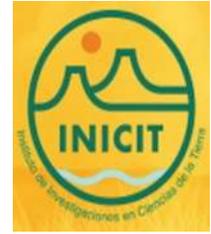




**UNIVERSIDAD MICHOACANA DE SAN  
NICOLÁS DE HIDALGO**



**INSTITUTO DE INVESTIGACIONES EN  
CIENCIAS DE LA TIERRA**

**TESIS:**

**COMPARACIÓN DE TRES MÉTODOS ESTADÍSTICOS  
EMPLEADOS PARA EL ANÁLISIS DE LA SUSCEPTIBILIDAD A  
PROCESOS DE REMOCIÓN EN MASA:**

***El caso del municipio de Los Cabos, Baja California Sur***

**QUE PARA OBTENER EL GRADO DE  
MAESTRO EN GEOCIENCIAS Y PLANIFICACIÓN DEL  
TERRITORIO**

**PRESENTA:**

**ING. ELIAS GABRIEL TORRES RUIZ**

**DIRECTOR:**

**DR. JESÚS ARTURO MUÑIZ JÁUREGUI**

**CO-DIRECTOR:**

**DR. VÍCTOR MANUEL HERNÁNDEZ MADRIGAL**

**MORELIA, MICHOACÁN, JUNIO DEL 2017.**

# INDICE

	<b>Páginas</b>
<b>Resumen</b> .....	1
<b>Abstract</b> .....	2
<b>Capítulo 1: Introducción general</b>	
1.1 Problema de investigación .....	3
<b>Capítulo 2: Marco de referencia</b>	
2.1 Antecedentes .....	6
2.2 Bases teóricas	
2.2.1 Procesos de remoción en masa (PRM) .....	9
2.2.1.1 Tipos de movimientos .....	9
2.2.1.2 Factores condicionantes y detonantes .....	14
2.2.1.3 Estados de actividad .....	18
2.2.1.4 Velocidad .....	19
2.2.2 Susceptibilidad a los PRM .....	20
2.2.3 Modelos para el análisis de la susceptibilidad a PRM .....	21
2.2.3.1 Modelo de análisis espacial para deslizamientos superficiales (SPATSMO-SL).....	23
2.2.3.2 Regresión logística .....	24
2.2.3.3 Red neuronal artificial.....	26
2.2.4 Métodos para la validación de modelos de susceptibilidad .....	28
<b>Capítulo 3: Área de estudio</b>	
3.1 Ubicación geográfica .....	32
3.2 Características de las pendientes .....	33
3.3 Geología.....	34
3.4 Edafología .....	35
3.5 Hidrología.....	36
3.6 Clima .....	37
<b>Capítulo 4: Metodología</b>	
4.1 Metodología general .....	40
4.2 Mapa inventario de PRM .....	41
4.3 Modelación de la susceptibilidad.....	42
4.3.1 Insumos cartográficos.....	42
4.3.2 Otros insumos cartográficos .....	43

4.3.3 Generación de capas temáticas de los factores condicionantes.....	43
4.3.3.1 Factores condicionantes derivados del modelo digital de elevación (MDE) .....	44
4.3.3.2 Factores condicionantes derivados de insumos cartográficos.....	50
4.3.4 Correlación de factores condicionantes derivados del MDE .....	53
4.3.5 Análisis de la susceptibilidad con SPATSMO-SL .....	53
4.3.6 Análisis de la susceptibilidad con regresión logística .....	56
4.3.7 Análisis de la susceptibilidad con red neuronal artificial .....	58
4.3.8 Clasificación de las probabilidades por modelo .....	61
4.4 Validación de modelos estadísticos empleando la curva ROC... ..	61
4.5 Validación de modelos estadísticos empleando la matriz de confusión.....	62
4.6 Comparación de resultados de pruebas de validación ... ..	62
<b>Capítulo 5: Resultados</b>	
5.1 Resultados del mapa inventario de PRM .... ..	63
5.2 Resultados de la elaboración de insumos cartográficos .....	65
5.3 Resultados de la generación de capas temáticas de factores condicionantes .....	67
5.4 Resultados de correlación de factores condicionantes derivados del MDE .....	68
5.5 Resultados del análisis con SPATSMO-SL .....	70
5.6 Resultados del análisis con regresión logística .....	72
5.7 Resultados del análisis con red neuronal artificial .....	74
5.8 Resultados de la clasificación de las probabilidades por modelo .....	77
5.9 Resultados de la susceptibilidad a PRM .....	78
5.9.1 Resultados de la susceptibilidad a PRM obtenido con el SPATSMO-SL .....	78
5.9.2 Resultados de la susceptibilidad a PRM obtenido con la regresión logística .....	82
5.9.3 Resultados de la susceptibilidad a PRM obtenido con la red neuronal artificial .....	84
5.10 Resultados de la validación con la curva ROC .....	86
5.11 Resultados de la validación con matriz de confusión .....	87
5.12 Resultados de la comparación de resultados de pruebas de validación .....	87
<b>Capítulo 6: Discusión</b> .....	92
<b>Capítulo 7: Conclusiones</b> .....	93
<b>Referencias citadas</b> .....	95
<b>Apéndice A</b> .....	110
<b>Apéndice B</b> .....	122

