



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

LICENCIATURA EN TECNOLOGÍAS PARA LA INFORMACIÓN EN CIENCIAS

Escuela Nacional de Estudios Superiores,
Unidad Morelia

FACTORES RELACIONADOS CON
LA SUSCEPTIBILIDAD A DESLIZAMIENTOS
DE MASA EN LA REGIÓN SIERRA
COSTA, MICHOACÁN POR MEDIO DEL
MODELO DE PROCESOS DE PUNTOS
DE COX LOG-GAUSSIANO

TESIS

QUE PARA OBTENER EL TÍTULO DE

LICENCIADO EN TECNOLOGÍAS PARA
LA INFORMACIÓN EN CIENCIAS

P R E S E N T A

JOSUÉ FRANCISCO SOTO CORTEZ

DIRECTOR DE TESIS: DR. MIGUEL ANGEL SALINAS MELGOZA
CO-DIRECTOR DE TESIS: DR. MANUEL EDUARDO MENDOZA CANTÚ

MORELIA, MICHOACÁN

OCTUBRE, 2023



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



ESCUELA
NACIONAL
de ESTUDIOS
SUPERIORES
ENES
UNIDAD MORELIA

10
años
(2011-2021)

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
ESCUELA NACIONAL DE ESTUDIOS SUPERIORES UNIDAD MORELIA
SECRETARÍA GENERAL
SERVICIOS ESCOLARES

MTRA. IVONNE RAMÍREZ WENCE

DIRECTORA

DIRECCIÓN GENERAL DE ADMINISTRACIÓN ESCOLAR

PRESENTE

Por medio de la presente me permito informar a usted que en la **sesión ordinaria 06** del **Comité Académico de la Licenciatura en Tecnologías para la Información en Ciencias** de la Escuela Nacional de Estudios Superiores (ENES), Unidad Morelia, celebrada el día **30 de agosto de 2023**, se acordó poner a su consideración el siguiente jurado para la presentación del Trabajo Profesional del alumno **Josué Francisco Soto Cortez** de la Licenciatura en **Tecnologías para la Información en Ciencias**, con número de cuenta **41812838-7**, con el trabajo titulado: **"Factores relacionados con la susceptibilidad a deslizamientos de masa en la región Sierra Costa, Michoacán por medio del modelo de procesos de puntos de Cox Log-Gaussiano"**, bajo la dirección como tutor del **Dr. Miguel Ángel Salinas Melgoza** y como co-tutor el **Dr. Manuel Eduardo Mendoza Cantú**.

El jurado queda integrado de la siguiente manera:

Presidente:	Dr. Jean Francois Raymond Marie Mas Causse
Vocal:	Dr. Sergio Rogelio Tinoco Martínez
Secretario:	Dr. Miguel Ángel Salinas Melgoza
Suplente:	Dr. Alejandro César Valdés Carrera
Suplente:	Dra. Karla Aurora de la Peña Guillén

Sin otro particular, quedo de usted.

Atentamente
"POR MI RAZA HABLARÁ EL ESPÍRITU"
Morelia, Michoacán a 24 de octubre de 2023.

DRA. YUNUEN TAPIA TORRES
SECRETARIA GENERAL

CAMPUS MORELIA

Antigua Carretera a Pátzcuaro N° 8701, Col. Ex Hacienda de San José de la Huerta
58190, Morelia, Michoacán, México. Tel: (443)689.3500 y (55)5623.7300, Extensión Red UNAM: 80614

www.enesmorelia.unam.mx

Agradecimientos institucionales

Agradezco el apoyo del proyecto PAPIIME PE304220 “Estrategias de fortalecimiento para las ciencias sociales: Énfasis en la enseñanza-aprendizaje a través de la tecnología de drones y modelos tridimensionales de realidad aumentada”.

Al proyecto de la UNAM IN110222 “Dendrogeomorfología: desarrollo e implementación de un esquema para cartografiar y evaluar peligros geomorfológicos en zonas montañosas intertropicales de México”

A la Universidad Autónoma de México, a la Escuela Nacional de Estudios Superiores, Unidad Morelia y a la Licenciatura en Tecnologías para la Información en Ciencias por haberme brindado una experiencia educativa enriquecedora y por todo el apoyo académico que recibí a lo largo de esta trayectoria universitaria.

Al Dr. Miguel Ángel Salinas Melgoza por su invaluable colaboración y orientación en la elaboración de este proyecto. Su guía y apoyo diario fueron fundamentales para alcanzar la culminación exitosa de esta investigación. Mi gratitud se extiende al Dr. Manuel E. Mendoza Cantú, quien compartió generosamente su profundo conocimiento sobre los procesos de remoción en masa y brindó su valioso respaldo a lo largo de todo el desarrollo del proyecto.

Al Dr. Sergio Tinoco, al Dr. Jean-François Mas, al Dr. Miguel Salinas, al Dr. Alejandro Valdés y a la Dr. Karla De la Peña, que tomaron el cargo jurado revisor de este trabajo. Gracias por darse el tiempo de revisar detenidamente la investigación, y hacerme notar esos pequeños detalles que pueden marcar una diferencia para ser un trabajo de calidad.

Agradecimientos personales

Agradezco primeramente a Dios, porque su gracia y misericordia han sido conmigo en cada día de mi vida, incluyendo mi trayectoria en la Universidad. Solo a Dios la gloria por todo lo que he logrado y por lo que está por venir.

A mis papás, Francisco y María, a mi hermana, Rebeca, y a mis sobrinas Dara y Priya que han sido un constante apoyo y ánimo en toda mi vida, y en especial en esta trayectoria universitaria.

A mis amigos de la carrera, en especial a Pablo, Luis, Donovan, Tomás y Andrés, que fueron una grata compañía en las noches de desvelos por proyectos y tareas.

A cada uno de los profesores que me impartieron clase, ha sido una oportunidad invaluable para adquirir conocimientos, habilidades y perspectivas que serán fundamentales en mi carrera profesional.

A la M. en G. Paz del Carmen Coba Pérez, que fue un gran apoyo en el inicio de este proyecto.

Resumen

El presente trabajo abordó el análisis de la significancia de los factores relacionados con la susceptibilidad a procesos de remoción en masa (PRM) en la región Sierra-Costa, Michoacán, utilizando el modelo de procesos de puntos de Cox Log-Gaussiano (CLG). El proceso de modelado comenzó con la recopilación y preparación de datos geospaciales, los cuales fueron obtenidos de investigaciones previas en la región Sierra Costa, incluyendo información del tipo de roca, distancia a fallas y fracturas, tipo de suelo, elevación, pendiente y su orientación, curvatura planar y de perfil, distancia a ríos y arroyos, y la ubicación de cada uno de los puntos espaciales de PRM. Estos datos, junto con las unidades de pendiente, fueron usados para construir un modelo CLG que incorpora la dependencia espacial de los eventos de PRM.

Los factores significativos identificados por el modelo que aumentan la susceptibilidad a PRM incluyen la pendiente, la elevación, la orientación, el tipo de roca y el tipo de suelo, mientras que la distancia a fallas y fracturas, la curvatura de perfil y la distancia a ríos y arroyos disminuyen la susceptibilidad.

La evaluación del rendimiento del modelo se llevó a cabo mediante dos métodos: dentro de las muestras y fuera de las muestras y, considerando tanto la escala a nivel del pixel como a nivel de unidades de pendiente. Se utilizó la técnica de la validación cruzada para evaluar la capacidad predictiva del modelo con datos nuevos y evitar el sobreajuste. Los resultados de la validación fueron de 0.98 para la evaluación del pixel sin validación cruzada, y 0.73 con la validación cruzada, dichos valores respecto al AUC. Mientras que la evaluación de unidades de pendiente arrojó valores de 0.984 sin validación cruzada y de 0.742 con

validación cruzada respecto al AUC. Estos resultados indican que el modelo tiene una alta capacidad predictiva en la clasificación de píxeles y unidades de pendiente con PRM, lo que demuestra su eficacia para distinguir entre áreas con mayor o menor susceptibilidad a PRM.

Abstract

This study evaluates the statistical significance of factors related to mass landslide susceptibility in the Sierra-Costa region of Michoacán, using the Log-Gaussian Cox Point Process (LGCPP) model. In order to do this, I first prepared the geospatial data, which were obtained from previous study of the Sierra Costa region. These data include information on rock type, distance to faults and fractures, soil type, elevation, slope and its orientation, planar and profile curvature, distance to rivers and the location of landslides. These data, along with slope units, were used to build an LGCPP model that incorporates the spatial dependence of landslide events.

Statistically significant factors that increase landslide susceptibility include slope, elevation, orientation, rock type, and soil type, while distance to faults and fractures, profile curvature, and distance to rivers decrease susceptibility.

Model performance evaluation was conducted using two methods: in-sample and out-of-sample, employing cross-validation to assess the predictive capability of the model with new data and to prevent overfitting. The validation performance was 0.98 for pixel evaluation without cross-validation and 0.73 with cross-validation, whereas slope unit performance evaluation yielded 0.984 without cross-validation and 0.742 with cross-validation. These results indicate that the model has high predictive ability in classifying pixels and slope units with landslides. This shows its effectiveness in distinguishing between areas with higher or lower landslide susceptibility.

Índice

Capítulo 1. Introducción.....	9
1.1 Antecedentes.....	9
1.2 Marco Teórico.....	10
1.2.1 Procesos de remoción en masa (PRM).....	10
1.2.2 Factores asociados a la inestabilidad de la ladera	16
1.2.3 Susceptibilidad a PRM.....	19
1.2.4 Análisis espacial de patrones de puntos	20
1.2.5 Proceso de Poisson.....	23
1.3 Hipótesis	31
1.4 Objetivo	31
1.4.1 Objetivo general	31
1.4.2 Objetivos particulares.....	31
Capítulo 2. Materiales y métodos.....	32
2.1 Área de estudio	32
2.2 Inventario de PRM.....	34
2.2.1 Factores predictores en la SC.....	34
2.2.2 Unidades de pendiente	45
Capítulo 3. Modelación de PRM.....	48
3.1 Preprocesamiento de datos.....	49
3.1.1 Configuración del entorno para la modelación del proceso de puntos de Cox-Log Gaussiano	49
3.1.2 Factores categóricos	49
3.1.3 Estructura de grafo de adyacencia.....	52
3.1.4 Conteo de eventos de PRM	53
3.1.5 Intercepto.....	55
3.1.6 Depuración de datos nulos o inconsistentes.....	56
3.1.7 Estructura del conjunto de datos	57
3.2 Modelación del proceso de puntos de Cox-Log Gaussiano (CLG).....	59
3.3 Extracción de factores significantes.....	63
3.4 Distribución espacial de la susceptibilidad a PRM.....	64

3.5 Evaluación del rendimiento de la modelación del proceso de puntos de Cox-Log Gaussiano (CLG) por medio de validación cruzada.	64
3.5.1. Validación Cruzada.	65
3.5.2. Curva ROC y AUC	67
Capítulo 4. Resultados.....	69
4.1 Análisis de factores significativos	69
4.1.1 Efecto espacial latente.....	79
4.1.2 Distribución espacial de susceptibilidad a PRM en la región Sierra-Costa	82
4.1.3 Validación del rendimiento del modelo de proceso de puntos de Cox-Log Gaussiano en la región Sierra-Costa	84
Capítulo 5. Discusión	87
Capítulo 6. Conclusiones.....	92
Referencias	94

Capítulo 1. Introducción

1.1 Antecedentes

Si bien el título de esta investigación hace referencia a los deslizamientos de masa, es importante destacar que este término se usa como representación general de una categoría más amplia de este tipo de eventos conocidos como procesos de remoción en masa (PRM). Los eventos de PRM son eventos naturales comunes en zonas montañosas que pueden traer indeseables consecuencias para las personas y las comunidades en todo el mundo, como la pérdida de viviendas, la destrucción de infraestructuras y, en casos extremos, la pérdida de vidas (Akgün y Bulut, 2007). Los PRM pueden ser de diferentes tipos, incluyendo derrumbes, flujos, deslizamientos, entre otros (Cruden y Varnes, 1996). Estos eventos pueden ser causados por una combinación de factores condicionantes y desencadenantes. Los factores condicionantes se refieren a las características del terreno, la geología, la hidrología, la exposición al clima y vegetación de la zona, y la acción humana sobre la ladera (van Westen et al., 2008). Estos factores proporcionan las condiciones previas para la ocurrencia de un PRM. Por otro lado, los factores desencadenantes son eventos o procesos que desencadenan un PRM, como los sismos, las precipitaciones intensas, y la erosión. Estos factores pueden actuar como desencadenantes adicionales sobre las condiciones previas y desencadenar un PRM en un momento específico (van Westen et al., 2008).

Los PRM han tenido una recurrencia significativa dentro de la región Sierra-Costa en Michoacán, debido a que dicha zona es afectada por tormentas tropicales, sismos y cercanía a las fallas geológicas (Segundo-Métay y Bocco, 2015; Esquivel y Muñoz, 2017; De la Peña

et al., 2021). En la región Sierra-Costa, los PRM representan un factor de riesgo adicional para las inundaciones. Esto se debe a que los PRM pueden desencadenar movimientos de masas que, a su vez, pueden provocar la acumulación de sedimentos y caudales en las cuencas hidrográficas (González-Arqueros et al., 2018). Esto afecta directamente a la probabilidad de ocurrencia a inundaciones en la zona afectada (González-Arqueros et al., 2018).

1.2 Marco Teórico

1.2.1 Procesos de remoción en masa (PRM)

Los PRM se definen como el desplazamiento de masas de la superficie del terreno (roca, suelo y escombros) hacia las partes bajas del terreno, por la acción de la gravedad (Cruden y Varnes, 1996). Estos movimientos se presentan en la superficie de la tierra en distintos lugares, cada uno con sus condiciones climáticas, geológicas y geomorfológicas propias y en diferentes escalas (Alcántara y Murillo, 2008).

Existen diferentes tipos de PRM, Los cuales se clasifican dependiendo del tipo de material de la superficie involucrada y el tipo de movimiento que lo originó. Pueden ser clasificados en cinco categorías en función de su geometría y características: a) deslizamientos rotacionales y b) traslacionales, c) caídas, d) volcamientos, e) expansión lateral, e) flujo de masa y f) procesos de remoción en masa complejos, estos últimos son una combinación de 2 o más tipos de PRM, de cualquier tipo (Marui, 1988; Cruden y Varnes, 1996; Valdés et al., 2021).

1.2.1.1 Deslizamientos rotacionales

Deslizamientos donde el material se desliza de manera rotacional a lo largo de una superficie cóncava, formando una curvatura cóncava en la parte superior (Figura 1).

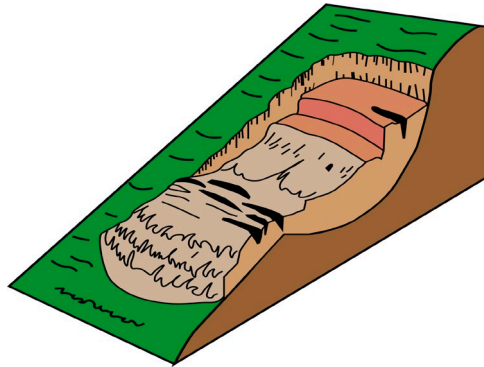


Figura 1: Deslizamiento rotacional (Modificado de Cruden y Varnes (1996))

1.2.1.2 Deslizamientos traslacionales

Son aquellos deslizamientos donde el material se desliza en una superficie de ruptura plana con pendiente abajo. La masa en movimiento consiste en una o pocas unidades de tierra que se mueven sincrónicamente a lo largo de la superficie (Figura 2).




Figura 2: Deslizamiento Traslacional (Modificado de Cruden y Varnes (1996))

1.2.1.3 Caída o caídos

La caída o caídos son desprendimientos de rocas o materiales geológicos en una pendiente o acantilado por movimientos abruptos debido a la gravedad. Los desprendimientos pueden ser

libres, por rebote o balanceo en la superficie. Los cuales se producen en fracturas, puntos de unión entre dos tipos de rocas, ruptura de rocas o presencia de agua (Figura 3).




Figura 3: Caída (Modificado de Cruden y Varnes (1996))

1.2.1.4 Volcamientos

Los volcamientos son desprendimientos de material desde un afloramiento de una masa de roca, esto debido a la influencia de la gravedad, fuerzas de unidades de masa vecinas o por fluidos en grietas (Figura 4).




Figura 4: Volcamiento (Modificado de Cruden y Varnes (1996))

1.2.1.5 Expansión lateral

Los PRM de este tipo son movimientos donde los materiales se extiende lateralmente, debido a la licuefacción del material debajo de la superficie, es decir, cuando los sedimentos se

encuentran saturados, sueltos o sin cohesión y pasan de estar de un estado sólido a un estado líquido, lo que ocasiona un flujo lento y constante del material. Estos movimientos suelen ocurrir en superficies planas o con una pendiente muy suave, haciendo que los materiales de la superficie se hundan, trasladen, desintegren, licúen, roten o fluyan (Figura 5).




Figura 5: Expansión lateral (Modificado de Cruden y Varnes (1996))

1.2.1.6 Flujos

Los flujos son movimientos de materiales donde la velocidad, dirección y forma del flujo varían a lo largo del mismo. Es un movimiento que combina materiales como las rocas, materia orgánica, agua y suelo suelto, que fluye de manera rápida pendiente abajo. Estos flujos son causados por fenómenos naturales como precipitaciones, deshielos, entre otros, que erosionan la superficie y producen su movimiento en las pendientes (Figura 6).




Figura 6: Flujo de escombros (Modificado de Cruden y Varnes (1996))

1.2.1.6.3 Flujo de lodo

El flujo de lodo es un flujo de tierra saturada de agua que fluye a una velocidad alta por la humedad en la que se encuentra la masa, que contiene 50% o más de material fino como arena o arcilla (Figura 8).




Figura 7: Flujo de lodo (Modificado de Cruden y Varnes (1996))

1.2.1.7 Reptación

La reptación es un movimiento de materiales en una pendiente que se caracteriza por ser muy lento, pero constante. Estos movimientos son causados por un esfuerzo cortante o de cizalla, es decir, un esfuerzo donde las fuerzas actúan de forma paralela, pero en direcciones opuestas, produciendo una deformación en la pendiente. Existen tres tipos de PRM de reptación. El primero es la reptación estacional, donde el movimiento es producido dentro del suelo, debido a las temperaturas y humedad del suelo. El segundo es la reptación continua, donde la resistencia del material se excede continuamente por el esfuerzo cortante. El tercero es la reptación progresiva, donde las pendientes están llegando al punto de ruptura, como los demás movimientos de masa (Figura 9).




Figura 8: Reptación (Modificado de Cruden y Varnes (1996))

1.2.1.8 Avalancha

En el caso de la avalancha la velocidad a la que el flujo se mueve es entre muy alta a extremadamente alta. Estos flujos de tierra están compuestos principalmente por material de grano fino. Este movimiento simula un reloj de arena, porque el material se licúa y se escurre por la pendiente, creando un vacío en la superficie donde el flujo comenzó (Figura 7).




Figura 9: Avalancha de escombros (Modificado de Cruden y Varnes (1996))

1.2.2 Factores asociados a la inestabilidad de la ladera

Los factores documentados que afectan la estabilidad de la ladera produciendo PRM han sido principalmente el tipo de roca, la distancia a fallas geológicas, distancia a ríos y arroyos, el uso de suelo y cobertura, la pendiente del terreno, la orientación de la ladera, la curvatura del terreno, el índice de humedad topográfica, intemperismo, entre otras (Cama et al., 2015; Reichenbach et al., 2018).

1.2.2.1 Intemperismo

El intemperismo desempeña un papel fundamental en la susceptibilidad a los procesos de remoción en masa. Este proceso, que incluye factores físicos, químicos y biológicos, contribuye a la degradación de la roca y el suelo con el tiempo. Su interpretación permite inferir la resistencia o susceptibilidad de la roca y el suelo al desplazamiento cuando está sometida a fuerzas gravitacionales (Dai et al., 2001; De la Peña, 2021).

1.2.2.2 Tipo de roca

Es la clasificación de las rocas debido a sus características químicas, petrológicas y estructurales. Las rocas ígneas metamórficas e intrusivas son los tipos de roca dominantes en la región Sierra-Costa (Solís-Castillo et al., 2019). La susceptibilidad de sufrir un PRM está influenciada por el grado de intemperización, rocas más intemperizadas tendrán mayor susceptibilidad (Dai et al., 2001; De la Peña, 2021).

1.2.2.3 Pendiente del terreno

Este factor indica la inclinación de la ladera y toma un papel muy importante dentro de los PRM, ya que afecta directamente a la estabilidad de una superficie inclinada. La pendiente

nos dice cuánta fuerza de gravedad hay sobre una superficie que podría caerse o deslizarse (Baeza y Corominas, 2001; Wati et al., 2010).

1.2.2.4 Orientación de la pendiente

Indica la dirección de la ladera respecto al norte geográfico. Este factor es de utilidad para describir los efectos de la radiación solar en la superficie de la tierra, ya que, dependiendo de la orientación de una pendiente, la forma e intensidad en que la radiación incide puede tener un mayor o menor efecto en la ladera, produciendo cambios de temperatura, viento, precipitaciones y la humedad de la pendiente (Reichenbach et al., 2018; De la Peña et al., 2021). En este estudio, la orientación permite medir el grado de alineación de la pendiente entre eventos de PRM, ya que, en la susceptibilidad, la dirección de la pendiente puede aumentar la exposición al impacto de otros eventos que afectan la estabilidad de la misma (Morales-Manilla, 2014; De la Peña et al. 2021).

