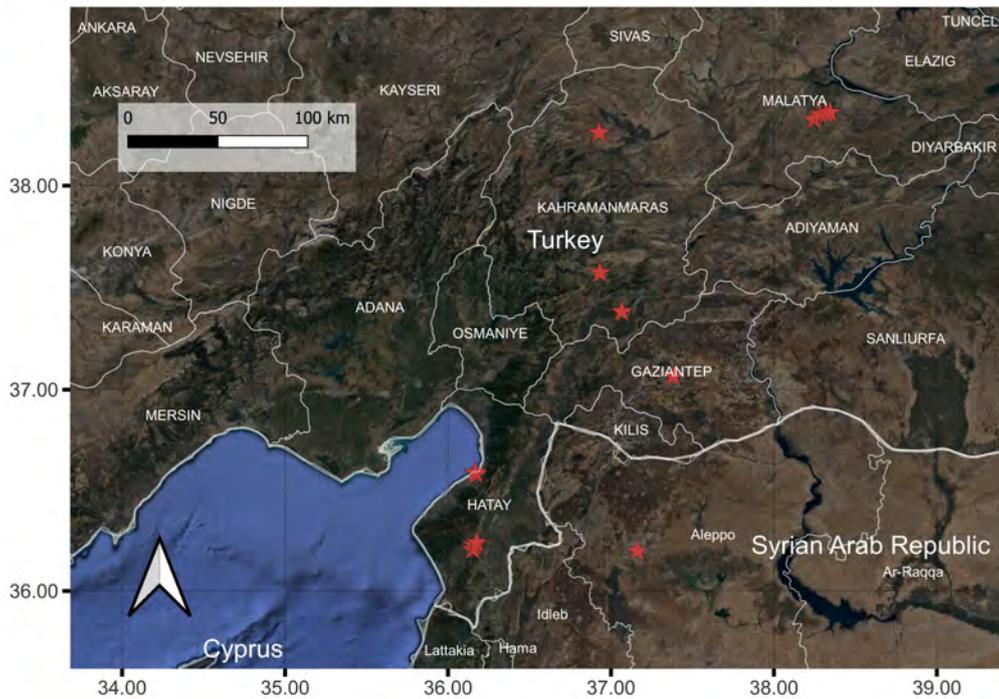


Figura 5.9: Edificaciones etiquetadas como colapsadas empleadas para calibración de la red y evaluación de resultados. Coordenadas en WGS84 EPSG: 4326. Elaboración propia a partir de la data de [16].

5.2.3 Resultados obtenidos

En este caso de estudio, se implementó el método propuesto en tiempo real y tras la ocurrencia del sismo. Se procuró simular las condiciones reales de operación, procesando las imágenes pre-evento, mientras se esperaba la imagen post-evento. Así mismo, durante este periodo, se identificaron y geolocalizaron 39 edificaciones colapsadas mediante el monitoreo de medios de noticias y redes sociales.

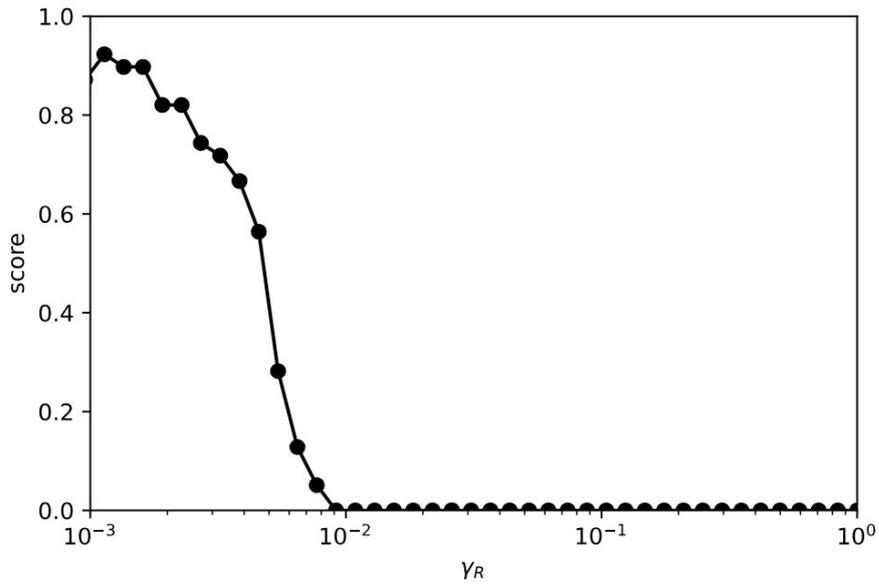


Figura 5.10: Diagrama de rendimiento de γ_R

Se implementó una red neuronal del tipo perceptrón multicapa con una arquitectura 10-20-20-10-1 para ser empleada como función clasificadora. La calibración del modelo se efectuó con un conjunto de 39 muestras etiquetadas, utilizando un factor $\gamma_R = 1.14 \times 10^{-3}$. Este valor se obtuvo mediante el método iterativo descrito en el Capítulo 4. La curva de iteración para γ_R se ilustra en la Figura 5.10. El entrenamiento de la red se desarrolló a lo largo de 200 épocas, y los resultados se muestran en la Figura 5.11.