## INDICE DE TABLAS Y FIGURAS

### Índice de tablas

Tabla 1. Clasificación de procesos de remoción en masa basada en Varnes (1978).....	9
Tabla 2. Velocidades de movimientos de ladera (Cruden y Varnes, 1996).....	19
Tabla 3. Modelo metodológico del SPASTMO-SL modificado.....	23
Tabla 4. Matriz de confusión. Fuente: Tsangaratos y Benardos, 2014.....	29
Tabla 5. Índices de validación en la matriz de confusión. Fuente: Tsangaratos y Benardos, 2014.....	29
Tabla 6. Factores condicionantes empleados para el estudio de la susceptibilidad a PRM.....	44
Tabla 7. Factores condicionantes derivados del MDE de 15 m .....	49
Tabla 8. Características espaciales condicionantes relacionadas con la ocurrencia de los PRM.....	52
Tabla 9. Pruebas paramétricas y no paramétricas utilizadas para evaluar el nivel de significancia.....	54
Tabla 10. Modelo de correlación para factores condicionantes obtenidos del MDE.....	69
Tabla 11. Distribución y proporciones de superficie y cantidad de PRM por unidad de terreno.....	70
Tabla 12. Estimación y significación de los coeficientes de las variables significativas (RL).....	72
Tabla 13. Simulación y pronóstico para la correcta clasificación del modelo (RL).....	73
Tabla 14. Clasificación de la susceptibilidad para cada modelo estadístico.....	77
Tabla 15. Área establecida para cada clase de grado de susceptibilidad (SPASTMO-SL).....	78
Tabla 16. Valores de las condiciones para la susceptibilidad a PRM para cada unidad de terreno.....	80
Tabla 17. Área establecida para cada clase de grado de susceptibilidad (RL).....	82
Tabla 18. Factores condicionantes relevantes para la susceptibilidad a PRM (RL).....	83
Tabla 19. Área establecida para cada clase de grado de susceptibilidad (RNA).....	84
Tabla 20. Factores condicionantes relevantes para la susceptibilidad a PRM (RNA).....	85
Tabla 21. Resultados del área bajo la curva (ROC) para los modelos de susceptibilidad....	86
Tabla 22. Resultados de la matriz de confusión para los modelos de susceptibilidad.....	87
Tabla 23. Número de PRM en cada clase de susceptibilidad por modelo.....	88

