



UNIVERSIDAD DE CONCEPCIÓN
Facultad de Ciencias Químicas
Departamento Ciencias de la Tierra



IDENTIFICACIÓN DE REMOCIONES EN MASA EN EL SUR DE CHILE CON MODELOS DE CLASIFICACIÓN DE IMÁGENES SATELITALES SENTINEL-2 Y LANDSAT-8

Memoria para optar al Título de Geólogo

Alberto Felipe Cortés González

Profesor Guía:
Profesores Comisión:

Dr. José Luis Palma Lizana
Dr. Ivo Janos Fustos Toribio
Dr. Jorge Andrés Quezada Flory

Concepción, 2025

A quienes están y a quienes ya partieron:

La vida me llevó a estudiar la tierra, esa misma tierra que los forma a ustedes,

Ustedes, que algún día serán parte de mí,

Como yo seré parte de ella,

Y así, nos volveremos a encontrar.

RESUMEN

1. INTRODUCCIÓN	1
1.1. PLANTEAMIENTO DEL PROBLEMA	1
1.2. OBJETIVOS.....	2
1.2.1. Objetivo general	2
1.2.2. Objetivos específicos	2
1.3. AGRADECIMIENTOS	2
2. MARCO TEÓRICO	4
2.1. PELIGRO Y RIESGO GEOLÓGICO	4
2.1.1. Peligro geológico	4
2.1.2. Exposición	4
2.1.3. Vulnerabilidad	4
2.1.4. Susceptibilidad	5
2.1.5. Riesgo	5
2.2. REMOCIONES EN MASA	5
2.2.1. Definición	6
2.2.2. Tipos de remociones en masa	6
2.2.2.1. Caídas o desprendimientos	6
2.2.2.2. Volcamientos o topples	7
2.2.2.3. Deslizamientos:	8
2.2.2.4. Flujos	9
2.2.2.5. Extensiones laterales.....	10
2.3. FACTORES CONDICIONANTES AL DESARROLLO DE REMOCIONES EN MASA.....	10
2.3.1. Geología	11
2.3.1.1. Litología	11
2.3.1.2. Grado de alteración y/o meteorización.....	12
2.3.1.3. Estructuras	12
2.3.2. Geomorfología	12
2.3.2.1. Pendiente	13
2.3.2.2. Orientación de la ladera.....	13
2.3.2.3. Cercanía a las redes de drenaje.....	13
2.3.3. Factor antropogénico y uso de suelo	13

2.4.	FACTORES DESENCADENANTES DE REMOCIONES EN MASA	14
2.4.1.	Precipitaciones	14
2.4.2.	Sismos	15
2.5.	HERRAMIENTAS GEOESPACIALES Y DE TELEDETECCIÓN	15
2.5.1.	Plataformas satelitales	15
2.5.1.1.	Landsat 8	15
2.5.1.2.	Sentinel 2	16
2.5.2.	Cálculo e interpretación de índices	17
2.5.2.1.	NDVI	17
2.5.2.2.	GNDVI	18
2.5.2.3.	SAVI	18
2.5.2.4.	NDWI	19
2.5.2.5.	BSI.....	20
2.5.2.6.	NDSI.....	20
2.5.2.7.	NBR.....	21
2.5.3.	Detección de remociones en masa con imágenes satelitales	22
2.5.3.1.	Diferencia de imagen para detección de cambios	23
2.6.	TÉCNICAS DE CLASIFICACIÓN.....	23
2.6.1.	K-means	23
2.6.2.	k-NN	24
2.7.	MÉTRICAS DE EVALUACIÓN DE MODELOS DE CLASIFICACIÓN	26
3.	METODOLOGÍA	28
3.1.	CONTEXTO Y REVISIÓN BIBLIOGRÁFICA.....	28
3.2.	PREPROCESAMIENTO DE IMÁGENES Y CREACIÓN DE INVENTARIOS CON ÍNDICES ESPECTRALES RELEVANTES	29
3.2.1.	Definición del área de interés (AOI)	30
3.2.2.	Filtrado de imágenes y enmascaramiento de nubes	30
3.2.3.	Enmascaramiento de nieve	31
3.2.4.	Cálculo de índices	31
3.2.5.	Cálculo de medias de las colecciones pre y post evento	31
3.2.6.	Cálculo de diferencias para índices y creación de imagen de diferencias ..	32
3.2.7.	Exportación de imágenes	32
3.3.	MODELO UMBRAL NDVI	33
3.3.1.	Carga de imágenes y máscaras de entrenamiento	33

3.3.2.	Procesamiento de imágenes	34
3.3.3.	Evaluación de predicciones	34
3.3.4.	Visualización y análisis	34
3.3.5.	Exporte de resultados	35
3.4.	MODELO K-MEANS	35
3.4.1.	Carga de imágenes y máscaras	36
3.4.2.	Preprocesamiento de datos	36
3.4.3.	Aplicación de K-means	36
3.4.4.	Generación de predicciones	36
3.4.5.	Evaluación de las predicciones	37
3.4.6.	Visualización y análisis	37
3.5.	CREACIÓN DE MÁSCARAS Y PREPROCESAMIENTO DE DATOS RÁSTER ...	38
3.5.1.	Instalación y configuración de librerías	38
3.5.2.	Verificación de la compatibilidad de CRS	39
3.5.3.	Generación de máscaras	39
3.5.4.	Visualización de imágenes y máscaras	40
3.6.	CLASIFICACIÓN CON EL MÉTODO K-NEAREST NEIGHBORS (K-NN)	40
3.6.1.	Importe de librerías	41
3.6.2.	Carga y procesamiento de datos	41
3.6.3.	Aumento de datos	41
3.6.4.	Aplicación del modelo k-NN	42
3.6.5.	Aplicación de postprocesamiento	42
3.6.6.	Reconstrucción y visualización de resultados	42
4.	RESULTADOS	44
4.1.	INVENTARIO	44
4.2.	MODELO UMBRAL BASADO EN NDVI	45
4.3.	MODELO K-MEANS	49
4.4.	MODELO K-NN JUNTO A POSTPROCESAMIENTO	52
5.	DISCUSIÓN	57
5.1.	TÉCNICAS DE CLASIFICACIÓN	57
5.2.	LIMITACIONES DEL MODELO Y DE LOS DATOS DISPONIBLES	58
5.2.1.	Resolución espacial de las imágenes satelitales	58
5.2.2.	Cobertura nubosa y condiciones atmosféricas	59
5.2.3.	Falta de inventarios de remociones en masa	59

5.3.	RECOMENDACIONES PARA TRABAJOS FUTUROS.....	60
6.	CONCLUSIÓN	61
7.	REFERENCIAS	62
	ANEXOS	68

ÍNDICE DE FIGURAS

Figura		Página
2.	1. Caída de rocas y caída de suelo extraídas de González de Vallejo <i>et al.</i> , 2002.....	7
2.	2. Volcamientos o topples extraída desde González de Vallejo <i>et al.</i> , 2002.....	8
2.	3. Deslizamientos traslacionales extraída desde González de Vallejo <i>et al.</i> , 2002.....	9
2.	4. Deslizamientos rotacionales extraída desde González de Vallejo <i>et al.</i> , 2002.....	9
2.	5. Tipos de flujos, extraídos desde González de Vallejo <i>et al.</i> , 2002.....	10
2.	6. Extensiones laterales, extraídas desde González de Vallejo <i>et al.</i> , 2002.....	10
2.	7. Modelo de satélite Landsat 8.....	15
2.	8. Modelos de satélites Sentinel 2a y 2b.....	16
2.	9. Ejemplo del clustering de K-means.....	24
2.	10. Ejemplo del algoritmo k-NN.....	25
3.	1. Diagrama de flujo de la Metodología.....	29
3.	2. Diagrama de flujo del script de GEE.....	30
3.	3. Ploteo de diferencias de NDVI, NDWI y BSI junto a imagen RGB.....	32
3.	4. Diagrama de flujo del Modelo umbral NDVI.....	33
3.	5. Diagrama de flujo del Modelo K-means.....	35
3.	6. Ejemplo de clustering de K-means con imagen RGB	37
3.	7. Diagrama de flujo del script de creación de máscaras.....	38
3.	8. Ejemplo de máscara binaria.....	39
3.	9. Diagrama de flujo del Modelo k-NN.....	40
4.	1. Inventario de remociones en masa.....	45
4.	2. Extracto del script del Modelo umbral NDVI.....	46
4.	3. Visualización de predicciones del Modelo umbral NDVI (1).....	47
4.	4. Visualización de predicciones del Modelo umbral NDVI (2).....	47

4.	5. Matriz de confusión y métricas del Modelo umbral NDVI.....	48
4.	6. Visualización de predicciones del Modelo K-means.....	50
4.	7. Matriz de confusión del Modelo K-means.....	51
4.	8. Visualización de predicciones del Modelo k-NN.....	53
4.	9. Matriz de confusión del Modelo k-NN.....	54
4.	10. Visualización de las predicciones antes y después de postprocesar.....	55
4.	11. Matriz de confusión del Modelo k-NN postprocesado.....	56

ÍNDICE DE TABLAS

Tabla		Página
2.	1. Bandas Landsat 8.....	16
2.	2. Bandas Sentinel-2.....	17
2.	3. Matriz de confusión de clasificación binaria.....	26
4.	1. Métricas del Modelo K-means.....	51
4.	2. Comparación de métricas del Modelo k-NN con y sin postprocesamiento.....	56

RESUMEN

El presente trabajo tiene como objetivo desarrollar un modelo de clasificación para la detección de remociones en masa mediante imágenes satelitales. El área de estudio se centra en eventos de remoción en masa en el sur de Chile, utilizando imágenes de Landsat 8 para eventos anteriores a 2019 y Sentinel-2 para los posteriores a esa fecha, debido a la cobertura temporal limitada de estos satélites. El análisis se enfoca en la comparación de índices de vegetación pre y post evento, como NDVI, NBR y SAVI.

El conjunto de datos utilizado incluye 33 eventos mapeados a través de fotointerpretación en plataformas como Google Earth y Google Earth Engine, y validados con informes técnicos de SERNAGEOMIN. Se emplearon bandas espectrales RGB y diferencias de índices entre imágenes pre y post evento para generar características que permiten distinguir entre remociones y no remociones. Se aplicaron diferentes técnicas de clasificación, comenzando con un umbral de diferencia en el índice NDVI para detectar remociones en masa. Luego, se empleó clustering no supervisado con KMeans para explorar patrones de clasificación sin la necesidad de etiquetas. Finalmente, se implementó un modelo supervisado con KNN, que demostró ser el más preciso al trabajar con las etiquetas y aprendizaje supervisado.

Los resultados obtenidos facilitan la identificación de eventos de remoción en masa, mejorando el monitoreo y ayudando en la toma de decisiones sobre gestión de riesgos, especialmente en áreas de difícil acceso, donde el monitoreo terrestre es limitado. Las métricas del modelo KNN, evaluadas antes y después del postprocesamiento, mostraron mejoras significativas. Después del ajuste, el modelo alcanzó un F1-Score de 0.86 para las remociones, con una precisión de 0.88 y un recall de 0.83, y mostró una precisión de 0.88, con un *accuracy* de 0.98. El postprocesamiento, basado en la eliminación de áreas pequeñas en las predicciones de remociones mediante componentes conectados, contribuyó a una mayor precisión y redujo el ruido en las predicciones. Con estos resultados, se confirma que el modelo KNN, combinado con las imágenes de Sentinel-2 y Landsat 8, junto con las técnicas de Machine Learning, entregan un método sólido para la identificación y clasificación de remociones en masa, ofreciendo herramientas útiles para la gestión de riesgos y la planificación de medidas preventivas en zonas vulnerables.

1. INTRODUCCIÓN

1.1. PLANTEAMIENTO DEL PROBLEMA

Los procesos de remoción en masa son fenómenos gravitacionales que involucran el desplazamiento, ya sea lento o rápido, de una cantidad específica de suelo, roca o una mezcla de ambos, en diferentes proporciones y velocidades. Estos procesos son las manifestaciones morfodinámicas más comunes en la inestabilidad de las laderas. Los principales factores internos que contribuyen a estos fenómenos incluyen: las características litológicas (como el tipo de roca, el grado de meteorización y la permeabilidad), las características estructurales (como la presencia de diaclasas y/o fallas), los rasgos morfológicos del terreno (como la topografía, las pendientes y la altura) y la densidad de la cobertura vegetal (Mardones y Rojas, 2012). Estos procesos se clasifican según el tipo de movimiento y el material involucrado como, por ejemplo, caídas de roca, deslizamientos de suelo o flujos de detritos (Cruden y Varnes, 1996; González de Vallejo *et al.*, 2002 y Hungr *et al.*, 2014).

El sur de Chile presenta un relieve en constante transformación, altamente susceptible a fenómenos naturales como terremotos, erupciones volcánicas y eventos climáticos extremos (Sepúlveda *et al.*, 2010; Korup *et al.*, 2019 y Morales *et al.*, 2021). La interacción de estos procesos, en diferentes niveles de intensidad, ha generado una respuesta dinámica en el paisaje, intensificando la actividad de remociones en masa y, por lo tanto, aumentando el riesgo para las comunidades que habitan las zonas montañosas y costeras de la región (Somos-Valenzuela *et al.*, 2020). Para estudiar la susceptibilidad a estos eventos y la evolución del paisaje mediante el ajuste de modelos, es crucial contar con inventarios de remociones en masa que permitan establecer la relación entre las condiciones climáticas y geomorfológicas locales (Guzetti *et al.*, 2012). Sin embargo, debido a las dificultades de acceso, estos inventarios son limitados en áreas montañosas y en regiones con baja densidad poblacional, lo que dificulta un análisis exhaustivo de los procesos.

En este estudio se propone desarrollar un modelo predictivo innovador que integre técnicas avanzadas de análisis de imágenes satelitales, procesamiento de datos geoespaciales y aprendizaje automatizado. El objetivo es utilizar imágenes satelitales para identificar y caracterizar áreas donde han ocurrido remociones en masa en el sur de Chile. A partir de caracterizaciones in situ de algunas

de estas remociones en masa obtenidas de la literatura, se podrán correlacionar estas características con parámetros obtenidos de las imágenes satelitales, y así crear un modelo automatizado que podrá reconocer remociones en masa de manera automatizada. Al mejorar la capacidad de detección y caracterización de las remociones en masa en el sur de Chile, se busca mejorar el conocimiento de estos fenómenos para reducir sus impactos en los asentamientos humanos, y establecer un modelo replicable para estos fenómenos en otras regiones del país.

1.2. OBJETIVOS

1.2.1. Objetivo general

Desarrollar un modelo automatizado para la detección y caracterización de remociones en masa en el sur de Chile en base a imágenes satelitales y descripciones de terreno.

1.2.2. Objetivos específicos

- Identificar remociones en masa en el sur de Chile a partir del análisis de imágenes satelitales y descripciones de terreno, aplicando algoritmos desarrollados en Python.
- Desarrollar un modelo de identificación y caracterización usando algoritmos de aprendizaje automático, validados con información obtenida a partir de bibliografía.

1.3. AGRADECIMIENTOS

Quiero expresar mi profundo agradecimiento al profesor José Luis Palma por todo el apoyo, tiempo y dedicación que me brindó. Sus consejos y la propuesta de ideas útiles fueron un aporte clave para este trabajo, ayudándome a resolver problemas y a avanzar con mayor claridad.

También agradezco a Jorge Quezada, Ivo Fustos y a Francisco Castro, quienes siempre estuvieron dispuestos a ayudar y fueron muy pacientes conmigo durante este proceso. A todos ellos, gracias por su apoyo y por compartir su conocimiento conmigo.

Quiero también mencionar a la gente del DCT: don Pedro, Jose y la señora Angélica, quienes hicieron que las visitas al cerro fueran mucho más agradables. Las anécdotas que compartieron

conmigo, los desayunos que me invitaron y el cariño que me demostraron durante este tiempo hicieron que la experiencia fuera realmente grata.

También quiero reconocer a mi gente de la U, a quienes me bancaron durante estos 6 años. A los Monos, a Palmo, Millanao, a los Guatones, Guatonas y a todos los que compartieron este tiempo conmigo. Gracias por tantas experiencias, risas, alegrías y por también estar en los malos. Han sido un montón de buenos momentos, y espero sigan siendo más.

A mis amigos de Cauquenes, a los que llevan estando mucho tiempo y los que la vida nos hizo que nos volviéramos a reencontrar, gracias por soportarme tanto, mis panitas Arturo, Chris y Cristóbal.

A mi familia, que siempre me apoyó y se interesó por mi bienestar y desafíos personales. A mis hermanas queridas, a mi viejo, a la Edu, a mis abuelos y al resto que de alguna u otra forma, se hicieron presentes en algún momento.

Finalmente, no tengo palabras suficientes para agradecer a las dos personas que son las responsables de que haya llegado hasta aquí. Aquellas que me aconsejaron en cada momento de duda, que apoyaron todas mis ideas y me levantaron cada vez que caí. No tengo la menor duda de que no hubiera llegado hasta este punto sin su tremendo apoyo y cariño. Siempre estaré profundamente agradecido con ustedes. Gracias, Mamá y Naranjita.

A todas y a todos, este logro no es solo mío, sino también de ustedes.

Gracias totales.

2. MARCO TEÓRICO

En este capítulo, se presentan las principales definiciones relacionadas con la terminología y los procesos clave para el estudio de las remociones en masa. Además, se incluye información relevante sobre el uso de imágenes satelitales y cómo estos procesos geológicos se manifiestan a través de dichas imágenes. Esta información ha sido recopilada a partir de una revisión de la literatura de diversos autores especializados en esta área.

2.1. PELIGRO Y RIESGO GEOLÓGICO

A continuación, se definen algunos términos asociados al peligro y riesgo geológico.

2.1.1. Peligro geológico

El peligro geológico se refiere a un evento o proceso natural, como remociones en masa, tsunamis o terremotos, originado por la dinámica interna o superficial del planeta, que posee el potencial de causar daños significativos, incluyendo muertes o lesiones, pérdidas materiales, interrupción de actividades sociales y económicas, o deterioro ambiental (SERNAGEOMIN, 2018).

Este concepto puede expresarse como la probabilidad de que un fenómeno de determinada intensidad ocurra en un área específica dentro de un periodo de tiempo dado. Su evaluación requiere analizar dónde y cuándo ocurrieron procesos similares en el pasado, su intensidad y magnitud, las áreas susceptibles a futuros eventos, y la frecuencia con que pueden ocurrir, considerando factores desencadenantes y periodos de retorno (González de Vallejo *et al.*, 2002).

2.1.2. Exposición

Hace referencia a la presencia de población, propiedades, sistemas u otros elementos en áreas donde existen amenazas naturales, lo que implica que están susceptibles a sufrir posibles pérdidas (UN/ISDR, 2009).

2.1.3. Vulnerabilidad

Se define como las características y las circunstancias de una comunidad, sistema o bien que los hacen susceptibles a los efectos dañinos de una amenaza. Estas características y circunstancias determinan el grado en que estos elementos pueden ser afectados negativamente por eventos

adversos, evidenciando su susceptibilidad a sufrir daños en caso de que ocurra una amenaza (UN/ISDR, 2009).

2.1.4. Susceptibilidad

Se define como la capacidad o potencial de una unidad geológica o geomorfológica para ser afectada por un proceso geológico específico. Este concepto representa la posibilidad espacial de que ocurra un evento, sin establecer una relación directa con la probabilidad de suceder dicho proceso en el tiempo (SERNAGEOMIN, 2022).

2.1.5. Riesgo

La combinación de la probabilidad de que ocurra un evento y las consecuencias negativas asociadas a dicho evento (UN/ISDR, 2009).

El riesgo puede definirse, según Varnes (1978), como el grado de pérdidas esperadas durante un periodo de tiempo determinado debido a la ocurrencia de un fenómeno específico. Este concepto se basa en la interacción de tres factores fundamentales: la peligrosidad del proceso, que representa la probabilidad de que ocurra el fenómeno; la vulnerabilidad de los elementos expuestos, que mide el grado en que estos pueden ser afectados; y la exposición, que corresponde a los elementos en riesgo. Si alguno de estos factores es nulo, el riesgo será inexistente. Además, el riesgo puede incrementarse por la ocupación de zonas peligrosas o la construcción de estructuras vulnerables, y puede reducirse actuando sobre la peligrosidad, la vulnerabilidad o la exposición. Se representa con la siguiente ecuación:

$$R = P * V * E$$

R= Riesgo; P= Peligro; V= Vulnerabilidad; E= Exposición

2.2. REMOCIONES EN MASA

A continuación, se presentan definiciones relacionadas a las remociones en masa, así como también, sus diferentes tipos y clasificaciones.