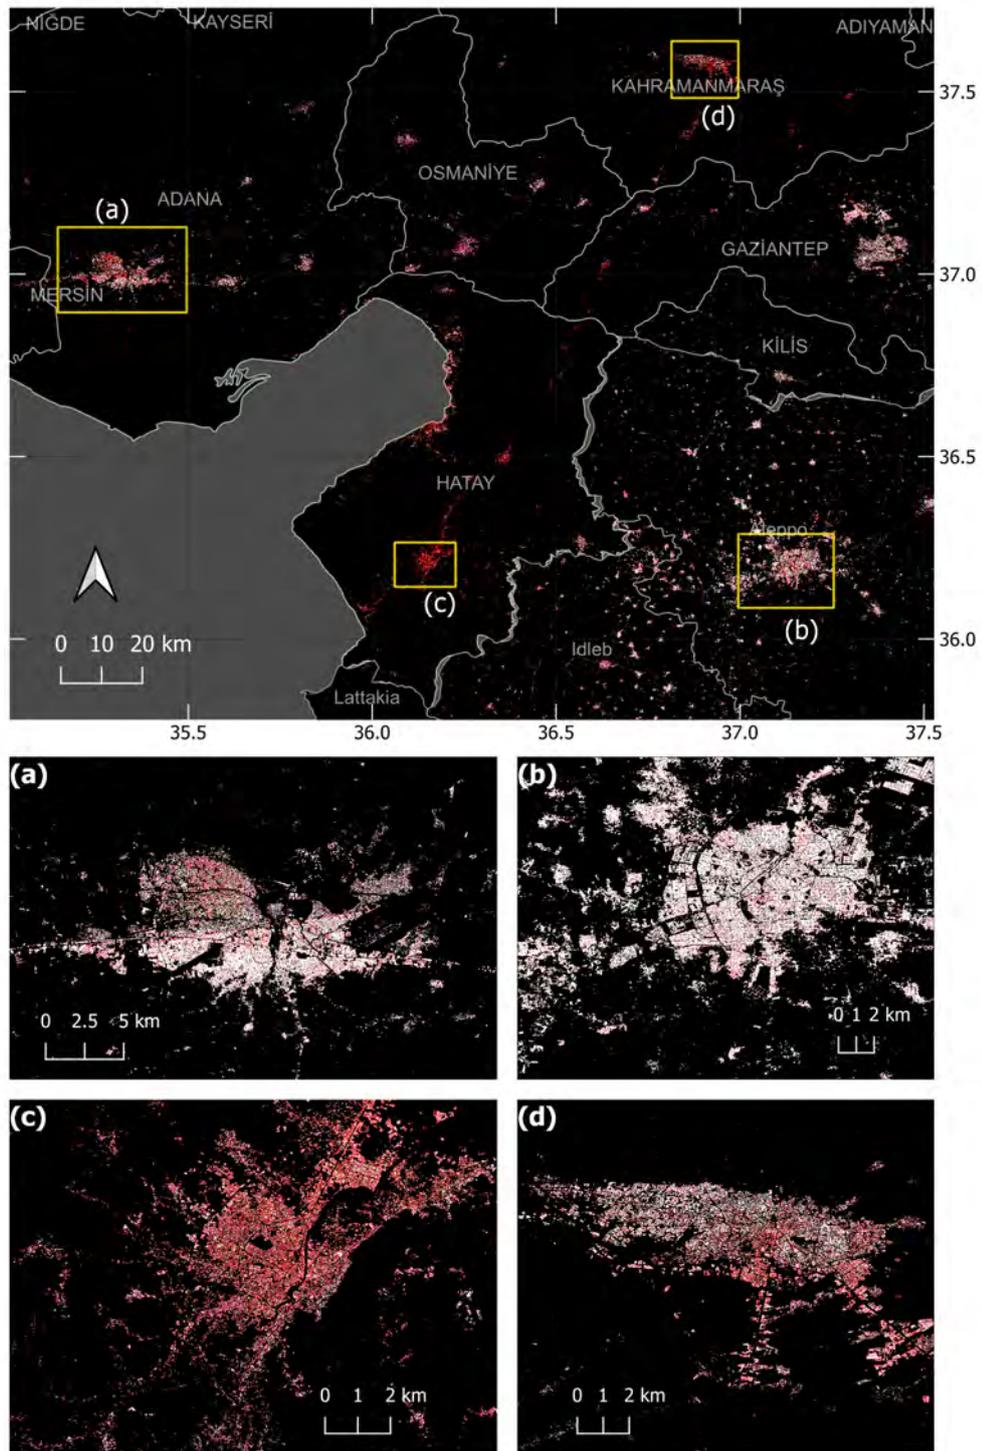


Figura 5.11: Predicción de edificaciones colapsadas (en rojo) sobre el inventario de edificaciones analizado. Coordenadas en WGS84 EPSG: 4326. Píxeles rojos y blancos denotan respectivamente zonas identificadas como dañadas y no dañadas. Se muestra en cada subimagen un acercamiento a las ciudades de Adana, Aleppo, Antakya y Kahramanmaraş en las subimágenes a,b,c,d respectivamente

Para la validación de los resultados, se utilizó la base de datos colaborativa de *OpenStreetMap* que contiene edificaciones colapsadas, así mismo, para completar la base de datos de validación,

fueron seleccionados 2361 muestras de manera aleatoria ubicadas en ciudades de muy baja demanda. En total se tienen 4722 muestras etiquetadas, las cuales serán usadas para la evaluación de la eficacia del método. El análisis de estos datos de referencia revela una precisión promedio del 82%. La correlación entre las predicciones y las bases de datos de referencia se detalla en la Tabla 5.8, mientras que los indicadores de precisión se exponen en la Tabla 5.8.