## Índice de figuras

Figura 1. Mecanismos por caída o desprendimiento (Coraminas y García, 1997).....	10
Figura 2. Mecanismos de vuelco. (Coraminas y García, 1997).....	11
Figura 3. Tipos de movimientos de deslizamientos. (Potter, 2007).....	11
Figura 4. Movimientos de flujo (Tagliaferro y Singer, 2012).....	12
Figura 5. Expansiones laterales. Arriba: por fluencia y extrusión del material subyacente. Abajo: por licuefacción (arcillas rápidas). Según Corominas y García (1997).....	13
Figura 6. Estados de actividad de los movimientos de ladera (UWP/WLI, 1993).....	19
Figura 7. Estructura de red neuronal artificial de tipo perceptrón multicapa.....	28
Figura 8. Ubicación del área de estudio. Fuente: Propia a través de datos de INEGI.....	32
Figura 9. Mapa de pendientes. Fuente: Propia a partir de datos de INEGI .....	33
Figura 10. Carta geológica del área de estudio, Fuente: SGM, 2002. ....	34
Figura 11. Carta edafológica del área de estudio, Fuente: INEGI, 2004.....	35
Figura 12. Carta de escurrimientos superficiales del área de estudio, Fuente: Propia.....	36
Figura 13. Carta de climas. Fuente: INEGI, 1976.....	37
Figura 14. Promedio diario de precipitación por mes.....	38
Figura 15. Precipitación y temperatura media por mes.....	39
Figura 16. Registro de temperaturas máximas y mínimas.....	39
Figura 17. Metodología para evaluar y validar la susceptibilidad a PRM.....	40
Figura 18. Inventario de PRM.....	63
Figura 19. Cicatrices de flujos de derrubios.....	64
Figura 20. Canal de un flujo de rocas de granito y esquistos metamórficos .....	64
Figura 21. Deslizamiento traslacional.....	65
Figura 22. Carta de vegetación y uso de suelo. Fuente: Propia .....	66
Figura 23. Carta geomorfológica del área de estudio, Fuente: Propia .....	67
Figura 24. Unidades de terreno para el análisis espacial de la susceptibilidad de los PRM en el municipio Los Cabos, Baja California Sur.....	71
Figura 25. Estructura de RNA para modelo propuesto.....	74
Figura 26. Importancia de factores condicionantes para la susceptibilidad a PRM (RNA)...	75
Figura 27. Ponderaciones y sesgos para cada unidad de la capa oculta.....	76
Figura 28. Ponderaciones y sesgos para cada unidad de capa de salida.....	76
Figura 29. Grado de susceptibilidad dentro de las zonas susceptibles (SPATSMO-SL).....	78
Figura 30. Susceptibilidad por SPATSMO-SL a PRM.....	79
Figura 31. Factores condicionantes relevantes en las unidades de terreno (SPATSMO-SL).....	79

Figura 32. Grado de susceptibilidad dentro de las zonas susceptibles (RL).....	82
Figura 33. Susceptibilidad por regresión logística a PRM.....	83
Figura 34. Grado de susceptibilidad dentro de las zonas susceptibles (RNA).....	84
Figura 35. Susceptibilidad por red neuronal artificial a PRM.....	85
Figura 36. Evaluación de la curva ROC para los modelos estadísticos de susceptibilidad.....	86
Figura 37. Clases de susceptibilidad por porcentaje de área para cada modelo estadístico.....	88
Figura 38. Comparación representativa de los modelos estadísticos.....	89

## RESUMEN

En la última década la evaluación de la susceptibilidad a procesos de remoción (PRM) en masa a través del método estadístico se convirtió en un tema importante para las instituciones científicas como una alternativa económica de bajo costo para grandes áreas de estudio. El problema al que actualmente se enfrentan las sociedades investigadoras es la gran cantidad de modelos estadísticos que se emplean en el estudio de la susceptibilidad a PRM. Existe la necesidad de depurar y proponer modelos con alto grado de confiabilidad en la zonificación de PRM. En este estudio se evaluaron y compararon mediante el uso de modelos de validación, mapas de susceptibilidad de PRM producidos con tres métodos estadísticos diferentes (SPATSMO-SL, Regresión logística y Red Neuronal Artificial). Se elaboró un inventario de PRM el cual fue dividido aleatoriamente en dos grupos 70% (654 PRM) para entrenamiento de los modelos y 30 % (280 PRM) para su respectiva validación. Para la modelación se eligieron 25 factores condicionantes como variables relacionadas a los PRM, la relación entre las distribuciones de PRM y las variables asociadas a ellos fueron analizados utilizando los tres métodos para posteriormente calcular la susceptibilidad de PRM del área de estudio. La exactitud, precisión y capacidad predictiva de los mapas de susceptibilidad de PRM final fueron evaluados sobre la base del 30% de PRM no empleados en el entrenamiento. La capacidad predictiva de cada modelo se determinó con el área bajo la curva ROC, la exactitud y precisión se determinaron mediante la matriz de confusión. Los trabajos realizados en nuestra zona de estudio identificaron la ubicación de 934 PRM, 16 movimientos traslacionales de derrubios, 8 flujos de roca y 910 flujos de derrubios. La curva ROC obtenida mediante los métodos SPATSMO-SL, regresión logística y red neuronal artificial fue de 0.854, 0.946, y 0.952 respectivamente. La exactitud y precisión obtenida en la matriz de confusión fue de 0.82, 0.83; 0.88, 0.89; 0.89 y 0.91 respectivamente. Finalmente la comparación de la susceptibilidad generada por los tres métodos estadísticos coincide en que el modelo de red neural artificial garantiza mejores resultados en cuanto a su precisión (91 %), exactitud (89 %) y capacidad predictiva (95.2 %).