2.2.1. Definición

Se definen como movimientos de grandes volúmenes de suelo o roca que se desplazan relativamente sobre una o varias superficies de ruptura, superando la resistencia al corte de estas superficies. La masa afectada generalmente se desplaza en equilibrio hacia la base de la pendiente debido a la pérdida de resistencia, la presencia de agua, o la inclinación del terreno, es decir, son procesos gravitacionales inducidos por una combinación de factores. Las remociones en masa se pueden clasificar según el tipo de movimiento y material involucrado (Varnes, 1996; González de Vallejo *et al.*, 2002 y Hungr *et al.*, 2014).

2.2.2. Tipos de remociones en masa

Debido a la diversidad de condiciones bajo las cuales pueden ocurrir los procesos de remoción en masa, existen varias formas de clasificarlos. En este trabajo, se utilizará la clasificación de Hungr *et al.*, (2014) y González de Vallejo *et al.*, (2002), los cuales se basan en el trabajo de Varnes (1978), la cual utiliza dos criterios principales: el tipo de movimiento y el tipo de material. Según esta clasificación, existen cinco tipos principales de movimientos: caída, volcamiento, deslizamiento, extensiones laterales y flujo. Los materiales se dividen en rocas y suelos, estos últimos a su vez subdivididos en detritos y tierra.

2.2.2.1. Caídas o desprendimientos

Son movimientos muy rápidos en los que bloques o masas rocosas caen libremente luego de desprenderse a lo largo de planos de discontinuidad preexistentes (fallas, diaclasas, planos de estratificación, etc.). Estos ocurren con frecuencia en las laderas de zonas montañosas escarpadas, acantilados y, en general, en paredes rocosas. Es común que las roturas sean forma de cuña o bloques, los cuales están separados por varias familias de discontinuidades. Las caídas (Figura 2.1) son provocadas por la erosión y la pérdida de apoyo de los bloques previamente sueltos, la infiltración de agua en las debilidades y grietas, sismos, entre otros. Los procesos de volcamiento (*topple*) pueden incluirse dentro de los desprendimientos, lo que dificulta a veces diferenciarlos claramente (González de Vallejo *et al.*, 2002).

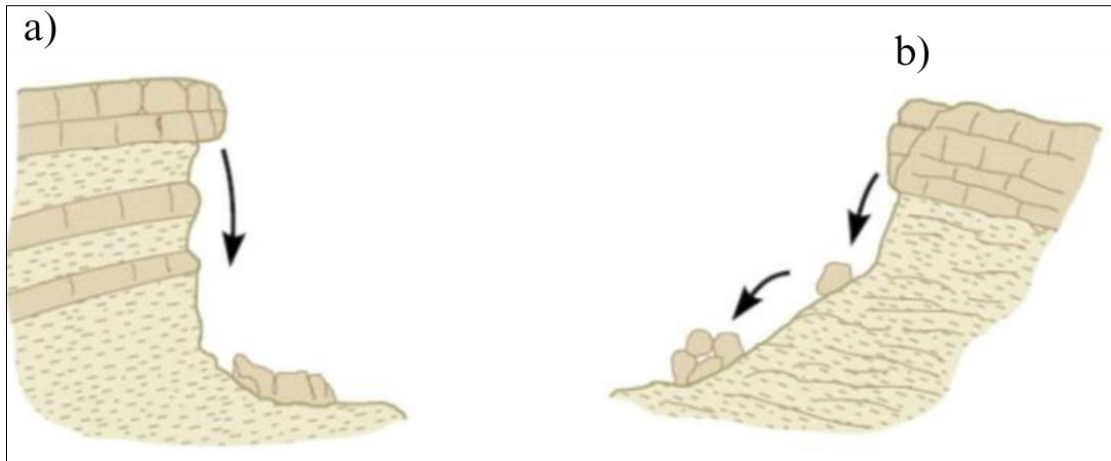


Figura 2.1: Caída de rocas y caída de suelo. Extraída desde González de Vallejo *et al.*, (2002).

2.2.2.2. Volcamientos o topples

Este tipo de movimiento consiste en la rotación hacia adelante de una o varias unidades de material térreo con centro un de giro por debajo del centro de gravedad de la unidad (Figura 2.2) y generalmente, ocurren en las formaciones rocosas (Suárez, 1998).

Se encuentran influenciados por la acción de la gravedad y las fuerzas ejercidas por unidades adyacentes o por fluidos en las grietas (Highland, 2008).

Volcamiento de bloques:

Se caracteriza por la rotación hacia adelante y el volcamiento de columnas o placas de roca, ya sea una o varias, separadas por diaclasas con inclinaciones pronunciadas. Estas rocas, que poseen una estructura relativamente masiva y compacta, experimentan rotación sobre discontinuidades basales bien definidas. Aunque el movimiento puede iniciarse de manera lenta, la etapa final de la falla puede ser extremadamente rápida. Ocurre a todas las escalas (Hungry *et al.*, 2014).

Volcamiento flexural:

Consiste en la flexión y rotación hacia adelante de una masa rocosa, caracterizada por la presencia de diaclasas o planos de esquistosidad muy cercanos entre sí, con una inclinación pronunciada y dispuestos de manera perpendicular a la dirección en que la pendiente cae. La roca es relativamente débil y fisible. El movimiento generalmente es lento y tiende a estabilizarse por sí mismo. Sin

embargo, puede desarrollarse un deslizamiento rotacional secundario en la zona de la bisagra del volcamiento. Ocurre a gran escala (Hungry *et al.*, 2014).




Figura 2.2: Volcamientos o topples. Extraída desde González de Vallejo *et al.*, (2002).

2.2.2.3. Deslizamientos:

Corresponden a movimientos de masas de suelo o roca que se desplazan relativamente respecto al sustrato, deslizándose sobre una o varias superficies de roturas netas al superarse la resistencia al corte de estas superficies. En general, la masa se mueve en conjunto, comportándose como una unidad en su recorrido; la velocidad puede ser muy variable, pero tienden a ser procesos rápidos y a alcanzar grandes volúmenes (González de Vallejo *et al.*, 2002).

Deslizamientos traslacionales:

Suelen ser menos profundos, aunque pueden abarcar grandes extensiones y recorrer grandes distancias. La rotura ocurre a lo largo de superficies planas de debilidad preexistentes (planos de estratificación, contactos, etc.). Generalmente, los deslizamientos traslacionales (Figura 2.3) son más rápidos que los rotacionales debido a las características cinemáticas del mecanismo de rotura (González de Vallejo *et al.*, 2002).

Deslizamientos rotacionales:

Ocurren con mayor frecuencia en suelos cohesivos homogéneos. La rotura, que puede ser superficial o profunda, se produce a lo largo de superficies curvas o en forma de cuchara (Figura 2.4). Una vez que comienza la inestabilidad, la masa inicia una rotación, que puede fragmentarse

en varios bloques que se deslizan entre sí, generando escalones con superficies inclinadas hacia la ladera y grietas de tracción estriadas (González de Vallejo *et al.*, 2002).




Figura 2.3: Deslizamientos traslacionales. Extraída desde González de Vallejo *et al.*, (2002).




Figura 2.4: Deslizamientos rotacionales. Extraída desde González de Vallejo *et al.*, (2002).

2.2.2.4. Flujos

Corresponden a movimientos de masas de suelo (flujos de barro o tierra), derrubios (coladas de derrubios o *debris flow*) o bloques rocosos (coladas de fragmentos rocosos) que contienen una abundante cantidad de agua (Figura 2.5). En estos casos, el material está disgregado y se comporta como un fluido, sufriendo una deformación continua sin la presencia de superficies de rotura definidas. El agua es el principal agente desencadenante, ya que provoca una pérdida significativa de resistencia en materiales poco cohesivos. Estos flujos, afectan principalmente a suelos arcillosos susceptibles que son susceptibles a perder resistencia cuando son movilizados (González de Vallejo *et al.*, 2002).




Figura 2.5: Flujos, de tierra, de detritos y avalancha de rocas respectivamente. Extraída desde González de Vallejo *et al.*, (2002).

2.2.2.5. Extensiones laterales

Corresponden al movimiento de bloques rocosos o masas de suelo muy coherentes y cementadas que se desplazan sobre un material blando y deformable (Figura 2.6). Estos movimientos son producidos por la pérdida de resistencia del material subyacente, que fluye o se deforma bajo el peso de los bloques rígidos. Los desplazamientos laterales también pueden ser provocados por licuefacción del material infrayacente, o por procesos de extrusión lateral de arcillas blandas y húmedas bajo el peso de las masas superiores. Este tipo de movimientos ocurre en laderas suaves y pueden ser muy extensos (González de Vallejo *et al.*, 2002).




Figura 2.6: Extensiones laterales. Extraída desde González de Vallejo *et al.*, (2002).

2.3. FACTORES CONDICIONANTES AL DESARROLLO DE REMOCIONES EN MASA

Se le llama así a cualquier factor que pueda crear una situación potencialmente peligrosa y, por ende, influye en la susceptibilidad de desencadenar un fenómeno de remoción en masa (Campos,

2014). Dentro de los factores condicionantes, las propiedades físicas y resistentes de los materiales (que están directamente relacionadas con la litología) y las características morfológicas y geométricas (pendiente, por ejemplo) de la ladera son fundamentales para la predisposición a la inestabilidad. Otros factores importantes incluyen la estructura geológica y las discontinuidades, las condiciones hidrogeológicas y los estados tenso-deformacionales (González de Vallejo *et al.*, 2002).

2.3.1. Geología

La geología es un factor condicionante clave en la ocurrencia de deslizamientos de tierra, ya que la composición, estructura y alteración de los materiales geológicos influyen directamente en su estabilidad. Los depósitos volcanoclásticos, aluviales, coluviales y de antiguos flujos de detritos, por su alta permeabilidad, facilitan la infiltración de agua y la saturación rápida, lo que aumenta la probabilidad de deslizamientos en pendientes (Hauser, 1997). En términos generales, esto también se aplica a materiales sueltos, incluyendo depósitos de deslizamientos previos, desprendimientos y laderas con movimientos lentos como la reptación o solifluxión (Hauser, 1993). En contraste, en materiales menos permeables, como los de grano fino, densos, arcillosos o rocosos con pocas fracturas, el agua superficial se desplaza más rápidamente debido a la baja capacidad de infiltración y a la menor rugosidad de sus estructuras (Jacoby, 2001).

La granulometría del material también influye en la estabilidad del terreno; suelos finos, como las arcillas, tienen alta cohesión, lo que puede generar superficies de deslizamiento bajo condiciones de saturación. Además, la densidad y la permeabilidad del suelo afectan el flujo de agua y la capacidad de retención, influyendo en la saturación y la resistencia al deslizamiento (Lambe y Whitman, 1972). Por último, las características litológicas y estructurales de las rocas, como las diaclasas y las fallas, pueden debilitar la roca y facilitar la formación de planos de deslizamiento (González de Vallejo *et al.*, 2002).

2.3.1.1. Litología

La litología es un factor importante en la caracterización de las rocas y partículas mayores en suelos, ya que influye en su resistencia y estabilidad. La composición y granulometría del material determinan sus propiedades mecánicas, influyendo directamente en su comportamiento en laderas.

En suelos finos, la plasticidad y humedad condicionan su grado de cohesión, y en el caso de las arcillas, pueden generar superficies potenciales de deslizamiento bajo cargas determinadas. Por otra parte, en suelos gruesos, como los arenosos, la cohesión y resistencia varían dependiendo de la humedad presente, influyendo directamente en su estabilidad (Lara, 2008).

La naturaleza del material de la roca está directamente relacionada con la inestabilidad que esta puede sufrir, ya que distintas litologías presentan diversos grados de susceptibilidad ante la ocurrencia de deslizamientos (González de Vallejo *et al.*, 2002).

2.3.1.2. Grado de alteración y/o meteorización

En el caso de rocas o la caracterización de partículas mayores en suelos, la litología cumple un rol fundamental en la resistencia a los procesos de meteorización y alteración. La presencia de minerales secundarios, como zeolitas, arcillas, sericita y clorita (típicos de alteraciones hidrotermales), acelera los procesos de meteorización, afectando significativamente propiedades como la pérdida de resistencia, la facilidad para absorber agua, la expansividad, el incremento de porosidad, entre otros (Lara, 2008).

2.3.1.3. Estructuras

La caracterización estructural es relevante, ya que está directamente relacionada con la generación de material detrítico o bloques que conforman zonas potencialmente inestables para ser removilizadas. Estas estructuras incluyen principalmente planos de estratificación, sets de diaclasas, grietas de tensión y fallas, las cuales deben ser caracterizadas respecto a su abertura, relleno y rugosidad. La presencia de diversos sets estructurales, junto con las estructuras que forman planos de ruptura mayores en la roca puede facilitar la generación de cuñas. Estas actúan como posibles superficies de deslizamiento, aumentando la inestabilidad en las laderas (Lara, 2008).

2.3.2. Geomorfología

Los rasgos geomorfológicos que condicionan eventos de remoción en masa incluyen principalmente la topografía, las pendientes de las laderas, los cambios bruscos en la inclinación de las laderas, así como la extensión y altura de las mismas. Estas características influyen en la

velocidad, volumen y energía de las remociones que puedan originarse. Además, cualquier modificación de alguno de estos factores puede transformar una ladera estable en inestable, generando así remociones (Lara, 2008).

2.3.2.1. Pendiente

El primer factor geomorfológico a considerar es la topografía escarpada y los altos ángulos de las pendientes de las laderas, que son especialmente propicios para la generación de flujos, deslizamientos y derrumbes (Lara, 2008). Cuanto mayor sea la pendiente de las laderas y de los cauces, mayor será la capacidad de transporte y la energía que estos flujos pueden generar (Campos, 2014).

2.3.2.2. Orientación de la ladera

La orientación de las laderas con respecto al norte es un factor condicionante importante. Este aspecto puede influir en el tiempo de exposición al sol, afectando así el grado de humedad, la presencia de vegetación y la meteorización en la ladera (Campos, 2014).

2.3.2.3. Cercanía a las redes de drenaje

La red de drenaje, las variaciones en el nivel freático, los caudales y los coeficientes de escorrentía e infiltración son factores hidrológicos e hidrogeológicos que influyen en la generación de remociones en masa, ya que están directamente relacionados a la incorporación de agua en suelos o en macizos rocosos. En suelos, la saturación puede disminuir su resistencia al reducir la tensión efectiva debido a la generación de presiones de poros (Lambe y Whitman, 1972). En roca, la infiltración de agua puede debilitar las estructuras internas, generando tensiones que comprometen su estabilidad (Lara, 2008).

2.3.3. Factor antropogénico y uso de suelo

El factor antropogénico cumple un rol fundamental en la estabilidad de las laderas, siendo, en muchos casos, determinante en la generación de eventos de remoción en masa. Actividades como excavaciones, rellenos, construcciones de estructuras, urbanización, cambios en el uso de suelo, extracción de áridos y acumulación de escombros pueden contribuir a la desestabilización de las laderas. Esto ocurre tanto por la disminución artificial de la resistencia del material, como por la

aportación de material suelto que puede ser movilizado en futuros eventos. Además, estas acciones alteran la escorrentía superficial y la topografía.

Por otra parte, las actividades mineras y la construcción de embalses pueden generar sismicidad inducida, cuyas vibraciones, (aunque no siempre de gran magnitud) son constantes y pueden debilitar progresivamente los depósitos y macizos rocosos, reduciendo su resistencia con el tiempo (Lara, 2008).

2.4. FACTORES DESENCADENANTES DE REMOCIONES EN MASA

Los factores desencadenantes o activos producen la ruptura una vez que ciertas condiciones se cumplen. Estos factores externos afectan los suelos o masas rocosas, alterando sus características y propiedades (González de Vallejo *et al.*, 2002). Los agentes desencadenantes más comunes de remociones en masa incluyen principalmente lluvias intensas y sismos, y en menor medida erupciones volcánicas, intervención humana, fusión de nieve, erosión de canales, entre otros (Lara, 2008).

2.4.1. Precipitaciones

Las precipitaciones influyen directamente en la estabilidad de las laderas, ya que aumentan el grado de saturación de los materiales, tanto en suelos como en fracturas rocosas. Este aumento en la saturación disminuye la cohesión y resistencia del material, lo que reduce su estabilidad. Además, las precipitaciones intensas incrementan la escorrentía superficial, lo que potencia la erosión del suelo suelto en las laderas y puede causar socavación o disolución de la base de la ladera, debilitando aún más su estructura y facilitando la generación de eventos de remoción en masa.

Las precipitaciones de baja intensidad prolongadas y las precipitaciones intensas en periodos cortos de tiempo pueden desencadenar eventos de remociones en masa en áreas con condiciones propicias para ello. En este contexto, las precipitaciones cortas e intensas tienden a provocar eventos superficiales, mientras que las remociones más profundas suelen ser el resultado de lluvias distribuidas a lo largo de un periodo extenso (Lara, 2008).

2.4.2. Sismos

Los sismos son uno de los principales factores desencadenantes de remociones en masa en diversos escenarios geológicos y topográficos. Las aceleraciones sísmicas generan un cambio temporal en el régimen de esfuerzos al que está sometida la ladera, tanto normales como de corte, lo que puede provocar su inestabilidad. Los tipos de remociones más comunes generados por terremotos incluyen caídas de rocas, deslizamientos de suelos en laderas con pendientes superiores a 15° y deslizamientos de roca en pendientes iguales o mayores a 40° (Lara, 2008).

2.5. HERRAMIENTAS GEOESPACIALES Y DE TELEDETECCIÓN

A continuación, se presentan algunas definiciones relacionadas a la teledetección, con el fin de lograr una mejor comprensión.

2.5.1. Plataformas satelitales

2.5.1.1. Landsat 8

El satélite Landsat 8 (Figura 2.7), fue lanzado el 11 de febrero de 2013, desde la Base Aérea Vandenberg en California, Estados Unidos. Este satélite fue desarrollado por medio de la colaboración de la National Aeronautics and Space Administration (NASA) y el U.S. Geological Survey (USGS), donde la NASA se encargó del diseño, lanzamiento y calibración en órbita, en tanto la USGS se encarga de su operación desde el 30 de mayo de ese mismo año.




Figura 2.7: Modelo de satélite Landsat 8. Extraída desde Riquelme, 2023

Dicho satélite cuenta con dos cargas útiles: Thermal Infrared Sensor (TIRS) y Operational Land Imager (OLI). De manera combinada, permiten capturar imágenes de hasta 11 bandas y en distintas resoluciones, las que se resumen en la siguiente tabla (Riquelme, 2023):

Tabla 2.1: Bandas Landsat 8.

Sensor	Banda	Longitud de onda (μm)	Resolución (m)	Descripción
OLI	B1	0,435 – 0,451	30	Costera – Aerosoles
OLI	B2	0,452 – 0,512	30	Azul
OLI	B3	0,533 – 0,590	30	Verde
OLI	B4	0,636 – 0,673	30	Rojo
OLI	B5	0,851 – 0,879	30	Infrarrojo cercano (NIR)
OLI	B6	1,566 – 1,651	30	Infrarrojo onda corta (SWIR 1)
TIR 1	B10	10,60 – 11,19	100	TIR 1
TIR 2	B11	11,50 – 12,51	100	TIR 2
OLI	B7	2,107 – 2,294	30	Infrarrojo onda corta 2 (SWIR 2)
OLI	B8	0,503 – 0,676	15	Pancromática
OLI	B9	1,363 – 1,384	30	Cirrus

2.5.1.2. Sentinel 2

La misión del Sentinel 2 consta de dos satélites iguales, tal como muestra la Figura 2.8, llamados Sentinel-2A y Sentinel-2B, con una órbita polar desfasada en 180° entre cada uno, los cuales fueron lanzados el 23 de junio del 2015 y el 7 de marzo del 2017, respectivamente. Estos satélites forman parte del proyecto Copernicus de la European Space Agency (ESA)



Figura 2.8: Modelo de satélites Sentinel 2a y 2b.

Extraída desde Riquelme, 2023

La carga útil que presenta Sentinel 2, consta de una cámara multispectral capaz de captar hasta 13 bandas, cuyas resoluciones van desde los 10(m) a 60(m) por píxel (Riquelme, 2023).

Tabla 2.2: Bandas Sentinel-2.