Para la validación de los resultados, se empleó la base de datos de *OpenStreetMap*, la cual incluye registros de edificaciones colapsadas. Adicionalmente, se seleccionaron 2361 muestras aleatorias de ciudades con muy baja demanda sísmica para complementar la base de datos de validación. En total, se contó con 4722 muestras etiquetadas para evaluar la efectividad del método. El análisis de estos datos reveló una precisión promedio del método del 82%. La correlación entre las predicciones del modelo y las bases de datos de referencia se presenta en la Tabla 5.8, junto con los indicadores de precisión.

Tabla 5.7: Comparación de las predicciones obtenidas por la función clasificadora con data previamente etiquetada. Las muestras colapsadas fueron etiquetadas por otro autor. Las muestras no colapsadas corresponden a muestras de ciudades con valores muy bajos de PGV. C: Colapsada, NC: No colapsada

		Observed		
		C	UC	Total
Predicted	C	2135	687	2822
	UC	226	1674	1900
	Total	2361	2361	4722

Tabla 5.8: User accuracy (UA), producer accuracy (PA), and F1 scores para las predicciones mostradas en la tabla 5.7

	UA	PA	F1
C	0.75	0.90	0.82
UC	0.88	0.71	0.79
Average	0.82	0.81	0.80

5.2.4 Discusión de resultados

La aplicación del método propuesto para identificar zonas urbanas afectadas tras un sismo ha demostrado un notable potencial. El considerable alcance del terremoto de Turquía-Siria de 2023 ha evidenciado la capacidad del método para analizar extensas áreas de forma rápida y efectiva, logrando una precisión promedio del 80%. Esta precisión se ha verificado mediante la comparación de nuestras predicciones con un conjunto de datos de edificaciones colapsadas compilado por otros investigadores.

Los mapas de daños generados ilustran claramente la utilidad de este método para obtener

rápida-mente una idea del nivel de daños en diversas ciudades. Por ejemplo, mientras Alepo muestra pocos daños, Antakya aparece gravemente afectada y se muestra casi completamente marcada en rojo. Dichos mapas proveen una herramienta visual intuitiva, ideal para presentar a los tomadores de decisiones que deben gestionar recursos limitados en respuesta a desastres de gran magnitud. Las áreas más dañadas indican donde probablemente se concentren más heridos o víctimas.

Por otro lado, dependiendo del tratamiento de los datos del inventario de edificaciones, es posible acceder a información más detallada sobre la distribución del daño por manzanas, barrios o urbanizaciones. Sin embargo, es importante destacar que los resultados obtenidos deben ser valorados de una manera más cualitativa y no tanto cuantitativa, ya que el resultado obtenido es en realidad un indicador probabilístico de que tan probable es que esa zona haya presentado un cambio como producto del desastre.

El análisis de vastas áreas que abarcan múltiples ciudades resalta una limitación significativa: la falta de información específica sobre los tipos de edificaciones presentes. Aunque integrar esta información al método de clasificación es sencillo, adquirirla no lo es tanto. Indudablemente, conocer la distribución de los diferentes tipos de edificaciones y sus respectivas curvas de fragilidad en las zonas analizadas mejoraría los resultados del estudio.

Un cambio crucial en este caso de estudio ha sido la implementación del método para determinar el factor γ_R , descrito en el Capítulo 4. Este enfoque ofrece una manera más sistemática y menos arbitraria de calcular este valor crucial para la calibración del clasificador. Por otro lado, la arquitectura de la red neuronal fue seleccionada de manera arbitraria. Establecer un procedimiento metódico para definir esta arquitectura es una mejora que se debería explorar en investigaciones futuras, con el fin de fortalecer el método y promover su aplicación más generalizada en diversos contextos.

En el caso de Turquía resalta sobre todo la cantidad de escombros generados y la problemática que esto genera en las tareas de limpieza y reconstrucción, debido a la inmensa área afectada y a la cantidad de centros urbanos que contiene la misma. Estudios anteriores, como [93], han utilizado información GIS para estimar la cantidad de escombros generados en desastres. El método propuesto en este estudio podría utilizarse para estimar la cantidad de escombros, calcular los volúmenes necesarios para mover y tratar estos residuos, y determinar los materiales requeridos para la reconstrucción. Por ejemplo, en [94], García estimó la cantidad de escombros en tres escenarios de riesgo en la ciudad de Tacna, Perú, utilizando CAPRA-GIS, *Material Flow Analysis* (MFA) y datos sobre las edificaciones de la ciudad. El método desarrollado en esta tesis podría reemplazar el componente de riesgo de CAPRA-GIS, ofreciendo resultados más precisos al basarse en el estado real de la ciudad después del evento. Esto permitiría una estimación más exacta de los escombros generados y mejoraría la planificación y ejecución de la reconstrucción después del desastre.

Capítulo 6

Conclusiones y recomendaciones

La presente investigación ha introducido un nuevo método para la identificación de zonas dañadas tras un sismo de gran magnitud, empleando imágenes satelitales, curvas de fragilidad, mapas de demanda y redes neuronales. A continuación, se destacan las conclusiones más relevantes obtenidas en este trabajo.

Se ha presentado una exposición detallada de los conceptos fundamentales necesarios para comprender e implementar el método propuesto. La comprensión de los sistemas de coordenadas utilizados en la captura de datos espaciales, así como el conocimiento de los sensores remotos y las imágenes satelitales SAR, resultan cruciales. Además, se requiere familiaridad con herramientas de riesgo sísmico como los mapas de demanda y las curvas de fragilidad. Adicionalmente, se ha proporcionado una revisión básica de los conceptos de aprendizaje automático (ML) y redes neuronales, aspectos esenciales para cualquier persona interesada en comprender el método propuesto.