**Palabras Claves: Susceptibilidad, modelos estadísticos, procesos de remoción en masa, evaluación y validación.**

### **ABSTRACT**

In the last decade, the evaluation of the susceptibility to landslide through the statistical method became an important issue for scientific institutions because is as a low cost economic alternative for large areas of study. The problem currently faced by research society is the large number of statistical models used in the study of susceptibility landslide. There is a need to debug and propose models with a high degree of reliability in the landslide zoning. In this work evaluated and compared by using validation models, landslide susceptibility maps produced with three different statistical methods (SPATSMO-SL, Logistic regression and artificial neural network). An inventory of landslide was developed which was randomly divided in two groups 70% (654 landslide) for training of the models and 30% (280 landslide) for their respective validation. For modeling, 25 conditioning factors were chosen as variables related to the landslide, the relationship between the distributions of landslide and the variables associated with them were analyzed using the three methods and later calculate the susceptibility of landslide of this study area. Accuracy, precision, and predictive capacity of final landslide susceptibility maps were evaluated on the basis of 30% of landslide not employed in the training. The predictive capacity of each model was determined with the area under the ROC curve, accuracy and precision were determined by the confusion matrix. The work carried in our study area identified the location of 934 landslide, 16 translational movements of debris, 8 rock flows and 910 debris flows .The ROC curve obtained by means of the methods SPATSMO-SL, Logistic regression and artificial neural network was of 0854, 0946, and 0952 respectively. The accuracy and precision obtained in the matrix of confusion was 0.82, 0.83; 0.88, 0.89; 0.89 and 0.91 respectively. Finally, the comparison of the susceptibility generated by the three statistical methods coincides that the artificial neural network model guarantees better results in terms of precision (91%), accuracy (89%) and predictive capacity (95.2%).

## Capítulo 1: Introducción general

### 1.1 Problema de investigación

El aumento en el interés del método estadístico para analizar la susceptibilidad a PRM permitió proponer a la comunidad científica más de 40 modelos estadísticos, sin embargo muchos de estos modelos solo se han utilizado en un número pequeño de investigaciones y por la tanto su eficacia y eficiencia para zonificar la susceptibilidad a PRM aún se encuentra en fase de prueba (Rossi *et al.*, 2010; Armaş, 2012; Tien Bui *et al.*, 2012 y Shahabi *et al.*, 2014).

El método estadístico se basa en el análisis de las relaciones entre los factores condicionantes y la distribución espacial de los PRM pasados y observados (Thiery *et al.*, 2007). Asume que los factores condicionantes que causaron con anterioridad PRM en una superficie en particular son similares a los que podrían generar PRM en el futuro (Baeza *et al.*, 2010). Se considera una metodología rápida y fiable que permite una aproximación y delimitación de las zonas con menor o mayor susceptibilidad (Pourghasemi *et al.*, 2013).

Los modelos estadísticos buscan en mayor medida la posibilidad de ser suficientemente generalizables de manera que permitan su aplicación a otras zonas con diferentes o similares condiciones conservando un alto grado de confiabilidad (Tien Bui *et al.*, 2012 y Meng *et al.*, 2015). Sin embargo este proceso aún está en gran incertidumbre debido a la gran variedad de modelos estadísticos, deficiencias en su manipulación y pocas pruebas científicas de cada uno de ellos (Tien Bui *et al.*, 2012; Wang *et al.*, 2013 y Sharma *et al.*, 2014).

Actualmente el modelo estadístico que mayor aprobación tiene en la comunidad científica es la regresión logística la cual se aplica en diversas áreas geográficas del mundo (Ayalew y Yamagishi, 2005; Van Den Eeckhaut, *et al.*, 2006; Davis *et al.*, 2006; Greco *et al.*, 2007; García *et al.*, 2008; Nandi y Shakoore, 2009; Das, 2010; Von Ruetten *et al.*, 2011; Tien Bui *et al.*, 2012; Wang *et al.*, 2013; Dahal, 2014; Zhuang *et al.*, 2015). Sin embargo la confiabilidad de su efectividad en los diferentes estudios es muy variable, investigaciones como Oh *et al.*, 2009; Erener y Düzgün, 2010; Bai

*et al.*, 2014; Timilsina *et al.*, 2014 y Ahmed, 2015, desacreditan totalmente el modelo estableciéndolo en un valor de confiabilidad por debajo de un 75 %. Para otros autores la efectividad resulta ser excelente posicionando con un valor mayor del 90 % (Pradhan, 2010; Pradhan y Lee, 2010; Kavzoglu *et al.*, 2015; Zhuang *et al.*, 2015; Shahabi *et al.*, 2015).