Banda	Centro longitud de onda (m)	Resolución (m)	Descripción
B1	443	60	Costera – Aerosoles
B2	490	10	Azul
B3	560	10	Verde
B4	665	10	Rojo
B5	705	20	Visible and Near Infrared (VNIR)
B6	740	20	Visible and Near Infrared (VNIR)
B7	783	20	Visible and Near Infrared (VNIR)
B8	842	10	Visible and Near Infrared (VNIR)
B8a	865	20	Visible and Near Infrared (VNIR)
B9	940	60	Short Wave Infrared (SWIR)
B10	1.375	60	Short Wave Infrared (SWIR)
B11	1.610	20	Short Wave Infrared (SWIR)
B12	2.190	20	Short Wave Infrared (SWIR)

2.5.2. Cálculo e interpretación de índices

2.5.2.1. NDVI

El Índice de Vegetación de Diferencia Normalizada (NDVI) es uno de los índices más utilizados para evaluar la salud y densidad de la vegetación mediante imágenes satelitales. Este índice se calcula utilizando las bandas del infrarrojo cercano (NIR) y el rojo (RED) de las imágenes, definida por la Ecuación 1:

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$$

Ecuación 1: Cálculo del NDVI.

El **NDVI** tiene un rango de valores que va de -1 a 1. Los valores bajos de NDVI, cercanos a -1, indican áreas no vegetadas como rocas, tierra estéril o nieve, mientras que los valores cercanos a 0

representan vegetación escasa, como arbustos o pastizales. Por otro lado, los valores altos de NDVI, que oscilan entre 0,6 y 0,9, corresponden a vegetación densa, como bosques tropicales o templados, y cultivos en su etapa máxima de crecimiento (Rouse *et al.*, 1973 y United States Geological Survey, 2023).

El NDVI permite realizar estudios temporales, comparando la misma zona en diferentes períodos de tiempo, lo que facilita el análisis de la salud de la vegetación en un área determinada. Este índice ha demostrado ser útil en el monitoreo de la vegetación, dado que las plantas tienen una firma espectral particular que puede ser detectada a través de la reflectancia de la radiación solar (Riquelme, 2023).

2.5.2.2. GNDVI

El Índice de Vegetación de Diferencia Normalizada Verde (GNDVI) es un índice de vegetación ampliamente utilizado en diversas aplicaciones fenológicas debido a su mayor sensibilidad en la detección de cambios en la concentración de clorofila en comparación con el NDVI. En el contexto de la detección de remociones en masa, investigaciones previas (Hölbling *et al.*, 2015 y Veena *et al.*, 2016) han utilizado el GNDVI para identificar cambios en la vegetación a pequeña escala que no son capturados por el NDVI, así como para reducir los falsos positivos asociados a terrenos áridos.

El cálculo del GNDVI es similar al del NDVI, pero la banda roja se reemplaza por la banda verde, como se muestra en la Ecuación 2:

$$\text{GNDVI} = \frac{\text{NIR} - \text{GREEN}}{\text{NIR} + \text{GREEN}}$$

Ecuación 2: Cálculo del GNDVI.

2.5.2.3. SAVI

El Índice de Vegetación Ajustado al Suelo (SAVI) fue creado para mitigar la influencia del brillo del suelo en áreas con vegetación escasa, una limitación común del NDVI. Para lograrlo, incorpora

un factor de corrección de brillo del suelo (L), que varía entre 0 y 1, dependiendo de la densidad de la vegetación. Este factor se establece típicamente en $L=0,5$, ya que resulta adecuado para una amplia variedad de tipos de cobertura del suelo, reduciendo eficazmente el ruido del suelo y mejorando la precisión en el rango de densidades de vegetación (Huete, 1988). Se expresa con la siguiente fórmula (Ecuación 3):

$$SAVI = \frac{NIR + RED}{NIR + RED + L} * (1 + L)$$

Ecuación 3: Cálculo del SAVI.

2.5.2.4. NDWI

El Índice de Diferencia Normalizada del Agua (NDWI) es un índice espectral diseñado para resaltar características de agua en imágenes satelitales. Se calcula como la diferencia normalizada entre las reflectancias en las bandas verde e infrarrojo cercano, según la fórmula (Ecuación 4):

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR}$$

Ecuación 4: Cálculo del NDWI.

Este índice maximiza la respuesta del agua en la banda verde y minimiza su baja reflectancia en el NIR. Valores positivos de NDWI suelen asociarse a cuerpos de agua, mientras que la vegetación y el suelo presentan valores cercanos a cero o negativos.

En el caso de las remociones en masa, el NDWI resulta especialmente útil debido a los cambios que estas provocan en el contenido de humedad del suelo. Al realizar un análisis antes y después del evento, se pueden identificar diferencias significativas en los valores de NDWI, ya que las remociones alteran las condiciones de saturación en las zonas afectadas. Valores positivos de NDWI (entre 0 y 0,2) indican áreas con menor contenido de humedad, mientras que valores

superiores a 0,5 reflejan zonas con alta saturación. Estas variaciones permiten detectar y analizar las remociones en masa al destacar las alteraciones en la distribución de humedad, especialmente en combinación con factores geomorfológicos como pendiente y tipo de suelo (McFeeters, 1996 y Ullah *et al.*, 2022).

Este índice también se utiliza para enmascarar cuerpos de agua en imágenes satelitales, ya que resalta estas áreas al presentar valores positivos debido a su alta reflectancia en la banda verde y baja reflectancia en el infrarrojo cercano.

2.5.2.5. BSI

El Bare Soil Index (BSI) es un índice espectral diseñado para resaltar áreas de suelo desnudo mediante la combinación normalizada de bandas espectrales visibles e infrarrojas, como el azul, rojo, infrarrojo cercano e infrarrojo de onda corta (SWIR). Este índice ha demostrado ser útil en múltiples aplicaciones de teledetección, como mapeo de suelos, monitoreo agrícola y detección de remociones en masa, ya que permite identificar trazas de movimiento de suelo al discriminar entre áreas completamente desnudas, con vegetación dispersa o densa. El BSI utiliza las bandas SWIR y Red para cuantificar la composición mineral del suelo y las bandas Blue y NIR para detectar la presencia de vegetación, facilitando la interpretación de variaciones en el suelo (Ariza *et al.*, 2021 y Roy *et al.*, 1996). La fórmula que define este índice se expresa como (Ecuación 5):

$$BSI = \frac{(SWIR + RED) - (NIR + BLUE)}{(SWIR + RED) + (NIR + BLUE)}$$

Ecuación 5: Cálculo del BSI.

2.5.2.6. NDSI

El Índice Normalizado de Diferencia de Nieve es un índice espectral diseñado para mapear y distinguir áreas cubiertas de nieve en imágenes satelitales. Este índice utiliza la diferencia normalizada de reflectancias entre una banda del espectro visible (como la banda verde) y una del infrarrojo cercano o infrarrojo de onda corta. La fórmula para calcular el NDSI es (Ecuación 6):

$$\text{NDSI} = \frac{\text{VIS} - \text{SWIR}}{\text{VIS} + \text{SWIR}}$$

Ecuación 6: Cálculo del NDSI.

La nieve presenta una alta reflectancia en el espectro visible, pero absorbe considerablemente en el infrarrojo cercano o el SWIR, lo que la distingue de otros elementos como nubes, vegetación o suelo. Este comportamiento espectral único permite que el NDSI sea ampliamente utilizado en algoritmos automatizados de mapeo de nieve (Hall, 2010).

El NDSI es especialmente útil para enmascarar áreas cubiertas de nieve, ya que diferencia efectivamente la nieve de las nubes, que suelen tener reflectancias similares en ambas bandas.

2.5.2.7. NBR

El Índice Normalizado de Área Quemada (NBR) utiliza la relación espectral entre las bandas de infrarrojo cercano e infrarrojo de onda corta para identificar áreas afectadas, como suelos expuestos y vegetación alterada. Originalmente diseñado para evaluar la severidad de incendios forestales, el NBR destaca por su capacidad para detectar cambios en la cobertura del suelo, con valores altos que indican vegetación saludable y valores bajos asociados a suelo expuesto o recientemente alterado. Esta característica lo hace especialmente útil en la detección de deslizamientos de tierra, donde la remoción de vegetación y la exposición del suelo generan firmas espectrales similares. Es por esto que el NBR puede aplicarse al monitoreo y análisis de estos eventos, ayudando a la identificación de áreas afectadas (Keeley, 2009). Su fórmula (Ecuación 7) es la siguiente:

$$\text{NBR} = \frac{\text{NIR} - \text{SWIR}}{\text{NIR} + \text{SWIR}}$$

Ecuación 7: Cálculo del NBR.

2.5.3. Detección de remociones en masa con imágenes satelitales

Para la identificación de deslizamientos de tierra a través de imágenes satelitales, la interpretación de fotos aéreas ha sido un método tradicionalmente utilizado. Este proceso se basa en características inherentes al deslizamiento, como tonalidad, contraste, tamaño, forma y sombras, junto con indicadores contextuales como la posición y dirección del deslizamiento (Liu *et al.*, 2002). Sin embargo, las imágenes de pequeña escala o los sistemas de teledetección con píxeles grandes no son eficaces para detectar deslizamientos pequeños debido a la resolución limitada de la imagen (Soeters y Cornelis, 1996).

Los avances en el análisis automatizado de imágenes multitemporales, como el uso de imágenes satelitales, han mejorado significativamente la identificación de deslizamientos a gran escala (Nichol y Wong, 2005). En áreas donde el contexto ambiental es conocido, los cambios en la tonalidad de la imagen entre dos fechas permiten detectar desplazamientos naturales, como deslizamientos de tierra o movimientos superficiales, minimizando los errores de interpretación (Nichol y Wong, 2005).

En cuanto a las imágenes satelitales, el uso de índices de vegetación, como el NDVI (Índice de Vegetación de Diferencia Normalizada), se ha destacado como una herramienta útil para interpretar las áreas afectadas por deslizamientos, ya que estas áreas son típicamente no vegetadas. En el caso de deslizamientos, los valores de NDVI suelen estar en el rango de 0 a -0,3, lo que indica una baja o nula cobertura vegetal (Liu *et al.*, 2002). Sin embargo, para evitar confusiones con otras áreas no vegetadas, como los depósitos fluviales o zonas urbanas, se requiere un procesamiento adicional de la imagen NDVI, eliminando los píxeles positivos y generando un mapa de contornos que sirva como referencia.

Finalmente, el uso de imágenes mejoradas como las descritas por Liu *et al.*, (2002), ha demostrado ser altamente eficaz para los geólogos al interpretar deslizamientos. En estas imágenes, las áreas forestales se representan en verde, mientras que las áreas de deslizamientos o no vegetadas se muestran en tonos marrones o terrosos, lo que facilita la identificación y análisis de los deslizamientos en comparación con las imágenes tradicionales en 2D. Esta técnica, que combina

el uso de índices de vegetación y el procesamiento de imágenes mejoradas, resulta en una herramienta útil para la detección de remociones en masa con la utilización de estas imágenes.

2.5.3.1. Diferencia de imagen para detección de cambios

La técnica de diferencia de imagen, descrita por Singh (1989), se emplea para identificar los cambios ocurridos antes y después de un deslizamiento de tierra. Consiste en restar las imágenes correspondientes a dos momentos diferentes (t_1 para el pre-evento y t_2 para el post-evento), pixel por pixel, generando una imagen que resalta las variaciones entre ambos períodos. Esta metodología permite detectar cambios en los valores de reflectancia o radiancia, interpretando dichas diferencias como indicadores de alteraciones en el terreno (Mahmoodzadeh, 2007).

Según Ingram *et al.*, (1981), las variaciones en la firma espectral, causadas por cambios en el uso del suelo o deslizamientos, deben ser más evidentes que aquellas producidas por factores como la iluminación, las condiciones atmosféricas, la calibración del sensor o la humedad del suelo. Es decir, los valores de la diferencia de píxeles entre los índices serán mayores en las áreas afectadas por los deslizamientos, lo que permitirá identificarlas de manera más clara.

2.6. TÉCNICAS DE CLASIFICACIÓN

Las técnicas de clasificación son herramientas útiles para analizar imágenes satelitales, asignando categorías a los píxeles según sus características. Se utilizan para identificar patrones y fenómenos, como cambios en la vegetación o la presencia de remociones en masa. Para esta investigación, se aplicarán métodos de clasificación para detectar áreas afectadas por variaciones significativas en índices, como, por ejemplo, el NDVI y NDWI.

2.6.1. K-means

El algoritmo K-means es un método de agrupamiento no supervisado que busca dividir un conjunto de datos en un número predefinido de clústeres, donde cada clúster contiene elementos similares entre sí (Figura 2.9). Funciona inicialmente seleccionando aleatoriamente los centroides de los clústeres y asignando los puntos de datos al clúster cuyo centroide esté más cercano, utilizando la distancia euclidiana. Luego, recalcula los centroides y repite el proceso hasta que ya no haya cambios significativos en los centroides (Lv *et al.*, 2020).

En el contexto de la investigación, el algoritmo K-means se aplica para agrupar las diferencias de índices derivados de imágenes satelitales, como el NDVI, NDWI, GNDVI, BSI, entre otros, para detectar áreas con cambios significativos asociados a remociones en masa. Al aplicar K-means, se pueden identificar zonas de la imagen que presentan variaciones relevantes en la vegetación o el contenido de humedad o en suelos expuestos.

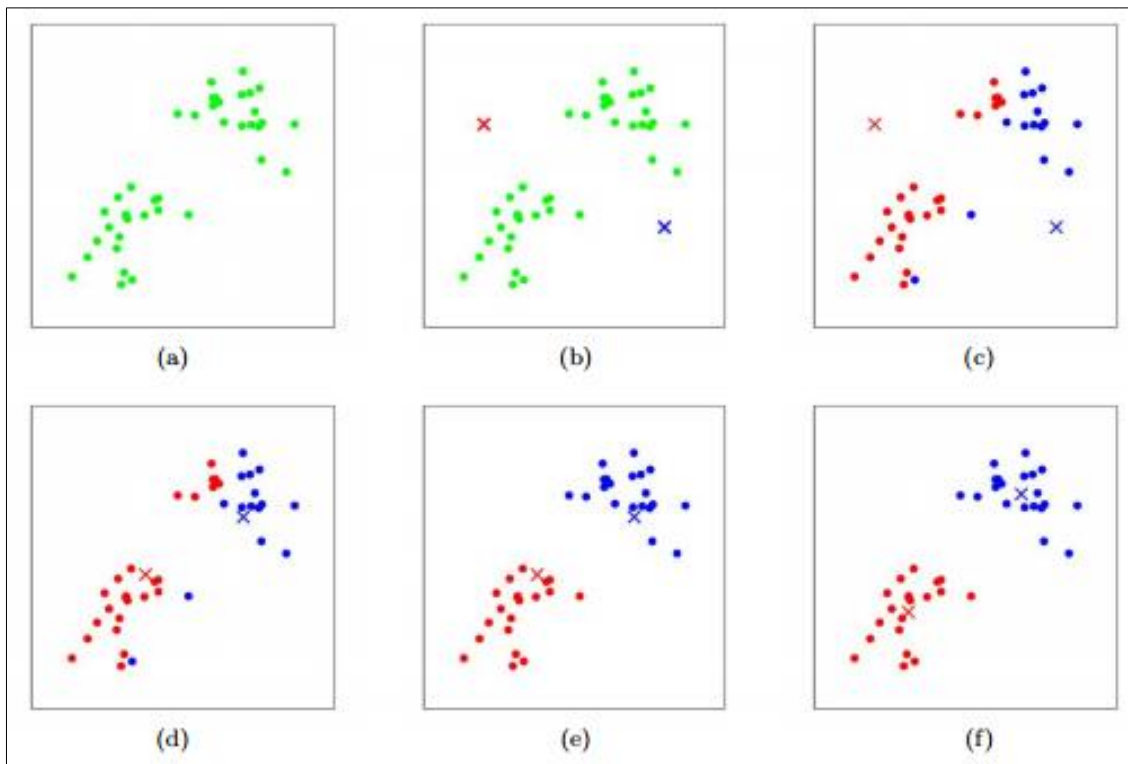


Figura 2.9: Ejemplo del clustering de K-means. Los puntos representan los ejemplos de entrenamiento y las cruces los centroides de los clusters. (a) Conjunto de datos original. (b) Inicialización aleatoria de los centroides. (c-f) Ejecución de dos iteraciones del algoritmo: en cada paso, los puntos se asignan al centroide más cercano (indicados por el mismo color), y luego los centroides se actualizan a la media de los puntos asignados. Extraído desde sitio web de Stanford University (stanford.edu/~cpiech/cs221/handouts/kmeans.html)

2.6.2. k-NN

El algoritmo K-Nearest Neighbors (KNN) es un modelo de aprendizaje supervisado y no paramétrico que clasifica puntos nuevos en función de la proximidad a los k vecinos más cercanos, calculada mediante una métrica de distancia, generalmente la euclidiana. Este modelo se caracteriza por su simplicidad y por no requerir un proceso de entrenamiento explícito (Figura

2.10), ya que basa sus predicciones en los datos almacenados, comparándolos directamente con nuevas observaciones (Cover y Hart, 1967).




Figura 2.10: Ejemplo del clustering de k-NN. El diagrama muestra el proceso del algoritmo K-Nearest Neighbors (KNN). Primero, se presenta un conjunto de datos con dos clases y un nuevo punto a clasificar. Luego, se calcula la distancia entre el nuevo punto y los datos existentes. Finalmente, se identifican los k vecinos más cercanos ($k=3$) y se asigna la clase mayoritaria mediante votación. Extraído desde sitio web de IBM (ibm.com/think/topics/knn)

En esta investigación, se utiliza el algoritmo KNN para la identificación de remociones en masa, empleando como variables predictoras las diferencias de índices espectrales y las bandas de imágenes satelitales. Esta técnica permite analizar cómo las variaciones en los índices espectrales, como NDVI y NBR, están asociadas a los eventos de remoción en masa, facilitando la delimitación de estas áreas. La aplicación de KNN se enfoca en aprovechar estas relaciones espectrales y espaciales para construir un modelo que contribuya al análisis de los eventos mapeados.

2.7. MÉTRICAS DE EVALUACIÓN DE MODELOS DE CLASIFICACIÓN

Evaluar el rendimiento de un modelo es fundamental al implementar cualquier método de clasificación supervisada. Una de las representaciones más comunes es la **matriz de confusión**, que compara los valores reales con los valores predichos. Esta matriz tiene dimensiones $K \times K$ (donde K es el número de clases), y se utiliza tanto en problemas de clasificación binaria como multiclase. Para un problema binario con clases positiva y negativa, la matriz de confusión se presenta en una tabla de 2×2 (Lemmens, 1994).

Tabla 2.3: Matriz de confusión de clasificación binaria.

Clase Real	Clase predictiva	
	Negativa	Positiva
Negativa	Tn	Fp
Positiva	Fn	Tp

Donde:

- Tn (Verdadero negativo): Casos correctamente clasificados como negativos.
- Fp (Falso positivo): Casos negativos incorrectamente clasificados como positivos.
- Fn (Falso negativo): Casos positivos incorrectamente clasificados como negativos.
- Tp (Verdadero positivo): Casos correctamente clasificados como positivos.

En función de esta matriz, se han propuesto distintas métricas para evaluar modelos en clasificación desequilibrada. Algunas de las métricas más utilizadas incluyen:

- **Precisión:** Mide cuántas predicciones correctas se obtienen de un total de observaciones clasificadas positivamente. Es especialmente importante cuando el costo de los falsos positivos es elevado.

$$\text{Precisión} = \frac{T_p}{T_p + F_p}$$

Ecuación 3: Cálculo de Precisión.

(Branco *et al.*, 2016).

- **Recuperación (Recall):** Mide cuántas predicciones correctas se realizan en relación con el total de observaciones positivas. Se enfoca en la importancia de no perder instancias positivas, y es crucial cuando el costo de los falsos negativos es alto.

$$\text{Recall} = \frac{T_p}{T_p + F_n}$$

Ecuación 4: Cálculo del Recall.

(Branco *et al.*, 2016).

- **Medida F (F1 Score):** Combina precisión y recuperación en una sola métrica, considerando la importancia relativa de cada una de ellas a través de un parámetro de ponderación β .

$$F_\beta = \frac{(1 + \beta^2) * \text{Precisión} * \text{Recall}}{\beta^2 * \text{Precisión} + \text{Recall}}$$

Ecuación 5: Cálculo de la Medida F (F1-Score).

(He y Garcia, 2008; Branco *et al.*, 2016).

La **Medida F** es especialmente útil para evaluar el rendimiento de un clasificador en tareas donde tanto la precisión como la recuperación son importantes.

3. METODOLOGÍA

3.1. CONTEXTO Y REVISIÓN BIBLIOGRÁFICA

La metodología comienza con una revisión bibliográfica detallada de las características geológicas, geomorfológicas, hidrogeológicas y climáticas del área de estudio, con especial énfasis en el registro histórico de remociones en masa. Para llevar a cabo esta revisión, se consultaron fuentes bibliográficas específicas del área, además del catálogo de deslizamientos de la NASA y de SERNAGEOMIN. Como parte de este trabajo, se elaboró un inventario propio de remociones en masa, basado en estudios previos e inventarios de investigaciones realizadas en la zona, complementado con un análisis detallado mediante fotointerpretación de imágenes satelitales a través de Google Earth. Este análisis utilizó series temporales de imágenes, permitiendo observar cambios a través del tiempo al comparar las condiciones antes y después de los eventos, en función de las fechas disponibles en GE y buscando fechas específicas obtenidas a partir de la bibliografía. Para la digitalización precisa de los polígonos de deslizamientos, se empleó el software ArcMap 10.8, lo que facilitó la creación de un inventario completo y detallado.