1.2.2.5 Curvatura del terreno

La curvatura planar describe la convergencia o divergencia de un flujo en la pendiente, permitiendo evaluar la convergencia de un flujo de agua. La curvatura del perfil describe la dirección de la pendiente máxima, la cual evalúa la velocidad del flujo de agua en una pendiente. Ambas curvaturas son factores proxy (es decir, una medida sustituta que se utiliza para inferir o estimar algo que no se puede medir directamente) para obtener el comportamiento del flujo del movimiento de masa (Reichenbach et al., 2018). La curvatura planar y de perfil contienen información relevante para la modelación de PRM, ya que describen el estado y la forma de la pendiente. Ambas curvaturas muestran la tendencia de la

morfología en la ladera, si la morfología es convexa lateralmente, la ladera se vuelve más propensa a un PRM que las morfologías cóncavas (Lombardo et al., 2018).

1.2.2.6 Índice de humedad topográfica (IHT)

El índice de humedad topográfica describe el comportamiento espacial de las zonas con exceso de humedad o con acumulación de agua, funcionando como un factor proxy para describir las propiedades del suelo en respecto a la humedad. Por ejemplo, cuando un sitio propenso a PRM acumula mucha agua, puede suceder un PRM (Wilson y Gallant, 2000).

1.2.2.7 Distancia a fallas y fracturas

Las fallas y las fracturas son condicionantes de PRM, porque su cercanía altera el equilibrio entre las fuerzas estabilizadoras de la ladera. La distancia a los factores asociados a la inestabilidad de la ladera, tales como las fallas y las fracturas, son factores comúnmente utilizados para evaluaciones de susceptibilidad a PRM. Esto se debe a que las rocas más cercanas a una falla están fracturadas y con esfuerzo de cizalla, por lo que son más débiles que rocas similares que se encuentran más alejadas de la falla (Foumelis et al., 2004; Leir et al., 2004; Morales-Manilla, 2014).

1.2.2.8 Distancia a ríos y arroyos

La distancia a ríos y arroyos es un factor importante en el análisis del comportamiento de la saturación del suelo, ya que está intrínsecamente relacionada con el grado de pérdida de cohesión y cementación entre las partículas del suelo, provocando que la tierra se deslice sobre una pendiente (Moreno et al., 2006).

Los factores morfométricos del terreno (como lo es la pendiente, su aspecto y curvatura) son factores “fáciles” de calcular a partir de un “Modelo Digital de Elevaciones”. El uso de estos factores en la modelación de la susceptibilidad es primordial, ya que describe el comportamiento de la estabilización de la ladera en diferentes escenarios, por ejemplo, la resistencia a que suceda un movimiento de masa en una ladera con mayor pendiente es menos que con una con menor pendiente (Reichenbach et al., 2018).

1.2.3 Susceptibilidad a PRM

La susceptibilidad a PRM es la probabilidad de que ocurra un PRM en un área dependiendo de las condiciones locales del terreno y el entorno (Guzzetti et al., 1999; Reichenbach et al., 2018). Esto permite estimar en dónde es probable que ocurran los PRM, identificando el grado en que un área puede ser afectada por PRM futuros (Rossi et al., 2010). En investigaciones de susceptibilidad, es muy común que se confunda el término “susceptibilidad” y el término “peligro” dado que se usan como sinónimos, aunque tengan definiciones diferentes. El peligro es algo más complejo en comparación con la susceptibilidad y por eso mismo, es más difícil de determinar, ya que la susceptibilidad es un componente espacial del peligro. El peligro, además de hacer una estimación de su magnitud, estima la ubicación y probable fecha de ocurrencia del PRM (Reichenbach et al., 2018).

En la actualidad hay una gran variedad de métodos para determinar la susceptibilidad de los PRM, como lo puede ser la cartografía geomorfológica, modelización numérica de base física, análisis de bases de datos de PRM, entre otros (Reichenbach et al., 2018). Algo en común que tienen todos los métodos o enfoques para determinar la susceptibilidad de los

PRM, son los supuestos en los que se basan (Reichenbach et al., 2018; Rossi et al., 2010; Valdés et al., 2021):

1. Los PRM dejan señales visibles que pueden ser identificadas, clasificadas y cartografiadas, estas pueden obtenerse por medio del análisis en el terreno o de imágenes satelitales.
2. Los PRM y la ocurrencia de los mismos están controlados en su mayoría por leyes físicas que se pueden analizar de forma heurística, estadística, o determinística.
3. Los factores que provocan inestabilidad en la ladera están directa o indirectamente relacionados con los PRM de masa.
4. En los PRM, el pasado y el presente se considera clave para el futuro, esto implica que es más probable que se produzcan futuros PRM donde hubo inestabilidad en un pasado.
5. La ocurrencia de los PRM espaciales puede deducirse de investigaciones heurísticas, que fueron calculadas por medio de análisis de información ambiental, o se puede inferir por medio de modelos estadísticos.

En este estudio, se estimó la susceptibilidad a los PRM y se analizaron los factores relacionados con la inestabilidad de laderas en la Región Sierra-Costa, utilizando el análisis espacial de patrones de puntos.

1.2.4 Análisis espacial de patrones de puntos

El análisis espacial se define como el proceso de eventos georreferenciados para obtener información adicional sobre los mismos (Diggle, 2014). Estos eventos pueden ser un conjunto de puntos, los cuales consisten en un grupo de datos referenciados espacialmente.

Éstos incluyen por lo menos su ubicación en una región determinada y pueden incluir características asociadas de los eventos proporcionando información adicional, en el caso de los PRM, las características asociadas al inventario de eventos de PRM son la pendiente del terreno, orientación de la ladera, curvatura planar, curvatura de perfil, uso de suelo, tipo de roca, distancia a cuerpos de agua y a fallas. Este tipo de eventos se denomina como proceso puntual y pueden ser modelado con técnicas estadísticas específicas, con el objetivo de identificar agrupaciones de eventos y su causa, la cual puede ser el azar o alguna causa específica (Ocaña-Riola y Garrido, 2012).

Dentro de los patrones de puntos existen el patrón completamente aleatorio, el patrón regular y el patrón agregado.

1.2.4.1 Patrón completamente aleatorio

En principio, cuando se tiene un patrón de puntos, se asume que es completamente aleatorio (Complete Spatial Randomness o CSR) (Figura 10), es decir, no existen factores que están determinando el comportamiento del patrón de puntos y tiene que cumplir con las siguientes características (Baddeley et al., 2015):

- El promedio de eventos por unidad de área (intensidad) es homogénea en el área de estudio.
- El número de eventos en dos regiones que no se sobreponen son independientes.
- El número de eventos en cualquier subregión sigue una distribución de Poisson.




Figura 10: Patrón completamente aleatorio

1.2.4.2 Patrón agregado

En la práctica existen agrupaciones con mayor o menor intensidad dentro del área de estudio debido a la influencia de algunos factores en los eventos (Diggle, 2014) (Figura 11).




Figura 11: Patrón agregado

1.2.4.3 Patrón regular

El último de los patrones de puntos, dentro de un análisis espacial, es el patrón regular, el cual tiene una intensidad constante en el área de estudio donde los puntos maximizan su distancia entre sí (Baddeley et al., 2015) (Figura 12).




Figura 12: Patrón regular

La intensidad es el promedio de eventos por unidad de área, la intensidad debe ser mayor o igual a 0, dado que el conjunto de eventos en una región A es una variable aleatoria exclusivamente positiva. Estimar la intensidad es el primer y más importante paso en el análisis de datos puntuales, ya que es la principal característica descriptiva de un conjunto de puntos en un proceso de análisis espacial. Se ha observado que en la naturaleza la intensidad varía espacialmente, dependiendo de factores externos, como los factores que afectan la estabilidad de la ladera. La intensidad se convierte en una función de la ubicación espacial, y se usan métodos estadísticos para estimarla por medio del conjunto de datos (Baddeley et al., 2015).

1.2.5 Proceso de Poisson

El proceso de puntos de Poisson es un modelo útil para modelar la distribución espacial de eventos puntuales. Es un tipo de proceso estocástico, es decir, una representación matemática para modelar y evaluar la evolución temporal o espacial de una o un conjunto de factores aleatorios. En el caso del proceso de puntos de Poisson, ayuda a analizar y modela la distribución de puntos aleatorios en un espacio. En este proceso, la probabilidad de que ocurra un evento depende solo de un intervalo de tiempo, deja fuera los factores desencadenantes del evento o el efecto que puede tener en áreas vecinas del evento (Baddeley

et al., 2015). A continuación, se abordará la distribución de Poisson, dado que el número de evento en cualquier subregión sigue una distribución de este tipo.

1.2.5.1 Distribución de Poisson

Esta distribución de probabilidad discreta se usa para modelar el número de eventos puntuales que ocurren en un espacio continuo, en este caso, un espacio geográfico, cuando la tasa promedio, es decir, la cantidad de eventos esperados, es conocida. La distribución de puntos de Poisson se puede calcular utilizando la fórmula de Poisson, la cual describe la probabilidad de que k eventos ocurran en un espacio definido. Si estos eventos tienen una ocurrencia constante conocida, la probabilidad P de que la variable aleatoria N obtenga exactamente k eventos es (Baddeley et al., 2015):

$$P\{N = k\} = \frac{\lambda^k e^{-\lambda}}{k!} \quad (1)$$

Donde k es el número de ocurrencias del evento, e es el número de Euler (2.71828...), λ es el promedio de la distribución de Poisson, en otras palabras, λ representa la tasa media de ocurrencia de eventos en un intervalo de espacio fijo, y $k!$ es la función factorial del número de ocurrencias del evento. En el presente estudio la variable aleatoria es el número de PRM por unidad de área.

Por ejemplo, la Figura 13 muestra las probabilidades para la distribución de Poisson con $\lambda = 0.6$, $\lambda = 3$, $\lambda = 6$ y $\lambda = 9$:




Figura 13: Distribuciones de Poisson con $\lambda = 0.6$, $\lambda = 3$, $\lambda = 6$ y $\lambda = 9$.

Teniendo definido esto, los procesos de Poisson están divididos en dos tipos de procesos; homogéneos y no homogéneos.

1.2.5.1.1 Proceso de Poisson homogéneo

Un proceso de Poisson homogéneo es un proceso en donde todos los eventos son independientes entre sí y están uniformemente distribuidos en una región A, donde el proceso de puntos ocurre. Por ejemplo, si tenemos una región A conformada por áreas montañosas y áreas de valle donde se tienen eventos de PRM, la ubicación de un evento de PRM no afecta la probabilidad de que otros eventos de PRM ocurran cerca. Esto puede suceder porque en la región no hay áreas donde los eventos tengan una mayor probabilidad de suceder debido a que no hay factores asociados a la ocurrencia de PRM, a pesar de haber condiciones ambientales contrastantes.

El proceso de Poisson homogéneo se define por estas dos condiciones:

- El número de eventos en la región A con área $|A|$, sigue una distribución de Poisson con media $\lambda |A|$, donde λ es constante en toda la región A .
- Dados n eventos en la región A , están uniformemente distribuidos en A .

Estas dos condiciones son muy semejantes a las condiciones bajo las cuales se define un CSR y la intensidad de los eventos es semejante en toda el área de estudio por no estar relacionada con algún factor (Diggle, 2014).

La intensidad es constante y no negativa en cualquier subregión s de la región A , es decir, $\lambda(s) = \lambda > 0, \forall s \in A$, y en un proceso de Poisson homogéneo se define de la siguiente manera:

$$\lambda(s) = \frac{n}{|s|} \quad (2)$$

donde $\lambda(s)$ es la intensidad en la subregión s . n el número de eventos observados en la región A y $|s|$ es el área de s .

1.2.5.1.2 Proceso de Poisson no homogéneo

La alternativa a los procesos de Poisson anteriormente, son los procesos de Poisson no homogéneos, los cuales son los procesos más importantes para muchos fines prácticos. En estos procesos encontramos no sólo una modificación de la aleatoriedad espacial completa en la que la densidad media de puntos varía espacialmente (Baddeley et al., 2015) sino que, además, la propiedad de independencia entre los eventos se mantiene, originando que los eventos puedan tener mayor probabilidad de ocurrencia en ciertas subregiones que en otras. Esto puede suceder por una asociación del proceso de puntos con ciertos factores (Diggle, 2014). Como consecuencia a esto, habrá zonas con una intensidad de puntos relativamente

elevada y otras zonas con una intensidad de puntos relativamente baja, lo que producirá un patrón agregado de eventos (Diggle, 2014).

El proceso de Poisson no homogéneo con la función de intensidad $\lambda(s)$ se define con las siguientes propiedades:

- **Independencia:** si la región se divide en subregiones que no se sobreponen, los patrones aleatorios dentro de estas subregiones son independientes entre sí.
- **Función de intensidad:** el número esperado de puntos que ocurren dentro de una región A es la integral de la función de intensidad en las subregiones s :

$$\int_A \lambda(s) ds \quad (3)$$

La intensidad no es semejante entre subregiones.

- **Recuentos con distribución de Poisson:** los puntos aleatorios dentro de una región siguen una distribución de probabilidad de Poisson.

1.2.5.2 Procesos de puntos de Cox Log-Gaussiano (CLG)

El proceso CLG es un modelo estadístico usado en la probabilidad y estadística para modelar la distribución de eventos puntuales en un espacio geográfico, tomando en cuenta la dependencia espacial de los eventos. CLG es una generalización del proceso de Poisson no homogéneo y es caracterizado por un proceso de patrones de puntos agregado, en el cual la ausencia de un patrón de puntos regular es determinada estocásticamente por un proceso aleatorio, lo que es conocido como doblemente aleatorio (Diggle, 2014). Esto también se ha interpretado como un modelo que toma en cuenta los efectos tanto lineales y no lineales de los cofactores, así como los componentes no observados que están correlacionados

espacialmente, tal como lo es el efecto desencadenante de un PRM, el cual se integra directamente en la intensidad del desprendimiento. Tomar en cuenta el efecto espacial, es importante cuando la intensidad del factor desencadenante del PRM (fuerte tormenta o un terremoto) no se observa y es muy heterogénea en el espacio (Lee, 2014). Por ejemplo, un evento de lluvia fuerte, donde la cantidad de precipitación es homogénea puede dominar sobre los otros efectos de los factores predictores directamente relacionados con las propiedades morfológicas de la zona (Lombardo et al., 2018).

Antes de abordar el modelo de CLG es necesario comprender tanto los procesos de puntos de Cox como el proceso Gaussiano.

1.2.5.2.1 Proceso de puntos de Cox

El proceso de puntos de Cox es una generalización de un proceso de Poisson no homogéneo, con la diferencia de que la función de intensidad es aleatoria y contiene un efecto espacial latente, el cual describe la intensidad aleatoria del proceso de puntos y gobierna la variación de la intensidad en el espacio no explicada por otros factores (Illian et al., 2008). Esto es porque es posible encontrar subregiones donde la intensidad de puntos es mayor o menor que la observada en promedio. Este modelo es un proceso de puntos de Poisson no homogéneo, con la diferencia de que la función de intensidad $\lambda(s)$ tiene una variación espacial aleatoria (Lombardo et al., 2018).

1.2.5.2.2 Procesos Gaussianos

Por otra parte, los procesos Gaussianos son un tipo de proceso estocástico para modelar la variación aleatoria de una variable continua en el espacio. Los Procesos Gaussianos son regularmente usados en estadística, en los cuales la frecuencia de sus observaciones es

simétrica respecto a su media, la moda y la mediana son ambas iguales a la media (Shumway, 2000).

Los procesos Cox log Gaussiano es una subclase de procesos de Cox, mediante los cuales se pueden derivar expresiones explícitas para las propiedades del proceso puntual. En el modelado de CLG se estima un efecto espacial latente, el cual es útil no sólo para detectar y cuantificar los patrones espaciales de puntos, sino que además nos proporciona una estimación de la autocorrelación espacial de la ocurrencia de PRM en la zona de estudio.

1.2.5.3 Autocorrelación espacial

La autocorrelación espacial (AE) analiza la variabilidad de un fenómeno a través del espacio geográfico para identificar patrones espaciales (Siabato y Guzmán-Manrique, 2019), en otras palabras, la AE estudia la manera en que un fenómeno se dispersa a través de unidades discretas espacialmente distribuidas (Vilalta y Perdomo, 2005). La existencia de AE implica la falta de independencia espacial entre eventos. La AE se encuentra comúnmente en datos ambientales y puede surgir por varias razones, incluidas causas por los componentes vivos de un ecosistema (bióticas), componentes físicos y químicos que son los elementos de la parte no viva en el ecosistema (abióticas) y causas humanas (Legendre y Fortin, 1989).

Cuando un conjunto de puntos tiene una distribución espacial agregada, se dice que existe una autocorrelación positiva, en cambio, si un conjunto de puntos muestra tendencia a una distribución uniforme, se dice que existe una autocorrelación negativa, de otra manera cuando la distribución espacial es al azar, los puntos tendrían una autocorrelación nula (Illian et al., 2008; Diggle, 2014) (Figura 14).




Figura 14: AE Positiva (Izquierda), AE Negativa (centro) y AE Nula (Derecha)

En estudios previos, se ha llevado a cabo la evaluación de la AE en datos de PRM, revelando la presencia de valores de autocorrelación positiva (Lombardo et al., 2018). Estos descubrimientos indican la existencia de patrones de agregación entre los eventos de PRM, lo que implica que la ocurrencia de un PRM aumenta la probabilidad de que se produzcan otros PRM en áreas cercanas en comparación con las más distantes (Legendre y Fortin, 1989).

La variable AE es un componente clave para el análisis de los eventos de PRM y puede ser obtenida utilizando únicamente la ubicación espacial del conjunto de datos de los PRM. La AE proporciona una medida cuantitativa de la relación espacial entre los eventos y permite comprender mejor los patrones de agregación y la propagación de los PRM en la región de estudio. Su inclusión en el análisis contribuye a una mejor caracterización y comprensión del fenómeno de los PRM y puede ser de utilidad en la toma de decisiones relacionadas con la gestión y mitigación de riesgos geológicos.

1.3 Hipótesis

Los factores relacionados con las formas de relieve, como son la orientación de la pendiente, la curvatura, el ángulo de la pendiente y la roca; son factores estadísticamente significativos para la susceptibilidad a PRM en la Región Sierra-Costa de Michoacán.

1.4 Objetivo

1.4.1 Objetivo general

Estimar la distribución espacial de la susceptibilidad a PRM en la región Sierra-Costa de Michoacán usando modelos estadísticos de procesos de puntos de Cox Log-Gaussiano.

1.4.2 Objetivos particulares

- Describir las características biofísicas y antrópicas de los sitios donde sucedieron PRM ubicados la Sierra-Costa de Michoacán, en los años 2006, 2009, 2010 y 2015.
- Detectar y cuantificar los patrones espaciales de puntos correspondientes a los RPM inventariados.
- Identificar los factores estadísticamente significativos causantes de los PRM, por medio del modelo de procesos de puntos de Cox Log-Gaussiano.
- Evaluar la capacidad predictiva del modelo obtenido.
- Identificar la distribución espacial de la susceptibilidad a PRM.

Capítulo 2. Materiales y métodos

2.1 Área de estudio

El estado de Michoacán se divide en 10 regiones económicas, las cuales son Lerma Chapala, Bajío, Cuitzeo, Oriente, Tepalcatepec, Purépecha, Pátzcuaro – Zirahuén, Tierra Caliente, Sierra-Costa e Infiernillo (COEAC, 2023). Este estudio se realizó en la región Sierra-Costa (SC) la cual tiene una superficie total de 13,760 km², siendo la región más grande de Michoacán, con el 23% de la extensión territorial del estado, y una población de 275,000 habitantes (COEAC, 2023). La SC abarca los municipios: Coahuayana, Chinicuila, Aquila, Coalcomán, Aguililla, Tumbiscatío, Arteaga y Lázaro Cárdenas. La región SC pertenece a la provincia fisiográfica Sierra Madre del Sur y a la subprovincia Cordillera Costera del Sur. El relieve de la región es muy variado (Tabla 1), no obstante, en el predominan las montañas y los lomeríos (Solis-Castillo et al., 2019; de la Peña et al., 2021). La altitud va desde el nivel del mar hasta los 2,914 metros sobre el nivel del mar (msnm). La región está cerca de la convergencia de tres placas tectónicas en el Océano Pacífico, las cuales son la Placa Norteamericana, la Placa Rivera y la Placa de Cocos, teniendo también la zona de subducción de la Placa de Cocos, lo cual ha afectado a la región con terremotos de corteza y sismos en dicha zona (Esquivel y Muñoz, 2017).