Otros modelos estadísticos que también presentan la misma disparidad en sus resultados que la regresión logística aunque en un número menor de trabajos son los pesos de evidencia (Thiery *et al.*, 2007; Xu *et al.*, 2012 y Youssef *et al.*, 2015), relación de frecuencia (Lee y Sambath, 2006; Poudyal *et al.*, 2010 y Ramesh y Anbazhagan, 2015), fuzzy (Regmi *et al.*, 2010; Pourghasemi *et al.*, 2012 y Meten *et al.*, 2015), índice de entropía (Devkota *et al.*, 2013 y Chen *et al.*, 2015) y jerarquía analítica (Suh *et al.*, 2011 y Günther *et al.*, 2014).

Existe una metodología estadística alternativa denominada red neuronal artificial que empezó a tomar mayor importancia en los últimos 5 años debido a los buenos resultados de validez obtenidos en más de una decena de publicaciones, las cuales establecen que esta metodología genera una confiabilidad mayor al 80% (Poudyal *et al.*, 2010; Nefeslioglu *et al.*, 2011; Tien Bui *et al.*, 2012; Conforti *et al.*, 2014 y Dou *et al.*, 2015).

Algunos otros modelos estadísticos no han tenido la oportunidad de poder ser replicados a un número mayor de 3 evaluaciones: Dempster-Shafer (Mohammady, *et al.*, 2014), Análisis lineal discriminante de Fisher (He *et al.*, 2012) y sistema de inferencia neuro-fuzzy adaptativo (Dehnavi *et al.*, 2015). El caso del modelo de bayes (Tien Bui *et al.*, 2012), análisis de conglomerados (Melchiorre *et al.*, 2008) y modelo espacial para deslizamientos superficiales (SPATSMO-SL; Muñiz-Jáuregui *et al.*, 2014) no han tenido una segunda oportunidad de réplica.

El en el caso del modelo estadístico SPATSMO-SL es un modelo moderno completamente en fase de prueba diseñado por investigadores mexicanos el cual no ha estado sometido a un parámetro de validez (Muñiz-Jáuregui *et al.*, 2014); por lo tanto se desconoce los alcances o límites que el modelo pudiera proporcionar.

La exactitud y precisión de los resultados obtenidos por los modelos estadísticos empleados en el estudio de la susceptibilidad a PRM en la actualidad aún es cuestionable, existen notables diferencias entre las diversas investigaciones: número de factores condicionantes empleados, escala o resolución espacial de insumos cartográficos, análisis por unidad espacial o pixel a pixel, selección de tamaño de muestras y tratamiento de los datos (Tien Bui *et al.*, 2012). Es por ello la necesidad de comparar diferentes modelos estadísticos a partir de una base datos estandarizada, para que en base a ello se pueda determinar y proponer un modelo estadístico que proporcione mejores valores de confiabilidad y validez en sus resultados (Tien Bui *et al.*, 2012).

Por lo tanto el objetivo principal de este trabajo es evaluar y comparar la precisión y exactitud de los modelos estadísticos regresión logística, red neuronal artificial y SPATSMO-SL aplicados en la zonificación de la susceptibilidad a PRM. La elección de los modelos se realizó en base a los argumentos presentados en los párrafos anteriores.

## Capítulo 2: Marco de referencia

### 2.1 Antecedentes

Los primeros trabajos enfocados al estudio de la susceptibilidad a PRM sólo fueron inventarios de PRM los cuales representaban de manera puntual y poligonal la distribución espacial de las cicatrices en las superficies afectadas por PRM, su elaboración consistía en la ubicación espacial de los PRM de manera directa del trabajo de campo (Chacón *et al.*, 2007). En el trabajo de Corominas y Moya (2008) se afirma que los primeros mapas de inventario de PRM se realizaron en la década de los 70's, aunque Chacón *et al.*, 2007, mencionan que Macau ya elaboraba un mapa inventario de PRM para la provincia de Granada en España entre 1962 y 1963, este mapa distinguía movimientos activos, inactivos y zonas inestables limitado a una escala 1:200,000 por las dificultades y carencias de la época de trabajo; su principal uso se basaba en indicar las zonas en las que existía mayores problemas de inestabilidad para evitar daños y reparaciones en la infraestructura pública.