La metodología se estructuró en etapas según los procesos a realizar y los modelos desarrollados, de manera que cada modelo se construyó por sí solo, pero compartiendo ciertos pasos iniciales. Todos los modelos requieren datos provenientes de imágenes satelitales, por lo que las etapas de descarga, preprocesamiento y análisis básico de estas imágenes se aplican de forma común a cada modelo. Esto se aprecia en la Figura 3.1:

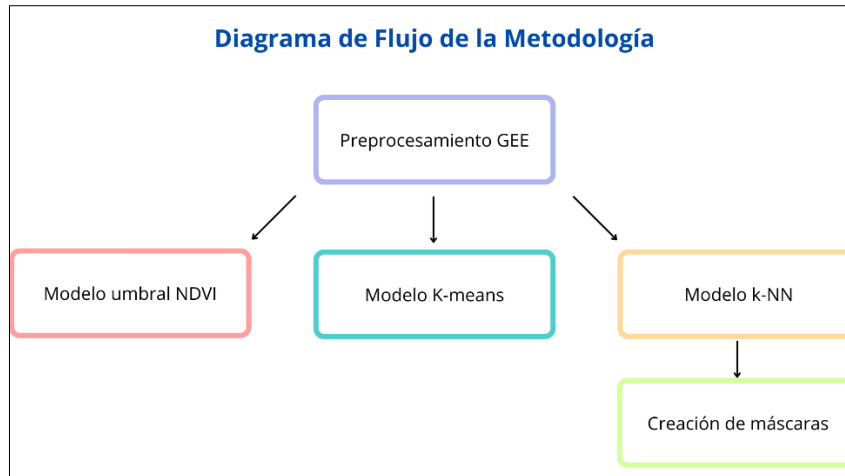


Figura 3.1: Diagrama de flujo de la metodología.

3.2. PREPROCESAMIENTO DE IMÁGENES Y CREACIÓN DE INVENTARIOS CON ÍNDICES ESPECTRALES RELEVANTES

En esta sección se describe el procesamiento de imágenes satelitales de Landsat-8 y Sentinel-2 (Figura 3.2) con el objetivo de generar un inventario de diferencias espectrales, que sirve como base para el análisis cuantitativo de remociones en masa. Este inventario complementa el mapeo manual de remociones realizado previamente, el cual consistió en la digitalización de polígonos basados en fotointerpretación. Se prioriza el uso de imágenes del satélite Sentinel-2 debido a su mayor resolución espacial y su cobertura temporal más reciente; sin embargo, para eventos ocurridos antes del lanzamiento de Sentinel-2, se emplean imágenes de Landsat-8, permitiendo así una mayor cobertura temporal para el análisis.

El procesamiento se realiza mediante un script en Google Earth Engine (GEE), que permite seleccionar imágenes pre y post evento, enmascarar nubes, nieve y cuerpos de agua, y calcular índices espectrales relevantes (NDVI, NDWI, entre otros). Además, se integran las bandas RGB para representar las imágenes en color natural. Posteriormente, se calculan las diferencias espectrales entre las fechas pre y post evento, las cuales se añaden como nuevas bandas a una imagen compuesta. Esta imagen, que contiene tanto las bandas RGB como las diferencias de índices espectrales, se exporta en formato .tif a una carpeta específica en Google Drive, para su posterior procesamiento en Google Colab.

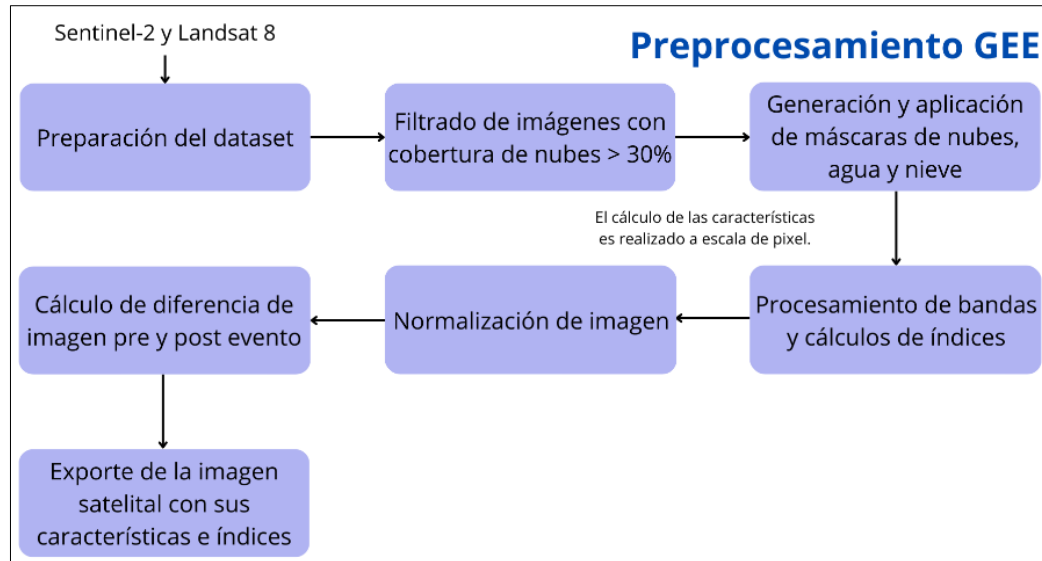


Figura 3.2: Diagrama de flujo del script de GEE.

3.2.1. Definición del área de interés (AOI)

El primer paso en el procesamiento de imágenes consiste en definir el área de interés (AOI). Esta zona se determina utilizando las coordenadas geográficas de los eventos de remociones en masa identificados en la revisión bibliográfica. De esta manera, se seleccionan únicamente las imágenes que corresponden a la región relevante para el análisis, asegurando que los resultados se centren en las áreas afectadas por remociones en masa.

3.2.2. Filtrado de imágenes y enmascaramiento de nubes

Una vez definido el AOI, se seleccionan las imágenes satelitales de Landsat-8 dentro del período pre y post evento, utilizando fechas específicas. Además, se establece un umbral de nubosidad del 30% para asegurar que las imágenes seleccionadas tengan suficiente claridad para el análisis. Se aplica un enmascaramiento de nubes utilizando la banda *QA_PIXEL* de Landsat-8, que permite identificar y eliminar las nubes y sombras presentes en la imagen, asegurando que solo se utilicen los píxeles libres de nubes para los cálculos posteriores.

De manera similar, para Sentinel-2 se seleccionaron imágenes de la colección COPERNICUS/S2_SR, aplicando un umbral de nubosidad del 30%. Se implementó una función personalizada para enmascarar las nubes en estas imágenes, utilizando la banda *MSK_CLDPRB*, que indica la probabilidad de nubosidad en cada píxel.

Este proceso asegura que los valores de reflectancia y los índices derivados, como el NDVI, no se vean distorsionados por la presencia de nubes siguiendo las recomendaciones de preprocesamiento estándar (Herrera, 2019).

3.2.3. Enmascaramiento de nieve

El enmascaramiento de nieve se realiza mediante el cálculo del índice NDSI (Índice de Nieve Normalizado), que permite identificar áreas cubiertas por nieve en las imágenes satelitales. Un valor de NDSI mayor a 0,4 indica la presencia de nieve (Hall *et al.*, 1998), por lo que se aplica una máscara para eliminar estos píxeles. Este paso es esencial para evitar que la nieve afecte los cálculos de los índices espectrales utilizados para detectar cambios relacionados con remociones en masa.

3.2.4. Cálculo de índices

En esta etapa, se calculan seis índices espectrales clave para el análisis de las imágenes: NDVI, NDWI, GNDVI, BSI, NBR y SAVI. Estos índices proporcionan información sobre la vegetación, la presencia de agua, los cambios en la reflectancia del suelo, la exposición de suelos desnudos y los cambios espectrales en la superficie, respectivamente. Cada índice se calcula utilizando combinaciones específicas de bandas provenientes de los satélites Landsat-8 y Sentinel-2, y se integra como nuevas bandas a las imágenes procesadas para un análisis posterior.

3.2.5. Cálculo de medias de las colecciones pre y post evento

Para cada periodo (pre y post evento), se calcula el promedio de las imágenes de la colección utilizando la función *mean()*. Esto permite suavizar las variaciones locales y obtener una representación más clara de los cambios ocurridos en la zona de interés entre ambos periodos. Por ejemplo, estas variaciones locales suelen estar influenciadas, en gran medida, por la estación del año en que se capturan las imágenes, lo que puede afectar la reflectancia debido a cambios estacionales en la vegetación, humedad del suelo y otras condiciones ambientales. Además, debido a la limitada disponibilidad de imágenes libres de nubes, en algunos casos es necesario ampliar el rango de fechas para capturar imágenes representativas, lo que puede incrementar la distancia temporal con respecto al día exacto del evento. Finalmente, la mediana de las colecciones pre y post evento se recorta para ajustarse al área definida en el AOI.

3.2.6. Cálculo de diferencias para índices y creación de imagen de diferencias

En esta etapa, se calculan las diferencias entre los índices (NDVI, NDWI, GNDVI, SAVI, BSI y NBR) de las colecciones pre y post evento. Las diferencias se obtienen restando las imágenes medianas del periodo pre evento de las del periodo post evento, lo que permite identificar variaciones significativas en la vegetación, la presencia de agua y las condiciones del suelo (Figura 3.3). Estos cambios son muy importantes para detectar y delimitar áreas potencialmente afectadas por remociones en masa. Los resultados de estas diferencias se integran en una nueva imagen compuesta, donde cada banda representa un índice específico y su respectiva diferencia.

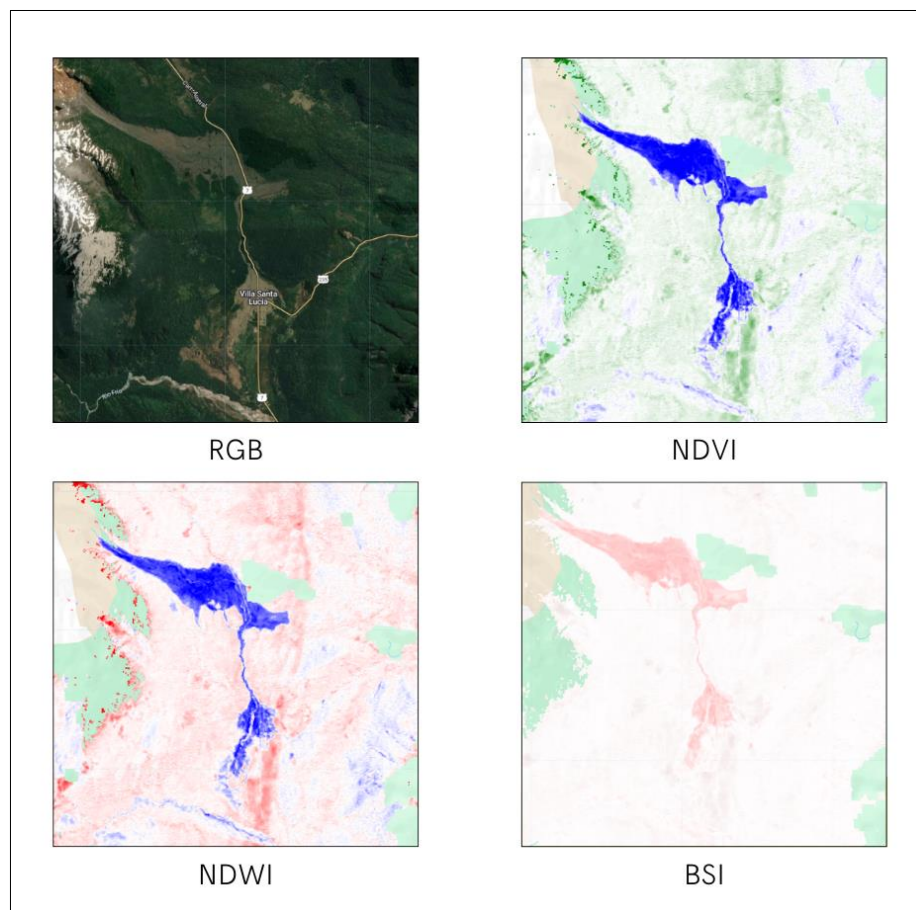


Figura 3.3: Ploteo de diferencias de NDVI, NDWI y BSI junto a imagen RGB.

3.2.7. Exportación de imágenes

Una vez completado el procesamiento, se exporta la imagen RGB post evento y las diferencias de índices espectrales, que se almacenan en las bandas 4 a 9 correspondientes a los índices NDVI, NDWI, GNDVI, SAVI, BSI y NBR. Las imágenes de Landsat-8 se exportan con una resolución

espacial de 30 metros por píxel, mientras que las imágenes de Sentinel-2, que tienen una resolución de 10 metros por píxel para las bandas visibles (B2, B3, B4), se exportan con la misma resolución (10m). El sistema de referencia utilizado es EPSG:32718 (UTM zona 18S). Todo el conjunto se guarda en formato GeoTIFF, y el recorte se realiza según el área de interés (AOI) definido previamente.

Este paso final asegura que las imágenes estén listas para ser utilizadas en Google Colab, donde se llevarán a cabo los análisis posteriores.

3.3. MODELO UMBRAL NDVI

El modelo de umbral NDVI (Figura 3.4) se utiliza para identificar áreas de remoción en masa a partir de las diferencias en la vegetación entre el estado pre y post evento. Este enfoque simple y eficaz aplica un umbral fijo al índice de vegetación (NDVI) para clasificar las áreas en dos categorías: remoción y no remoción. Los valores de NDVI inferiores a $-0,07$ son considerados como indicativos de remoción en masa, mientras que los valores superiores o iguales son clasificados como no remoción. A continuación, se presenta un diagrama de flujo que resume el procedimiento completo de este modelo:

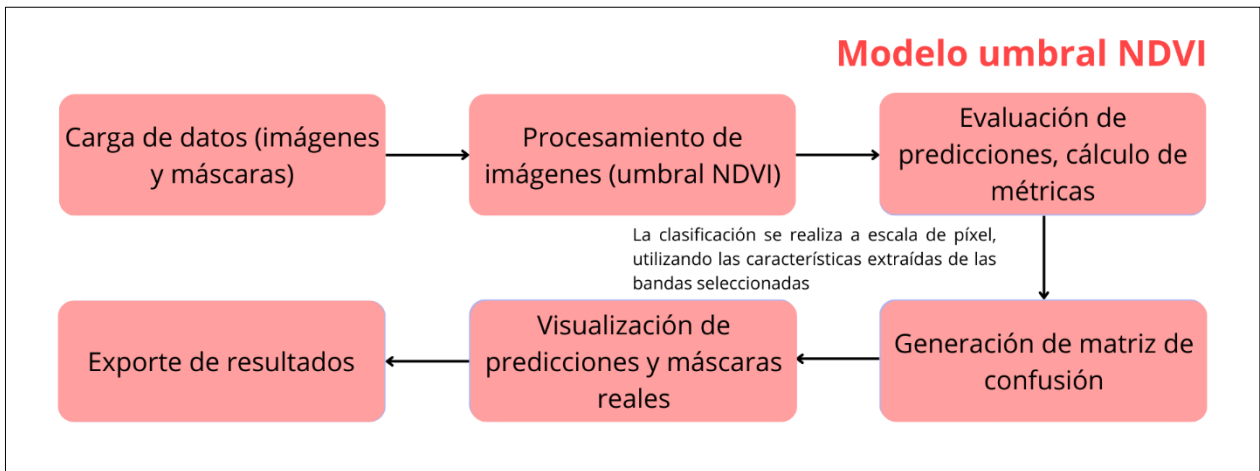


Figura 3.4: Diagrama de flujo del Modelo umbral NDVI.

3.3.1. Carga de imágenes y máscaras de entrenamiento

En esta etapa, se cargan las imágenes de entrenamiento y sus máscaras correspondientes desde los directorios predefinidos. Las imágenes están organizadas en formato .tif y las máscaras se

encuentran en una carpeta separada. Para este análisis, se utiliza específicamente la banda 4 de las imágenes, que representa las diferencias de NDVI entre el estado pre y post evento de remoción en masa. Esta banda es fundamental, ya que refleja cambios en la vegetación que pueden estar asociados con áreas de remoción. Las máscaras sirven como referencia para validar los resultados, asignando el valor 1 a las zonas de remoción y 0 a las zonas sin remoción.

3.3.2. Procesamiento de imágenes

En esta etapa, se aplica un umbral fijo al NDVI para generar predicciones binarias. Los valores de NDVI menores a $-0,07$ se consideran indicativos de áreas de remoción y se etiquetan con un 1, mientras que los valores iguales o superiores se etiquetan con un 0, identificándolos como áreas sin remoción. Este criterio permite convertir la banda de NDVI en una matriz binaria que puede ser comparada directamente con las máscaras de referencia.

3.3.3. Evaluación de predicciones

Las predicciones generadas se comparan con las máscaras reales para evaluar el rendimiento del modelo. Se calcula la matriz de confusión, que permite analizar los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Con base en estos resultados, se obtienen métricas como precisión, recall, F1-score y precisión general. Estas métricas se calculan tanto a nivel individual, para cada imagen, como a nivel global, acumulando los resultados de todas las imágenes del conjunto de entrenamiento. Esto permite evaluar la capacidad del modelo para identificar correctamente las áreas de remoción en masa.

3.3.4. Visualización y análisis

Los resultados se visualizan mediante gráficos que incluyen la banda NDVI, las predicciones generadas por el modelo y las máscaras reales. Estas representaciones visuales permiten realizar una comparación directa entre las áreas detectadas como remoción y las áreas referenciadas en las máscaras, facilitando la identificación de patrones de error o zonas donde el modelo puede ser más preciso. Además, se presenta la matriz de confusión global para destacar el rendimiento del modelo de forma resumida.

3.3.5. Exporte de resultados

Las predicciones binarias generadas por el modelo se convierten en shapefiles para facilitar su análisis espacial posterior. Cada predicción se guarda con el sistema de referencia espacial original de las imágenes, asegurando su compatibilidad con softwares de análisis geoespacial como QGIS o ArcGIS. Además, las métricas calculadas se almacenan en un archivo separado para su documentación, permitiendo un análisis detallado del rendimiento del modelo en cada imagen y del conjunto completo. Esto permite que los resultados sean reproducibles y que puedan integrarse en estudios posteriores.

3.4. MODELO K-MEANS

El modelo de clustering K-means (Figura 3.5) se aplica para identificar y clasificar áreas afectadas por remociones en masa en imágenes satelitales. Este algoritmo no supervisado agrupa los píxeles de las imágenes en dos clústeres principales: uno correspondiente a las áreas de remoción y otro a las áreas sin remoción. El siguiente diagrama de flujo resume los pasos en el proceso de implementación de este modelo, desde la carga de datos hasta la evaluación de las predicciones.

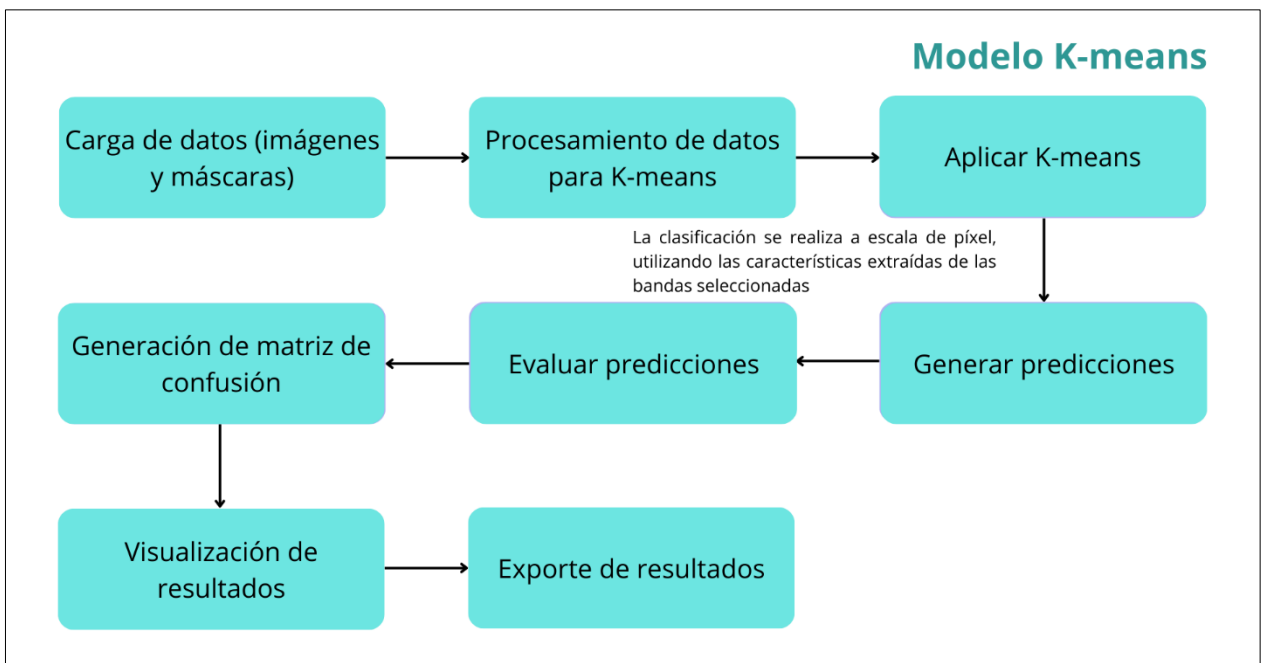


Figura 3.5: Diagrama de flujo del Modelo K-means.