Aunque un inventario detallado de edificaciones sería ideal, se ha demostrado que un mapa genérico de uso de suelo que incluya zonas urbanas puede servir como base para implementar el método, como se evidenció en el caso de estudio del terremoto Turquía-Siria de 2023, utilizando el mapa *World Settlement Footprint* de la Agencia Espacial Alemana. Por lo tanto, el método es aplicable a eventos sísmicos en cualquier lugar del mundo, sustituyendo inventarios detallados con mapas de uso de suelo.

Las muestras etiquetadas proporcionadas a la red neuronal para su calibración no representan una limitación significativa para la implementación del método, como se demostró en el caso de estudio de Kumamoto 2016, donde solo se utilizaron 6 muestras para la calibración.

La adquisición de imágenes satelitales pre y post evento puede ser limitada por la disponibilidad y los parámetros de adquisición necesarios. Sin embargo, esta limitación puede superarse seleccionando imágenes pre evento de acuerdo con los parámetros de adquisición de la primera imagen post evento disponible después del sismo.

En ambos casos de estudio presentados se han empleado arquitecturas arbitrarias que con-

sistieron de redes multicapa con 2 neuronas en la capa de ingreso y 1 neurona en la capa de salida, afectada por una función sigmoide con el fin de obtener un resultado entre el rango $[0,1]$, mientras que las capas intermedias fueron distintas en ambos casos. Las condiciones de entrada y salida son las únicas inamovibles en la arquitectura, en tanto la capa inicial representa el ingreso de la información de coherencia de los rasters pre y post evento y el resultado final es la predicción que debe variar entre 0 y 1. El método tal y como se presenta en esta investigación no ha desarrollado un método racional y ordenado para la selección más apropiada de la arquitectura de la red neuronal de la función clasificadora. Por lo tanto, se concluye que este es un punto débil de la investigación, que requerirá un estudio más detallado en futuras investigaciones para optimizar el rendimiento del método.

Las funciones de fragilidad son curvas que describen el comportamiento esperado para ciertos tipos de edificaciones sometidas a un cierto nivel de demanda sísmica. En esta investigación estas han sido empleadas para sustituir el uso de muestras etiquetadas en la fase de calibración, prescindiendo así de la necesidad de grandes bases de datos de muestras etiquetadas. No obstante, en ambos casos de estudio, al no estar disponible información precisa sobre el tipo de edificaciones existentes en las zonas analizadas, se han empleado funciones de fragilidad únicas para ambos casos: la correspondiente a edificaciones de media altura de madera para Kumamoto 2016 y la función de fragilidad para edificaciones aporricadas con muros de relleno de media altura para Turquía-Siria 2023. Esta suposición seguramente ha disminuido la precisión del método en cuanto a los resultados obtenidos. Por lo tanto, el uso de diversas curvas de fragilidad que representen adecuadamente la distribución de arquetipos de edificaciones presentes en las zonas a analizar aumentará la precisión del método. Un análisis comparativo que brinde una aproximación de la diferencia entre ambos enfoques es una tarea a futuro para otra investigación.

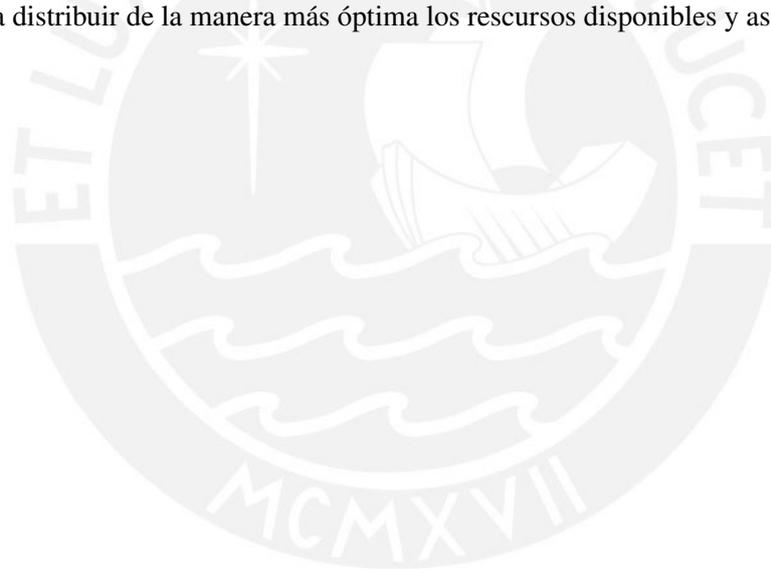
El factor de regularización es básicamente un término que valora la importancia de las muestras etiquetadas suministradas a la red neuronal. Este término es necesario debido a la gran disparidad en cantidad de muestras etiquetadas y el total de muestras usadas para calibración. Durante el desarrollo del caso de estudio de Kumamoto 2016 se identificaron errores significativos cuando no se empleó dicho factor, obteniéndose que la red clasifica a todas las muestras como no colapsadas. En la presente investigación se propuso el uso de este término, a la vez que se propone una manera racional y ordenada para seleccionar el mejor término de regularización. Por lo tanto, se concluye que el término de regularización y su selección es fundamental para un buen desempeño del método propuesto.