A finales de los años setenta, se llevaron a cabo los primeros experimentos para probar la posible utilización de los modelos estadísticos multivariados para evaluar la susceptibilidad de deslizamientos en tres diferentes zonas al sur de Italia en Calabria. Los resultados probaron que estos modelos podían ser capaces de predecir con éxito la existencia real y potencial de la susceptibilidad en la pendiente en cada zona estudiada (Carrara, 1983 y 1989). Sin embargo, este enfoque reveló limitaciones e inconvenientes, en cuanto al tiempo requerido para codificar y digitalizar la gran cantidad de datos necesarios.

Entre los años ochenta Carrara *et al.*, (1990), aplicando un análisis discriminante, clasificaron el ángulo de inclinación de la pendiente en categorías de unidades estables e inestables, tomando como base sus características morfológicas y geológicas, en la cuenca Tescio en Umbría ubicada en la región centro de Italia; este método mejoró la comprensión de la relación existente entre los PRM y la características anteriormente mencionadas. A finales de esa década empezaron a

desarrollarse técnicas computacionales lo cual automatizó el proceso de captura de datos, por consiguiente, la reducción del tiempo de procesamiento y los resultados fueron de mayor calidad (Carrara *et al.*, 1990).

A inicios de los 90's comenzó el auge de los Sistemas de Información Geográfica (SIG) los cuales eran empleados de manera restringida por el gobierno, es por ello que hasta a mediados de esta época empezaron a difundirse a nivel del usuario general y a emplearse en el análisis de la susceptibilidad a PRM (Soeters y Van Westen, 1996). A partir de 1996 se realizaron inventarios de PRM detallados sobre los tipos, las características y la distribución de los PRM con el fin de aplicarlo en modelos de susceptibilidad a PRM (Guzzetti *et al.*, 1996). Van Westen *et al* (1999) dividió las técnicas de mapeo en dos grupos: 1. Mapeo directo, en la que el grado de susceptibilidad se determina por la cartografía geomorfológica, basándose en la experiencia y conocimiento del investigador de las condiciones del terreno; 2. Mapeo indirecto, en los cuales los modelos estadísticos o deterministas son usados para zonificar áreas susceptibles a PRM, basándose en la información obtenida de la relación entre factores condicionantes del ambiente y la distribución de PRM.

Si bien todos los antecedentes antes mencionados forman parte del desarrollo y evolución de los modelos estadísticos aplicados al estudio de la susceptibilidad de PRM los registros más relevantes se encuentran a partir del 2000. Luzi *et al*, 2000 realizaron un estudio regional de susceptibilidad a PRM en la parte superior de la cuenca del río Serchio en Garfagnana, Italia, los modelos empleados en él estudio fueron el modelo bayesiano y el peso evidencia. Utilizaron la escala espacial 1:10,000 como datos de entrada para los factores condicionantes geológicos, geomorfológicos e hidrológicos con la finalidad de minimizar en la medida de lo posible errores de ubicación espacial de las zonas susceptibles, como resultado de la prueba se obtuvieron resultados diferentes para cada modelo pero es imposible proponer como fiable alguno de ellos por falta de validez en los modelos.

Gritzner *et al.*, 2001 con apoyó del modelo de probabilidad bayesiana asoció significativamente la ocurrencia de PRM a características particulares de la

pendiente (inclinación, curvatura, orientación, acumulación de flujo, longitud de la pendiente y elevación) en Wondogenet, Etiopía. Estas características espaciales fueron obtenidas a través de un modelo digital de elevación con una resolución espacial de 30m por pixel; reconoció que existen otros factores que se consideran importantes para el análisis de la susceptibilidad como la geología, la vegetación y la distancia a caminos pero les fue imposible disponer de esa información en formato digital. La comprobación de la fiabilidad en los resultados no fue comprobada.