3.4.1. Carga de imágenes y máscaras

En esta etapa, se cargan las imágenes de entrenamiento y sus correspondientes máscaras desde los directorios previamente definidos. Las imágenes están en formato .tif y contienen varias bandas, de las cuales, para este análisis, se seleccionan las bandas 4 a 9. Estas bandas representan las diferencias de índices calculados entre las condiciones pre y post evento de remoción en masa, y proporcionan información importante para identificar cambios relacionados con estas remociones. Las máscaras, que delimitan áreas conocidas de remoción y no remoción, actúan como referencia para evaluar los resultados del modelo no supervisado.

3.4.2. Preprocesamiento de datos

Antes de aplicar el algoritmo de K-means, los datos de las bandas seleccionadas deben ser reorganizados en un formato adecuado. Cada píxel de las imágenes se convierte en una fila de una matriz, mientras que las bandas seleccionadas (4 a 9) se convierten en columnas, generando así una representación bidimensional de las características de cada píxel. Esto transforma las imágenes originales de tres dimensiones (alto, ancho, bandas) en un formato estructurado apto para el clustering. Adicionalmente, cualquier valor nulo (NaN) presente en los datos es reemplazado por un valor cercano a cero (0,00001) para prevenir errores numéricos y garantizar una ejecución robusta del algoritmo.

3.4.3. Aplicación de K-means

Con los datos preparados, se implementa el algoritmo de K-means para agrupar los píxeles en dos clústeres principales: uno asociado a las áreas de remoción y el otro a las áreas sin remoción. El algoritmo utiliza un número de clústeres definido previamente (dos) y ajusta iterativamente los centros de los clústeres para minimizar la varianza dentro de cada grupo. Para identificar cuál de los clústeres corresponde a las remociones, se calculan las distancias de los centros de los clústeres al origen del espacio de características. El clúster con la mayor distancia al origen se asocia con las áreas de remoción, ya que representa los cambios más pronunciados en los índices utilizados.

3.4.4. Generación de predicciones

Una vez que el modelo ha ajustado los clústeres, se generan etiquetas que asignan cada píxel a uno de los grupos determinados por el K-means. Estas etiquetas se reorganizan para reconstruir una

matriz que conserve las dimensiones espaciales originales de la imagen. Esto permite visualizar directamente el resultado del clustering como una nueva capa, donde se resaltan las áreas clasificadas como remoción. Este paso facilita la interpretación espacial de las predicciones, proporcionando un mapa que puede ser comparado con las máscaras reales.

3.4.5. Evaluación de las predicciones

La evaluación del modelo se realiza al comparar las etiquetas generadas por el K-means con las máscaras de referencia. Se construye una matriz de confusión para analizar el desempeño del algoritmo, evaluando cuántos píxeles fueron correctamente clasificados como remoción o no remoción y cuantificando los errores. Con base en esta matriz, se calculan métricas clave como la precisión, el recall y el F1-score. Estas métricas permiten medir objetivamente la efectividad del modelo, identificando fortalezas y áreas de mejora en la detección de remociones.

3.4.6. Visualización y análisis

Los resultados del clustering (Figura 3.6) se integran visualmente con las bandas seleccionadas y las máscaras reales, lo que facilita el análisis de la calidad de la clasificación. Las visualizaciones incluyen subgráficos que muestran las diferencias de índices más relevantes, como NDVI y GNDVI, junto con las predicciones y las máscaras. Además, se generan gráficos y tablas que resumen el desempeño del modelo a nivel global, permitiendo identificar tendencias y posibles sesgos en la clasificación. Este análisis visual complementa las métricas cuantitativas y proporciona una visión más completa del comportamiento del modelo.

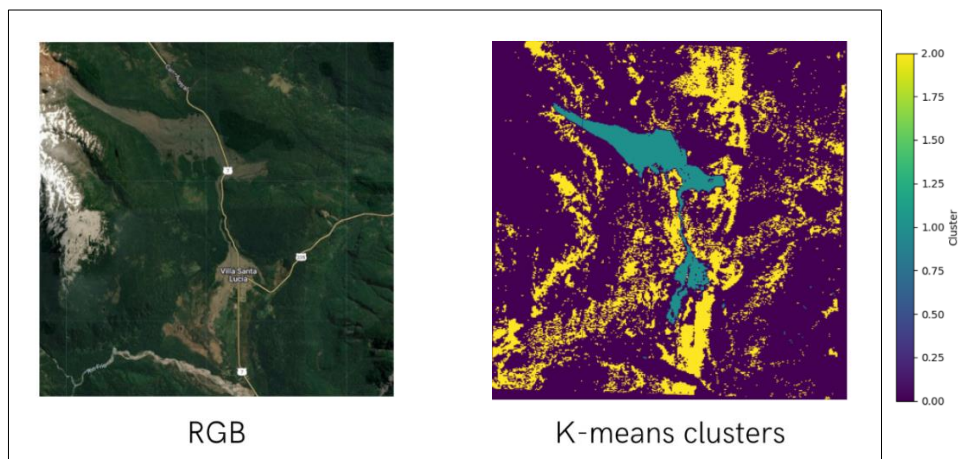


Figura 3.6: Ejemplo de clustering de K-means con imagen RGB.

3.5. CREACIÓN DE MÁSCARAS Y PREPROCESAMIENTO DE DATOS RÁSTER

Una vez que se han obtenido los archivos ráster de las imágenes satelitales y los shapefiles de las remociones en masa, que se obtuvieron en los pasos 3.1 y 3.2 de la metodología, se procede a la creación de máscaras binarias (Figura 3.7). Este proceso es fundamental para identificar y separar las áreas de interés (las zonas afectadas por remociones en masa) en las imágenes satelitales. Las máscaras se generan a partir de la rasterización de los polígonos de remociones, asignando valores binarios (0 o 1) a los píxeles correspondientes a las zonas afectadas y no afectadas. Dichas máscaras se utilizan como base para la clasificación que se realiza en el paso 3.6. Se adjunta un diagrama de flujo que explica de forma resumida esta sección:

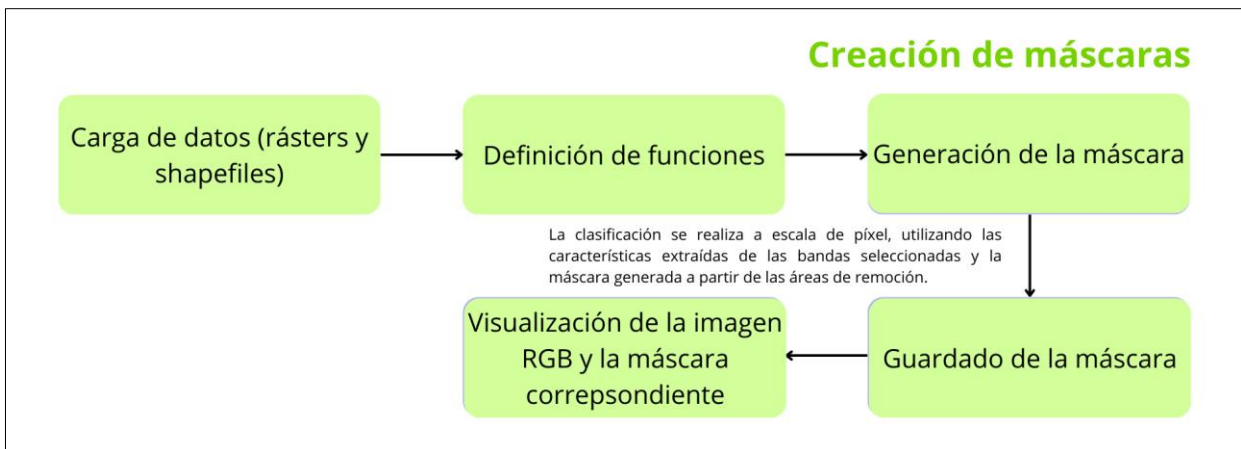


Figura 3.7: Diagrama de flujo del script de creación de máscaras.

3.5.1. Instalación y configuración de librerías

El proceso de creación de las máscaras requiere el uso de diversas librerías especializadas para el manejo de datos ráster y vectoriales. Entre las librerías incluyen *rasterio* para leer y escribir archivos ráster, *geopandas* para manipular shapefiles y geometrías vectoriales, y *shapely* para la manipulación y análisis geométrico. Además, es necesario instalar otras librerías como *fiona* para la lectura de archivos geoespaciales y *numpy* para la manipulación eficiente de matrices numéricas. Estas librerías proporcionan las funcionalidades necesarias para realizar la rasterización y asegurar la compatibilidad entre los datos ráster y vectoriales.

3.5.2. Verificación de la compatibilidad de CRS

Antes de avanzar con la rasterización, es muy importante verificar que el sistema de referencia espacial (CRS) del archivo ráster y del shapefile de remociones coincidan. En caso de que los sistemas de referencia sean distintos, es necesario realizar una transformación espacial de los datos para alinearlos correctamente. Esta verificación asegura que los polígonos de remociones coincidan con precisión con las ubicaciones correctas en la imagen ráster. Si se detecta que los CRS son diferentes, se lleva a cabo una conversión para garantizar que ambas representaciones geoespaciales sean compatibles, lo que permite realizar la rasterización sin distorsiones.

3.5.3. Generación de máscaras

Una vez que chequeada la compatibilidad entre los sistemas de referencia espacial, se procede a la generación de las máscaras. En este paso, se carga tanto el archivo ráster (que contiene la imagen de satélite) como el shapefile de las remociones en masa. Luego, se transforma cada uno de los polígonos del shapefile a las coordenadas del ráster, asegurando que las geometrías se ajusten al sistema de referencia espacial adecuado. A continuación, los polígonos se rasterizan, lo que significa que se convierten en una imagen binaria en la que los píxeles que caen dentro de las zonas afectadas por remociones se asignan un valor de 1 (indicado como área de remoción), mientras que el resto de los píxeles fuera de estos polígonos se asignan un valor de 0. El resultado es una máscara que refleja las áreas de remoción en masa, que será utilizada en análisis posteriores (Figura 3.8).




Figura 3.8: Ejemplo de máscara binaria.

3.5.4. Visualización de imágenes y máscaras

Después de generar la máscara binaria, es importante visualizarla junto con la imagen original para verificar su calidad y precisión. La visualización de las imágenes y las máscaras permite comprobar si las zonas afectadas por remociones están correctamente identificadas y representadas en la máscara. Para ello, se presentan ambas imágenes (la original y la máscara) de manera comparativa. En la imagen original, se combinan las bandas RGB (rojo, verde y azul) para crear una visualización natural, mientras que en la máscara, las zonas afectadas por remociones se muestran en blanco, destacándose sobre el fondo oscuro. Esta comparación facilita la validación del proceso de creación de máscaras y nos asegura que las áreas de interés fueron correctamente segmentadas.

3.6. CLASIFICACIÓN CON EL MÉTODO K-NEAREST NEIGHBORS (K-NN)

Una vez generadas las máscaras y las imágenes preprocesadas en el paso anterior, se da paso a aplicar el método de clasificación k-Nearest Neighbors (k-NN) para identificar y segmentar las áreas asociadas a remociones en masa (Figura 3.9). Este método es ampliamente utilizado en clasificación supervisada debido a su simplicidad y eficacia, ya que asigna la clase de un píxel basándose en las clases de sus vecinos más cercanos en un espacio multidimensional definido por las características espectrales de las imágenes. Se adjunta un diagrama de flujo que explica de forma resumida el proceso de la clasificación de imágenes:

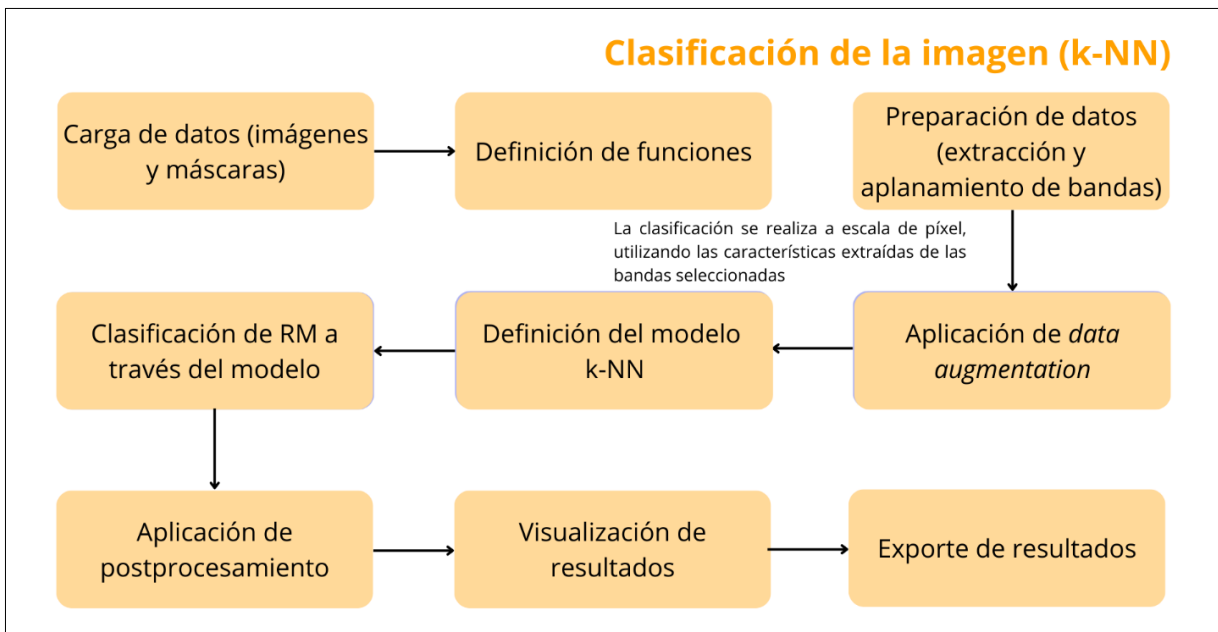


Figura 3.9: Diagrama de flujo del Modelo k-NN.

3.6.1. Importe de librerías

Además de *rasterio* y *numpy*, que ya fueron empleados para manejar imágenes y datos numéricos respectivamente, se introduce el uso de *scikit-learn*. Esta biblioteca es muy útil en el campo de machine learning debido a su robustez y flexibilidad para implementar una gran cantidad de algoritmos. En este caso, se utiliza la clase *KNeighborsClassifier*, que implementa el modelo k-NN, permitiendo ajustar parámetros como el número de vecinos (*n_neighbors*) para optimizar la clasificación. Adicionalmente, se utiliza *matplotlib* para la visualización de los resultados. Esto nos entrega una comparación directa entre las predicciones generadas por el modelo y las máscaras reales previamente generadas, ofreciendo así, una visión del rendimiento del modelo.

3.6.2. Carga y procesamiento de datos

Para preparar los datos, se definen funciones específicas que estructuran el flujo de trabajo. La función *cargar_imagen* permite cargar imágenes satelitales en formato .tif y gestionar valores nulos (NaN) presentes en las bandas espectrales mediante su reemplazo por valores mínimos (0.0001). Además, extrae información espacial, como la transformación y los metadatos, para mantener la coherencia espacial de las imágenes.

Por otro lado, la función *reescalar_mascara* asegura que las máscaras tengan el mismo tamaño que las bandas espectrales de las imágenes, utilizando técnicas de interpolación por proximidad (nearest resampling). Este paso es importante para asegurar que las máscaras sean compatibles con las imágenes durante el entrenamiento y la validación.

3.6.3. Aumento de datos

Para mejorar la generalización del modelo KNN, se implementó una estrategia de *data augmentation* mediante rotaciones geométricas de 90°, 180° y 270°. Este proceso consistió en cargar las imágenes satelitales originales junto con sus máscaras, aplicando las rotaciones a cada una de ellas. Las imágenes y máscaras resultantes se guardaron en sus respectivas carpetas, manteniendo su georreferenciación y sistema de coordenadas original. Este método permitió triplicar el tamaño del conjunto de datos, generando variaciones adicionales de los datos sin perder la coherencia espacial, lo que es esencial para mejorar el rendimiento del modelo en la clasificación de remociones en masa.

3.6.4. Aplicación del modelo k-NN

El modelo k-NN se implementa mediante la función *aplicar_knn*, utilizando las bandas como características espectrales. Este modelo clasifica los píxeles en función de las clases de sus vecinos más cercanos en un espacio multidimensional. Para ello, las bandas son aplanadas en vectores que pueden ser procesados por el modelo, mientras que los píxeles con datos incompletos o inválidos son filtrados para evitar errores durante la clasificación.

Una vez entrenado con las etiquetas de las máscaras reales, el modelo asigna una clase a cada píxel basándose en las clases predominantes entre sus vecinos. Este proceso resulta en una segmentación inicial de las áreas asociadas a remociones en masa.

3.6.5. Aplicación de postprocesamiento

El postprocesamiento en el modelo KNN se realiza mediante el uso de componentes conectados para eliminar pequeñas áreas de remociones predichas. Primero, las etiquetas de las predicciones se binarizan, marcando las áreas de remoción como 1 y las de no remoción como 0. Luego, se aplica la función *remove_small_objects* de la librería *skimage.morphology* para eliminar regiones conectadas que tengan un tamaño inferior a un valor mínimo predefinido (20 píxeles en este caso).

Después de este paso, las etiquetas filtradas se convierten nuevamente a valores binarios (0 y 1). Además, el proceso de postprocesamiento también incluye la visualización de los resultados con las predicciones postprocesadas y las máscaras reales, y el cálculo de métricas de evaluación, como la matriz de confusión y el informe de clasificación. Estas métricas permiten evaluar el impacto del postprocesamiento en la precisión del modelo.

3.6.6. Reconstrucción y visualización de resultados

Una vez que el modelo k-NN realiza las predicciones, las etiquetas clasificadas se reconstruyen para que coincidan con las dimensiones de las imágenes originales. Este paso es importante para poder comparar directamente las predicciones con las máscaras reales y evaluar la precisión de la clasificación.

La evaluación del modelo se lleva a cabo tanto en el conjunto de entrenamiento como en el de validación. Mientras que el conjunto de entrenamiento se utiliza para ajustar los parámetros del modelo, el conjunto de validación permite verificar la capacidad del modelo para generalizar.

Para facilitar la evaluación, se utiliza la función *visualizar_clustering*, que genera visualizaciones que incluyen las bandas RGB, las bandas espectrales seleccionadas, la máscara real y las predicciones del modelo. Estas visualizaciones permiten analizar el rendimiento del modelo de manera visual, ayudando a identificar áreas correctamente clasificadas y posibles errores en la segmentación, lo cual asegura que las áreas de remoción en masa estén correctamente identificadas.

4. RESULTADOS

En esta sección se presentan los resultados obtenidos a partir de tres modelos diseñados para identificar remociones en masa. Los modelos fueron implementados de manera progresiva, aumentando en complejidad con el objetivo de mejorar la capacidad de detección y las métricas de rendimiento. El primer método consiste en un modelo sencillo basado en un umbral de NDVI, el cual utiliza un criterio directo para diferenciar las áreas afectadas. Posteriormente, se aplicó un modelo de clustering no supervisado mediante K-Means, que agrupa los datos en categorías sin necesidad de etiquetas previas. Finalmente, se desarrolló un modelo supervisado basado en KNN, el cual utiliza datos etiquetados para entrenar un clasificador más robusto. Este enfoque progresivo permite analizar cómo cada metodología responde a las características de los datos y evaluar si el incremento en la complejidad del modelo contribuye a una mejor capacidad de detección y clasificación de remociones en masa.