Relieve	Área (km ²)	Porcentaje (%)
Montañas	7,980.8	58
Lomeríos altos	2,889.6	21
Lomeríos bajos	1,100.8	8
Colinas	550.4	4

Planicies	825.6	6
Altiplanicies	275.2	2
Piedemontes	6.8	1

Tabla 1: Tipos de relieve en la Región SC (De la Peña et al., 2021)

La Región SC está limitada por el estado de Colima al oeste, la Meseta Tarasca al norte, la Tierra Caliente en el estado de Guerrero al este, y el Océano Pacífico al sur. La región SC tiene climas cálido subhúmedo, semicálido subhúmedo y templado subhúmedo (SNIGF, 2023), por lo tanto, la temperatura media anual es de 20°C y la precipitación anual oscila entre 800 y 1,200 mm³ (Segundo-Métay y Bocco, 2015). La mayor parte de precipitación es estacional, es decir, sucede por temporadas y está asociada a los vientos del oeste y a las tormentas tropicales que suceden entre mayo y octubre (De la Peña et al. 2021).

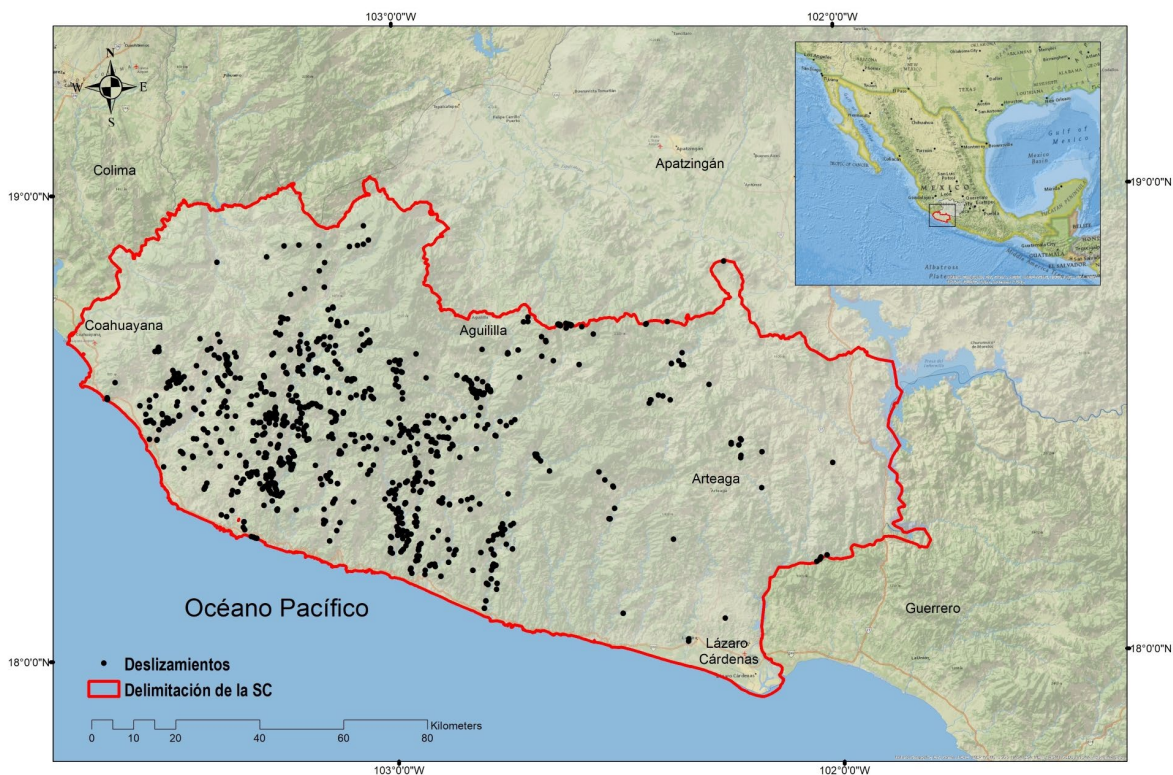


Figura 15: Mapa del área de estudio (SC) junto con la ubicación de los PRM del conjunto de datos. Proyección UTM, Datum WGS 1984.

2.2 Inventario de PRM

Como se observa en la Figura 15, los datos usados en la presente tesis son 1,337 registros puntuales de PRM en la región y fueron obtenidos por Solís-Castillo (2019) y actualizados por De la Peña et al. (2021) haciendo uso de 1995 ortofotos con resolución de 2m para la identificación de PRM (INEGI). Este conjunto de datos de PRM está georreferenciado y categorizado por el tipo de PRM e incluyen eventos de los años 2006, 2009, 2010, y 2015.

Los datos fueron explorados y se realizó una depuración de los datos nulos o inconsistentes que se encontraban en el conjunto. Además, por medio de la unión de datos ráster con el inventario de PRM, se añadieron a cada uno de los registros, la información de los factores predictores que se usaron en el modelo: pendiente del terreno, orientación de la ladera, curvatura planar, curvatura de perfil, uso de suelo, tipo de roca, distancia a fallas y distancia a ríos y arroyos.

2.2.1 Factores predictores en la SC

La selección adecuada de factores predictores es fundamental para el modelo de proceso de puntos de Cox-Log Gaussiano que se desarrolló. Los factores predictores utilizados en este estudio representan una amplia gama de características y condiciones ambientales relevantes para el fenómeno de interés (Illian et al., 2008). El uso de factores de geología, edafología, morfometría e hidrografía permitió una mejor comprensión de los factores que influyen en la distribución espacial de los eventos (Tabla 2).

Tabla 2: Lista de factores predictores para la modelación de proceso de puntos de Cox-Log Gaussiano. NA= No aplica.

Cartografía	Parámetro	Rango o categorías de la variable	Fuente	Escala/Resolución
Inventario de PRM	Ubicación y tipo de PRM	NA	Solís-Castillo (2019) y actualizados por De la Peña et al. (2021).	2 x 2 mts.
Geología	Tipo de roca	[Aluvial, Andesita, Andesita-Toba intermedia, Andesita-Conglomerado, Caliza, Caliza-Lutita, Complejo metamórfico, Conglomerado, Diorita, Gabro, Granito, Granito-Granodiorita, Granodiorita, Lacutre, Latita, Litoral, Lutita, Lutita-Arenisca, No aplica, Riodacita, Toba ácida, Tonalita, Volcano clástico]	Solís-Castillo et al. (2019)	Escala 1:250,000
	Distancia a fallas y fracturas (mts)	[<1000], [1000-2000], [2000-3000], [3000-4000], [>4000]	Instituto Nacional de Estadística Geográfica (INEGI)	
Edafología	Tipo de suelo	Agricultura de riego, agricultura de temporal, asentamientos humanos, bosque, cuerpos de agua, cultivo perenne, manglar, pastizal inducido pastizal cultivado, popal-tular, selva y sin vegetación aparente	Instituto Nacional de Estadística Geográfica (INEGI)	Escala 1:250,000

Morfometría	Modelo digital de elevación	0 - 2845	Aster, https://earthexplorer.usgs.gov	30 x 30 m
	Pendiente (°)	[<15], [15-20], [20-30], [30-45], [>45]	DEM	30 x 30 m
	Orientación	Plano, Norte, Noroeste, Este, Sureste, Sur, Suroeste, Oeste y Noroeste	DEM	30 x 30 m
	Curvatura planar	Lateralmente cóncava (-), superficie lineal (0), lateralmente convexa (+)	DEM	30 x 30 m
	Curvatura de Perfil	Convexo hacia arriba (-), Lineal (0), Cóncavo hacia arriba (+)	DEM	30 x 30 m
Hidrografía	Distancia a ríos y arroyos (mts)	[<50], [50-100], [100-150], [150-200], [>200]	DEM	30 x 30 m

La región SC es montañosa, con elevaciones que van desde el nivel del mar hasta 2,914 m sobre el nivel del mar y está rodeada en la zona sur por una estrecha llanura costera del Pacífico (Figura 16). Solís-Castillo et al. (2019) asociaron los sistemas de fallas de la región SC, las áreas con pendientes pronunciadas y los suelos erosionados con los PRM.




Figura 16: Modelo Digital de Elevación DEM de la SC. Proyección UTM, Datum WGS 1984.

En la región SC se tienen contabilizadas 10 fallas (Figura 17), con longitudes desde 1.36 km hasta 26.61 km, teniendo un promedio de longitud de 10.04 km, con un coeficiente de variación (CV) de alrededor de 68.25%. También, se tienen contabilizadas 90 fracturas, con longitudes desde 634.69 m hasta 23.34 km, dominando las fracturas que tienen una longitud entre 5 y 10 km, teniendo un promedio, entre las 90 fracturas, de 8 km con un coeficiente de variación (CV) de aproximadamente 47.5%.

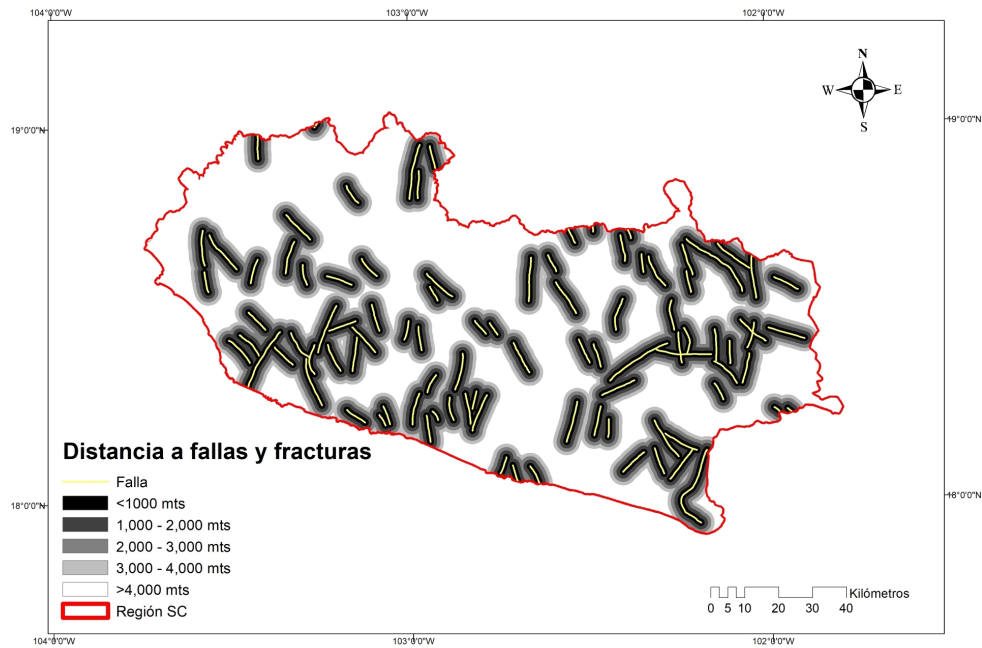


Figura 17: Mapa de las distancias a fallas y fracturas de la SC. Proyección UTM, Datum WGS 1984.

En este estudio se evaluó la importancia de la distancia a ríos y arroyos en la susceptibilidad (Figura 18) a los desprendimientos creando 5 clases de distancia. Estas clases fueron propuestas por De la Peña et al.,2021 y se obtuvieron con un umbral de distancia de 50 m (Tabla 3).

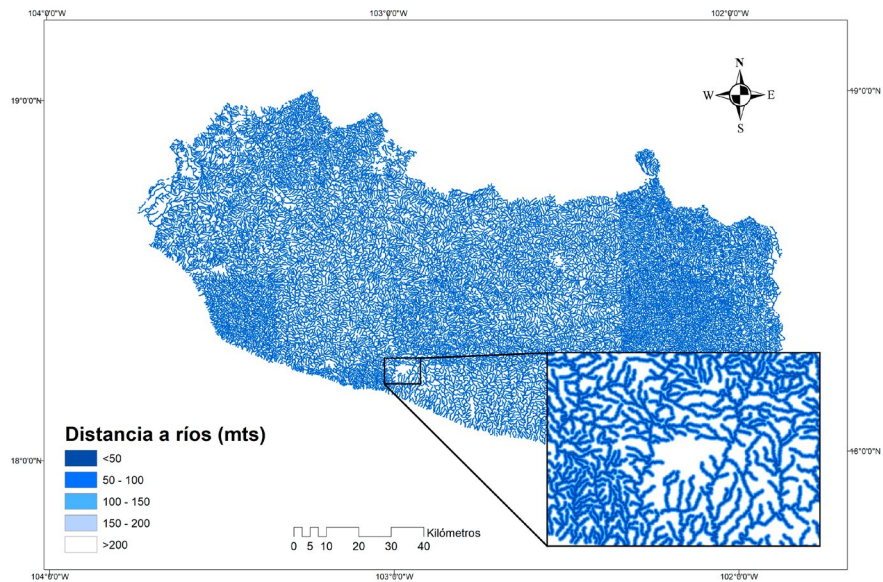


Figura 18. Distancia a ríos y arroyos de la región SC. Proyección UTM, Datum WGS 1984.

Tabla 3: Rangos de distancia a ríos y arroyos.

Clase	Rango de distancia (m)
Clase 1	[0, 50[
Clase 2	[50, 100[
Clase 3	[100, 150[
Clase 4	[150, 200[
Clase 4	[> 200]

Usando el DEM se obtuvieron datos como la pendiente y la orientación de la misma (Figura 19 y 20), las cuales muestran áreas con pendientes más pronunciadas en color más naranja/rojizo, mientras que las áreas más verdes son sitios más planos. También se obtuvieron datos como la curvatura planar y de perfil (Figuras 21a y 22b).

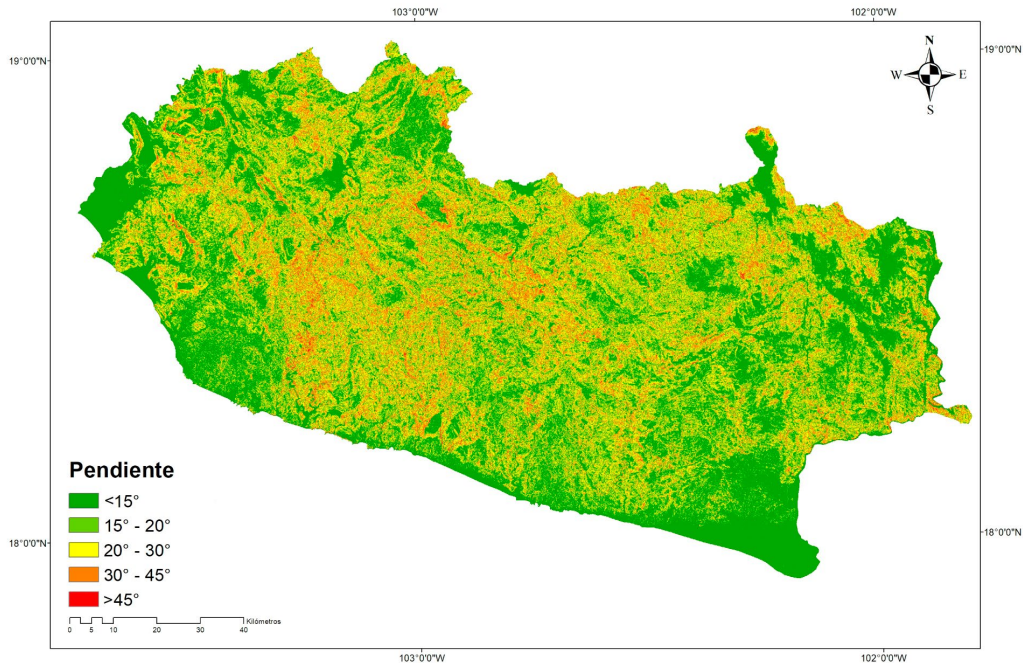


Figura 19. Mapa de pendiente de la región SC. Proyección UTM, Datum WGS 1984.

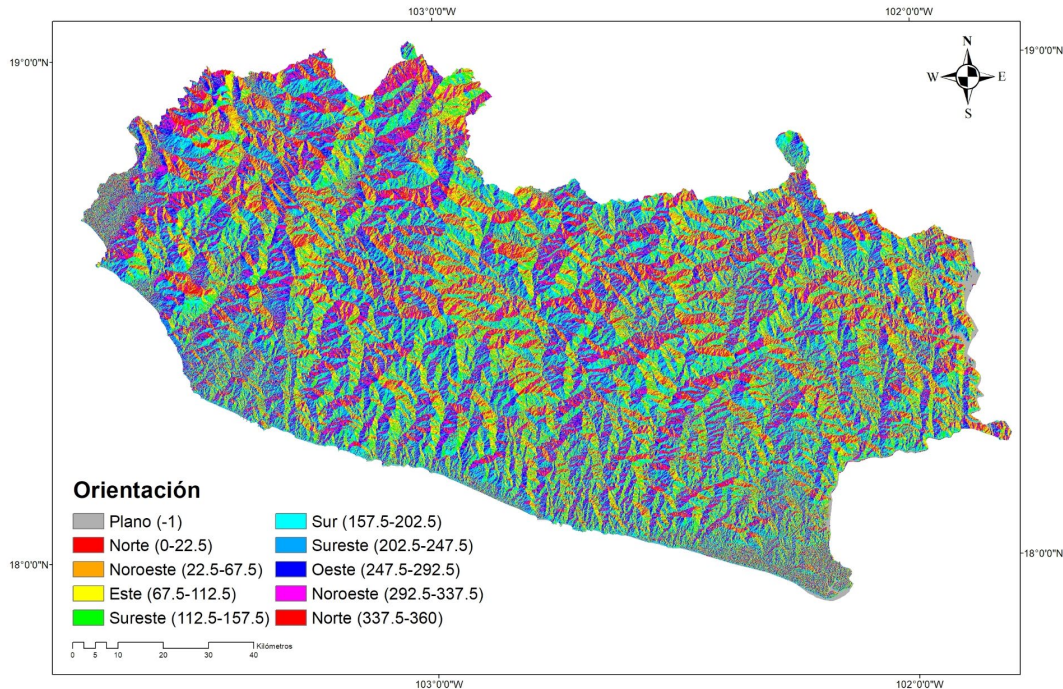


Figura 20: Mapa de la orientación de la pendiente de la SC. Proyección UTM, Datum WGS 1984.

En el mapa de pendientes (Figura 19) se puede observar que existen superficies con pendientes muy pronunciadas, pero también hay superficies con pendiente casi nula. Al realizar una clasificación de la pendiente en intervalos de 10 grados, con el objetivo de visualizar la extensión territorial de cada clase, es posible identificar las superficies de cada una de ellas (Tabla 4)

Tabla 4. Área de la pendiente clasificada en 8 rangos.

Pendiente (°)	Área (km ²)
0° - 10°	2,682.3
10° - 20°	4,059.4
20° - 30°	4,428.5
30° - 40°	2,169.7
40° - 50°	324.7
50° - 60°	18.2
60° - 70°	0.7
70° ≥	0.05

A pesar de que es notorio que hay una gran extensión territorial de planicies, se puede observar que las superficies con pendiente de 20° a 30° son las más frecuentes, ya que tienen la mayor extensión territorial en la región SC (Tabla 5).

El mapa de orientación de la pendiente (Figura 20) indica la orientación de una pendiente respecto al norte. En la Tabla 5 se presenta la distribución de las superficies ocupadas por las clases de orientación de laderas. La orientación con mayores superficies es la suroeste y, la que menos superficies ocupa, es la norte. Dependiendo de la ubicación latitudinal, los sitios con orientación norte están asociados a menor luz, más humedad y un ambiente más fresco que sitios con orientación sur.