Los casos de estudio presentados: El terremoto de Kumamoto Japón de 2016 y la serie de terremotos en Turquía-Siria del 2023 fueron utilizados como casos modelo para la implementación del método presentado. En ambos casos se obtuvieron resultados más que aceptables con precisiones promedio de 87% y 82% respectivamente. Estos casos fueron desarrollados intentando mantener condiciones reales de operación, sobretodo en cuanto al tiempo para obtener y procesar la información. Aunque el método se desempeña correctamente en ambos casos de estudio, son

necesarias muchas más evaluaciones experimentales a fin de desafiar la eficacia y versatilidad del método, a la vez que se buscan nuevos defectos que podrían aparecer en casos particulares, los cuales serán oportunidades para mejorar el método en futuras investigaciones.

Esta tesis introduce un método innovador para detectar edificaciones colapsadas usando imágenes satelitales, mapas de demanda, curvas de fragilidad y redes neuronales. Por sus características, este método tiene el potencial para ser empleado para estimar la cantidad de escombros generados por un sismo. Esta información brindaría información valiosa para las fases posteriores, como la limpieza y la reconstrucción. El desarrollo y aplicación de estas nuevas capacidades será objeto de estudio de futuras investigaciones.

En cuanto el caso de estudio de Turquía-Siria del 2023, resalta sobre todo la extensión de las áreas analizadas, donde se pudo obtener información valiosa sobre el grado de afectación de muchas ciudades de ambos países en muy poco tiempo. Este caso demuestra el potencial del método para servir como una herramienta crucial en la respuesta rápida después de la ocurrencia de un sismo de gran magnitud. La información que proporciona ayudará a los tomadores de decisiones a distribuir de la manera más óptima los recursos disponibles y así salvar más vidas.



Referencias

- [1] L. Moya, E. Mas, B. Adriano, S. Koshimura, F. Yamazaki, and W. Liu, “An integrated method to extract collapsed buildings from satellite imagery, hazard distribution and fragility curves,” *International journal of disaster risk reduction*, vol. 31, pp. 1374–1384, 2018.
- [2] L. Moya, L. R. Marval Perez, E. Mas, B. Adriano, S. Koshimura, and F. Yamazaki, “Novel unsupervised classification of collapsed buildings using satellite imagery, hazard scenarios and fragility functions,” *Remote Sensing*, vol. 10, no. 2, p. 296, 2018.
- [3] J. P. Snyder, *Map projections—A working manual*. US Government Printing Office, 1987, vol. 1395.
- [4] P. Vanicek and E. J. Krakiwsky, *Geodesy: the concepts*. Elsevier, 2015.
- [5] M. Lapaine and N. Frančula, “Map projections classification,” *Geographies*, vol. 2, no. 2, pp. 274–285, 2022.
- [6] B. Lenka and D. R.K., *An Introduction to Digital Soil Mapping*, 06 2020, pp. 1–17.
- [7] J. B. Campbell and R. H. Wynne, *Introduction to remote sensing*. Guilford press, 2011.
- [8] F. Yamazaki and W. Liu, “Remote sensing technologies for post-earthquake damage assessment: A case study on the 2016 kumamoto earthquake,” in *6th Asia Conf. on Earthquake Engg*, 2016.
- [9] L. M. Huallpa, “Apuntes de clase del curso de temas avanzados de análisis de riesgos,” 2022, pontificia Universidad Católica del Perú, Semestre 2022-2.
- [10] S. Shalev-Shwartz and S. Ben-David, *Understanding machine learning: From theory to algorithms*. Cambridge university press, 2014.
- [11] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, “Activation functions: Comparison of trends in practice and research for deep learning,” *arXiv preprint arXiv:1811.03378*, 2018.
- [12] J. Santarcangelo, “Deep neural networks with pytorch,” IBM, 2023, iBM Developer Skills Network. Available on Coursera. [Online]. Available: <https://www.coursera.org/>
- [13] USGS, “M 8.0 - 41 km SW of San Vicente de Cañete, Peru ,” Available at <https://earthquake.usgs.gov/earthquakes/eventpage/usp000fjta/shakemap/intensity>, 2007.