4.1. INVENTARIO

Para esta investigación, se seleccionaron un total de 33 eventos de remociones en masa como base del análisis. Estos eventos fueron identificados principalmente a partir de la información proporcionada por SERNAGEOMIN, verificando su mapeabilidad en función de la resolución de las imágenes satelitales disponibles. Cada evento fue evaluado cuidadosamente utilizando Google Earth (GE) y Google Earth Engine (GEE) para confirmar su visibilidad y definir su inclusión en el inventario. Como criterio adicional, se estableció que una remoción debía abarcar al menos 9 píxeles contiguos para ser considerada válida, garantizando así la representatividad del fenómeno a la escala espacial de las imágenes utilizadas (Figura 4.1).

Las remociones en masa abarcadas en este estudio se distribuyen principalmente en las regiones de Los Ríos, Los Lagos y, en menor medida, Aysén. La combinación de factores geológicos, como la presencia de la Falla Liqueñe-Ofqui, y climáticos, como las intensas precipitaciones, contribuye a la alta frecuencia e intensidad de los eventos de remoción en masa en estas regiones. Estas condiciones también facilitan la identificación y análisis de los eventos mediante imágenes satelitales, ya que las alteraciones en la cobertura terrestre son fácilmente detectables debido a la abundante vegetación en el sur de Chile.

Además, en el inventario se incluyó información detallada sobre cada evento, como la coordenada geográfica precisa de su ubicación, la fecha exacta en que ocurrió el evento de remoción y el rango de fechas en el que se extrajeron las colecciones de imágenes satelitales utilizadas en el análisis.

Para generar dichas colecciones, se definió un rango de fechas específico, considerando tanto las condiciones previas como las posteriores a los eventos. Se emplearon imágenes satelitales de Landsat 8 y Sentinel-2, siendo especialmente relevantes las imágenes de Sentinel-2 debido a su alta resolución y disponibilidad continua, especialmente a partir de 2019, donde se ha priorizado el uso de estas imágenes para los eventos más recientes. Esto permitió una mejor cobertura temporal y espacial para el análisis de los cambios en la cobertura de suelo a través del tiempo.

Se adjunta la Figura 4.1 que muestra una vista preliminar del inventario de eventos de remociones en masa. El inventario completo con todos los detalles será incluido en el Anexo A.

Evento	Fecha_Inicio_Pre	Fecha_Fin_Pre	Fecha_Inicio_Post	Fecha_Fin_Post	Polígono	Lugar	Satélite	Fecha de la RM
Evento1	2017-11-02	2017-12-15	2017-12-30	2018-02-15	[-72.4373439	Santa Lucía	L8	16-12-2017
Evento2	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6704304	Chaitén 1	L8	may-15
Evento3	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6785939	Chaitén 2	L8	may-15
Evento4	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6714604	Chaitén 3	L8	may-15
Evento5	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6907216	Chaitén 4	L8	may-15
Evento6	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6884042	Chaitén 5	L8	may-15
Evento7	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6865159	Chaitén 6	L8	may-15
Evento8	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6720963	Chaitén 7	L8	may-15
Evento9	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6699506	Chaitén 8	L8	may-15
Evento10	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6716672	Chaitén 9	L8	may-15
Evento22	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6469479	Chaitén 10	L8	may-15
Evento23	2015-01-01	2015-04-25	2016-01-01	2016-04-25	[-72.6242886	Chaitén 11	L8	may-15
Evento24	2015-01-01	2015-03-25	2016-01-01	2016-03-25	[-72.6098691	Chaitén 12	L8	may-15
Evento25	2015-01-01	2015-03-25	2016-01-01	2016-02-25	[-72.5880681	Chaitén 13	L8	may-15
Evento26	2015-01-01	2015-03-25	2016-01-01	2016-02-25	[-72.5658379	Chaitén 14	L8	may-15

Figura 4.1: Extracto del inventario de remociones en masa.

4.2. MODELO UMBRAL BASADO EN NDVI

Basándonos en las propiedades del índice NDVI descritas en el marco teórico, se propone utilizar este índice como indicador preliminar para identificar remociones en masa. Los valores bajos de NDVI, que indican la ausencia de vegetación o la presencia de superficies expuestas, son característicos de áreas afectadas por deslizamientos de tierra. En este modelo inicial, se define un umbral fijo que permita separar los píxeles afectados de los no afectados, con el objetivo de evaluar la capacidad del NDVI para detectar estos eventos.

Para implementar este modelo, se trabajó con un conjunto de datos de entrenamiento compuesto por imágenes satelitales almacenadas en el directorio *train* y sus correspondientes máscaras de referencia en *maskstrain*. Las imágenes contienen múltiples bandas espectrales, pero en este caso se utilizó exclusivamente la banda 4, que corresponde al NDVI. El umbral seleccionado para identificar áreas de remoción en masa fue un valor de NDVI menor a $-0,07$. Este umbral se definió a partir de un proceso de prueba y error, probando distintos valores y seleccionando aquel que más se acercaba a las máscaras reales.

El proceso comenzó con la carga de las imágenes y las máscaras mediante la biblioteca *rasterio* (Figura 4.2). Para cada imagen, se extrajo la banda de NDVI y se aplicó el umbral definido, generando un mapa binario de predicciones. Los píxeles que cumplían con la condición ($\text{NDVI} < -0,07$) fueron clasificados como remociones en masa, mientras que los restantes se no se consideraron remociones. Posteriormente, estas predicciones se compararon con las máscaras de referencia para evaluar su precisión.

```

import os
import numpy as np
import rasterio
import matplotlib.pyplot as plt
from sklearn.metrics import confusion_matrix, accuracy_score, precision_score, recall_score, f1_score
import geopandas as gpd
from shapely.geometry import Polygon
from rasterio.features import shapes

# Configuración de directorios
directorio_base = "/content/drive/MyDrive/rfi"
directorio_train = os.path.join(directorio_base, "train")
directorio_maskstrain = os.path.join(directorio_base, "maskstrain")
directorio_salida = os.path.join(directorio_base, "predicciones")
os.makedirs(directorio_salida, exist_ok=True)

imagenes_train = sorted([os.path.join(directorio_train, f) for f in os.listdir(directorio_train) if f.endswith('.tif')])
mascaras_train = sorted([os.path.join(directorio_maskstrain, f) for f in os.listdir(directorio_maskstrain) if f.endswith('.tif')])

# Función para leer una imagen y extraer la banda NDVI (banda 4)
def cargar_banda_ndvi(ruta_imagen):
    with rasterio.open(ruta_imagen) as src:
        num_bands = src.count
        if num_bands >= 4:
            banda_ndvi = src.read(4)
        else:
            banda_ndvi = src.read(1)
    print(f"Warning: Image {ruta_imagen} has only {num_bands} bands. Using band 1 instead of 4.")
    return banda_ndvi, src.transform, src.crs

# Función para cargar máscaras
def cargar_mascara(ruta_mascara):
    with rasterio.open(ruta_mascara) as src:
        mascara = src.read(1)
    return (mascara > 0).astype(int) # Convertir a binaria

# Función para calcular métricas
def calcular_metricas(y_true, y_pred):
    y_true_flat = y_true.ravel()
    y_pred_flat = y_pred.ravel()
    cm = confusion_matrix(y_true_flat, y_pred_flat, labels=[0, 1])
    tn, fp, fn, tp = cm.ravel()

```

Figura 4.2: Extracto del script del Modelo umbral NDVI.

La visualización de resultados incluyó la generación de figuras comparativas. En cada figura se mostraron tres plots: la imagen original de NDVI, el mapa de predicciones basado en el umbral y la máscara de referencia correspondiente. Esto permitió identificar visualmente las coincidencias y discrepancias entre las predicciones y las áreas etiquetadas manualmente como remociones (Figura 4.3 y 4.4).

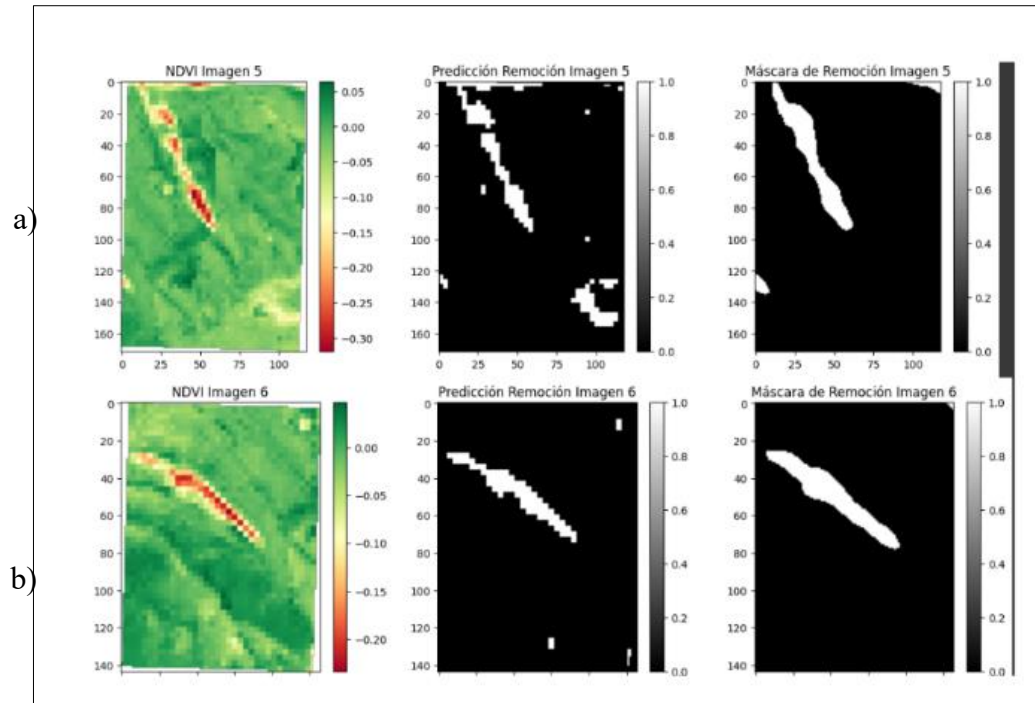


Figura 4.3: Visualización de predicciones del Modelo umbral NDVI. Se visualizan en (a) y (b) dos eventos con sus respectivas predicciones y máscaras.

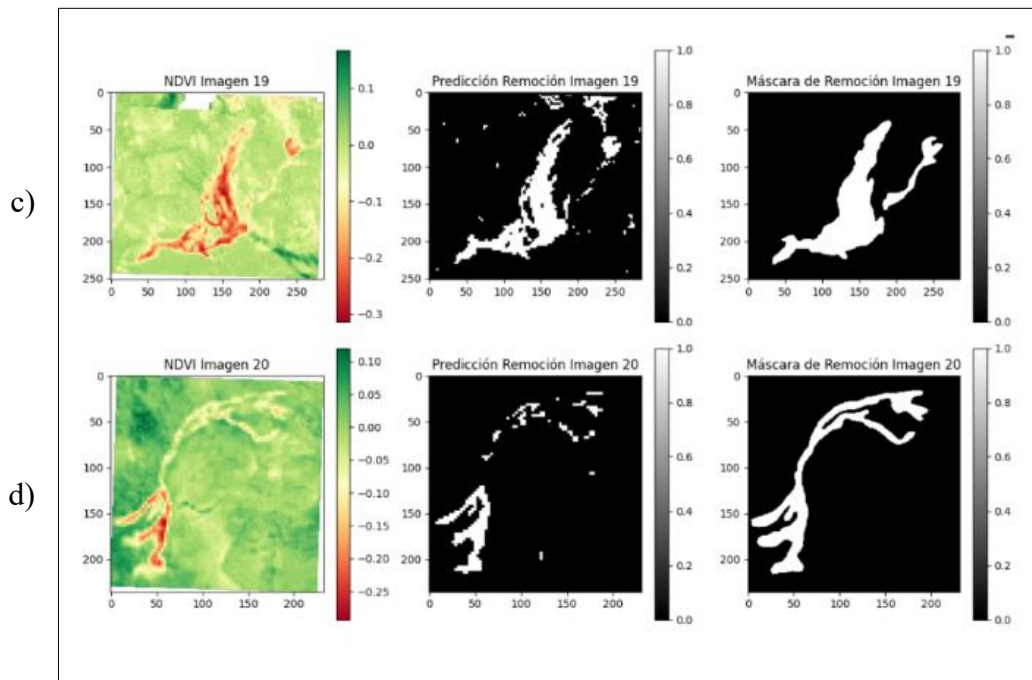


Figura 4.4: Visualización de predicciones del Modelo umbral NDVI (2). Se visualizan en (c) y (d) dos eventos con sus respectivas predicciones y máscaras.

Sin embargo, también se observaron limitaciones importantes. El modelo es altamente sensible al ruido presente en los valores de NDVI y depende de manera crítica del umbral seleccionado. Esto puede generar clasificaciones incorrectas, ya sea falsas positivas (píxeles clasificados como remoción sin serlo) o falsas negativas (remociones no detectadas). Un umbral fijo puede no ser adecuado para todas las imágenes o eventos, ya que las condiciones ambientales y las características de las remociones pueden variar considerablemente. Otro factor a considerar es la presencia de nubes en las imágenes satelitales, que puede interferir en el cálculo de los índices y generar información errónea, dificultando la detección precisa de las remociones en masa. Además, sin conocer la forma de las remociones, nunca se podrá definir con certeza un umbral que coincida con las áreas afectadas, lo que dificulta encontrar el valor ideal. Esto representa una desventaja crítica al intentar aplicar este modelo a nuevas remociones, ya que el proceso se vuelve complejo y poco automatizable.

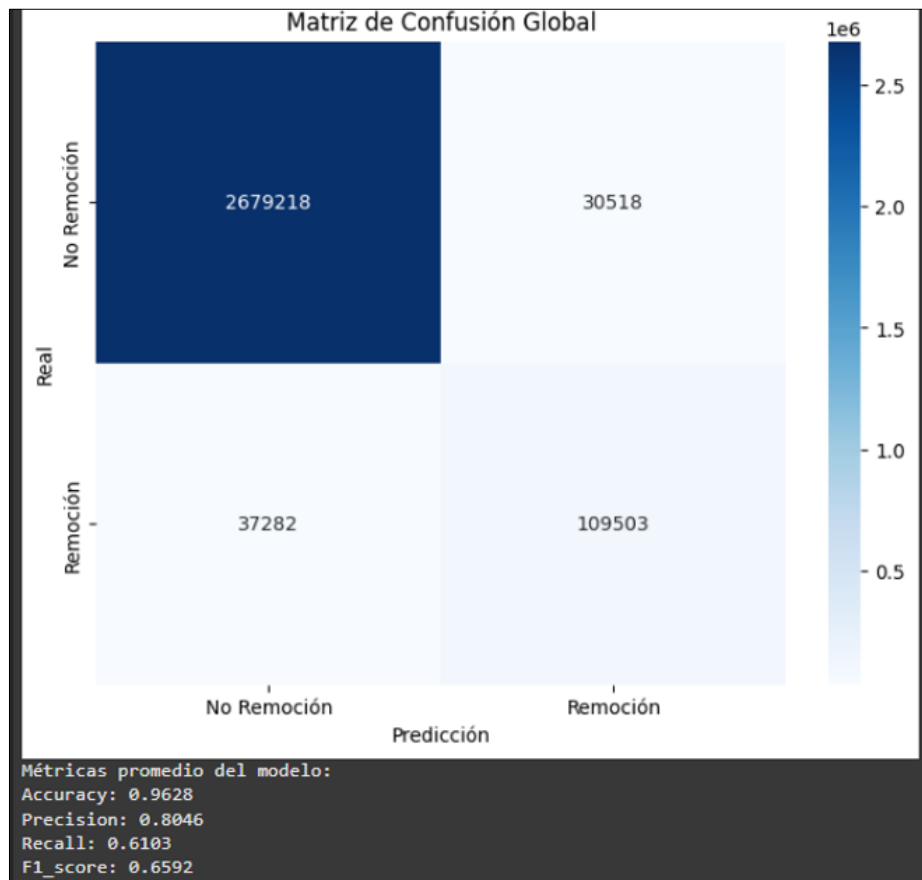


Figura 4.5: Matriz de confusión y métricas del Modelo umbral NDVI.

Respecto al análisis, se evaluó el desempeño del modelo mediante métricas como *accuracy*, precisión, recall y F1 score. Aunque el *accuracy* fue alto (0,9628), este valor está sobrestimado debido al desequilibrio de clases, donde los píxeles de "no remoción" dominan el conjunto de datos. La matriz de confusión (Figura 4.5) mostró que el modelo identificó correctamente 2.679.218 píxeles como "no remoción" (verdaderos negativos) y 109.503 píxeles como "remoción" (verdaderos positivos). Sin embargo, también clasificó erróneamente 30.518 píxeles como "remoción" (falsos positivos) y dejó sin identificar 37.282 píxeles de "remoción" (falsos negativos).

La precisión de 0,8046 indica que, del total de píxeles clasificados como "remoción", aproximadamente el 80% fueron correctos, mientras que el recall de 0,6103 refleja que el modelo identificó solo el 61% de los píxeles de remoción reales. Esto evidencia que aún hay margen para reducir los falsos negativos y aumentar la sensibilidad del modelo. El F1 score de 0,6592 sintetiza este desempeño, mostrando un equilibrio moderado entre precisión y recall. La comparación visual con las máscaras de referencia confirma estas limitaciones, especialmente en áreas afectadas por ruido, nubes o bordes de remociones difíciles de delinear.

4.3. MODELO K-MEANS

Basándose en un método de clasificación no supervisado, el modelo K-Means se aplicó para identificar remociones en masa mediante el análisis de las bandas 4 a 9 de las imágenes satelitales, que incluyen índices descritos previamente. Este modelo divide los píxeles en dos grupos principales: remoción y no remoción, utilizando las distancias entre los valores de las bandas y los centroides de los clústers para asignar las clases. La identificación del clúster asociado a las remociones se realizó seleccionando el centroide con mayor magnitud en el espacio multidimensional definido por las bandas utilizadas, es decir, el clúster con los píxeles con valores de diferencia de índices más altos (Figura 4.6).

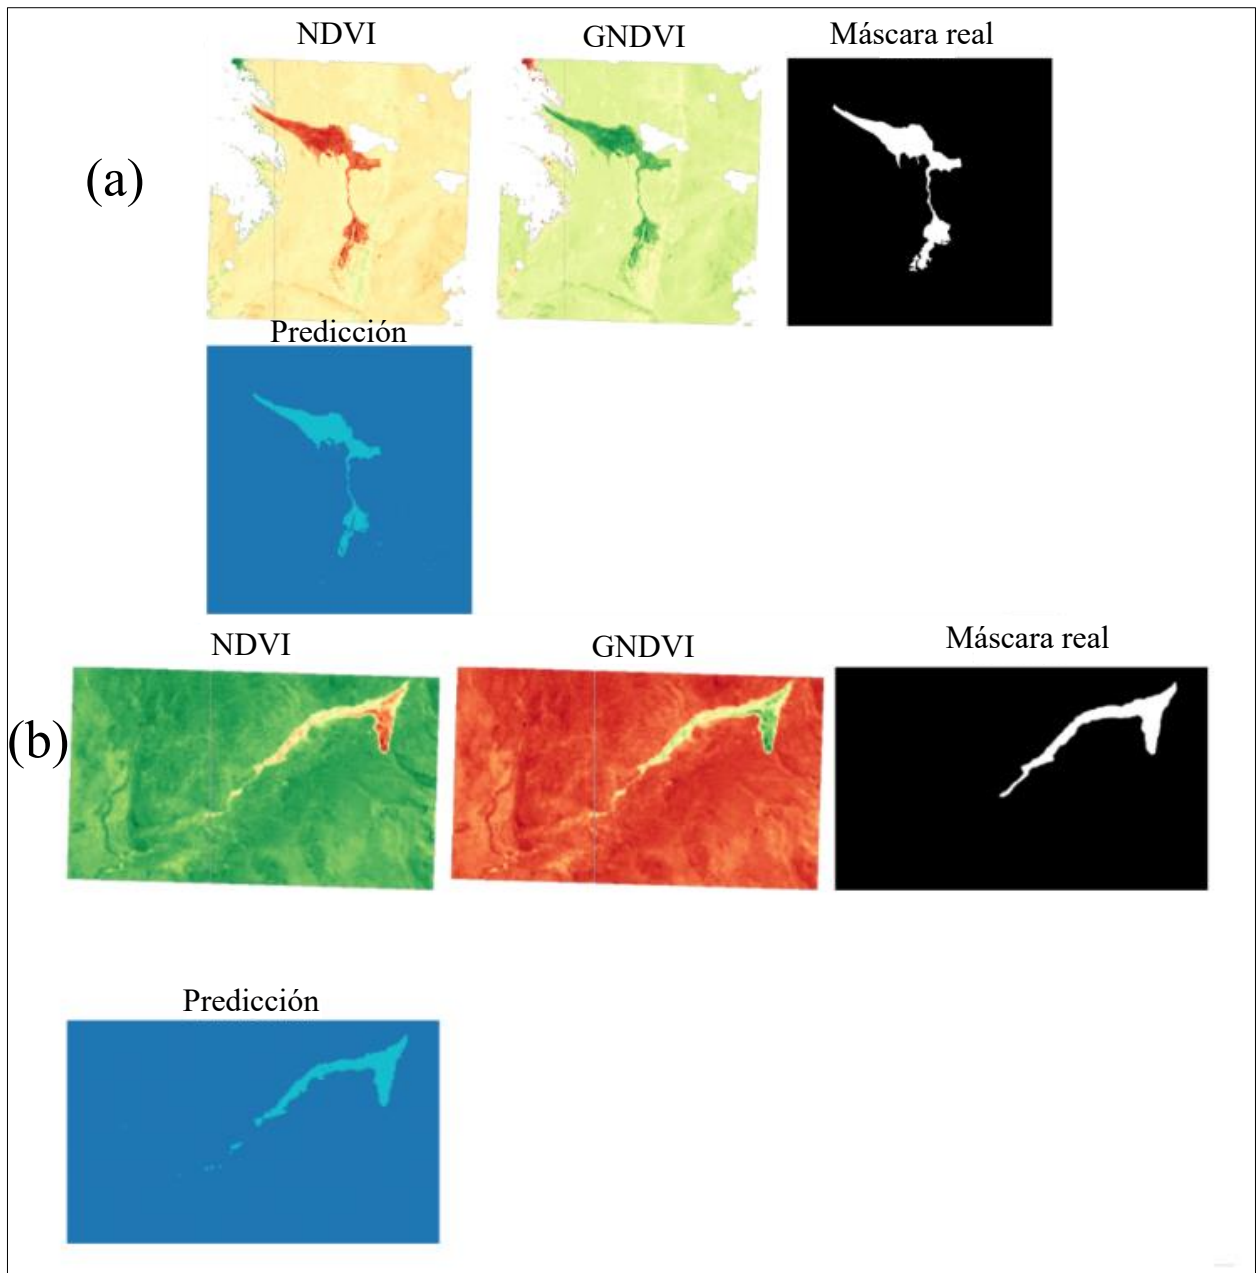


Figura 4.6: Visualización de predicciones del Modelo K-means. Se visualizan (a) y (b) con sus respectivas diferencias de NDVI y GNDVI, además de su predicción y máscara.