Tabla 5. Área de las orientaciones de la pendiente

<i>Orientación</i>	<i>Área (km²)</i>
<i>Plano</i>	1,036.83
<i>Norte</i>	733.68
<i>Noreste</i>	1,517.11
<i>Este</i>	1,700.13
<i>Sureste</i>	1,693.18
<i>Sur</i>	1,861.26
<i>Suroeste</i>	1,896.17
<i>Oeste</i>	1,755.88
<i>Noroeste</i>	1,565.76

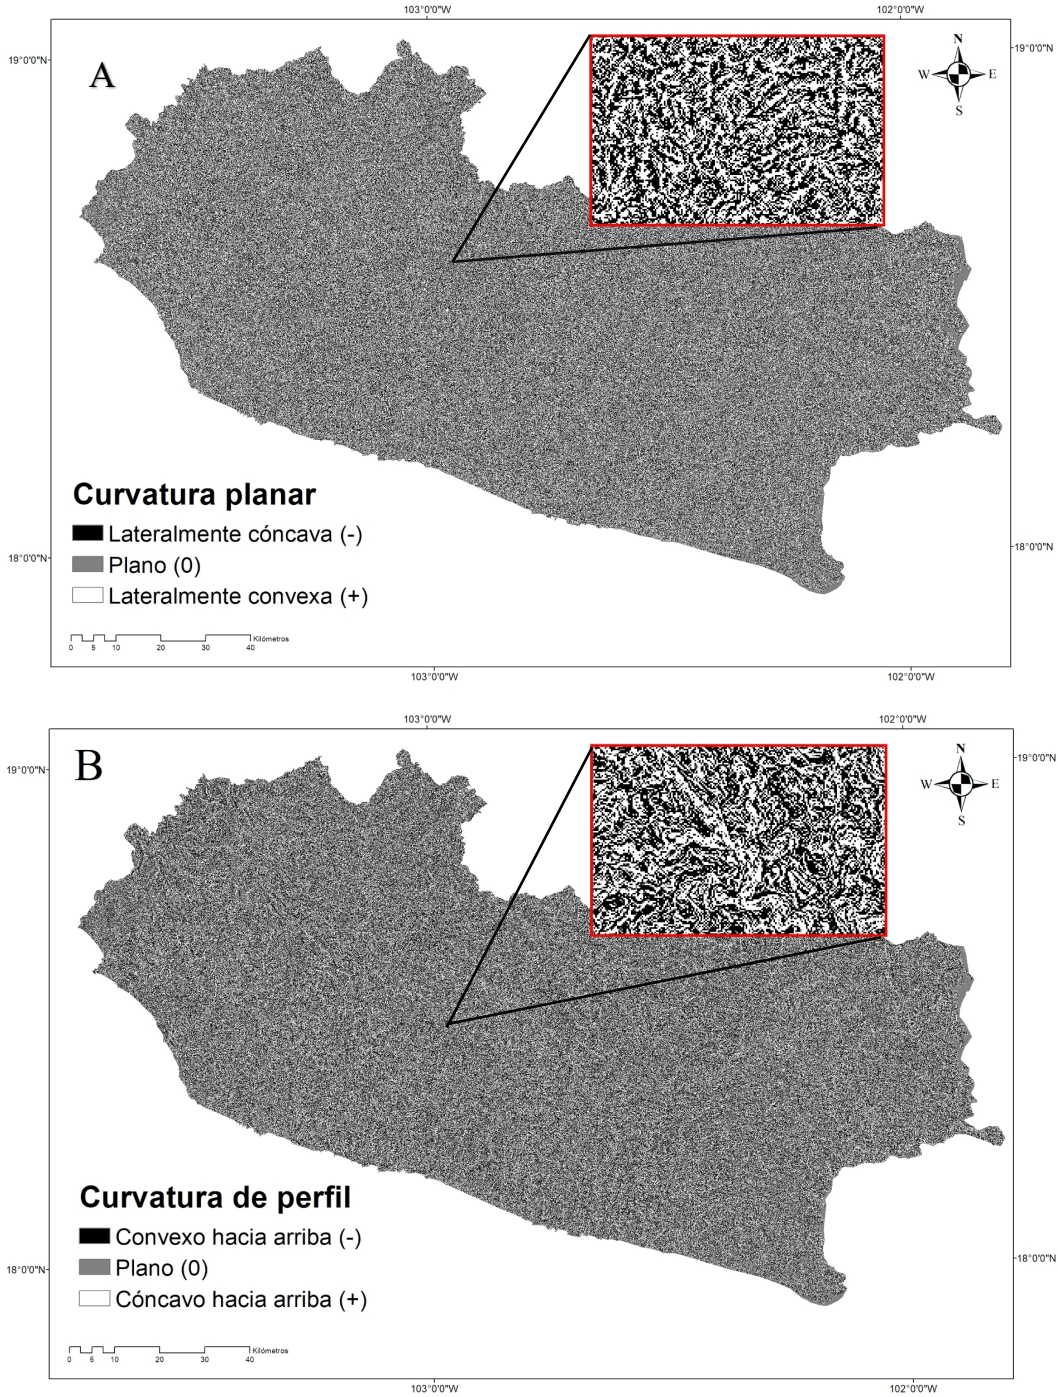


Figura 21: Mapa de curvatura planar de la SC (A) y mapa de curvatura de perfil de la SC (B). Proyección UTM, Datum WGS 1984.

Los datos como los tipos de rocas y coberturas y uso de suelo (Figura 22), se obtuvieron de Solís-Castillo et al. (2019). En la SC existen 23 tipos de roca (Figura 22(A)) y 19 tipos de uso de suelo (Figura 22(B)), dominando las actividades agrícolas, ganaderas y forestales.

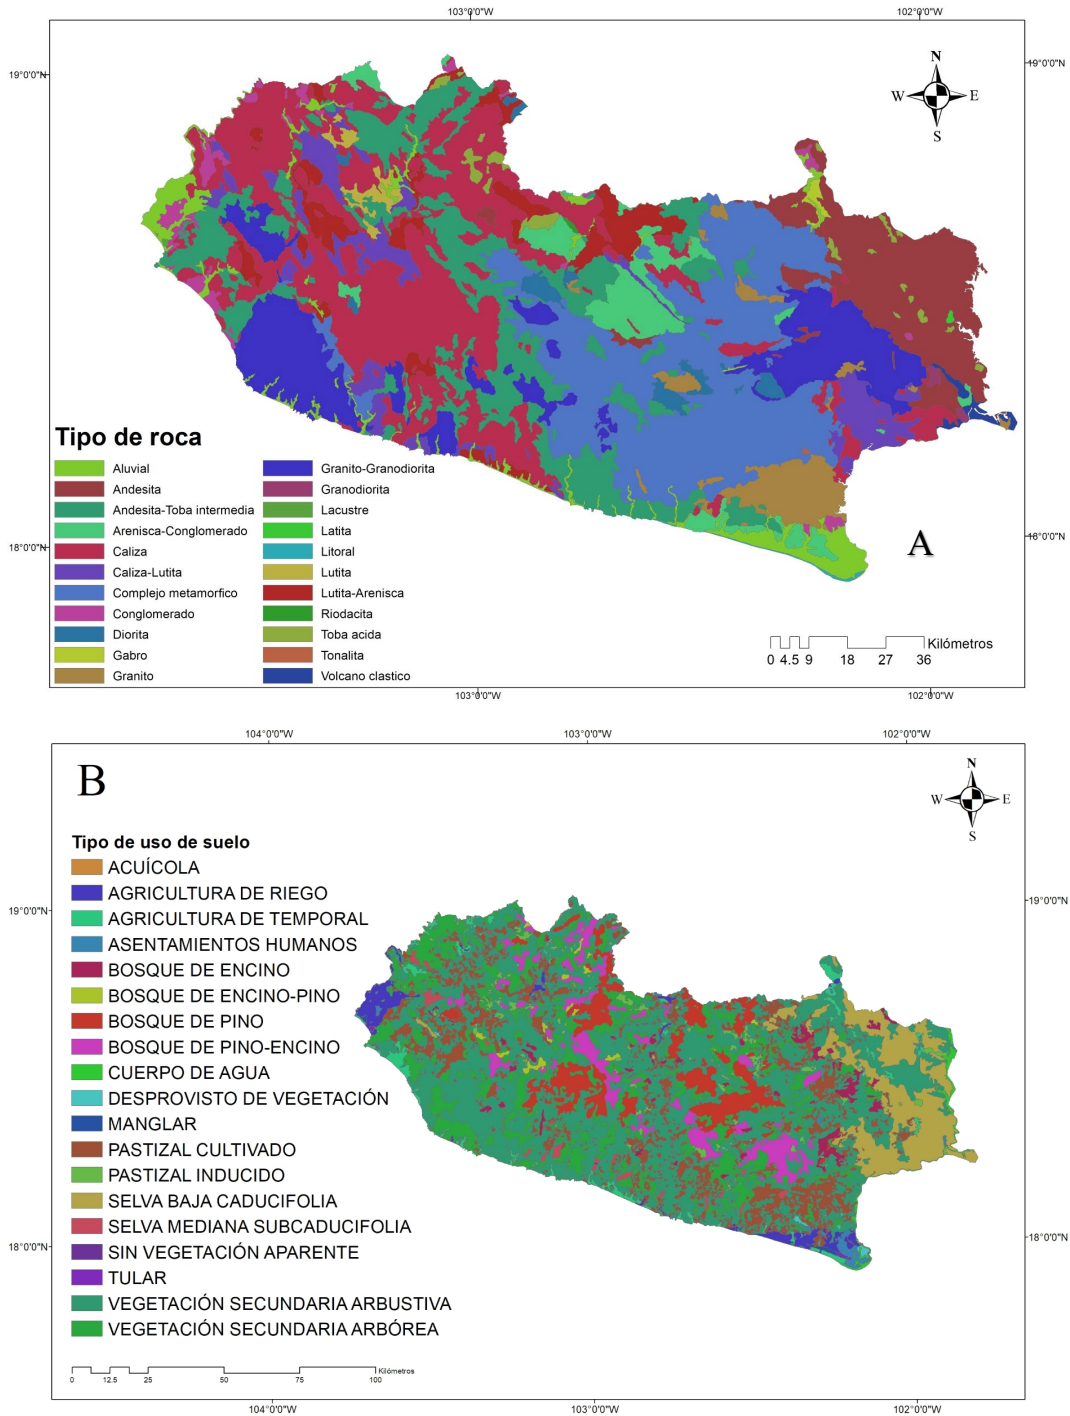


Figura 22: Mapa de tipos de roca de la SC (A) y mapa del tipo de uso de suelo de la SC (B). Proyección UTM, Datum WGS 1984.

La SC cuenta en la mayoría de su territorio con rocas ígneas metamórficas e intrusivas (cuando las rocas ígneas como la Andesitas o rocas sedimentarias como las Calizas son

sometidas a largos periodos de calor y humedad) (Solís-Castillo et al., 2019). Las propiedades de estas rocas hacen que tengan una mayor susceptibilidad a PRM (De la Peña et al. 2021).

Tabla 6. Área de los tipos de roca en la región SC.

Tipo de roca	Superficie en la SC (km²)	Porcentaje en la SC (%)
Aluvial	646.45	4.47
Andesita	1186.73	8.2
Andesita-Toba intermedia	1973.78	13.64
Arenisca-Conglomerado	564.62	3.9
Caliza	3133.39	21.66
Caliza - Lutita	658.47	4.55
Complejo metamórfico	2590.54	17.91
Conglomerado	173.97	1.2
Diorita	165.92	1.14
Gabro	23.60	0.16
Granito	426.99	2.95
Granito – Granodiorita	1978.12	13.68
Granodiorita	16.34	0.11
Lacustre	2.08	0.01
Latita	3.94	0.02
Litoral	14.54	0.10
Lutita	86.38	0.59
Lutita – Arenisca	586.64	4.05
Riodacita	4.58	0.031

Toba ácida	108.21	0.74
Tonalita	1.92	0.01
Volcano clástico	51.29	0.35

En este estudio se utilizó información topográfica y temática listada en la Tabla 2, toda la información fue editada o creada en ArcMap en su versión 10.4, el cual es un software de Sistemas de Información Geográfica (SIG) que tiene una amplia variedad de herramientas para administrar y analizar información geográfica (ArcGIS, 2010).

2.2.2 Unidades de pendiente

Las unidades de terreno fueron subdivisiones que delimitan la homogeneidad dentro de cada unidad de terreno y distinguen la heterogeneidad entre unidades adyacentes, principalmente por atributos del paisaje. Una unidad de pendiente, es una unidad de terreno que se delimita a partir de las características de la pendiente como son sus procesos hidrológicos y geomorfológicos (Lombardo et al., 2018). Las unidades de pendiente dividen cualquier superficie en subcuencas usando rasgos paisajísticos de la zona. Las unidades de pendiente dependen de factores como el tamaño y complejidad de la zona de estudio y resolución del DEM, ya que es el único dato de entrada para el cálculo de las mismas (Lombardo et al., 2018).

El cálculo de las unidades de pendiente puede ser hecho manualmente; sin embargo, podría tener muy poca exactitud y requiere mucho tiempo (Lombardo et al., 2018); la solución a esto es automatizar el cálculo de las unidades de pendiente por medio de GRASS GIS, un software SIG para el procesamiento digital de vectores e imágenes ráster. Lombardo et al., (2018) sugieren que, para la modelación de proceso de puntos, las unidades de pendiente sean

obtenidas mediante el comando `r.slopeunits`, el cual fue programado por Alvioli et al., (2016). Analizando los parámetros mencionados por Alvioli et al., (2016) y siguiendo las sugerencias de Lombardo et al., (2018), se corrió el comando de la siguiente manera:

```
./r.slopeunits demmap=DEM_SC1@ PERMANENT slumap=SUraster slumapclean=SUclean  
thresh=150000 areamin= 10000 cvmin=0.25 rf=2 maxiteration=10 cleansize=2000
```

donde identificamos el DEM de entrada como `DEM_SC1`; nuestra salida, es decir, el mapa de unidades de pendiente será `SUraster`; además, se definieron la acumulación inicial de flujo (`thresh`) en 150,000 m², el factor de reducción (`rf`) en 2, el área mínima de la unidad de pendiente (`areamin`) en 10,000 m², la varianza circular mínima del aspecto del terreno dentro de las unidades de pendiente (`cvmin`) en 0.25, el área umbral por debajo de la cual se eliminan las unidades de pendiente más pequeñas (`cleansize`) a 2,000 m², y el número máximo de iteraciones para subdividir recursivamente las unidades de pendiente (`maxiteration`) a 10.

Después de vectorizar el mapa ráster resultado del procesamiento, se obtiene un mapa donde cada polígono es una unidad de pendiente (Figura 23).

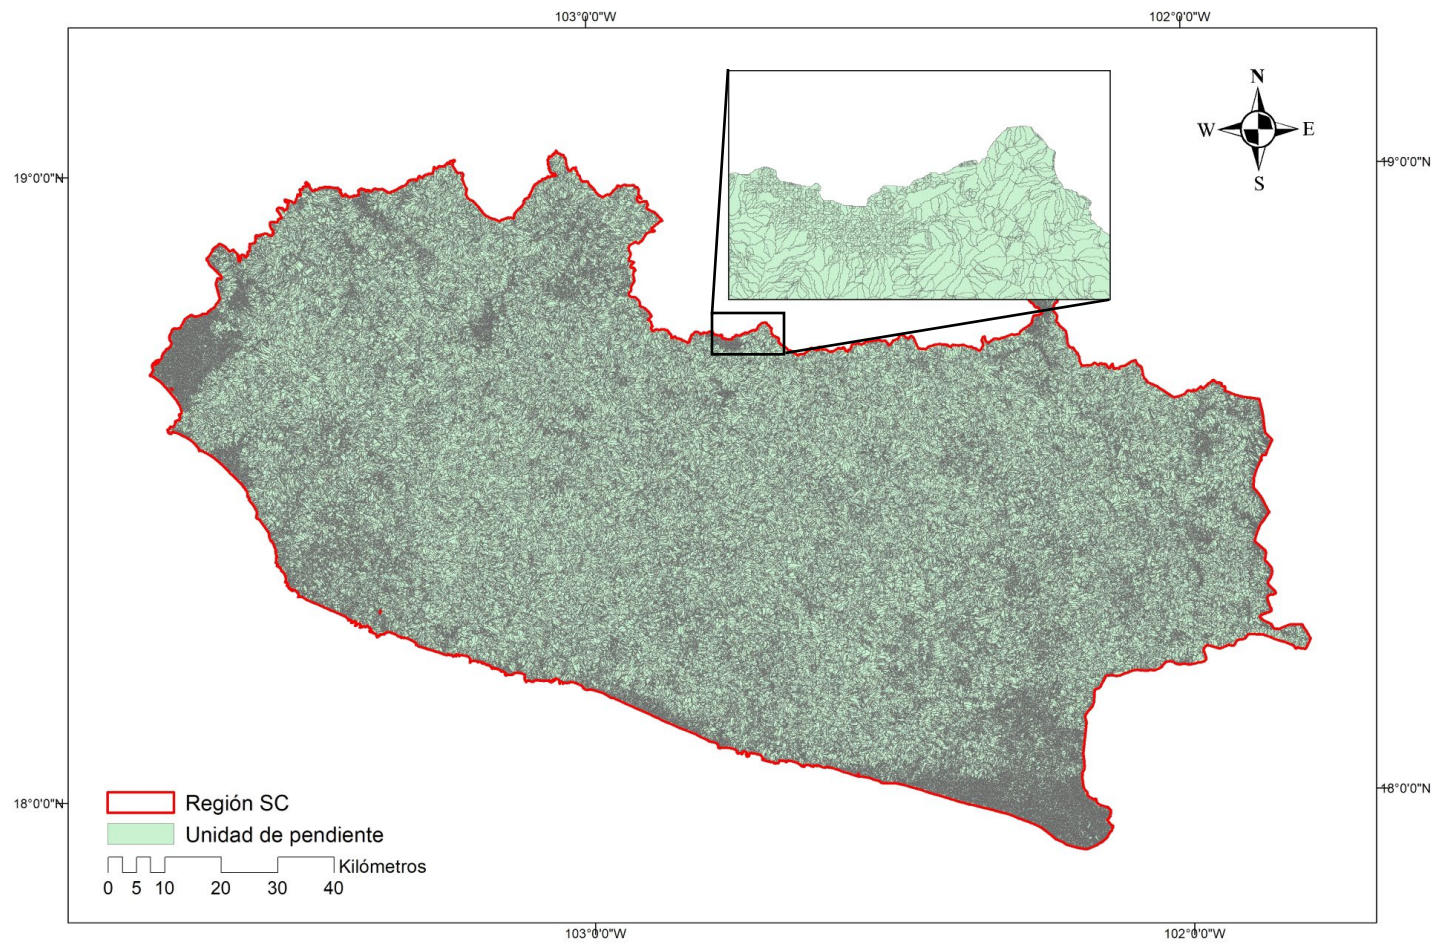


Figura 23. Mapa de las Unidades de pendiente en la SC. Proyección UTM, Datum WGS 1984.

Capítulo 3. Modelación de PRM

La modelación del inventario de PRM se llevó a cabo mediante el modelo propuesto por Lombardo et al., (2019), el cuál es desarrollado en R-INLA para modelar los procesos de puntos. Este modelo ajusta un proceso de puntos de Cox Log-Gaussiano que proporciona una descripción espacial continua de la intensidad de los PRM, lo que permite obtener la distribución de los recuentos de en la región SC.

La distribución de PRM se estima regularmente usando odelos estadísticos de presencia / ausencia de acuerdo a la distribución de Bernoulli. Esta distribución describe las probabilidades de que ocurra o no un evento, en este caso, un PRM en una unidad cartográfica determinada (Greco et al., 2007). Sin embargo, el hacer uso de esta distribución puede ser limitado, ya que solo estima la susceptibilidad y no considera el recuento de PRM por unidad cartográfica, dejando a un lado la intensidad de los PRM. La solución a esto es modelar de acuerdo a la distribución de Poisson, ya que, con esta distribución, es posible estimar la intensidad de los PRM (Lombardo et al., 2018).

En este momento es donde toma el protagonismo el proceso de puntos de Cox Log-Gaussiano, el cual proporciona un análisis para describir patrones espaciales puntuales, en este caso, PRM en una unidad cartográfica continua. Así que, para llevar a cabo dicho modelo, es necesario hacer un pre-procesamiento de datos, donde se hará el conteo de eventos de PRM en un área de 500 m², categorización de factores de texto y la unión de los factores predictores con el mapa de conteo de eventos.

3.1 Preprocesamiento de datos

3.1.1 Configuración del entorno para la modelación del proceso de puntos de Cox-Log Gaussiano

La tarea de identificar los factores predictores estadísticamente significativas causantes de los PRM se llevaron a cabo con la modelación del proceso de puntos de Cox Log-Gaussiano por medio de R, en su versión 2022.07.1, por medio de la interfaz R Studio. El paquete principal que se usó para la modelación de la susceptibilidad a PRM es R-INLA versión 22.05.07 (Aproximación de Laplace anidada integrada, en su traducción al español). Este paquete proporciona las herramientas para el modelado espacial y espacio-temporal en campos aleatorios gaussianos (Blangiardo, 2013). El uso de la unidad de procesamiento gráfico (GPU) es clave en el procesamiento, por lo tanto, se hizo uso de un equipo de cómputo con las siguientes características:

- Procesador Intel Core i9 – 9900 CPU @3.10 GHz
- 64 GB de memoria RAM
- Unidad de procesamiento gráfico dedicado NVIDIA 1650 Súper, 4 GB de RAM DDR6 a 12 GHz

3.1.2 Factores categóricos

La categorización de datos es un proceso muy importante cuando hay factores con un formato de texto, ya que se obtiene un mejor entendimiento de los datos, una eficiencia en el almacenamiento y una mejora de rendimiento en el entrenamiento y la modelación (Florián, 2013). Los factores categóricos de texto se clasificaron con un ID de la siguiente manera:

Tabla 7. Categorías e ID de uso de suelo.

Uso de suelo	ID	Uso de suelo	ID
ACUÍCOLA	1	AGRICULTURA DE TEMPORAL ANUAL Y SEMIPERMANENTE	21
DESPROVISTO DE VEGETACIÓN	2	AGRICULTURA DE TEMPORAL PERMANENTE	22
ASENTAMIENTOS HUMANOS	3	AGRICULTURA DE TEMPORAL SEMIPERMANENTE Y PERMANENTE	23
BOSQUE DE PINO	4	MANGLAR	24
BOSQUE DE PINO-ENCINO	5	VEGETACIÓN SECUNDARIA ARBÓREA DE BOSQUE MESÓFILO DE MONTAÑA	25
BOSQUE DE ENCINO	6	VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE PINO	26
BOSQUE DE ENCINO-PINO	7	VEGETACIÓN SECUNDARIA ARBÓREA DE BOSQUE DE PINO	27
SIN VEGETACIÓN APARENTE	8	VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE PINO-ENCINO	28
CUERPO DE AGUA	9	VEGETACIÓN SECUNDARIA ARBÓREA DE BOSQUE DE PINO-ENCINO	29
PASTIZAL CULTIVADO	10	VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE ENCINO	30
PASTIZAL INDUCIDO	11	VEGETACIÓN SECUNDARIA ARBÓREA DE BOSQUE DE ENCINO	31
AGRICULTURA DE RIEGO ANUAL	12	VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE ENCINO-PINO	32
AGRICULTURA DE RIEGO ANUAL Y PERMANENTE	13	VEGETACIÓN SECUNDARIA ARBÓREA DE BOSQUE DE ENCINO-PINO	33
AGRICULTURA DE RIEGO ANUAL Y SEMIPERMANENTE	14	VEGETACIÓN SECUNDARIA ARBUSTIVA DE SELVA BAJA CADUCIFOLIA	34
AGRICULTURA DE RIEGO PERMANENTE	15	VEGETACIÓN SECUNDARIA ARBÓREA DE SELVA BAJA CADUCIFOLIA	35

AGRICULTURA DE RIEGO SEMIPERMANENTE Y PERMANENTE	16	VEGETACIÓN SECUNDARIA ARBUSTIVA DE SELVA MEDIANA SUBCADUCIFOLIA	36
SELVA BAJA CADUCIFOLIA	17	VEGETACIÓN SECUNDARIA ARBÓREA DE SELVA MEDIANA SUBCADUCIFOLIA	37
SELVA MEDIANA SUBCADUCIFOLIA	18	VEGETACIÓN SECUNDARIA ARBÓREA DE MANGLAR	38
AGRICULTURA DE TEMPORAL ANUAL	19	TULAR	39
AGRICULTURA DE TEMPORAL ANUAL Y PERMANENTE	20		

Tabla 8. Categorías e ID de tipo geológico.