- [14] H. Lovon, N. Tarque, V. Silva, and C. Yepes-Estrada, "Development of fragility curves for confined masonry buildings in lima, peru," *Earthquake Spectra*, vol. 34, no. 3, pp. 1339–1361, 2018.
- [15] K. Torisawa, M. Matsuoka, K. Horie, M. Inoguchi, and F. Yamazaki, "Development of fragility curves for japanese buildings based on integrated damage data from the 2016 kumamoto earthquake," *Journal of Disaster Research*, vol. 17, no. 3, pp. 464–474, 2022.
- [16] "Strong motion seismograph networks (k-net, kik-net)," <https://www.kyoshin.bosai.go.jp/>.
- [17] M. A. Erberik, "Fragility-based assessment of typical mid-rise and low-rise rc buildings in turkey," *Engineering Structures*, vol. 30, no. 5, pp. 1360–1374, 2008.
- [18] USGS, "M 7.8 - 26 km ENE of Nurdađı, Turkey," Available at <https://earthquake.usgs.gov/earthquakes/eventpage/us6000jllz/executive> (2023/02/20), 2023.
- [19] S. Ghaffarian and S. Emtihani, "Monitoring urban deprived areas with remote sensing and machine learning in case of disaster recovery," *Climate*, vol. 9, no. 4, p. 58, 2021.
- [20] J. Kersten, M. Kopitzsch, J. Bongard, and F. Klan, "Combining remote sensing with web-data and machine learning to support humanitarian relief work," in *EGU General Assembly Conference Abstracts*, 2021, pp. EGU21–8621.
- [21] O. Rubel, V. Lukin, A. Rubel, and K. Egiazarian, "Selection of lee filter window size based on despeckling efficiency prediction for sentinel sar images," *Remote Sensing*, vol. 13, no. 10, p. 1887, 2021.
- [22] Z. Sun, H. Geng, Z. Lu, R. Scherer, and M. Woźniak, "Review of road segmentation for sar images," *Remote Sensing*, vol. 13, no. 5, p. 1011, 2021.
- [23] Y. Wang, L. Cui, C. Zhang, W. Chen, Y. Xu, and Q. Zhang, "A two-stage seismic damage assessment method for small, dense, and imbalanced buildings in remote sensing images," *Remote Sensing*, vol. 14, no. 4, p. 1012, 2022.
- [24] V. Zahs, B. Herfort, J. Kohns, T. Ullah, K. Anders, L. Stempniewski, A. Zipf, and B. Höfle, "3d point cloud-based assessment of detailed building damage through a combination of machine learning, crowdsourcing and earthquake engineering," Copernicus Meetings, Tech. Rep., 2021.
- [25] M. Moradi and R. Shah-Hosseini, "Earthquake damage assessment based on deep learning method using vhr images," *Environmental Sciences Proceedings*, vol. 5, no. 1, p. 16, 2020.
- [26] Y. Li, W. Hu, H. Dong, and X. Zhang, "Building damage detection from post-event aerial imagery using single shot multibox detector," *Applied Sciences*, vol. 9, no. 6, p. 1128, 2019.
- [27] N. Takhtkeshha, A. Mohammadzadeh, and B. Salehi, "A rapid self-supervised deep-learning-based method for post-earthquake damage detection using uav data (case study: Sarpol-e zahab, iran)," *Remote Sensing*, vol. 15, no. 1, p. 123, 2022.

- [28] A. Cerbelaud, G. Blanchet, L. Roupioz, P. Breil, and X. Briottet, "Mapping pluvial flood-induced damages with multi-sensor optical remote sensing: A transferable approach," *Remote Sensing*, vol. 15, no. 9, p. 2361, 2023.
- [29] H. Tavera, "Evaluación del peligro asociado a los sismos y efectos secundarios en Perú," 2014. [Online]. Available: <https://repositorio.igp.gob.pe/handle/20.500.12816/777>
- [30] H. Tavera, Y. I. Bernal Esquia, C. Condori Quispe, M. Ordaz, A. Zevallos, and O. Ishizawa, "Re-evaluación del peligro sísmico probabilístico para el Perú," 2014. [Online]. Available: <https://repositorio.igp.gob.pe/handle/20.500.12816/783>
- [31] E. Silgado Ferro, "Historia de los sismos más notables ocurridos en el Perú (1513-1974)-[boletín c 3]," 1978. [Online]. Available: <https://repositorio.ingemmet.gob.pe/handle/20.500.12544/251#files>
- [32] J.-M. Nocquet, J. C. Villegas-Lanza, M. Chlieh, P. Mothes, F. Rolandone, P. Jarrin, D. Cisneros, A. Alvarado, L. Audin, F. Bondoux *et al.*, "Motion of continental slivers and creeping subduction in the northern andes," *Nature Geoscience*, vol. 7, no. 4, pp. 287–291, 2014.
- [33] J. K. Horiuchi, "Manual para la reducción del riesgo sísmico de viviendas en el Perú," *Lima-Perú: Industrias Graficas Ausangate SAC*, 2016.
- [34] Ministerio de Transportes y Comunicaciones, "Sismate: La alerta temprana de sismos y desastres naturales implementada por mtc será operada por el indeci," *Nota de prensa*, Enero 2022. [Online]. Available: <https://www.gob.pe/institucion/mtc/noticias/574558-sismate-la-alerta-temprana-de-sismos-y-desastres-naturales-implementada-por-mtc-sera-operada-p>
- [35] A. G. Macintyre, J. A. Barbera, and E. R. Smith, "Surviving collapsed structure entrapment after earthquakes: a "time-to-rescue" analysis," *Prehospital and disaster medicine*, vol. 21, no. 1, pp. 4–17, 2006.
- [36] M. Kennedy and S. Kopp, *Understanding map projections*, 2000.
- [37] A. Leick, L. Rapoport, and D. Tatarnikov, *GPS satellite surveying*. John Wiley & Sons, 2015.
- [38] C. F. Gauss, *General investigations of curved surfaces of 1827 and 1825*. Princeton university library, 1902.
- [39] E. L. Usery, M. P. Finn, and C. J. Mugnier, "Coordinate systems and map projections," *M. Madden, (Ed-in-Chief), The Manual of Geographic Information Systems. American Society for Photogrammetry and Remote Sensing, Bethesda, Maryland*, pp. 87–112, 2009.
- [40] K.-T. Chang, *Introduction to geographic information systems*. Mcgraw-hill Boston, 2008, vol. 4.
- [41] R. Nicolai and G. Simensen, "The new epsg geodetic parameter registry," in *70th EAGE Conference and Exhibition incorporating SPE EUROPEC 2008*. European Association of Geoscientists & Engineers, 2008, pp. cp–40.