El proceso de clasificación incluyó la carga de imágenes y máscaras de referencia mediante *rasterio*, la extracción de las bandas relevantes y la aplicación del algoritmo K-Means para generar mapas binarios de predicción. Los píxeles correspondientes al clúster con las características más evidentes asociadas a remociones fueron etiquetados como "remoción", mientras que los demás se clasificaron como "no remoción".




Figura 4.7: Matriz de confusión del Modelo K-means.

En cuanto a los resultados del modelo K-Means, la matriz de confusión mostró un desempeño mixto (Figura 4.7). El modelo logró clasificar correctamente 2.482.676 píxeles como "no remoción" (verdaderos negativos) y 102.674 píxeles como "remoción" (verdaderos positivos). Sin embargo, también presentó 227.060 falsos positivos, es decir, píxeles clasificados erróneamente como "remoción", y 44.111 falsos negativos, que corresponden a píxeles de remoción no detectados.

Tabla 1.1: Métricas del Modelo K-means

Métrica	Valor
Precision	0,31
Recall	0,7
F1-Score	0,43
<i>Accuracy</i>	0,91

Las métricas globales reflejan estas limitaciones. Aunque la *accuracy* del modelo fue alta (0,91), esta métrica está influenciada por el gran número de píxeles de "no remoción". La precisión para

la clase "remoción" fue baja, con un valor de 0,31, lo que indica que solo el 31% de los píxeles clasificados como "remoción" fueron correctos. Por otro lado, el recall para esta clase alcanzó 0,70, lo que significa que el modelo logró identificar el 70% de las remociones reales, aunque dejando un 30% sin clasificar. El F1 score fue de 0,43, reflejando un desempeño moderado pero limitado en la detección de remociones.

Estos resultados muestran que el modelo K-Means es capaz de captar algunas características distintivas de las remociones en masa, pero también es sensible a la heterogeneidad de los eventos analizados. En ciertos casos, el modelo logra resultados satisfactorios con los parámetros iniciales, mientras que en otros eventos marca de forma inconsistente áreas que no corresponden a remociones. Este comportamiento evidencia una de las principales desventajas del modelo: la necesidad de ajustar el número de clústeres y otros parámetros para cada evento, lo que dificulta la generalización de este mismo.

4.4. MODELO K-NN JUNTO A POSTPROCESAMIENTO

En este modelo, se utilizó el algoritmo k-NN para la clasificación supervisada de remociones en masa. A diferencia de los dos modelos anteriores, el modelo k-NN aprovecha un conjunto de entrenamiento etiquetado para aprender la relación entre las características espectrales de las imágenes y las clases de remoción y no remoción. Las bandas 4 a 9 se emplearon para representar las características de los píxeles y permitir la clasificación.

El proceso comenzó con la carga y preprocesamiento de las imágenes de entrenamiento y sus máscaras de referencia, obtenidas según lo descrito en el subcapítulo 3.4 de la metodología. Estas máscaras fueron utilizadas para identificar las áreas de remoción y no remoción, binarizándolas para facilitar su uso en el modelo. Posteriormente, se reestructuraron las características (basadas en las bandas NDVI, GNDVI) y las etiquetas para entrenar el modelo k-NN, con un número de vecinos de 5 (Figura 4.8).

Cabe destacar que este conjunto de datos es el único de los tres modelos al que se le aplicó *data augmentation*, como se detalla en la metodología. Este proceso incluyó transformaciones como

rotaciones de las imágenes y sus máscaras, lo que permitió aumentar la cantidad de datos a analizar por el modelo.

Además, el conjunto de datos fue dividido en un 70 % para entrenamiento y un 30 % para validación. Esta división permitió evaluar el desempeño del modelo de manera objetiva y garantizar que los resultados no estuvieran sesgados hacia el conjunto de entrenamiento.

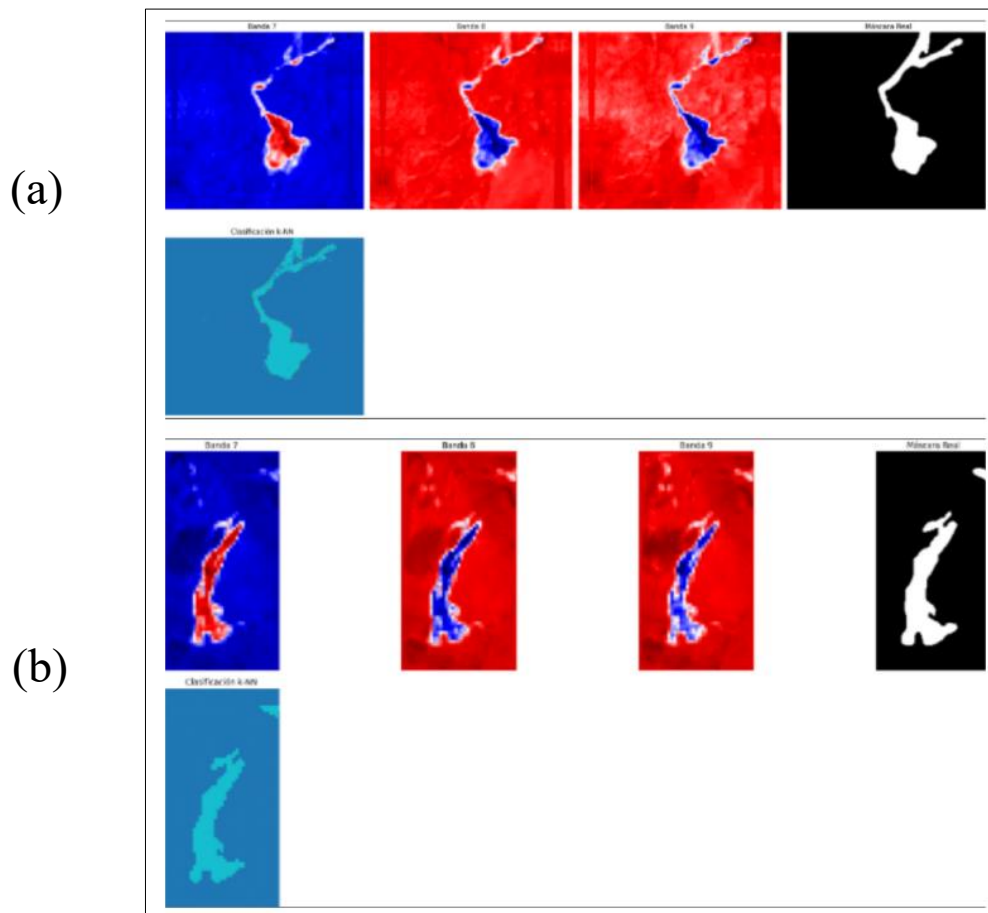


Figura 4.8: Visualización de predicciones del Modelo k-NN. Se presentan las diferencias de índices BSI, NBR y SAVI, junto a su máscara y predicción del modelo para el evento (a) y (b).

El algoritmo k-NN se aplicó a las imágenes y máscaras de validación para generar mapas de predicción. Los resultados obtenidos fueron visualizados comparando las etiquetas predichas con las máscaras reales de remoción. La matriz de confusión original mostró que el modelo clasificó correctamente 3.681.022 píxeles como "no remoción" (verdaderos negativos) y 217.182 píxeles

como "remoción" (verdaderos positivos), aunque también presentó 61.604 falsos positivos y 42.672 falsos negativos (Figura 4.9).




Figura 4.9: Matriz de confusión del Modelo k-NN.

Para mejorar los resultados, se aplicó un proceso de postprocesamiento. Este proceso tiene como objetivo eliminar áreas pequeñas y no significativas de remoción, las cuales a menudo son causadas por errores del modelo o ruido en los datos. La idea es conservar solo las regiones con un tamaño mínimo de píxeles para garantizar que las predicciones sean más precisas y representen áreas de remoción reales. Sin embargo, esta estrategia implica un compromiso entre precisión y recall, ya que al eliminar regiones pequeñas se reducen los falsos positivos, mejorando la precisión, pero a costa de potencialmente descartar algunas remociones pequeñas, lo que puede afectar el recall. La función implementada, *postprocesar_remociones_por_componentes*, binariza las etiquetas predichas y elimina aquellas áreas que no cumplen con un umbral de tamaño mínimo. Esto ayuda

a reducir la cantidad de falsos positivos, como aquellos que representan pequeñas regiones no válidas como remociones (Figura 4.10).

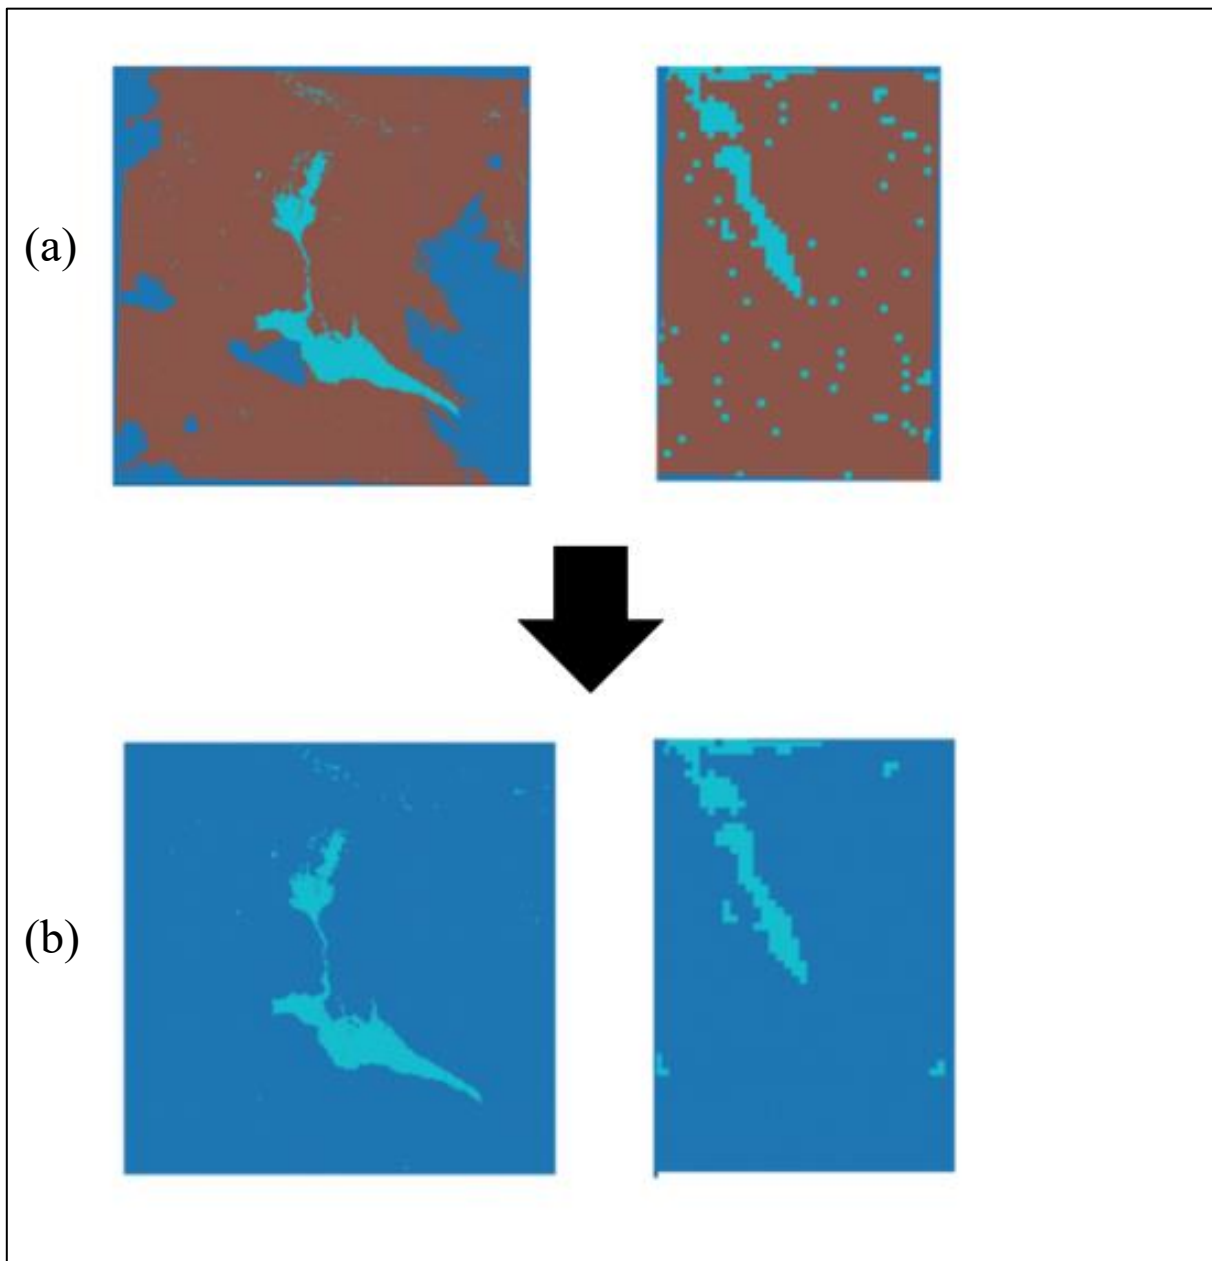


Figura 4.10: Visualización de las predicciones antes y después de postprocesar. (a) Se visualiza la predicción del modelo k-NN. (b) Se visualiza la predicción luego de aplicarse el postprocesamiento, se aprecia la disminución de ruido.

Después de aplicar el postprocesamiento, los resultados mostraron una mejora considerable en las métricas. La matriz de confusión reveló que el modelo logró clasificar correctamente 3.714.080

píxeles como "no remoción" y 215.588 como "remoción", con una reducción de los falsos positivos a 28.546 y un leve aumento de los falsos negativos a 44.266 (Figura 4.11).




Figura 4.11: Matriz de confusión del Modelo k-NN postprocesado.

Las métricas globales postprocesamiento fueron las siguientes: la precisión subió a 0,88, con un recall de 0,83 y un F1 score de 0,86, mostrando la eficacia del postprocesamiento.

Tabla 4.2: Comparación de métricas del modelo k-NN con y sin postprocesamiento

Métrica	Antes del Postprocesamiento	Después del Postprocesamiento
Precision	0,78	0,88
Recall	0,84	0,83
F1-Score	0,81	0,86
<i>Accuracy</i>	0,97	0,98

5. DISCUSIÓN

5.1. TÉCNICAS DE CLASIFICACIÓN

En esta investigación se ha utilizado una metodología basada en la clasificación de remociones en masa a partir de imágenes satelitales, empleando diferentes técnicas de machine learning y procesado de índices, destacando especialmente el uso de un umbral de diferencia de NDVI, el clasificador KNN y el método KMeans. Como primer paso, el uso de un umbral de NDVI permitió diferenciar áreas de remoción en masa con base en cambios significativos en la vegetación. Aunque este enfoque se aplicó de manera diferente en este estudio, es similar al utilizado por Herrera (2019) y Yang *et al.*, (2012), quienes también emplearon el NDVI como un proxy para detectar remociones en masa, destacando su capacidad para reflejar alteraciones en la cobertura vegetal. Sin embargo, la capacidad del umbral de NDVI para detectar remociones se ve limitada por la variabilidad en la cobertura vegetal y la complejidad geológica del área de estudio.

Por otro lado, el clasificador KNN permitió una mayor flexibilidad para modelar relaciones no lineales entre las características extraídas de las bandas espectrales y los índices calculados, como el NDVI, el NBR y el SAVI. Este modelo supervisado ha demostrado ser efectivo en estudios de detección de remociones en masa debido a su capacidad para manejar datos con características diversas y su robustez frente a distribuciones heterogéneas. Sin embargo, al igual que el Random Forest analizado por Herrera (2019), el KNN requiere de un adecuado balance en la distribución de clases para minimizar la generación de falsos positivos o negativos, como se evidenció en este estudio. Esto destaca la importancia de implementar estrategias adicionales, como la segmentación de datos o técnicas de balanceo, para mejorar la calidad de las predicciones.

Además, tanto Herrera (2019) como Mezaal *et al.*, (2018) resaltaron el uso de características texturales como la homogeneidad (GLCM Homogeneity), que, junto con variables como la pendiente y la intensidad espectral, pueden contribuir significativamente a la correcta separación de remociones en masa de otras clases, como suelos expuestos o áreas urbanas. Estas características han demostrado ser relevantes para aumentar la precisión de los clasificadores al distinguir entre

remociones y otras coberturas terrestres, destacando la relevancia de una adecuada selección de características en el diseño de modelos supervisados.

En cuanto al uso de técnicas de clustering no supervisado, como el KMeans, se observó que este enfoque permitió identificar patrones subyacentes en las diferencias de índices y facilitó la segmentación inicial de las imágenes. A diferencia de este estudio, que trabajó directamente a escala de píxel, Herrera (2019) utilizó el KMeans para crear segmentos y luego analizar características a nivel de segmento, adoptando un enfoque orientado a objetos. Herrera (2019) enfrentó la problemática de la sobresegmentación añadiendo texturas derivadas del NDVI y clasificando los segmentos a partir de estos, junto con otros índices como por ejemplo, el NDVI y la desviación estándar del Brightness. Esto permitió mejorar la separación entre áreas afectadas y no afectadas.

Finalmente, el análisis de las características espectrales, junto con el uso de índices de vegetación, resalta la importancia de los datos satelitales en la detección de remociones en masa. La integración de diferentes fuentes de datos, como imágenes de Sentinel-2 y el uso de modelos de clasificación, es clave para mejorar la precisión de la detección.

5.2. LIMITACIONES DEL MODELO Y DE LOS DATOS DISPONIBLES

5.2.1. Resolución espacial de las imágenes satelitales

A pesar de que las imágenes de Landsat 8 ofrecen una resolución espacial de 30 m, adecuada para la identificación de grandes remociones en masa, esta puede resultar insuficiente para detectar eventos pequeños o con límites difusos. Este desafío se presenta especialmente en áreas con remociones más pequeñas o en paisajes complejos. La resolución espacial limitada de Landsat 8 puede afectar la precisión en la delimitación de los deslizamientos, especialmente en zonas con alta vegetación o terrenos irregulares. Este problema también se observa en el caso del satélite Sentinel-2, que comparte una resolución espacial similar y también es otra fuente de información satelital de libre acceso.