GEO_TIPO	ID	GEO_TIPO	ID
Aluvial	1	Granito – Granodiorita	12
Andesita	2	Granodiorita	13
Andesita-Toba intermedia	3	Lacustre	14
Arenisca-Conglomerado	4	Latita	15
Caliza	5	Litoral	16
Caliza - Lutita	6	Lutita	17
Complejo metamórfico	7	Lutita – Arenisca	18
Conglomerado	8	No aplica	19
Diorita	9	Riodacita	20
Gabro	10	Toba acida	21
Granito	11	Tonalita	22
		Volcano clástico	23

La variable de la orientación de la pendiente, también requirió ser categorizada, debido a que es una variable circular (valores continuos de 0 a 360), las cuales pueden perjudicar la precisión del modelo y el rendimiento computacional a la hora de la modelación. Lombardo et al. (2018), sugieren que 16 clases equidistantes de 22.5 grados en cada segmento son suficientes para lograr una buena precisión en el modelado y un buen rendimiento

computacional. Se hizo uso de la función llamada `inla.group`, que se encuentra en el paquete INLA para lograr la categorización de la orientación.

3.1.3 Estructura de grafo de adyacencia

Un grafo de adyacencia es una representación gráfica de las relaciones de vecindad entre las unidades de análisis, en este caso, las unidades de pendiente (Bivand et al., 2013). En esta modelación, la estructura de grafo de adyacencia permite modelar la autocorrelación espacial entre los PRM en la región SC y determina las relaciones de vecindad entre las unidades de pendiente. La elaboración de dicha estructura se realizó con la función `nb2INLA()` del paquete `spdep` en R. La función mencionada anteriormente asigna un número de identificación (ID) a cada una de las unidades de pendiente y se obtiene como resultado un conjunto de datos donde está el ID de cada unidad de pendiente, seguida de los ID de las unidades de pendiente vecinas, indicando las unidades de pendiente que están cerca una de la otras en el espacio y, por lo tanto, están más relacionadas.

La estructura de adyacencia se usó en la modelación de la dependencia espacial por medio del modelo autoregresivo correlacional (CAR), con base en el vecindario de las unidades de pendiente. CAR se basa en la idea de que los valores de densidad de PRM en una unidad de pendiente están correlacionados con los valores de densidad de sus unidades de pendiente vecinas, de la misma manera que la autocorrelación espacial, descrita en la Sección 1.2.5.3. A partir de la estructura de grafo de adyacencia, se construye una matriz de pesos que indica la magnitud de la relación entre los puntos vecinos (Besag, 1975).

3.1.4 Conteo de eventos de PRM

Se desarrolló una función específica que permite obtener la cantidad de PRM en un pixel, el cual representa un área de 500 m². En esta función se utilizó un mapa ráster con pixeles cuya resolución fue de 500 m². Estos pixeles fueron la unidad de análisis, lo cual permitió obtener la cantidad de PRM en cada unidad de análisis de 500 m² para la SC. Por ejemplo, si en la unidad de análisis de 500 m² se registraron 5 PRM, el pixel correspondiente tendrá un valor de 5, esto indicando la densidad.

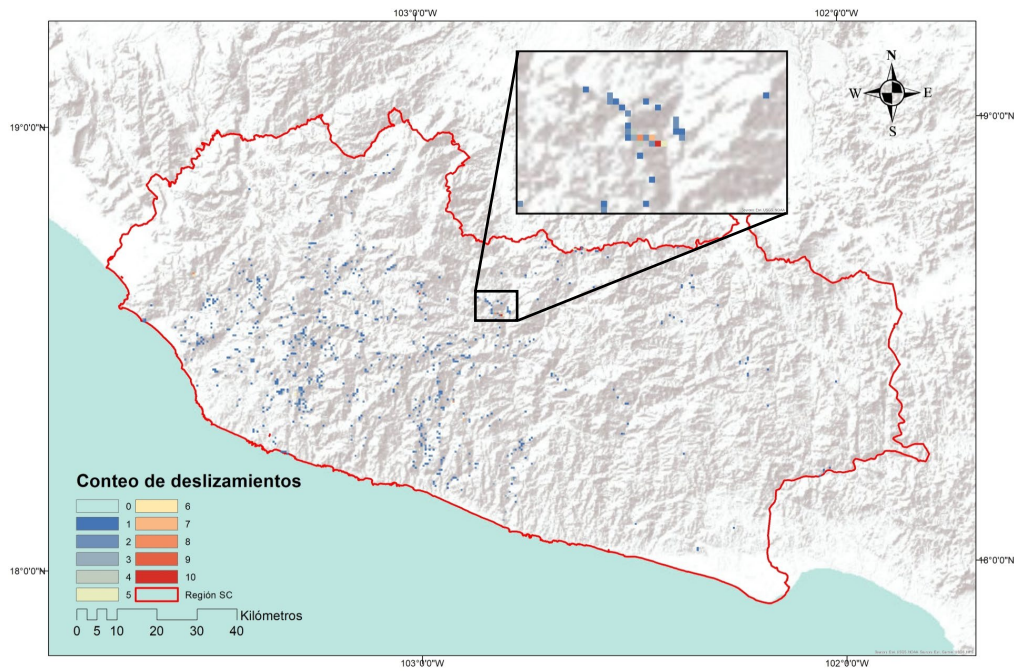


Figura 24: Mapa de conteo de eventos de PRM en la SC. Proyección UTM, Datum WGS 1984.

En la Figura 24 se observa que la mayor cantidad de eventos en un área de 500 m² es de 10 PRM. En el área de la SC es más frecuente observar unidades de análisis de 500 m² con un PRM, seguido de dos PRM, mientras que sólo una unidad de análisis registró la presencia de 10 PRM (Figura 25).

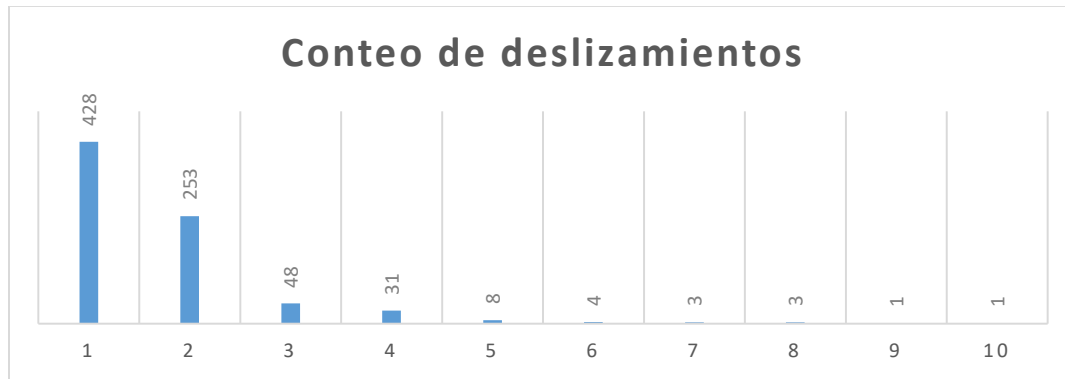


Figura 25. Frecuencia del conteo de densidades de PRM en la región SC.

El siguiente paso fue unir en una matriz, para cada unidad de análisis, la información del conteo de PRM con los factores predictores como son elevación, pendiente, curvatura de perfil, curvatura planar, distancia a fallas y fracturas geológicas, distancia a ríos y arroyos, orientación, uso de suelo y unidades de pendiente. La información de cada uno de los factores predictores, para cada unidad de análisis, fue extraída mediante la función `extract()` del paquete `ráster`. Dicha función permitió consultar los mapas ráster de todos los factores predictores de la Sección 2.2.1. Además, los factores predictores fueron re-proyectados a un tamaño de pixel de 500 metros cuadrados. Este tamaño fue el que se fijó para la modelación, basado en el mapa de inventario de PRM (figura24). La re-proyección se realizó con el método de interpolación bilineal, para los factores continuos. Este método toma los valores de los cuatro puntos más cercanos a la ubicación del punto desconocido y estima una combinación lineal ponderada de los valores conocidos en los cuatro puntos. Los factores categóricos fueron re-proyectados mediante el método de NGB (Nearest Neighbor, que en su traducción al español es “vecino más cercano”). Este método de interpolación espacial estima el valor de un punto desconocido en función de los valores de los puntos cercanos conocidos, esta estimación depende de la distribución de los puntos conocidos y de la

distancia entre el punto desconocido y los puntos vecinos más cercanos (Gotway y Young, 2002).

3.1.5 Intercepto

El modelo CLG tiene un parámetro llamado intercepto, el cual representa el valor de la variable de respuesta cuando todos los factores predictores son iguales a 0. En el caso de la susceptibilidad a PRM, representa el valor de la probabilidad, de por lo menos, un PRM cuando todos los factores predictivos son igual a 0 o están ausentes.

Este parámetro permite una mejor interpretación de los coeficientes de los factores predictores, es decir, la relación entre la variable de respuesta con los factores predictores (Lombardo et al., 2018).




Figura 26. Regresión lineal con intercepto

En la Figura 26 podemos ver un ejemplo de la regresión lineal simple, la cual ajusta una línea recta a la mejor relación lineal entre una variable de respuesta (eje y) y una variable predictora

(eje x). Debido a que el intercepto es el valor de la variable de respuesta cuando la variable predictora es igual a ($x=0$), en este ejemplo, el valor del intercepto es aproximadamente 1. La pendiente de la línea indica la magnitud de incremento de Y cuando se incrementa una unidad de X, en otras palabras, de la relación entre ambos factores. En este caso, la pendiente es positiva, por lo tanto, mientras nuestra variable predictora (x) aumente una unidad, nuestra variable de respuesta aumenta (y), es decir, hay una relación positiva entre ambos factores.

3.1.6 Depuración de datos nulos o inconsistentes

Una etapa crucial en la modelación consiste en asegurar que las unidades de análisis del conjunto de datos tengan sus datos completos en todos sus factores, tanto de respuesta como explicativas. Algunas unidades de análisis de nuestra área de estudio no cuentan con información completa para ambos grupos de factores, a esto se le llaman datos nulos o inconsistentes. Incluir estos datos faltantes en la modelación puede generar una representación incompleta del modelo CLG, lo cual puede sesgar las estimaciones de susceptibilidad. En nuestro caso, las capas de información ráster quedan comprendidas en un rectángulo definido por las coordenadas extremas de la región SC. En el rectángulo conformado por estas coordenadas extremas, además del área de estudio donde se cuenta con información, se encuentran áreas sin información. Dentro del rectángulo se cuenta en total con 108,197 unidades de análisis de 500 m². Las unidades de análisis de la SC con datos nulos fueron 54,087 unidades. Una vez identificadas, se procedió a eliminar todas las unidades de análisis con datos nulos, resultando en un conjunto de datos final de 54,110 unidades.

3.1.7 Estructura del conjunto de datos

El resultado de todo el preprocesamiento descrito resulta en un conjunto de datos final de 54,110 unidades, con catorce factores correspondientes a cada una de ellas. Por ejemplo, la unidad de análisis con el ID **36255** (Tabla 10), la cual está ubicada en las coordenadas geográficas $x = 654696$, $y = 2065266$, la presentó 4 eventos de PRM (COUNT = 4); con una elevación de 977 msnm; con una pendiente de 27° con orientación al este (ORIENTACION = 103); con una curvatura de perfil negativa, es decir, convexa hacia arriba y una curvatura planar positiva, es decir, lateralmente convexa; con una distancia a la falla o fractura más cercana de 361 mts; a una distancia del río perenne o intermitente más cercano de 436 mts; el tipo de roca es caliza (GEO_TIPO = 5); con un uso de pastizal cultivado (USO_SUELO = 10) y una ubicación en la unidad de pendiente N.º 96886.

Tabla 9. Ejemplos de la estructura del conjunto de datos para la modelación de procesos de puntos de Cox-Log Gaussiano.

ID	X	Y	ELEVACIÓN	COUNT	PENDIENTE	CURVATURA DE PERFIL	CURVATURA PLANAR	DISTANCIA A FALLAS	DISTANCIA A RIOS Y ARROYOS	TIPO DE ROCA	ORIENTACIÓN	USO DE SUELO	UNIDAD DE PENDIENTE
4320	685196	2103266	523	0	16	1.4	-0.4	1683	147	4	338	35	452
11935	703696	2094266	1632	1	14	-0.1	0.1	8937	91	3	120	27	10385
36255	654696	2065266	977	4	27	-0.6	0.3	361	436	5	103	10	96886
79778	734696	2013766	326	6	18	0.1	0.1	4725	65	7	181	34	326830
45248	730696	2054766	1359	8	33	-1.2	0.7	7725	169	3	28	34	144951

3.2 Modelación del proceso de puntos de Cox-Log

Gaussiano (CLG)

El modelo de proceso de puntos de Cox Log-Gaussiano (CLG) se utilizó en esta investigación como una herramienta estadística poderosa en la comprensión de la distribución espacial de procesos de remoción en masa (PRM). Este modelo utiliza una combinación de técnicas estadísticas comentadas anteriormente, como el proceso de puntos de Cox y el proceso Log Gaussian, o que se amalgaman en una aproximación Bayesiana integrada por Laplace (INLA). Con esta aproximación se estiman los parámetros del modelo y se realizan las inferencias estadísticas para analizar y predecir la ocurrencia de los PRM (Rue et al., 2021).

Esta aproximación Bayesiana (INLA) es una técnica estadística que permite el análisis de modelos Bayesianos mediante la integración numérica. Esta técnica aproxima la distribución posterior de los parámetros del modelo, es decir, combina información previa que se tiene sobre los parámetros con la información que se ha obtenido a partir de los datos (McElreath, 2020). En este trabajo se usó la información de los eventos de PRM de tierra para estimar los parámetros del modelo, que incluyen la intensidad del proceso, los efectos fijos de los factores predictores, así como los efectos aleatorios en algunas de ellos, dependiendo cual sea el caso de cada uno.

Se realizó una modelación sobre la ocurrencia de PRM en la región SC. En el modelo de procesos de puntos de Cox Log-Gaussiano que se ajustó en este estudio se supone que el logaritmo de la intensidad de eventos de deslaves $\log(\lambda(s))$ es una variable aleatoria que sigue una distribución gaussiana y cuya media y estructura de covarianza son determinadas por factores predictores y efectos latentes (Lombardo et al., 2018). Es decir, se modeló la

intensidad de eventos de deslaves en función de los factores predictores como la elevación, la pendiente, etc., así como efectos aleatorios, por lo tanto, la intensidad sigue una distribución de Poisson en pequeñas regiones alrededor de cada ubicación (Lombardo et al., 2018). El modelo CLG ajustado para este estudio tiene la siguiente estructura:

$$\log\{\Lambda(s)\} = \beta_0 + \sum_{j=1}^j \beta_j z_j(s) + \sum_{k=1}^k W_{z_k}(s) \quad (4)$$

donde, $\log\{\Lambda(s)\}$ representa el logaritmo natural de la intensidad de los PRM en una unidad de análisis s . La ecuación a la derecha de la igualdad representa la parte sistemática del modelo, donde β_0 es el intercepto (Acción 3.1.4), β_j son los coeficientes de regresión asociados con los factores predictores z_j en s , y $W_{z_k}(s)$ representa la contribución a la intensidad del efecto aleatorio espacial latente del proceso gaussiano no observado.

La primera sumatoria $\sum_{j=1}^j \beta_j z_j(s)$ representa el efecto lineal de los factores predictores en la intensidad del proceso de puntos. Cada uno de los factores tiene un coeficiente de regresión β_j asociado que representa la relación entre la variable y el evento de PRM, por lo tanto, representa la contribución de esa covariable a la intensidad. La segunda sumatoria $\sum_{k=1}^k W_{z_k}(s)$ representa el efecto aleatorio espacial no observado, el cual se modela utilizando un proceso gaussiano no observado y un conjunto de factores predictores espaciales $W_{z_k}(s)$ (Lombardo et al., 2018). El vector $W_{z_k}(s)$ es un vector gaussiano multivariado que se aplica a cada unidad de pendiente específica dentro la ubicación s , a su vez, dentro del área de estudio.

En este modelo, se considera que cada evento de PRM ocurre en una unidad de pendiente específica. $W_{z_1}(s)$ se modela usando una estructura de grafos de adyacencia de s por medio del modelo autorregresivo correlacional (Sección 3.1.2), la cual es el valor de la variable aleatoria gaussiana que se le asigna a la ubicación s en función de la unidad de pendiente en la que se encuentra. Los otros efectos aleatorios $k = 2, \dots, K$ corresponden a los efectos no lineales de factores predictores como, por ejemplo, en este estudio, la “ORIENTACION” es una variable predictora cuyos rangos de variación oscilan entre 0° y 360° . Esta variable fue considerada “cíclica” porque sus valores 0° y 360° son equivalentes, los cuales representan la misma dirección y se consideró que tiene un efecto no lineal. La ORIENTACIÓN será incluida en el modelo como un efecto aleatorio, con el fin de analizar si la incorporación de la componente no lineal mejora significativamente el modelo. Sin embargo, en la Sección 3.1.1 sobre la categorización de esta variable, se dividió en 16 clases, por lo tanto, se convierte en una variable categórica ordenada cíclica, ya que las clases están ordenadas de manera natural de menor a mayor en términos de ángulo. Estas 16 clases, tienen una estructura de dependencia entre los efectos aleatorios, y son modeladas a través de un paseo aleatorio gaussiano de primer orden. Esto significa que la dependencia entre las 16 clases de orientación adyacentes se modela por medio de una distribución gaussiana. El control de esa fuerza de dependencia se realiza mediante el parámetro τ_{Asp} en el modelo, donde valores más grandes, implican una dependencia más fuerte y viceversa. Lombardo et al. (2018) sugieren un valor de 25 para τ_{Asp} , ya que representa un valor con una dependencia moderada entre las clases adyacentes, lo anterior quiere decir que las clases cercanas entre sí tienen alguna relación. Es importante tener en cuenta que la fuerza de la dependencia entre las clases adyacentes y, por lo tanto, el valor óptimo del parámetro de precisión τ_{Asp} , dependerá no solo del modelo utilizado, sino también de las características intrínsecas de los datos.

La Ecuación (4) es definida por medio de una estructura que combina aditivamente los diferentes sistemas del modelo desarrollado en R con la librería INLA. Primero, se agregó el término de intercepto, seguido de los efectos lineales, seguido de la orientación, luego los efectos aleatorios y, finalmente, se incluyó la estructura del grafo de adyacencia (Lombardo et al., 2018).

Los factores continuos como “ELEVACION”, “DIST_FALLA”, “DIST_RIO”, “CURV_PLAN”, “CURV_PERF”, y “PENDIENTE” se incluyeron al modelo como efectos lineales fijos. Los factores categóricos “USO_SUELO”, “GEO_TIPO” fueron incorporados al modelo como efectos aleatorios gaussianos independientes, de esta manera se tiene en cuenta que la relación entre estos factores categóricos y la variable de respuesta es incierta y puede variar de una muestra a otra (Lombardo et al., 2018).

La variable “U_PENDIENTE”, junto con la estructura de grafo de adyacencia, se modeló como el efecto aleatorio espacial, en otras palabras, la AE. El efecto medio de la AE para cada una de las unidades de pendiente corresponde al promedio de las unidades de pendiente vecinas, por lo tanto, existe una autocorrelación espacial y, mientras más cercanas estén 2 unidades de pendiente entre sí, mayor será la autocorrelación de sus efectos correspondientes y viceversa. La magnitud de la autocorrelación espacial ($W_{z_k}(s)$) representa la autocorrelación entre los datos de cada unidad de pendiente y su vecindario, esta variable controla la suavidad de la función de la predicción espacial. Cuanto mayor sea la magnitud, mayor es la autocorrelación entre los datos espaciales y menor la variabilidad en la predicción (Lombardo et al., 2018).

El modelado de CLG permite obtener en primer lugar una estimación del número de PRM por unidad de análisis. A partir de esta estimación, se estima la probabilidad de que cada unidad de análisis presente por lo menos un PRM mediante la ecuación:

$$1 - \exp(-\lambda(s)) \quad (5)$$

donde: λ es el número de PRM por unidad de área y s es cada unidad de análisis (Lombardo et al., 2018).