- [42] J. Iliffe, *Datums and map projections for remote sensing, GIS, and surveying*. CRC Press, 2000.
- [43] T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote sensing and image interpretation*. John Wiley & Sons, 2015.
- [44] K. Tempfli, G. Huurneman, W. Bakker, L. L. Janssen, W. Feringa, A. Gieske, K. Grabmaier, C. Hecker, J. Horn, N. Kerle *et al.*, *Principles of remote sensing: an introductory textbook*. International Institute for Geo-Information Science and Earth Observation, 2009.
- [45] H. Maître, *Processing of synthetic aperture radar (SAR) images*. John Wiley & Sons, 2013.
- [46] ESA, “Sentinel 1 mission guide,” 2023. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- [47] ———, “Terrasar-x and tandem-x,” 2023. [Online]. Available: <https://earth.esa.int/eogateway/missions/terrasar-x-and-tandem-x>
- [48] F. Filippini, “Sentinel-1 grd preprocessing workflow,” in *International Electronic Conference on Remote Sensing*. MDPI, 2019, p. 11.
- [49] S. Software, “Help document,” 2019. [Online]. Available: <https://step.esa.int/main/toolboxes/snap/>
- [50] C. Witharana, M. R. Udawalpola, A. K. Liljedahl, M. K. W. Jones, B. M. Jones, A. Hasan, D. Joshi, and E. Manos, “Automated detection of retrogressive thaw slumps in the high arctic using high-resolution satellite imagery,” *Remote Sensing*, vol. 14, no. 17, p. 4132, 2022.
- [51] L. Missions, “Landsat 1,” 2023. [Online]. Available: <https://www.usgs.gov/landsat-missions/landsat-1#:~:text=Aboard%20a%20Delta%209000%20rocket,designed%20to%20study%20planet%20Earth.>
- [52] ESA, “Sentinel 2 mission guide,” 2023. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
- [53] Z. Yang, C. Gong, T. Ji, Y. Hu, and L. Li, “Water quality retrieval from zy1-02d hyperspectral imagery in urban water bodies and comparison with sentinel-2,” *Remote Sensing*, vol. 14, no. 19, p. 5029, 2022.
- [54] NASA, “Avisis,” 2023. [Online]. Available: <https://aviris.jpl.nasa.gov/>
- [55] Y. Li, L. Zhoing, Z. Lai, and Z. Gan, “Instantaneous coastline extraction from lidar point cloud and high resolution remote sensing imagery,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 42, pp. 975–979, 2018.
- [56] NASA, “Global ecosystem dynamics investigation (gedi),” 2023. [Online]. Available: <https://www.earthdata.nasa.gov/sensors/gedi>

- [57] C. M. Bishop and N. M. Nasrabadi, *Pattern recognition and machine learning*. Springer, 2006, vol. 4, no. 4.
- [58] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [59] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- [60] M. A. Nielsen, *Neural networks and deep learning*. Determination press San Francisco, CA, USA, 2015, vol. 25.
- [61] C. A. Cornell, “Engineering seismic risk analysis,” *Bulletin of the seismological society of America*, vol. 58, no. 5, pp. 1583–1606, 1968.
- [62] J. Douglas, “Earthquake ground motion estimation using strong-motion records: a review of equations for the estimation of peak ground acceleration and response spectral ordinates,” *Earth-Science Reviews*, vol. 61, no. 1-2, pp. 43–104, 2003.
- [63] D. J. Wald, V. Quitoriano, T. H. Heaton, and H. Kanamori, “Relationships between peak ground acceleration, peak ground velocity, and modified mercalli intensity in california,” *Earthquake spectra*, vol. 15, no. 3, pp. 557–564, 1999.
- [64] B. A. Bolt, “Earthquakes and geological discovery,” (*No Title*), 1993.
- [65] D. J. Wald, V. Quitoriano, T. H. Heaton, H. Kanamori, C. W. Scrivner, and C. B. Worden, “Trinet “shakemaps”: Rapid generation of peak ground motion and intensity maps for earthquakes in southern california,” *Earthquake Spectra*, vol. 15, no. 3, pp. 537–555, 1999.
- [66] M. Matsuoka and N. Yamamoto, “Web-based quick estimation system of strong ground motion maps using engineering geomorphologic classification map and observed seismic records,” in *Proceedings of the 15th World Conference on Earthquake Engineering, Lisbon, Portugal*, 2012, pp. 24–28.
- [67] M. A. Erberik, *Seismic Fragility Analysis*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, pp. 1–10. [Online]. Available: https://doi.org/10.1007/978-3-642-36197-5_387-1
- [68] K. Pitilakis, H. Crowley, and A. M. Kaynia, “Syner-g: typology definition and fragility functions for physical elements at seismic risk,” *Geotechnical, Geological and Earthquake Engineering*, vol. 27, pp. 1–28, 2014.
- [69] K. Porter, *A Beginner’s Guide to Fragility, Vulnerability, and Risk*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, pp. 1–29. [Online]. Available: https://doi.org/10.1007/978-3-642-36197-5_256-1
- [70] E. Allen, T. Amaya, A. Chamorro, H. Santa María, F. Baratta, H. de Solminihac, and T. Echaveguren, “Development and comparison of seismic fragility curves for bridges based on empirical and analytical approaches,” *Structure and Infrastructure Engineering*, vol. 19, no. 7, pp. 949–963, 2023.