Ese mismo año Baeza y Corominas (2001), pusieron a prueba el análisis discriminante en dos zonas distintas de los Pirineos Orientales en España utilizando como variables dependientes atributos de la pendiente (elevación, inclinación, orientación y curvatura), atributos de cuenca (área y longitud), vegetación y litología; determinando en las dos áreas que las laderas con mayor probabilidad de PRM se distinguían por tener ángulos pronunciados, grandes cuencas deforestadas y una curvatura cóncava. Emplearon el índice de densidad relativa aplastante como medida de validez en sus resultados del cual se tiene muy poco conocimiento; concluyen que los resultados tienen una confiabilidad del 88.5 y 88.8.

A fin de evaluar la susceptibilidad a PRM mediante el uso de SIG aplicando métodos estadístico muchos investigadores han intentado proponer diferentes modelos: probabilidad condicional (Wu *et al.*, 2001), referencias cruzadas (Donati y Turrini, 2002), superposición espacial (Zhou *et al.*, 2002) y regresión logística (Ohlmacher y Davis 2003). Del periodo del 2005 a 2015 se encontraron 118 antecedentes de modelos estadísticos empleados al estudio de la susceptibilidad a PRM (apéndice A: 3), de los cuales un 25% no cuenta con pruebas de confiabilidad en sus resultados.

## 2.2 Bases teóricas

### 2.2.1 Procesos de remoción en masa

Muchos son los términos que hacen referencia a este tipo de procesos que pueden ser naturales o como producto derivado de las actividades humanas: movimientos de masa dado por Hutchinson (1968), movimientos de ladera, procesos gravitacionales y procesos de remoción aplicados por Varnes (1978), diferencia entre movimiento de masas y masas transportadas determinada por Brunsten (1984), y movimientos de terreno aportada por Alcántara (2000).

Por lo cual, para la elaboración de este trabajo se consideró a los PRM como el desplazamiento de un conjunto de materiales (rocas, arena o la combinación de ellos) producto del efecto de la gravedad, y controlado por procesos naturales o antrópicos que actúan en la superficie terrestre

#### 2.2.1.1 Tipos de movimientos

Para clasificar los tipos de movimientos, se eligió seguir la clasificación de Varnes (1978). Esta clasificación sugiere siete tipos de remociones en masa y varios subtipos (Tabla 1).

Tabla 1. Clasificación de procesos de remoción en masa basada en Varnes (1978)

TIPO DE MOVIMIENTO		TIPO DE MATERIAL		
		ROCA	SUELO	
			Materiales gruesos	Materiales finos
CAIDAS O DESPRENDIMIENTO		Caída de rocas	Caída de derrubios	Caída de arenas
VUELCOS O DESPLOMES		Desplome de rocas	Desplome de derrubios	Desplome de arenas
DESPLAZAMIENTO	ROTACIONAL	Deslizamiento de roca	Deslizamiento de derrubios	Deslizamiento de arenas
	TRANSLACIONAL			
EXTENSIÓN LATERAL		Extensión de roca	Extensión de derrubios	Extensión de arenas
FLUJOS		Flujo de roca	Flujo de derrubios	Flujo de arenas
COMPLEJOS		Combinación de 2 o más tipos de movimientos principales		

- **Caídas o desprendimiento.** Son movimientos de caída libre y posteriormente rebote o rodadura de distintos materiales (figura 1) tales como rocas, derrubios o suelos (Alcántara, 2000). Se origina por el desprendimiento del material de una superficie inclinada. La propagación con pendientes superiores a los  $76^\circ$  se produce preferentemente por caída libre, por debajo de estos ángulos menores a  $45^\circ$  la propagación se realiza por rodadura (Alcántara, 2000). Estos movimientos son definidos con base en el material involucrado, clasificándose de manera general en caídas de rocas, caídas o desprendimientos de derrubios y caídas o desprendimiento de suelos (Alcántara, 2000).