3.3 Extracción de factores significantes

Una de las maneras de analizar los resultados de la modelación es determinando los factores clave o significativos que contribuyen en la generación de un PRM. Si los cuantiles inferior y superior de un intervalo de credibilidad al 95% contienen el valor cero, los coeficientes estimados de cada uno de los factores son estadísticamente significativos. En este estudio el cuantil inferior fue de 2.5% y el superior de 97.5%. Si los signos de ambos intervalos de credibilidad coinciden con el signo del coeficiente estimado de la variable, entonces éste se considera estadísticamente significativo. La información de los intervalos de credibilidad y los valores de los factores se obtuvo a partir de los resultados de los coeficientes estimados por el modelo. Se desarrolló una función en R para estimar los factores categóricos, la cual analiza e identifica las categorías de los factores categóricos estadísticamente significativos, logrando comprender cada uno de los factores y las relaciones que tienen entre sí (Micheletti et al., 2014).

3.4 Distribución espacial de la susceptibilidad a PRM

Habiendo extraído los factores significativos, logramos comprender los elementos que influyen en la ocurrencia de RPM, sin embargo, para obtener un panorama más completo y detallado de toda la Región Sierra-Costa, es necesario estimar la distribución espacial de la susceptibilidad a RPM. La distribución espacial de la susceptibilidad a PRM representa la probabilidad de que ocurra por lo menos un PRM en diferentes áreas geográficas, basándose en los factores significantes que influyen en la ocurrencia de los eventos de PRM en un área determinada (Guzzetti et al., 1999). Habiendo obtenido los factores significativos que influyen en la ocurrencia de estos eventos es posible obtener la susceptibilidad a los PRM en función de los factores condicionantes estadísticamente significativos. De esta forma es posible identificar las áreas que son más propensas a sufrir PRM y la caracterización de los factores que contribuyen a esta susceptibilidad. La identificación de áreas propensas a PRM es clave para la planificación y la toma de decisiones en la gestión del riesgo de PRM.

3.5 Evaluación del rendimiento de la modelación del proceso de puntos de Cox-Log Gaussiano (CLG) por medio de validación cruzada.

La evaluación de rendimiento de un modelo es una tarea importante, ya que se evalúa la capacidad predictiva del modelo. En este trabajo, dicha evaluación se realizó mediante dos métodos: Dentro de las muestras y fuera de las muestras (“Within the sample” y “out of the sample”, por sus términos en inglés). El primero realiza la evaluación del modelo utilizando los datos del mismo conjunto de muestras con las que se construyó el modelo obteniendo

métricas de rendimiento, como la precisión, comparando las predicciones del modelo con los valores reales conocidos en el conjunto de entrenamiento (James et al., 2013). Mientras que el segundo método realiza la evaluación utilizando un conjunto de datos que no se utilizó para construir el modelo. Se toma un conjunto de datos independiente, que puede ser una muestra nueva o una muestra dividida del conjunto de datos original, aplicando la misma métrica de rendimiento, la precisión, pero en este caso se comparan las predicciones del modelo con los valores reales en el conjunto de datos de prueba (James et al., 2013).

3.5.1. Validación Cruzada.

El método fuera de las muestras involucra la técnica de la validación cruzada, la cual consiste en evaluar la capacidad del modelo para hacer predicciones precisas en datos nuevos y se realizó siguiendo lo sugerido por Lombardo et al. (2018). Esto se realizó dividiendo el conjunto de datos de PRM en dos subconjuntos, subconjunto de entrenamiento y subconjunto de prueba. Primeramente, se ajusta el modelo con el subconjunto de entrenamiento y la capacidad predictiva se evalúa con el subconjunto de prueba. Este proceso se repite cuatro veces y cada vez los subconjuntos son diferentes. La evaluación con un subconjunto de datos nuevo ayuda a mejorar el rendimiento del modelo con datos diferentes a los del entrenamiento, por lo tanto, evita un sobreajuste en el modelo. Un modelo está sobreajustado cuando la predicción con el conjunto de datos es casi perfecta, ya que se ajusta demasiado a los datos de entrenamiento, esto genera una varianza alta y un sesgo bajo, por lo tanto, tiene dificultades para generalizar y predecir de una manera precisa nuevos datos que no se han utilizado en el entrenamiento (Kuhn, 2021).

Dentro de las técnicas de validación cruzada existe la validación cruzada de *k-partes* (*k-fold* por sus términos en inglés). Esta técnica divide los datos en k partes iguales, entrenando el modelo con $k-1$ conjuntos y usando el conjunto restante como conjunto de prueba. Este proceso se repite k veces, con el objetivo de utilizar exactamente una vez cada uno de los conjuntos como conjunto de prueba. Finalmente, se calcula el promedio de todos los resultados de las k iteraciones, obteniendo una medida general de la precisión del modelo (Lui et al., 2021). Por ejemplo, en un conjunto de datos de 98 observaciones, el conjunto se divide en 7 subconjuntos ($k=7$), cada uno de ellos está conformado por 14 observaciones. Se realiza el entrenamiento del modelo con 6 de los 7 conjuntos y, el conjunto restante, se utiliza como conjunto de prueba. Se repite este proceso 7 veces para que todos los conjuntos puedan ser usados como conjunto de prueba. Se calcula el promedio los resultados de las 7 iteraciones y se obtiene la evaluación general de la exactitud del modelo.

En este estudio, la evaluación de la exactitud del modelo para predecir la probabilidad de ocurrencia de PRM se realizó con una validación cruzada *k-partes*. De esta manera se estimó la capacidad de generalización del modelo de proceso de puntos de Cox Log-Gaussiano para predecir la ocurrencia de, por lo menos, un PRM en áreas o con datos nuevos. Se usó una $k=4$ para esta evaluación, ya que es adecuado en la mayoría de los casos, sobre todo, considerando que nuestro conteo de puntos tiene una dimensión de $\sim 53,000$ registros, proporcionando un equilibrio entre la varianza del estimador y la cantidad de los datos utilizados para la validación.

3.5.2. Curva ROC y AUC

Los resultados obtenidos y evaluados mediante la validación cruzada se pueden presentar gráficamente y de diferentes maneras. Una de ellas es la curva ROC (Receiver Operating Characteristic, por sus siglas en inglés), la cual es una representación gráfica que muestra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos en un modelo de clasificación. La tasa de verdaderos positivos, también se le conoce como sensibilidad, ya que es la proporción de instancias positivas que se clasifican correctamente, mientras que la tasa de falsos positivos es la proporción de instancias negativas que se clasifican incorrectamente (Hanley y McNeil, 1982). En el contexto de PRM, las instancias positivas se refieren a los casos de PRM reales que han sido correctamente clasificados por el modelo como eventos de PRM. Estos casos representan las ubicaciones o áreas donde ha ocurrido un PRM de masa. Por otro lado, las instancias negativas se refieren a las ubicaciones o áreas sin PRM que han sido incorrectamente clasificadas por el modelo como áreas con PRM. Estas instancias negativas representan las áreas donde no ha ocurrido ningún PRM.

La interpretación de la curva ROC se basa en la noción de que un modelo de clasificación ideal tendría una tasa de verdaderos positivos de 1 y una tasa de falsos positivos de 0, lo que indica una clasificación perfecta sin falsos positivos ni falsos negativos. Un modelo con una mayor área bajo la curva ROC sugiere una mejor capacidad de clasificación, ya que indica una mayor capacidad para distinguir entre clases (Hanley y McNeil, 1982). El área bajo la curva (AUC – Area under the Curve por sus siglas en inglés) es una medida numérica que resume la curva ROC en un solo valor. La AUC varía entre 0 y 1, donde un valor de 1 indica un modelo de clasificación perfecto, un valor de 0.5, indica un rendimiento similar al azar. Mientras el valor de AUC sea más cercano a 1, mejor será el rendimiento del modelo en

términos de clasificación. El valor del AUC en la validación cruzada proporciona una medida de la probabilidad de que el modelo clasifique correctamente las instancias en sus respectivas categorías, positiva o negativa (Hanley y McNeil, 1982).

La AUC es un componente fundamental en la evaluación del rendimiento del modelo CLG para el análisis de factores de PRM en la región Sierra-Costa. Esta validación se realizó con dos niveles de análisis: el nivel de píxeles y el nivel de unidades de pendiente. Los píxeles representan las unidades de análisis, examinando la cantidad de PRM para cada unidad de análisis, calculando la probabilidad o intensidad de PRM para cada unidad de pendiente. El nivel de unidades de pendiente se considera un nivel de análisis más agregado en comparación con el nivel de píxeles ya que, en lugar de analizar cada píxel individualmente, las unidades de pendiente agrupan varios píxeles que comparten características similares en términos de su inclinación o pendiente. Esto proporciona información sobre los factores y patrones de PRM en una escala más amplia.

Swets (1988) estableció una clasificación de la capacidad predictiva de los modelos usando umbrales del AUC. Mientras que un $AUC < 0.5$ sugiere que los modelos utilizados no tienen poder predictivo, un valor de AUC entre 0.7 y 0.9 indica una capacidad predictiva razonable y los valores superiores a 0.9 indican modelos de clasificación muy precisos. La medida de AUC utilizada en este estudio está respaldada por la teoría presentada por Swets (1988), quien propone que el AUC es una medida adecuada y univaluada de precisión para sistemas de diagnóstico.

Capítulo 4. Resultados

A lo largo de este trabajo se obtuvieron varios resultados de significancia de los factores predictivos del modelo, en esta sección se muestran los resultados que evidencian con claridad la significancia estadística de los factores predictores y la importancia del uso del modelo de proceso de puntos Cox-Log Gaussiano.

Durante el desarrollo de este trabajo, se invirtió un total de 480 horas en la programación del modelo, teniendo en cuenta las horas dedicadas exclusivamente al trabajo de este estudio. Esta estimación abarca no solo el tiempo necesario para diseñar, implementar y depurar el código del modelo, sino también el desarrollo de mapas y gráficas en R y ArcGIS, asegurando su funcionalidad óptima. Asimismo, es importante destacar que se ha realizado un seguimiento riguroso para garantizar la exactitud y eficiencia del proceso de programación.

Después de un riguroso análisis de sintaxis en el código, los cálculos del modelo tomaron un tiempo de 4 horas, donde se usó 1 hora en la preparación del modelado, preparando factores y definiendo la estructura del modelo. La ejecución del modelo tomó 2 horas 40 minutos, donde se entrenó al modelo, se realizaron predicciones o inferencias, y se extrajeron los resultados del modelo. La etapa posterior al modelado donde los resultados del modelo fueron procesados tomó 20 minutos.

4.1 Análisis de factores significativos

El análisis de los factores significativos que contribuyen a la ocurrencia de los PRM se realizó a través del análisis de los efectos fijos y aleatorios, así como la evaluación de los parámetros

del modelo, proporcionando un resultado detallado de los factores predictores que influyen en la ocurrencia de PRM en la región SC.

Tabla 10. Efectos fijos después de la modelación del proceso de puntos Cox-Log Gaussiano.

Factores predictores	Media	Desviación estándar	95% IC	Amplitud	KLD	Significante
Elevación	0.246	0.052	[0.144, 0.347]	0.203	1.907e-07	Sí
Distancia a fallas y fracturas	-0.135	0.047	[-0.227, -0.044]	0.183	3.354e-07	Sí
Distancia a ríos y arroyos	0.193	0.037	[0.119, 0.263]	0.144	7.009e-07	Sí
Curvatura planar	-0.041	0.033	[-0.106, 0.024]	0.130	4.379e-09	No
Curvatura de perfil	-0.109	0.033	[-0.174, -0.045]	0.129	6.771e-07	Sí
Pendiente	0.431	0.034	[0.364, 0.498]	0.134	3.352e-07	Sí

Los resultados obtenidos indican que varios factores tienen valores significativos como efectos fijos en el modelo. Estos factores incluyen la elevación, la distancia a las fallas y fracturas, la distancia a los ríos y arroyos, la curvatura de perfil y la pendiente. Estos resultados se presentan en la Tabla 10 que consta de 7 columnas. La primera columna son los nombres de los factores mientras que, la segunda, muestra los valores promedio estimados del coeficiente de los factores, para factor predictor en unidades de desviación estándar. La tercera columna representa el valor de la desviación estándar del coeficiente estimado, la cual indica la variabilidad o incertidumbre asociada con la estimación del efecto de cada variable.

La cuarta columna es el intervalo de credibilidad al 95%, es decir, representa el rango de posibles valores estimados del coeficiente con un nivel de credibilidad del 95% (cuantiles 0.0025 y 0.975). El cuantil 0.025 representa el límite inferior del intervalo de credibilidad al 95% para el coeficiente de cada variable, mientras que el cuantil 0.975 representa el límite superior del intervalo de credibilidad al 95% para el coeficiente, es decir, es el valor estimado del coeficiente por encima del cual se espera que caiga el verdadero valor del coeficiente con una probabilidad del 2.5%. Cuanto más estrecho sea el intervalo de credibilidad, más precisa será la estimación del coeficiente (Cumming, 2014). La quinta columna representa la amplitud del intervalo. La sexta columna de la Tabla 10 representa la divergencia de Kullback-Leibler (KLD). Esta métrica mide la diferencia entre dos distribuciones de probabilidad diferentes. Si la diferencia entre ambas distribuciones es cercana a 0, quiere decir que son distribuciones similares, por otro lado, si la diferencia es 0, quiere decir que son iguales (Popescu, 2016). Como se puede observar en la Tabla 10, el valor de la KLD en todos los factores predictores es muy cercana a 0, por lo tanto, el modelo es capaz de capturar adecuadamente las características de la distribución de probabilidad de los datos observados. Esto es fundamental, ya que el modelo es útil para realizar la predicción de nuevos PRM y para identificar los factores significantes que condicionan los PRM.

Un punto importante es el signo de la media del coeficiente de la variable predictora. Si el valor en la significancia es positivo impacta positivamente a los eventos de PRM y viceversa. Coeficientes mayores indican un efecto relativo mayor en comparación de coeficientes pequeños. La elevación, la distancia a ríos y arroyos, y la pendiente tuvieron un efecto positivo en la ocurrencia de eventos de PRM mientras que, la distancia a fallas y fracturas y

la curvatura de perfil, tuvieron un efecto negativo. Los primeros efectos incrementan la susceptibilidad y el número de PRM; los segundos, la reducen.




Figura 27. Valor medio del coeficiente de la distancia de un evento de PRM al río próximo.

La distancia de un evento de PRM al río más cercano tiene un efecto positivo estadísticamente significativo a partir de los 25 metros de distancia. Este resultado es muy cercano a la realidad, ya que el número de eventos de PRM decrece entre 0 a 25 m, pero incrementa considerablemente con distancias mayores a 25 m (Figura 27).

La magnitud de los coeficientes indica que la pendiente tuvo el mayor efecto positivo, dado que la región SC es un área donde existen más pendientes entre 20° a 30° que planicies y las pendientes alcanzan los 72° . Los PRM son eventos influenciados por la gravedad, así que, a medida que la pendiente del terreno aumenta, la gravedad tiene una mayor influencia en la dirección hacia abajo. Además, las pendientes pronunciadas pueden causar una mayor erosión del suelo, lo cual debilita la estabilidad del terreno y aumenta la probabilidad de

ocurrencia de un PRM. La elevación y distancia a ríos y arroyos también tienen efecto positivo, mientras que el mayor efecto negativo fue la distancia a fallas y fracturas, seguido de la curvatura de perfil.

Los factores predictores como el tipo de uso de suelo, el tipo de roca y la orientación fueron modelados como efectos aleatorios. La significancia con los efectos aleatorios se maneja de la misma manera que con los efectos fijos, si el intervalo de credibilidad es del mismo signo y la media del coeficiente de la variable está dentro del intervalo, el efecto es estadísticamente significativo, lo cual también puede ser representado gráficamente. La orientación de la pendiente en dirección de 200° a 220° (Suroeste) y 240° a 280° (Oeste) son orientaciones estadísticamente significativas para la ocurrencia de PRM (Figura 28). Por otro lado, la orientación de la pendiente en dirección de 0° a 40° (Noreste) y de 320° a 360° (Noroeste) impactan negativamente al desencadenamiento de PRM.




Figura 28. Significancia de las clases de la variable predictora: orientación. La línea punteada representa una significancia nula. El área sombreada en color rojo representa las clases de la orientación cuyos efectos positivos son estadísticamente significativos. El área sombreada en color negro representa las clases de la orientación cuyos efectos negativos son estadísticamente significativos.

No todas las clases del tipo de roca suelen ser significantes para los PRM, así que se realizó el análisis de significancia por clases del tipo de roca. De las 23 clases de tipo de roca que se tienen, la caliza y lutita-arenisca impacta positivamente a la ocurrencia de PRM, mientras que el tipo de roca andesita y complejo metamórfico impactan negativamente (Figura 29). El tipo de roca puede ser un factor significativo para la ocurrencia de PRM, ya que la estructura y composición de la roca pueden afectar su resistencia a la deformación y a la erosión.




Figura 29. Significancia de las clases de la variable predictora: tipo de roca. La línea punteada representa una significancia nula. Si el intervalo de alguna categoría está por encima del valor 0, implica una significancia estadísticamente positiva; por el contrario, si está por debajo de 0, implica una significancia negativa. “No aplica” significa que en estas áreas no existe información.




Figura 30. Significancia de las clases de la variable predictora: uso de suelo. La línea punteada representa una significancia nula. Si el intervalo de alguna categoría está por encima del valor 0, implica una significancia positiva; si está por debajo, implica una significancia negativa.

De las 39 clases que se usaron para la modelación del tipo de uso de suelo, la vegetación secundaria arbustiva de bosque encino-pino y la vegetación secundaria arbustiva de selva baja caducifolia son las únicas clases que tienen un efecto positivo, y el bosque de pino, un efecto negativo (Figura 29). Esto puede ser por diferentes causas, ya que depende de varias características intrínsecas de la región SC, como la estabilidad del suelo o la capacidad de retención de agua. El tipo de uso de suelo es una variable relevante para el análisis de la susceptibilidad de los PRM ya que, la forma en la que se utiliza el suelo, puede influir en la permeabilidad, estabilidad y capacidad de retención de agua en el suelo, lo cual afecta a la susceptibilidad de la región SC. La relación entre los factores de un modelo se puede analizar mediante varias herramientas, la más popular de ellas es la matriz de correlación.




Figura 31: Matriz de correlación de los factores predictores del modelo del proceso de puntos de Cox-Log Gaussiano. Mientras más rojo sea el valor, implica mayor correlación. Mientras más azul sea el valor, implica una correlación negativa mayor.

En la Figura 31 se puede observar la aplicación de la matriz de correlación de los factores predictores del modelo del proceso de puntos de CLG, de la cual resulta evidente cómo están relacionados dichos factores. Se puede notar que la elevación y la pendiente son los dos factores que tienen una correlación más alta, indicando que, al aumentar la elevación, también aumenta la pendiente.

Esta matriz no solo nos proporciona una visión integral de las relaciones y dependencias entre los factores que influyen en los procesos de remoción en masa, sino que también sirve como

punto de partida para nuestro análisis. Al incorporar el Efecto espacial latente en este marco, añadimos una dimensión esencial a nuestra comprensión. Al unir estas dos perspectivas, la matriz de correlación de factores y el Efecto espacial latente, creamos un enfoque completo y robusto para evaluar la susceptibilidad a PRM, revelando no solo las conexiones entre factores sino también las influencias espaciales subyacentes en la región de estudio.

4.1.1 Efecto espacial latente

La autocorrelación espacial de los PRM de la región SC resultó estadísticamente significativa. Se calculó el coeficiente del hiperparámetro de las unidades de pendiente, el cual representa la variable τ_{CAR} y se obtuvo un valor medio de 0.16, con un intervalo de credibilidad del 95% de [0.144, 0.17]. Estos valores indican que los datos de PRM presentan una autocorrelación espacial y, debido a que el intervalo de credibilidad no incluye el valor cero, la autocorrelación espacial es estadísticamente significativa.

En total 1,893 unidades de pendiente, de 406,067 en total, fueron estadísticamente significativas, es decir, el 0.46% del total de unidades de pendiente de la SC, por lo tanto, es posible inferir una relación espacial entre las unidades de pendiente y la ocurrencia de eventos de PRM. La mayor magnitud de la autocorrelación espacial en las unidades de pendiente fue de 6.7, esto indica que el conteo de eventos de PRM en estas unidades de pendiente vecinas está fuertemente correlacionado y coincide con la unidad donde se presenta un mayor número de PRM, capturando patrones complejos de agregación. Las agrupaciones de unidades de pendiente autocorrelacionadas sugieren una posible influencia de factores locales en la aparición de los PRM. Además, se identificaron las unidades de pendiente con baja o nula autocorrelación, lo que indica áreas donde los PRM son menos comunes. Es

importante destacar que los municipios del sur de Coahuila, norte de Aguila, sureste de Chihuahua y Sur de Durango presentan altos valores de autocorrelación y una mayor probabilidad de experimentar PRM (Figura 32).