Herrera (2019) plantea esta misma limitación en su trabajo, destacando la necesidad de datos con mayor resolución espacial para mejorar la identificación y caracterización de remociones en masa. Una posible solución sería acceder a fotografías satelitales de mayor resolución, como las ofrecidas por PlanetScope, que proporciona imágenes con 3 m/píxel e incluso está desarrollando tecnologías que permiten obtener imágenes con una resolución de 50 cm/píxel. Sin embargo, estas imágenes no son de libre acceso, lo que representa una limitación financiera para investigaciones que requieren una amplia cantidad de datos. A pesar de estas limitaciones, el acceso a imágenes de mayor resolución podría ser clave para identificar con mayor precisión eventos más pequeños, que no son mapeables con las resoluciones ofrecidas por Landsat 8 y Sentinel-2.

5.2.2. Cobertura nubosa y condiciones atmosféricas

La presencia de nubes en las imágenes de Landsat 8 y Sentinel 2 puede afectar significativamente la calidad de los datos, especialmente cuando se utilizan índices como el NDVI, que dependen de la reflectancia en el espectro visible e infrarrojo cercano. Aunque se pueden aplicar técnicas de corrección atmosférica, las nubes o la neblina pueden seguir interfiriendo con la detección precisa de cambios en la vegetación, limitando la capacidad para identificar remociones en masa en ciertas épocas del año. Este factor puede generar imprecisiones en la estimación de la variabilidad temporal y espacial de los cambios en la vegetación antes y después de los eventos de remoción. Además, el área de estudio, al encontrarse en el sector sur del país, se ve afectada por un clima caracterizado por ser lluvioso y mantener constantemente una cobertura de nubes considerable, lo que agrava las dificultades asociadas a la obtención de imágenes satelitales sin interferencias.

5.2.3. Falta de inventarios de remociones en masa

Uno de los mayores retos en la aplicación de este modelo es la falta de inventarios exhaustivos de remociones en masa para el entrenamiento. El inventario de *SERNAGEOMIN*, elaborado por *Natalia Garrido*, es un recurso valioso a nivel nacional; sin embargo, su uso en este estudio fue limitado debido a la falta de coincidencia temporal con las imágenes satelitales y al predominio de remociones pequeñas, muchas de las cuales no eran visibles. Además, el acceso a este inventario fue complejo. Estas limitaciones resaltan la necesidad de contar con bases de datos actualizadas, accesibles y con registros precisos de la fecha del evento para mejorar la detección de remociones en masa.

5.3. RECOMENDACIONES PARA TRABAJOS FUTUROS

Para mejorar la precisión y generalización de los modelos de detección de remociones en masa, es fundamental contar con un conjunto de datos más amplio y diverso. Un ejemplo de ello es el inventario de Morales et al. (2022), el cual presenta un gran número de muestras y un alto potencial para el entrenamiento de modelos basados en redes neuronales convolucionales (CNN), especialmente a escalas regionales o nacionales. Sin embargo, su aplicación en esta investigación fue limitada debido a la falta de información sobre la fecha de ocurrencia de los eventos, un requisito fundamental para el análisis de diferencias espectrales entre imágenes pre y post evento. Futuras investigaciones podrían explorar la integración de este tipo de inventarios con registros temporales precisos para mejorar la aplicabilidad de modelos basados en enfoques espectrales.

Además, se sugiere considerar la incorporación de imágenes SAR (Radar de Apertura Sintética), que ofrecen ventajas significativas en la detección de remociones en masa, particularmente en áreas con nubosidad frecuente o en condiciones donde las imágenes ópticas son limitadas. Las imágenes SAR pueden proporcionar información complementaria valiosa sobre la topografía, la humedad del suelo y la alteración del terreno, lo que enriquecería el análisis y aumentaría la precisión del modelo.

Por otro lado, la incorporación de datos LiDAR (Light Detection and Ranging) podría complementar significativamente los análisis, ya que proporciona información precisa sobre la estructura tridimensional del terreno. Estos datos permitirían una mejor caracterización de las variaciones topográficas y una identificación más precisa de las áreas afectadas por remociones en masa. Su uso combinado con imágenes satelitales y SAR ofrecería una visión más detallada y completa, mejorando la detección y clasificación de eventos de remoción.

6. CONCLUSIÓN

La conclusión de este estudio refleja el cumplimiento exitoso de los objetivos planteados, destacando la efectividad del modelo para la detección y caracterización de remociones en masa en el sur de Chile. A través del análisis de imágenes satelitales y descripciones de terreno, se logró identificar de manera precisa las áreas afectadas por estos fenómenos. Esto se alcanzó utilizando algoritmos desarrollados en GEE y Python, que permitieron procesar y clasificar considerables volúmenes de datos geoespaciales.

En cuanto al primer objetivo específico, el análisis de las imágenes satelitales, incluyendo varios índices espectrales, permitió identificar y caracterizar las remociones en masa en función de su comportamiento espectral. Los resultados fueron validados con datos de terreno y eventos históricos, lo que permitió reafirmar la exactitud del modelo y su capacidad para identificar correctamente las áreas afectadas.

El segundo objetivo específico se cumplió mediante el desarrollo de un modelo basado en algoritmos de aprendizaje automático, particularmente el modelo KNN, el cual fue validado con de la misma forma. Este modelo mostró una buena capacidad para identificar las remociones en masa, superando las dificultades relacionadas con la variabilidad de las condiciones del terreno y la complejidad de los eventos de remoción.

7. REFERENCIAS

- Alarcón, F. (1995). *Los riesgos naturales en el área metropolitana de Concepción a través de la información del Diario El Sur, 1960-1990*. Concepción: Memoria para optar al título de Profesor de Historia y Geografía, Departamento de Historia, Universidad de Concepción.
- Ariza, A., Davila, N. A., Kemper, H., & Kemper, G. (2021). Landslide Detection in Central America Using the Differential Bare Soil Index. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 679-684.
- Branco, P., Torgo, L., & Ribeiro, R. P. (2016). A survey of predictive modeling on imbalanced domains. *ACM Computing Surveys (CSUR)*, 49(2):31.
- Campos Maza, F. (2014). *Evaluación de la susceptibilidad de remociones en masa en la Quebrada de Los Chanchos, Región Metropolitana, Chile*. Disponible en <https://repositorio.uchile.cl/handle/2250/130232>.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- Cruden, D. M., & Varnes, D. J. (1996). Landslide types and processes. En A. K. Turner & R. Schuster (Eds.), *Landslides, investigation and mitigation*, Special report 247, pp. 36-75. Washington D.C.: Transportation Research Board. ISBN: 030906208X.
- González de Vallejo, L., Ferrer, M., Ortuno, L., & Oteo, C. (2002). *Ingeniería Geológica*. Prentice Hall, Madrid.
- Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K. T. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1-2), 42-66.
- Hall, D. K., & Riggs, G. A. (2010). Normalized-difference snow index (NDSI). En *Encyclopedia of snow, ice and glaciers*.

- Hall, D. K., Foster, J. L., Verbyla, D. L., Klein, A. G., & Benson, C. S. (1998). Assessment of snow-cover mapping *accuracy* in a variety of vegetation-cover densities in central Alaska. *Remote sensing of Environment*, 66(2), 129-137.
- Hauser, A. (1993). Remociones en masa en Chile. *Servicio Nacional de Geología y Minería*, Santiago. Boletín No. 45, p. 7-29.
- Hauser, A. (1997). Los aluviones del 18 de junio de 1991 en Antofagasta: Un análisis crítico a cinco años del desastre. *Boletín N° 49*. Servicio Nacional de Geología y Minería.
- He, H., & Garcia, E. A. (2008). Learning from imbalanced data. *IEEE Transactions on Knowledge & Data Engineering*, 9:1263–1284.
- Herrera Herrera, M. (2019). *Landslide detection using random forest classifier*. Master of Science in Geomatics at Delft University of Technology.
- Highland, L. M., & Bobrowsky, P. (2008). *The landslide handbook-A guide to understanding landslides* (No. 1325). US Geological Survey.
- Hölbling, D., Friedl, B., & Eisank, C. (2015). An object-based approach for semi-automated landslide change detection and attribution of changes to landslide classes in northern Taiwan. *Earth Science Informatics*, 8(2), 327-335.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.
- Hungr, O., Leroueil, S., & Picarelli, L. (2014). The Varnes classification of landslide types, an update. *Landslides*, 11(2), 167-194.

Ingram, K., Knapp, E., and Robinson, J. (1981). Change detection procedure development for improved urbanized area delineation. *Technical memorandum CSC/TM-81*, 6087.

Jacoby, D. (2001). *Vulnerabilidad del sector urbano de La Reina frente a desbordes de la Quebrada de Ramón*. Memoria para optar al Título de Ingeniero Civil, Departamento de Ingeniería Civil, Universidad de Chile.

Keeley, J. E. (2009). Fire intensity, fire severity and burn severity: a brief review and suggested usage. *International journal of wildland fire*, 18(1), 116-126.

Korup, O., Seidemann, J., & Mohr, C. H. (2019). Increased landslide activity on forested hillslopes following two recent volcanic eruptions in Chile. *Nature Geoscience*, 12(4), 284-289.

Lambe, W., & Whitman, R. (1972). *Mecánica de suelos*. Instituto Tecnológico de Massachusetts, Editorial Limusa-Wiley S.A., 583 p.

Lara, M., & Sepúlveda, S. (2008). *Remociones en masa*. Apuntes del curso. Universidad de Chile, curso de Geología Aplicada.

Li, Z., Zhu, Q., & Gold, C. (2005). *Digital Terrain Modelling, Principles and Methodology*. Boca Raton, FL: CRC Press.

Liu, J. K., Wong, C. C., Huang, J. J., & Yang, M. J. (2002). Landslide enhancement images for the study of torrential rainfall landslides. *Proceedings of the 23rd Asian Conference on Remote Sensing (ACRS'2002)*, Kathmandu, November 2002; 193–198.

Lv, Z., Hu, Y., Zhong, H., Wu, J., Li, B., & Zhao, H. (2010). Parallel k-means clustering of remote sensing images based on mapreduce. En *Web Information Systems and Mining: International Conference, WISM 2010, Sanya, China, October 23-24, 2010. Proceedings* (pp. 162-170). Springer Berlin Heidelberg.

- Mahmoodzadeh, H. (2007). Digital change detection using remotely sensed data for monitoring green space destruction in Tabriz. *International Journal of Environmental Research*, 1(1):35–41.
- Mardones, M., Echeverría, F., & Jara, C. (2006). Una contribución al estudio de los desastres naturales en Chile centro sur: efectos ambientales de las precipitaciones del 26 de junio del 2005 en el área metropolitana de Concepción. *Revista Investigaciones Geográficas*, N°38, 1-25.
- Mardones, M., & Rojas, J. (2012). Procesos de remoción en masa inducidos por el terremoto del 27F de 2010 en la franja costera de la Región del Biobío, Chile. *Revista de Geografía Norte Grande*, 53, 57–74.
- McFeeters, S.K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, 17(7), 1425-1432.
- Meena, S. R., Nava, L., Bhuyan, K., Puliero, S., Soares, L. P., Dias, H. C., ... & Catani, F. (2023). HR-GLDD: a globally distributed dataset using generalized deep learning (DL) for rapid landslide mapping on high-resolution (HR) satellite imagery. *Earth System Science Data*, 15(7), 3283-3298.
- Mezaal, M. R., Pradhan, B., & Rizeei, H. M. (2018). Improving landslide detection from airborne laser scanning data using optimized Dempster–Shafer. *Remote Sensing*, 10(7), 1029.
- Nichol, J., & Wong, M. S. (2005). Detection and interpretation of landslides using satellite images. *Land Degradation & Development*, 16(3), 243-255.
- Morales, B., Lizama, E., Somos-Valenzuela, M. A., Lillo-Saavedra, M., Chen, N., & Fustos, I. (2021). A comparative machine learning approach to identify landslide triggering factors in northern Chilean Patagonia. *Landslides*, 18(8), 2767-2784.
- Riquelme Adriasola, D. (2023). *Uso de imágenes satelitales para el análisis y generación de reportes automáticos en zonas de sequías en el territorio nacional*. Tesis para optar al grado de

magíster en tecnologías de la información, Departamento de Ciencias de la Comunicación, Universidad de Chile. Disponible en <https://repositorio.uchile.cl/handle/2250/199700>.

Rouse, J. W., Haas, R. H., Schell, J. A. y Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *Proceedings of Third Earth Resources Technology Satellite Symposium (Vol. 1, pp. 309-317)*. NASA. (NASA SP-351).

Roy, P. S., Sharma, K. P., & Jain, A. (1996). Stratification of density in dry deciduous forest using satellite remote sensing digital data—An approach based on spectral indices. *Journal of Biosciences, 21*, 723-734.

Servicio Nacional de Geología y Minería (SERNAGEOMIN). (2018). *Origen y efectos de la remoción en masa del 16.12.2017 que afectó la localidad de Villa Santa Lucía, comuna de Chaitén, Región de Los Lagos*. Informe técnico actualizado al 15.01.2018. Servicio Nacional de Geología y Minería, Chile. Recuperado de https://www.portalgeo.sernageomin.cl/Informes_PDF_Nac/RM-2018-19.pdf.

SERNAGEOMIN. (2018). *Glosario ilustrado de peligros geológicos*. Servicio Nacional de Geología y Minería. Recuperado de <https://www.sernageomin.cl/wp-content/uploads/2018/04/Glosario-ilustrado-de-peligros-geologicos.pdf>.

Sepúlveda, S. A., Serey, A., Lara, M., Pavez, A., & Rebolledo, S. (2010). Landslides induced by the April 2007 Aysén fjord earthquake, Chilean Patagonia. *Landslides, 7*, 483-492.

Singh, A. (1989). Review article digital change detection techniques using remotely sensed data. *International journal of remote sensing, 10*(6):989–1003.

Soeters, R., & Cornelis, J. W. (1996). Slope instability recognition, analysis and zonation. En R. L. Schuster & A. K. Turner (Eds.), *Landslides: Investigation and Mitigation, Special Report No. 247*, pp. 129–177. National Academy Press: Washington, DC.

Somos-Valenzuela, M. A., Oyarzún-Ulloa, J. E., Fustos-Toribio, I. J., Garrido-Urzua, N., & Chen, N. (2020). The mudflow disaster at Villa Santa Lucía in Chilean Patagonia: understandings and insights derived from numerical simulation and postevent field surveys. *Natural Hazards and Earth System Sciences*, 20(8), 2319-2333.

Suarez, J. (1998). Mecanismos de falla. En *Deslizamientos: Análisis geotécnico*. (pág. 38). UIS. Obtenido de www.erosion.com.co.

Ullah, I., Aslam, B., Shah, S. H. I. A., Tariq, A., Qin, S., Majeed, M., & Havenith, H. B. (2022). An integrated approach of machine learning, remote sensing, and GIS data for the landslide susceptibility mapping. *Land*, 11(8), 1265.

UNISDR. (2009). *Terminología sobre Reducción del Riesgo de Desastres*. Oficina de las Naciones Unidas para Reducción de Riesgo de Desastres.

Varnes, D. J. (1978). Slope movement types and processes, *Special report*, 176, 11-33.

Veena, V. S., Sai, S. G., Tapas, R. M., Deepak, M., & Rama, R. N. (2016). Automatic detection of landslides in object-based environment using open source tools.

Yang, W., Wang, M., & Shi, P. (2012). Using MODIS NDVI time series to identify geographic patterns of landslides in vegetated regions. *IEEE Geoscience and Remote Sensing Letters*, 10(4), 707-710.

Zhou, Q. (2017). Digital elevation model and digital surface model. *International Encyclopedia of Geography: People, the Earth, Environment and Technology*, 1-17.

ANEXOS

ÍNDICE DE ANEXOS

Anexo

Página

1	Anexo A	70-71
---	---------------	-------

Anexo A: Inventario de RM. Elaboración propia.

Tabla 8.1: Inventario de RM.

Id	Fecha Inicio Pre	Fecha Fin Pre	Fecha Inicio Post	Fecha Fin Post	Centroide	Lugar	Fecha de la RM	Satélite
1	2017-11-02	2017-12-15	2017-12-30	2018-02-15	(-72.37710549949, -43.39645828926)	Santa Lucía	16-12-2017	L8
2	2019-01-01	2019-04-30	2020-01-01	2020-04-30	(-72.41017574691, -41.97686659812)	Hornopirén	Jun-19	S2
3	2019-01-05	2019-06-05	2019-06-10	2019-10-15	(-72.4903317397, -42.16470544613)	Isla Llancahue	6-10 de junio 2019	S2
4	2018-01-05	2018-07-15	2018-07-30	2018-10-15	(-73.09127892393, -39.80753463983)	Pishuinco	Jul-18	L8
5	2020-04-05	2020-05-10	2020-05-20	2022-08-15	(-72.44889665999, -43.001399020102)	Termas el Amarillo	Invierno 2020	S2
6	2019-01-01	2019-04-30	2020-01-01	2020-04-30	(-72.45696249218, -42.13717038166)	Hornopirén 2	Invierno 2019	S2
7	2018-01-01	2018-03-25	2020-01-01	2020-03-25	(-72.90626601512, -46.56407953051)	Río Norte	Invierno 2018	L8
8	2020-11-01	2021-02-02	2023-11-01	2024-02-02	(-72.21316083216, -40.678991078070)	Río Gol Gol	Invierno 2021	S2
9	2020-01-01	2020-05-10	2021-01-01	2021-05-10	(-72.21929695266, -43.7388391163)	Río Palena	Invierno 2020	S2
10	2022-02-01	2022-04-25	2023-02-01	2023-04-25	(-72.39835443178, -41.14657382699)	Petrohué	Invierno 2020	S2
11	2018-02-01	2018-04-25	2020-02-01	2020-04-25	(-72.61270748884, -42.8138114745)	Río Rayas	Invierno 2018	S2
12	2018-02-01	2018-04-25	2020-02-01	2020-04-25	(-72.61083916992, -42.84457797291)	Río Rayas 2	Invierno 2018	S2
13	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.66356403278, -42.92061245738)	Chaitén 1	May-15	L8
14	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.6724141903, -42.92470295135)	Chaitén 2	May-15	L8
15	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.65905792164, -42.90568218290)	Chaitén 3	May-15	L8
16	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.68162357969, -42.8985610308)	Chaitén 4	May-15	L8

17	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.67703163786, -42.89161286444)	Chaitén 5	May-15	L8
18	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.67565834685, -42.884852570162)	Chaitén 6	May-15	L8
19	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.66561615629, -42.8774619189)	Chaitén 7	May-15	L8
20	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.65754807158, -42.895322282028)	Chaitén 8	May-15	L8
21	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.65634644194, -42.87878270605)	Chaitén 9	May-15	L8
22	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.63334381743, -42.88280787629)	Chaitén 10	May-15	L8
23	2015-01-01	2015-04-25	2016-01-01	2016-04-25	(-72.60853874846, -42.89331039517)	Chaitén 11	May-15	L8
24	2015-01-01	2015-03-25	2016-01-01	2016-03-25	(-72.59909737272, -42.95069406823)	Chaitén 12	May-15	L8
25	2015-01-01	2015-03-25	2016-01-01	2016-02-25	(-72.5772963778, -42.95220162799)	Chaitén 13	May-15	L8
26	2015-01-01	2015-03-25	2016-01-01	2016-02-25	(-72.54880058928, -42.95207600750)	Chaitén 14	May-15	L8
27	2015-01-01	2015-03-25	2016-01-01	2016-02-25	(-72.53575432463, -42.984609065314)	Chaitén 15	May-15	L8
28	2015-01-01	2015-03-25	2016-01-01	2016-02-25	(-72.61926758452, -42.9423061660)	Chaitén 16	May-15	L8
29	2015-01-01	2015-02-25	2016-01-01	2016-02-25	(-72.64750588103, -42.94381457688)	Chaitén 17	May-15	L8
30	2022-10-01	2022-12-30	2023-10-01	2023-12-01	(-72.68029320402, -42.85660789072)	Chaitén 18	Invierno 2023	S2
31	2015-01-01	2015-03-25	2016-01-01	2016-03-25	(-72.71552903890, -42.74981075089)	Chaitén 19	May-15	L8
32	2017-01-01	2017-03-25	2018-01-01	2018-03-25	(-72.6835141920, -42.744764174498)	Chaitén 20	Invierno 2017	L8
33	2015-01-01	2015-02-25	2016-01-01	2016-02-25	(-72.59656770467, -42.73934762120)	Chaitén 21	May-15	L8
34	2018-01-01	2018-02-25	2020-01-01	2020-02-25	(-72.54244911833, -43.0177190967)	Chaitén 22	Invierno 2018	L8