- [71] L. Gueguen and R. Hamid, "Large-scale damage detection using satellite imagery," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1321–1328.
- [72] F. Yamazaki, Y. Yano, and M. Matsuoka, "Visual damage interpretation of buildings in bam city using quickbird images following the 2003 bam, iran, earthquake," *Earthquake Spectra*, vol. 21, no. 1_suppl, pp. 329–336, 2005.
- [73] W. Liu, F. Yamazaki, H. Gokon, and S.-i. Koshimura, "Extraction of tsunami-flooded areas and damaged buildings in the 2011 tohoku-oki earthquake from terrasars-x intensity images," *Earthquake Spectra*, vol. 29, no. 1_suppl, pp. 183–200, 2013.
- [74] L. Moya, A. Muhari, B. Adriano, S. Koshimura, E. Mas, L. R. Marval-Perez, and N. Yokoya, "Detecting urban changes using phase correlation and l1-based sparse model for early disaster response: A case study of the 2018 sulawesi indonesia earthquake-tsunami," *Remote Sensing of Environment*, vol. 242, p. 111743, 2020.
- [75] Y. Bai, C. Gao, S. Singh, M. Koch, B. Adriano, E. Mas, and S. Koshimura, "A framework of rapid regional tsunami damage recognition from post-event terrasars-x imagery using deep neural networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 1, pp. 43–47, 2017.
- [76] J. Tu, H. Sui, W. Feng, and Z. Song, "Automatic building damage detection method using high-resolution remote sensing images and 3d gis model," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3, pp. 43–50, 2016.
- [77] X. You, J. Meng, M. Zhang, and T. Dong, "Remote sensing based detection of crop phenology for agricultural zones in china using a new threshold method," *Remote Sensing*, vol. 5, no. 7, pp. 3190–3211, 2013.
- [78] Y. Su, H. Yu, X. Sun, L. Gao, and X. Chen, "A target detection method with morphological knowledge for high-spatial resolution remote sensing image applying for search and rescue in aviation disaster," in *Land Surface Remote Sensing II*, vol. 9260. SPIE, 2014, pp. 360–367.
- [79] J. Wang, Q. Qin, J. Zhao, X. Ye, X. Qin, X. Yang, J. Wang, X. Zheng, and Y. Sun, "A knowledge-based method for road damage detection using high-resolution remote sensing image," in *2015 IEEE international geoscience and remote sensing symposium (IGARSS)*. IEEE, 2015, pp. 3564–3567.
- [80] K. Zhao, J. Liu, Q. Wang, X. Wu, and J. Tu, "Road damage detection from post-disaster high-resolution remote sensing images based on tld framework," *IEEE Access*, vol. 10, pp. 43 552–43 561, 2022.
- [81] J. Cui, Y. Guo, Q. Xu, D. Li, W. Chen, L. Shi, G. Ji, and L. Li, "Extraction of information on the flooding extent of agricultural land in henan province based on multi-source remote sensing images and google earth engine," *Agronomy*, vol. 13, no. 2, p. 355, 2023.

- [82] B. Gaffinet, R. Hagenseker, L. Loi, and G. Schumann, "Supervised machine learning for flood extent detection with optical satellite data," in *IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2023, pp. 2084–2087.
- [83] G. Abdi, M. Esfandiari, and S. Jabari, "Building damage detection in post-event high-resolution imagery using deep transfer learning," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. IEEE, 2021, pp. 531–534.
- [84] M. Zhang and Z. Chen, "Deep metric learning for damage detection using bitemporal satellite images," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. IEEE, 2021, pp. 562–565.
- [85] L. Moya, C. Geiß, M. Hashimoto, E. Mas, S. Koshimura, and G. Strunz, "Disaster intensity-based selection of training samples for remote sensing building damage classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 59, no. 10, pp. 8288–8304, 2021.
- [86] T.-T.-H. Pham, P. Apparicio, C. Gomez, C. Weber, and D. Mathon, "Synthesis report on current resources of land and biomass to produce bio-energy in the upper rhine region (urr)," p. 15, 06 2014.
- [87] C. Sun, H. Chen, C. Du, and N. Jing, "Semibuildingchange: A semi-supervised high-resolution remote sensing image building change detection method with a pseudo bitemporal data generator," *IEEE Transactions on Geoscience and Remote Sensing*, 2023.
- [88] A. Cerbelaud, L. Roupioz, G. Blanchet, P. Breil, and X. Briottet, "Supervised classification methods for automatic damage detection caused by heavy rainfall using multitemporal high resolution optical imagery and auxiliary data," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 43, pp. 693–700, 2021.
- [89] Earth Observation Center, "World settlement footprint 2019," Available at <https://download.geoservice.dlr.de/WSF2019/> (2023/02/17), 2019.
- [90] L. Moya, E. Mas, F. Yamazaki, W. Liu, and S. Koshimura, "Statistical analysis of earthquake debris extent from wood-frame buildings and its use in road networks in japan," *Earthquake Spectra*, vol. 36, no. 1, pp. 209–231, 2020.
- [91] B. Wei, G. Nie, G. Su, L. Sun, X. Bai, and W. Qi, "Risk assessment of people trapped in earthquake based on km grid: a case study of the 2014 ludian earthquake, china," *Geomatics, Natural Hazards and Risk*, vol. 8, no. 2, pp. 1289–1305, 2017.
- [92] The Independent, "Watch again: View from hatay after third quake hits turkey," Available at <https://youtu.be/QkSjKtSj7Ls> (2023/02/21), February 2023.
- [93] H. Tanikawa, S. Managi, and C. M. Lwin, "Estimates of lost material stock of buildings and roads due to the great east japan earthquake and tsunami," *Journal of Industrial Ecology*, vol. 18, no. 3, pp. 421–431, 2014.

- [94] S. García-Torres, R. Kahhat, and S. Santa-Cruz, “Methodology to characterize and quantify debris generation in residential buildings after seismic events,” *Resources, Conservation and Recycling*, vol. 117, pp. 151–159, 2017.