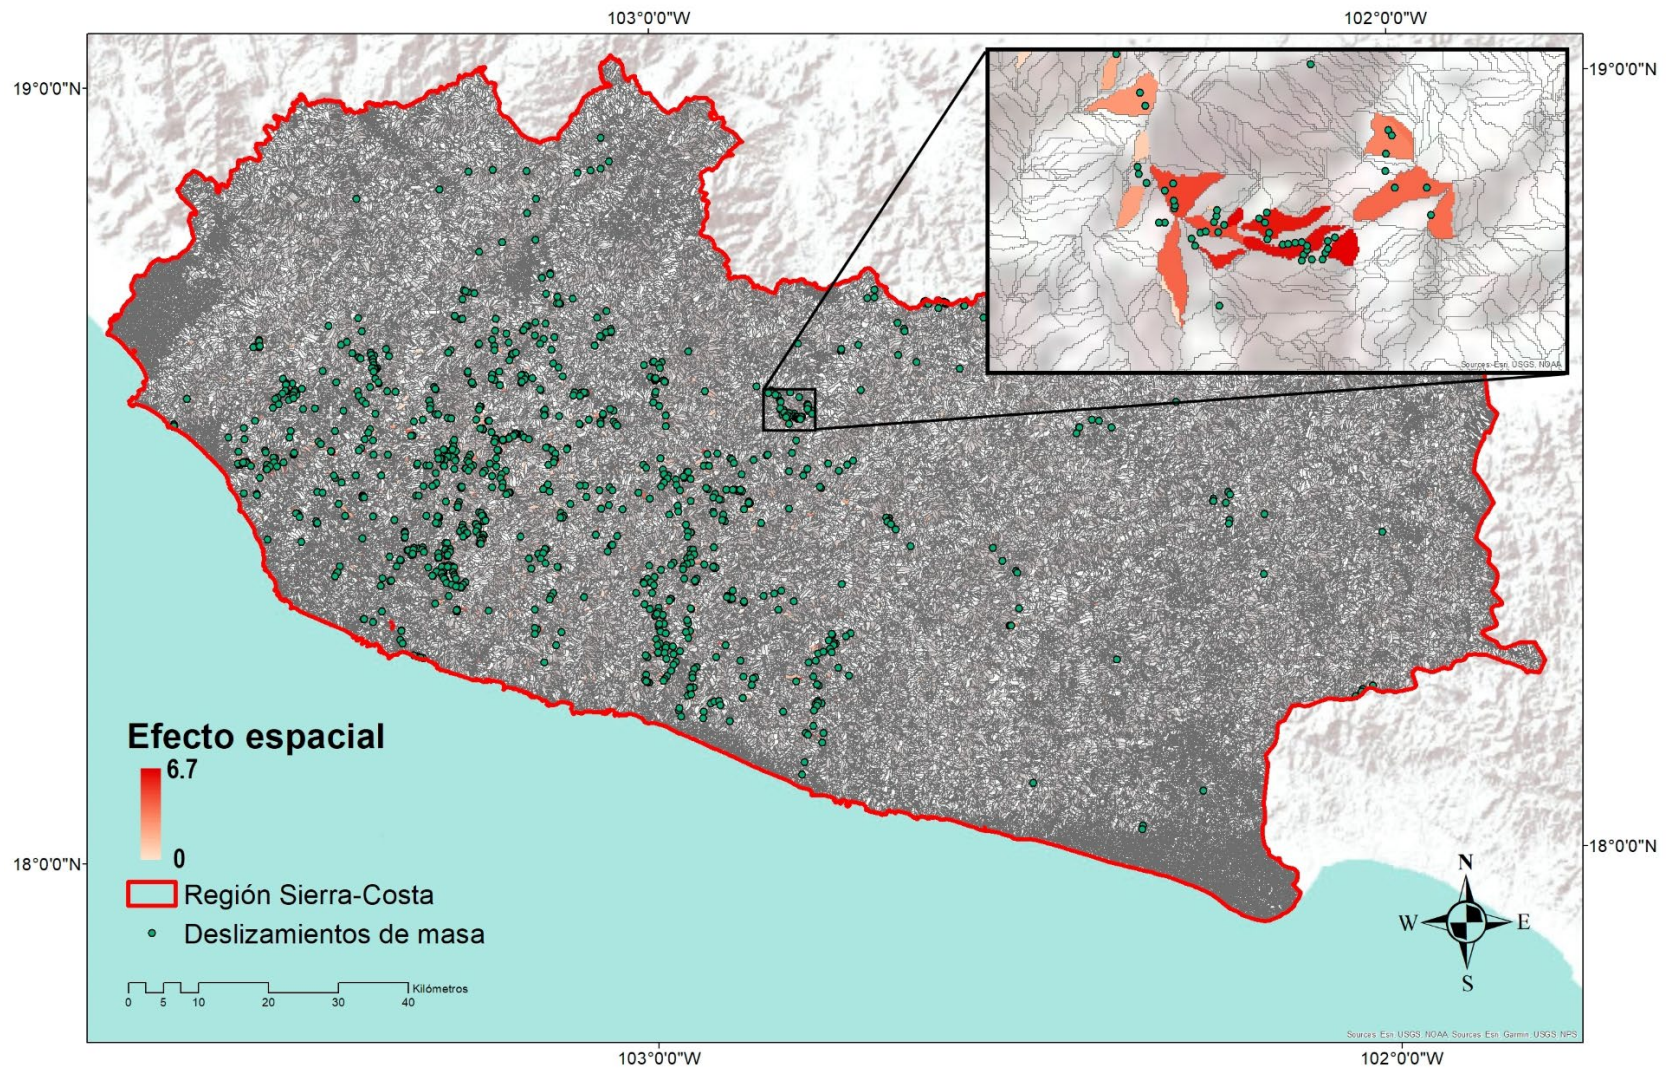


Figura 32: Magnitud del efecto espacial latente de las unidades de pendiente que fueron estadísticamente significativas en la región SC. Proyección UTM, Datum WGS 1984.

4.1.2 Distribución espacial de susceptibilidad a PRM en la región Sierra-Costa

En este trabajo, la susceptibilidad a PRM en la región SC se estudió utilizando un enfoque basado en el modelo del proceso de puntos de Cox-Log Gaussiano, permitiendo analizar y comprender los factores relacionados con los PRM en la región. Como resultado, se generó un mapa de distribución espacial de susceptibilidad a PRM, el cual proporciona información valiosa sobre las áreas de mayor susceptibilidad.

El mapa se creó dividiendo el área de estudio en las unidades de análisis de entrada del modelo (Sección 3.2), lo que resultó en un total de 54,093 unidades de análisis. Cada pixel en el mapa representa una de estas unidades de análisis y se asigna una intensidad de PRM correspondiente. En la Figura 33, se observa que la intensidad de 189 unidades de análisis es mayor a 1, lo que indica que estas áreas presentan una mayor probabilidad de experimentar PRM, revelando patrones espaciales de susceptibilidad en la región SC. Particularmente, al sur Coalcomán, norte de Aquila, sureste de Chinicuila y sur de Aguililla.

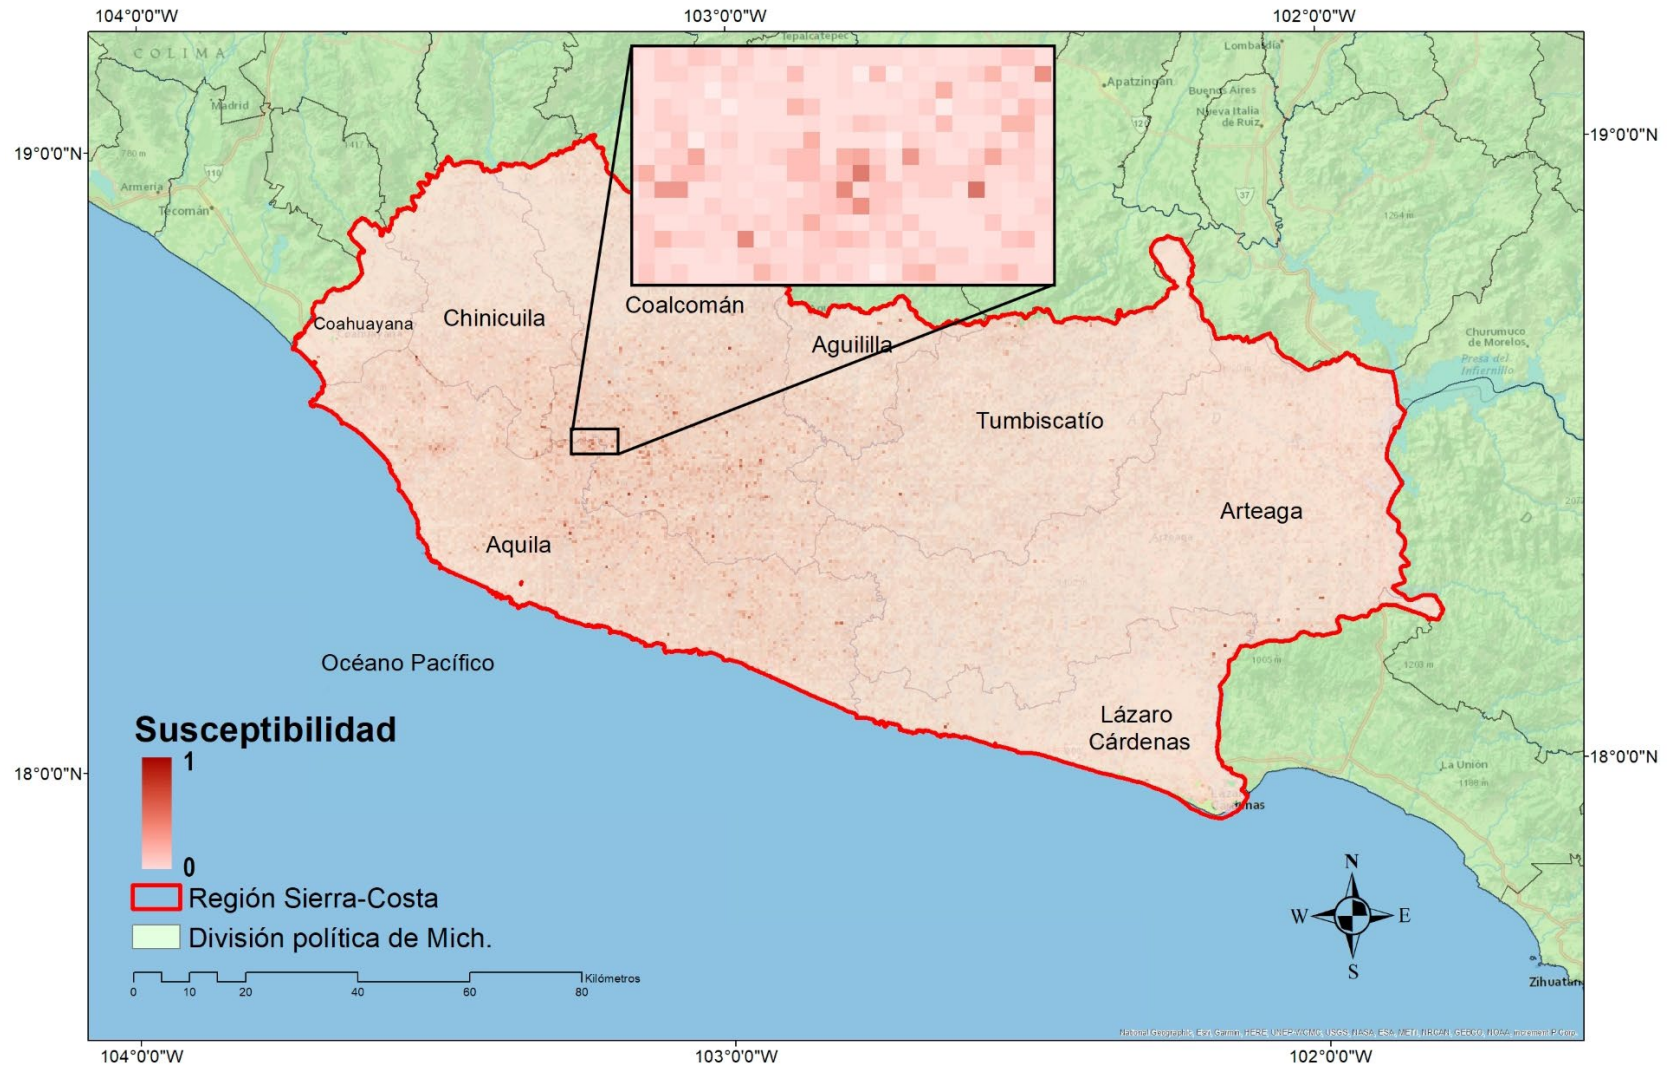


Figura 33: Distribución espacial de susceptibilidad a PRM en la Región SC. Proyección UTM, Datum WGS 1984.

4.1.3 Validación del rendimiento del modelo de proceso de puntos de Cox-Log Gaussiano en la región Sierra-Costa

El rendimiento del modelo del proceso de puntos de Cox-Log Gaussiano es óptimo en las métricas utilizadas del estudio. Se utilizó de la medida de rendimiento AUC, la cual se basa en la curva ROC, que representa la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos para modelos de clasificación. Entre mayor sea el AUC mejor será el rendimiento del modelo. En el contexto de este estudio, un valor de AUC cercano a 1 indica que el modelo tiene una alta capacidad para distinguir entre los píxeles / unidades de pendiente con, por lo menos, un PRM y aquellos sin PRM.

Después de realizar la evaluación del rendimiento del modelo utilizado en esta tesis, se calcularon los valores de AUC. En particular, se obtuvo un AUC de 0.98 para la evaluación del píxel sin validación cruzada, lo cual indica una alta capacidad del modelo para distinguir entre píxeles sin y con por lo menos un PRM. En cuanto a la evaluación con validación cruzada, se obtuvo un AUC de 0.73 para la evaluación del píxel, lo cual aún muestra una capacidad predictiva razonable (Figura 34; Swets, 1988).




Figura 34: Curva ROC del nivel de análisis del pixel. La línea azul claro representa la validación del modelo, mientras que la línea negra representa el modelo con validación cruzada.

Además, se calcularon los valores de AUC para la evaluación de unidades de pendiente. Sin validación cruzada, se obtuvo un AUC de 0.984, mientras que con validación cruzada se obtuvo un AUC de 0.742 (Figura 35). Estos resultados revelan que, después de corregir la AUC por sobreajuste, el modelo tiene una capacidad predictiva razonable en la identificación de unidades de pendiente con por lo menos un PRM, esto considerando la clasificación propuesta por (Swets, 1988).

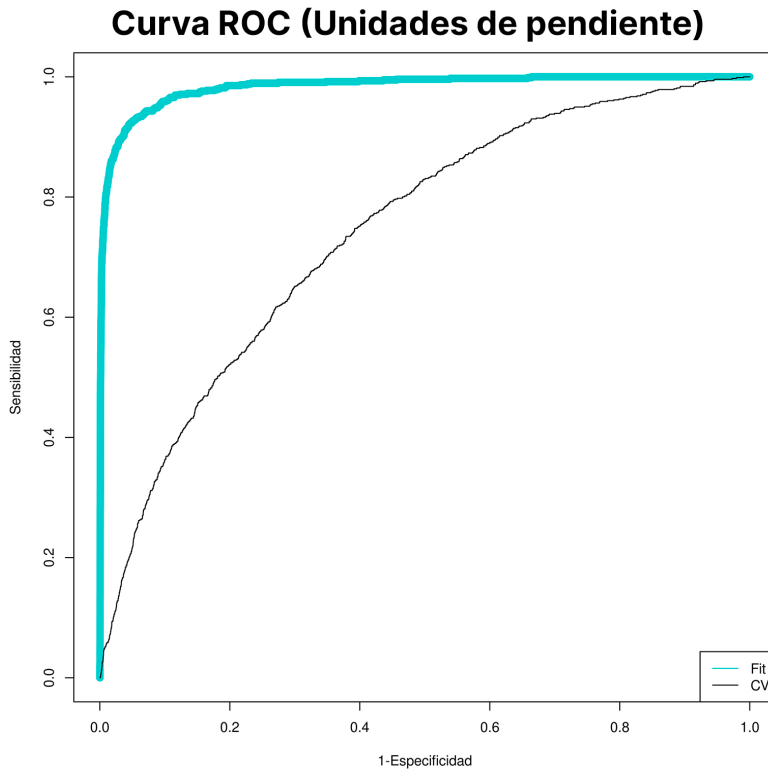


Figura 35: Curva ROC del nivel de análisis de las unidades de pendiente. La línea azul claro representa la validación del modelo, mientras que la línea negra representa el modelo con validación cruzada.

Capítulo 5. Discusión

En este estudio se logró desarrollar un modelo para estimar la intensidad de los PRM en la región de la Sierra-Costa, el cual involucra no sólo factores biofísicos condicionantes, sino que además contempla la autocorrelación espacial presente en los datos de PRM. Mediante este modelo, se identificaron y cuantificaron de manera efectiva los factores que estadísticamente influyen en la ocurrencia de PRM, tanto positiva como negativamente. Esto fue posible mediante el análisis de una amplia gama de factores, incluyendo el tipo de roca y suelos, características morfométricas y red de drenaje. El proceso de modelado usó un enfoque basado en un modelo del proceso de puntos de Cox-Log Gaussiano, el cual ofrece estimaciones confiables que pueden ser utilizadas para, entre otras cosas, una planificación urbana más informada, el manejo de tierras y la mitigación de desastres, permitiendo la identificación de áreas de mayor vulnerabilidad y la focalización de esfuerzos de prevención y mitigación.

Estudios anteriores han identificado factores como la pendiente, la distancia a fallas y la litología como factores relevantes en la susceptibilidad a los PRM en la región SC (de la Peña et al., 2022); sin embargo, no han establecido relaciones estadísticamente significativas entre sus factores utilizando modelos predictivos. Los autores realizaron una investigación similar a la que se elaboró en esta tesis, ya que fue con el mismo inventario de eventos de PRM en la región SC, pero usando un esquema de modelado heurístico combinado con métodos estadísticos que permitieron calcular la importancia relativa de los factores. El modelo heurístico está basado en el proceso analítico de jerarquías, el cual es una técnica de toma de decisiones basada en la descomposición jerárquica y en la comparación de alternativas en

función de múltiples criterios. Estos criterios incluyen los factores como la litología, distancia a fallas, pendiente del terreno, orientación de pendientes, geoformas, tipo de suelo, distancia a ríos y arroyos, y cobertura del suelo. De la Peña et al. (2022) observaron que los factores con mayor efecto en la SC son la pendiente, la distancia a fallas y la litología. Factores como la orientación y la distancia a fallas son importantes para identificar áreas susceptibles a PRM. En esta tesis, además de saber cuál es la magnitud del efecto, fue posible conocer si contribuía a la ocurrencia o si reducían la ocurrencia de PRM, logrando también el cálculo de la magnitud del efecto de las clases de los factores categóricos.

En la literatura científica se han llevado a cabo varias investigaciones que han evaluado el efecto de los factores identificados en este estudio y que fueron estadísticamente significativos. Por ejemplo, Lombardo et al. (2018) encontraron que la pendiente, la orientación, la litología, el tipo de roca, la cobertura vegetal, la distancia a los ríos y arroyos, la actividad sísmica, y el uso de suelo fueron estadísticamente significativas en el modelo desarrollado en su investigación. Los autores sugieren que estos factores podrían usarse para desarrollar estrategias de evaluación y mitigación del riesgo de PRM en otras áreas. Más aún, indican que, al considerar distancia a los ríos y arroyos, cuanto menor es la distancia a un río mayor es la susceptibilidad a un RPM y viceversa. El patrón identificado en la SC es semejante, lo que sugiere la existencia de una implicación en la cercanía a ríos y arroyos, y el número de PRM, también reportada en estudios en la región SC por De la Peña et al. (2022).

Otros estudios previos (Guzzetti et al., 2012, Ramos-Scharrón et al., 2020) que evalúan las técnicas disponibles para evaluar el peligro y susceptibilidad de un PRM, destacaron la importancia de la orientación de la pendiente en el desencadenamiento de PRM. En este

estudio también se confirmó su significancia, pero se observó que esta influencia varía dependiendo de la orientación de la pendiente. Se encontró que la pendiente fue la variable con el efecto positivo más fuerte entre los factores de valores continuos, coincidiendo con lo reportado por Lombardo et al. (2018), quienes usaron un enfoque semejante al de la presente investigación. Decir lo anterior sugiere que cuanto mayor es la pendiente de un sitio, mayor es la susceptibilidad a PRM.

Por otra parte, Lombardo et al. (2018) identificaron que el factor de elevación tenía un efecto negativo en la susceptibilidad a PRM. Sin embargo, en el presente estudio se obtuvieron resultados contradictorios, ya que se observó que la elevación tuvo el segundo mayor efecto positivo en la ocurrencia de PRM. Estos resultados pueden atribuirse a las características específicas de la región SC y a las particularidades del modelo utilizado. Es posible que en la SC la elevación desempeñe un papel distinto en la susceptibilidad a PRM debido a la interacción con otros factores, como los geológicos, hidrológicos o topográficos.

Lombardo et al. (2020) también destacaron la influencia de los factores en la susceptibilidad a PRM y argumentaron que comprender y considerar estos factores es crucial para la toma de decisiones para la mitigación del riesgo en áreas propensas a PRM. Sus hallazgos revelaron una relación negativa entre la curvatura de perfil y la probabilidad de PRM, indicando que las áreas con pendientes de baja curvatura son menos propensas a experimentar PRM. Sus resultados son coincidentes con los del presente estudio, el coeficiente de la curvatura de perfil tiene una media de -0.109, lo cual significa un efecto negativo para la ocurrencia de PRM, respaldando aún más la importancia de la curvatura de perfil como un factor significativo en la evaluación de la susceptibilidad a PRM.

Es importante destacar que el modelo usado en esta tesis puede ser utilizado como herramienta para la toma de decisiones en la prevención y mitigación de PRM en zonas vulnerables, como en el sur Coalcomán, norte de Aquila, sureste de Chinicuila y sur de Aguililla. Además, los resultados obtenidos pueden ser de gran utilidad para los organismos encargados de la planificación territorial y la gestión del riesgo en áreas propensas a PRM.

La susceptibilidad a PRM en una región determinada se puede calcular empleando distintos modelos. Micheletti et al. (2014) menciona tres modelos comúnmente usados, el modelo de Máquinas de Vectores de Soporte Adaptativas (MVSA), el modelo de Bosques Aleatorios, y el modelo AdaBoost. Estos modelos se han destacado por obtener resultados precisos en su rendimiento, el cual oscilan entre 0.83 y 0.92 de AUC. Además, algunos de los modelos pueden manejar grandes conjuntos de datos con buena eficiencia a la hora de la modelación, como lo hace el modelo MVSA (Tien Bui, et al., 2012). Pueden tener una precisión significativa en la clasificación, o un buen manejo de datos nulos o datos con ruido en el modelo, como lo hace el modelo de bosques aleatorios (Kim, et al., 2018). Adicionalmente, AdaBoost se distingue por la precisión del modelo combinando varios modelos más simples en uno más complejo (Wu, et al., 2020). Con este estudio pudimos confirmar que el modelo del proceso de puntos de Cox-Log Gaussiano es especialmente adecuado para este tipo de fenómenos, ya que es posible no sólo modelar la intensidad sino, además, la probabilidad de ocurrencia de por lo menos un PRM.

Santiago (2020) realizó una comparación de modelos estadísticos para la evaluación de la susceptibilidad a PRM en la subcuenca del río Tuxpan, Michoacán. En la cual hizo uso del modelo de regresión logística, de razón de verosimilitud, y de pesos de evidencia. En el modelo de regresión logística desechó los factores de elevación y la distancia a las vías de

comunicación ya que no fueron significativos para la ocurrencia de PRM, quedándose con factores como la litología, la pendiente, la orientación, el tipo de suelo y cubierta y el tipo de uso de suelo como significativos para la ocurrencia de PRM, con un rendimiento del modelo de 0.85 de AUC. Además, en los modelos de razón de verosimilitud y de pesos de evidencia se observó la significancia solo de factores como la pendiente, la orientación y el tipo de suelo, arrojando un rendimiento en el modelo de razón de verosimilitud de 0.83 y en el modelo de pesos de evidencia de 0.82, ambos con respecto al AUC. En comparación con los valores AUC de este estudio, se observa un mayor rendimiento en el modelo del proceso de puntos de Cox-Log Gaussiano implementado; sin embargo, se tuvo en cuenta el riesgo de sobreajuste. La aplicación de la validación cruzada permite evaluar el rendimiento del modelo en datos no utilizados durante el entrenamiento, lo que ayuda a garantizar una mayor generalización y confiabilidad de estos.

Se deben puntualizar las limitaciones de este estudio, ya que pueden facilitar la toma de decisiones en caso de hacer uso de este modelo. En la modelación realizada no se incluyó la variable del tiempo, la cual, Lombardo et al. (2020) mencionan que es fundamental para capturar la dinámica espacio-temporal de la ocurrencia de PRM en una región. Ellos presentaron un modelo semejante al que se usó en este estudio para predecir la ocurrencia de PRM, logrando concluir un modelo capaz de predecir la ocurrencia de PRM no sólo con un alto grado de precisión, sino también haciendo uso de la variable del tiempo. Al incorporar el tiempo en su modelo, los autores tomaron en cuenta el hecho de que la ocurrencia de PRM no es un proceso estático, sino un proceso dinámico que puede ser influenciado por una variedad de factores incluyendo la lluvia, la actividad sísmica y los cambios en el uso del suelo.

Capítulo 6. Conclusiones

Con este estudio se comprendió con una mayor profundidad sobre los eventos de PRM y su comportamiento en la región Sierra-Costa, logrando detectar y cuantificar los patrones espaciales de los eventos de PRM.

La modelación de eventos de PRM por medio del modelo del proceso de puntos de Cox-Log Gaussiano contribuyó al conocimiento de la importancia de varios factores topográficos y ambientales en la predicción de PRM a nivel regional (Región Sierra-Costa). Se identificaron 8 factores estadísticamente significativos que promueven el aumento y disminución de la susceptibilidad a PRM. Los factores positivos fueron: la pendiente, la elevación, la orientación, el tipo de roca y el tipo de uso de suelo; mientras que los negativos fueron: la distancia a fallas y fracturas, la curvatura de perfil y la distancia a ríos y arroyos.

El análisis de los factores predictores en este tipo de estudios es fundamental para determinar la significancia de cada variable en la ocurrencia de los PRM. La identificación de patrones y/o correlaciones entre los factores puede proporcionar información valiosa, ya que las características de una variable predictora pueden depender de otra variable predictora.

Con los resultados del modelo, se encontró un efecto positivo, con respecto a la influencia de ocurrencia de PRM, entre la elevación y la probabilidad de PRM. Las zonas de mayor elevación mostraron una mayor susceptibilidad a PRM, lo cual puede estar relacionado con la presencia de superficies inestables que tiene la región SC. Estos resultados permiten apoyar la hipótesis planteada inicialmente, la cual sugirió que los factores como la orientación, la curvatura, la pendiente y el tipo de roca son factores estadísticamente significativos para la susceptibilidad a PRM de masa en la región SC. Los resultados obtenidos muestran un efecto

positivo en los factores como la pendiente, la orientación y el tipo de roca. Sin embargo, también se muestra un efecto positivo para la elevación de la superficie y el tipo de uso de suelo. En el caso de la curvatura, se muestra un efecto negativo solo con la curvatura de perfil, por lo tanto, entre mayor sea la curvatura de perfil, la susceptibilidad será menor.

La pendiente del terreno es el factor estadísticamente significativo con mayor efecto en la ocurrencia de PRM, con valores más pronunciados de pendiente asociados a una mayor probabilidad de PRM. Sin embargo, la inclusión de la variable de orientación de la pendiente brinda una mayor comprensión de la relación entre la topografía y los PRM. El modelo utilizado reveló que, en algunas orientaciones de la pendiente, como las orientaciones hacia el sureste y oeste, están más relacionadas con la ocurrencia de PRM. Esto sugiere que áreas con mayor pendiente y con dirección sureste y oeste presentan mayor riesgo de PRM en comparación con pendientes más suaves, influyendo en la estabilidad del terreno y la predisposición a los PRM en diferentes áreas de la región.

Se puede concluir que, existe evidencia de que la susceptibilidad a PRM de masa en la región SC tiene que ver con los factores relacionadas con la forma de relieve, y se sugiere la necesidad de seguir investigando para comprender mejor el impacto de dichos factores para la planificación y gestión de riesgos en la Región SC.

En este estudio no solo se comprendió lo que es un análisis de datos espaciales por medio de un modelo del proceso de puntos, sino que se tuvo la oportunidad de una aplicación real. Los resultados obtenidos por el modelo desarrollado en esta tesis son comparables en calidad a los reportados por modelos propuestos en la literatura de la misma temática.

Referencias

Alcántara Ayala, I, y Murillo García, F. (2008). Procesos de remoción en masa en México: hacia una propuesta de elaboración de un inventario nacional. *Investigaciones geográficas*, 66, 47-64. DOI: [10.14350/rig.17981](https://doi.org/10.14350/rig.17981)

Alvioli, M., Marchesini, I., Reichenbach, P., Rossi, M., Ardizzone, F., Fiorucci, F., y Guzzetti, F. (2016). Automatic delineation of geomorphological slope units with R. *slopeunits* v1. 0 and their optimization for landslide susceptibility modeling. *Geoscientific Model Development*, 9(11), 3975-3991. <https://doi.org/10.5194/gmd-9-3975-2016>

ArcGIS. (2010). Version 10.4.1. Redlands, CA: Environmental Systems Research Institute, Inc.

Baddeley, A., E. Rubak, y R. Turner. (2015). *Spatial Point Patterns: Methodology and Applications with R*. Boca Raton, Florida: Chapman & Hall/CRC. DOI: [10.1201/b19708](https://doi.org/10.1201/b19708)

Baeza, C., y Corominas, J. (2001). Assessment of shallow landslide susceptibility by means of multivariate statistical techniques. *Earth Surface Processes and Landforms*, 26(12), 1251–1263. <https://doi.org/10.1002/esp.263>

Besag, J. (1975). Statistical analysis of non-lattice data. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 24(3), 179-195. <https://doi.org/10.2307/2987782>

Bivand, R. S., Pebesma, E. J., y Gómez-Rubio, V. (2013). *Applied spatial data analysis with R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4614-7618-4>

Blangiardo, M., Cameletti, M., Baio, G. y Rue, H. (2013) Spatial and spatio-temporal models with R-INLA, *Spatial and Spatio-temporal Epidemiology*, 4, 33-39. <https://doi.org/10.1016/j.sste.2012.12.001>.

Cama, M., Lombardo, L., Conoscenti, C., Agnesi, V., y Rotigliano, E. (2015). Predicting storm-triggered debris flow events: application to the 2009 Ionian Peloritan disaster (Sicily, Italy). *Natural Hazards and Earth System Sciences*, 15(8), 1785-1806. <https://doi.org/10.5194/nhess-15-1785-2015>

Consejo Estatal de Armonización Contable del Estado de Michoacán de Ocampo (COEAC). (2023). Estructura por Regiones. Recuperado el 23 de febrero del 2023 de <http://sfa.michoacan.gob.mx/coeac/regiones.php>

Cruden, D. y Varnes, D., (1996) Landslide types and processes. Landslides-investigation and mitigation. National Academy of Sciences, 247, 36-75.

Cumming, G. (2014). The new statistics: Why and how. Psychological science, 25(1), 7-29. <https://doi.org/10.1177/0956797613504966>

Dai, F. C., Lee, C. F., Li, J. X., y Xu, Z. W. (2001). Assessment of landslide susceptibility on the natural terrain of Lantau Island, Hong Kong. Environmental Geology, 40(3), 381–391. <https://doi.org/10.1007/s002540000163>

De La Peña Guillen, K., Mendoza, M., Macías, J. y Solis-Castillo, B. (2021): Landslide susceptibility analysis based on a semiquantitative method in the sierra-costa region, michoacan, México, Physical Geography. <https://doi.org/10.1080/02723646.2021.1899476>

Diggle, P.J. (2014) Statistical Analysis of Spatial and Spatio-Temporal Point Patterns. 3rd. ed. CRC Press, Boca Raton, Florida. <https://doi.org/10.1201/b15326>

Esquivel, R. C., y Muñoz, M. E.. (2017). Principales efectos causados por el sismo del 20 de marzo de 2012 en la costa de los estados de Guerrero y Oaxaca, México. Servicio Geológico Mexicano.

Florián Noriega, J. A. (2013). Categorización de texto usando técnicas de Machine Learning aplicado a la clasificación de reclamos en los procesos de la Universidad Tecnológica de Bolívar. Programa de Ingeniería de Sistemas.

Foumelis, M., Lekkas, E., y Parcharidis, I. (2004). Landslide susceptibility mapping by gisbased qualitative weighting procedure in corinth area. Bulletin of the Geological Society of Greece, 36 (2), 904–912. <https://doi.org/10.12681/bgsg.16840>

García, I., Trigo, L., Costanzo, S., y Horst, E. (2010). Procesos gaussianos en la predicción de las fluctuaciones de la economía mexicana. El trimestre económico, 77(307), 585-602. <https://doi.org/10.20430/ete.v77i307.447>

González-Arqueros, M. L., Mendoza, M. E., Bocco, G., y Castillo, B. S. (2018). Flood susceptibility in rural settlements in remote zones: The case of a mountainous basin in the Sierra-Costa region of

Michoacán, Mexico. Journal of environmental management, 223, 685-693.
<https://doi.org/10.1016/j.jenvman.2018.06.075>

Gotway, C. A., y Young, L. J. (2002). Combining incompatible spatial data. Journal of the American Statistical Association, 97(460), 632-648. <https://doi.org/10.1198/016214502760047140>

Greco, R., Sorriso-Valvo, M., y Catalano, E. (2007). Landslide susceptibility zonation using GIS and artificial neural networks: an application to the Tyrrhenian coastal fringe of Calabria (southern Italy). Natural Hazards and Earth System Science, 7(4), 495–506. <https://doi.org/10.5194/nhess-7-495-2007>

Guzzetti, F., Carrara, A., Cardinali, M., y Reichenbach, P. (1999). Landslide hazard evaluation: A review of current techniques and their application in a multi-scale study, Central Italy. Geomorphology, 31(1–4), 181–216. [https://doi.org/10.1016/S0169-555X\(99\)00078-1](https://doi.org/10.1016/S0169-555X(99)00078-1)

Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., y Santangelo, M. (2012). Landslide inventory maps: new tools for an old problem. Earth-Science Reviews, 112(1-2), 42-66. <https://doi.org/10.1016/j.earscirev.2012.02.001>

Hanley, J. A., y McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. Radiology, 143(1), 29-36. <https://doi.org/10.1148/radiology.143.1.7063747>

Illian, J., Penttinen, A., Stoyan, H., y Stoyan, D. (2008). Statistical analysis and modelling of spatial point patterns (Vol. 70). John Wiley & Sons. <https://doi.org/10.1002/9780470725160>

Instituto Nacional de Estadística Geografía e Informática (INEGI). (2022). <https://www.inegi.org.mx/>

Iriondo, M. (2007). Introducción a la Geología (3^a ed.). Argentina: Editorial Brujas.

James, G., Witten, D., Hastie, T., y Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: springer. <https://doi.org/10.1007/978-1-4614-7138-7>

Kim, J. C., Lee, S., Jung, H. S., y Lee, S. (2018). Landslide susceptibility mapping using random forest and boosted tree models in Pyeong-Chang, Korea. Geocarto international, 33(9), 1000-1015. <https://doi.org/10.1080/10106049.2017.1323964>

Kuhn, M. (2021). caret: Classification and Regression Training. R package version 6.0-88. <https://CRAN.R-project.org/package=caret>

Lee, C.-T. (2014). Statistical seismic landslide hazard analysis: An example from Taiwan. *Engineering Geology, Special Issue on The Long-Term Geologic Hazards in Areas Struck by Large-Magnitude Earthquakes*, 182, 201-212. <https://doi.org/10.1016/j.enggeo.2014.07.023>

Legendre, P. y Fortin, M.J. (1989). Spatial pattern and ecological analysis. *Vegetatio*, (80), 107-138. <https://doi.org/10.1007/bf00048036>

Leir, M., Michell, A., y Ramsay, S. (2004). Regional landslide hazard susceptibility mapping for pipelines in British Columbia. *Geo-engineering for the society and its environment*. Old Quebec, Canada, 1-9.

Lombardo, L., Opitz, T. y Huser, R. (2018). Point process-based modeling of multiple debris flow landslides using INLA: an application to the 2009 Messina disaster, *Stochastic Environmental Research and Risk Assessment*, 32, 2179-2198. <https://doi.org/10.1007/s00477-018-1518-0>

Lombardo, L., Opitz, T., y Huser, R. (2019). Numerical recipes for landslide spatial prediction using R-INLA: a step-by-step tutorial. In: *Spatial modeling in GIS and R for earth and environmental sciences*, 55-83. Elsevier. <https://doi.org/10.1016/b978-0-12-815226-3.00003-x>

Marui, H. (1988). FAO watershed management field manual: Landslide prevention measures. Food & Agriculture Org. 4(13).

McElreath, R. (2020). *Statistical rethinking: A Bayesian course with examples in R and Stan*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429029608>

Micheletti, N., Foresti, L., Robert, S., Leuenberger, M., Pedrazzini, A., Jaboyedoff, M., y Kanevski, M. (2014). Machine learning feature selection methods for landslide susceptibility mapping. *Mathematical geosciences*, 46, 33-57. <https://doi.org/10.1007/s11004-013-9511-0>

Morales-Manilla, L. M. (2014). The definition of a minimum set of spatial relations. Ph.D. thesis. Universidad Nacional Autónoma de México.

Moreno, H. A., Vélez, M. V., Montoya, J. D., y Rhenals, R. L. (2006). La lluvia y los deslizamientos de tierra en Antioquía: análisis de su ocurrencia en las escalas interanual, intraanual y diaria. *Revista EIA*, (5), 59-69.

Ocaña-Riola, R., y Garrido, C. S. C. (2012). Epidemiología y análisis espacial. *Información Estadística y Cartográfica de Andalucía*, (2), 146-153.

Popescu, P. G., Dragomir, S. S., Slușanschi, E. I., & Stănășilă, O. N. (2016). Bounds for kullback-leibler divergence. *Electronic Journal of Differential Equations*, 2016.

R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>.

Ramos-Scharrón, C. E., Arima, E. Y., y Hughes, K. S. (2020). An assessment of the spatial distribution of shallow landslides induced by Hurricane María in Puerto Rico. *Physical Geography*, 1–29. <https://doi.org/10.1080/02723646.2020.1801121>

Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., y Guzzetti, F. (2018). A review of statistically-based landslide susceptibility models. *Earth-Science Reviews*, 180, 60-91. <https://doi.org/10.1016/j.earscirev.2018.03.001>

Rossi, M., Guzzetti, F., Reichenbach, P., Mondini, A. C., & Peruccacci, S. (2010). Optimal landslide susceptibility zonation based on multiple forecasts. *Geomorphology*, 114(3), 129-142. <https://doi.org/10.1016/j.geomorph.2009.06.020>

Rue, H., Martino, S., Lindgren, F., Simpson, D., y Riebler, A. (2021). INLA: A library for Bayesian inference using Integrated Nested Laplace Approximation. Recuperado de <https://www.r-inla.org/>

Santiago Charchabal, Y. (2020). Evaluación de la susceptibilidad a procesos de remoción en masa: Una comparación de modelos estadísticos en la subcuenca del Río Tuxpan, Michoacán. Tesis de maestría. Centro de Investigaciones en Geografía Ambiental. Universidad Nacional Autónoma de México.

Segundo-Métay, I., y Bocco, G. (2015). Vulnerable and invisible: Impact of hurricane activity on a peasant population in a mountainous region on the Mexican Pacific coast. *Journal of Latin American Geography*, 14(2), 159–179. <https://doi.org/10.1353/lag.2015.0016>

Shumway, R. H., Stoffer, D. S., y Stoffer, D. S. (2000). *Time series analysis and its applications* (Vol. 3). New York: springer. <https://doi.org/10.1007/978-1-4757-3261-0>

Siabato, W., y Guzmán-Manrique, J. (2019). La autocorrelación espacial y el desarrollo de la geografía cuantitativa. *Cuadernos de Geografía: Revista Colombiana de Geografía*, 28(1), 1-22. <https://doi.org/10.15446/rcdg.v28n1.76919>

Sistema Nacional de Información y Gestión Forestal, (2023) Resultados del Inventario Estatal de Michoacán. Publicaciones CONAFOR. Recuperado el 23 de febrero del 2023 de <https://old-snigf.cnf.gob.mx/producto/resultados-del-inventario-estatal-de-michoacan/>

Solís-Castillo, B., Mendoza, M. E., Vázquez Castro, G., y Bocco, G. (2019). Landslide inventory map of the tropical dry Sierra Costa region, Michoacán México. *Physical Geography*, 40(6), 554–577. <https://doi.org/10.1080/02723646.2019.1574136>

Swets, J. A. (1988). Measuring the accuracy of diagnostic systems. *Science*, 240(4857), 1285-1293. DOI:[10.1126/science.3287615](https://doi.org/10.1126/science.3287615)

Tien Bui, D., Pradhan, B., Lofman, O., y Revhaug, I. (2012). Landslide susceptibility assessment in vietnam using support vector machines, decision tree, and Naive Bayes Models. *Mathematical problems in Engineering*, 2012. <https://doi.org/10.1155/2012/974638>

Valdés, C.A.C., Mendoza, M.E., Carlón, A.T. & Macías, J.L. (2021). A review of recent studies on landslide hazard in Latin America. *Physical Geography*. 44(3):243-286 <https://doi.org/10.1080/02723646.2021.1978372>

van Westen, C. J., Castellanos, E., & Kuriakose, S. L. (2008). Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview. *Engineering Geology*, 102(3–4), 112–131. <https://doi.org/10.1016/j.enggeo.2008.03.010>

Wati, S. E., Hastuti, T., Widjojo, S., & Pinem, F. (2010). Landslide susceptibility mapping with heuristic approach in mountainous area. A case study in Tawangmangu sub district, Central Java, Indonesia. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*, 38(8), 248–253.

Wilson, J.P. & Gallant, J.C. (2000). *Terrain analysis: principles and applications*. John Wiley & Sons. 520

Wu, Y., Ke, Y., Chen, Z., Liang, S., Zhao, H., y Hong, H. (2020). Application of alternating decision tree with AdaBoost and bagging ensembles for landslide susceptibility mapping. *Catena*, 187, 104396. <https://doi.org/10.1016/j.catena.2019.104396>