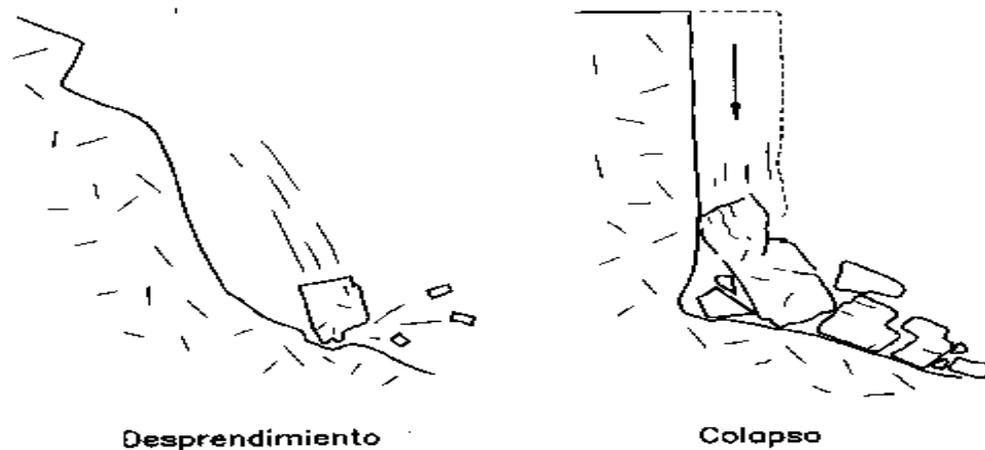


Figura 1. Mecanismos por caída o desprendimiento (Corominas y García, 1997)

- **Vuelcos o desplomes.** Consiste en la rotación de una masa de suelo, derrubios o rocas entorno a un eje o pivote determinado por su centro de gravedad (Alcántara, 2000; figura 2). El movimiento es hacia la parte externa, por lo cual involucra inclinación o basculamiento, pero no involucra colapsamiento (Alcántara, 2000). Se clasifican en vuelcos o desplomes de rocas, de derrubios o detritos y de suelos (Alcántara, 2000).

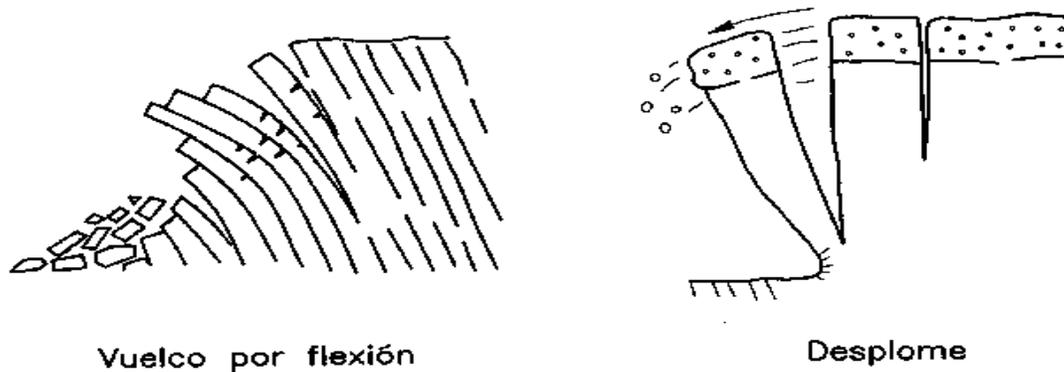


Figura 2. Mecanismos de vuelco. (Corominas y García, 1997)

- **Deslizamientos.** Son movimientos ladera abajo de una masa de suelo, detritos o roca, la cual ocurre sobre una superficie reconocible de ruptura (Alcántara, 2000). La superficie de ruptura define el tipo de deslizamiento, por lo que las superficies curvas, cóncavas o en forma de cuchara se asocian a deslizamientos rotacionales; las superficies de ruptura planas, semiplanas u onduladas a los movimientos traslacionales (Alcántara, 2000; figura 3). Los deslizamientos rotacionales se clasifican en simples, múltiples y sucesivos (Alcántara, 2000). Los deslizamientos traslacionales se subdividen en deslizamientos de roca en bloque, deslizamiento de derrubio en bloque y deslizamientos traslacionales de suelos (Alcántara, 2000).



Figura 3. Tipos de movimientos de deslizamientos. (Potter, 2007)

- **Flujos.** Son movimientos espacialmente continuos, en los que las superficies de cizalla son muy próximas, de poca duración (Alcántara, 2000; figura 4). El movimiento es muy parecido al de un fluido viscoso, razón por la que la distribución de las velocidades no es homogénea y origina la formación de lóbulos a partir del predominio del movimiento intragranular (Alcántara, 2000). Los flujos envuelven todos los tipos de materiales disponibles y se clasifican con base en su contenido, dividiéndose en flujos de rocas, flujos o corrientes de derrubios y flujos de arena o suelo (Alcántara, 2000).

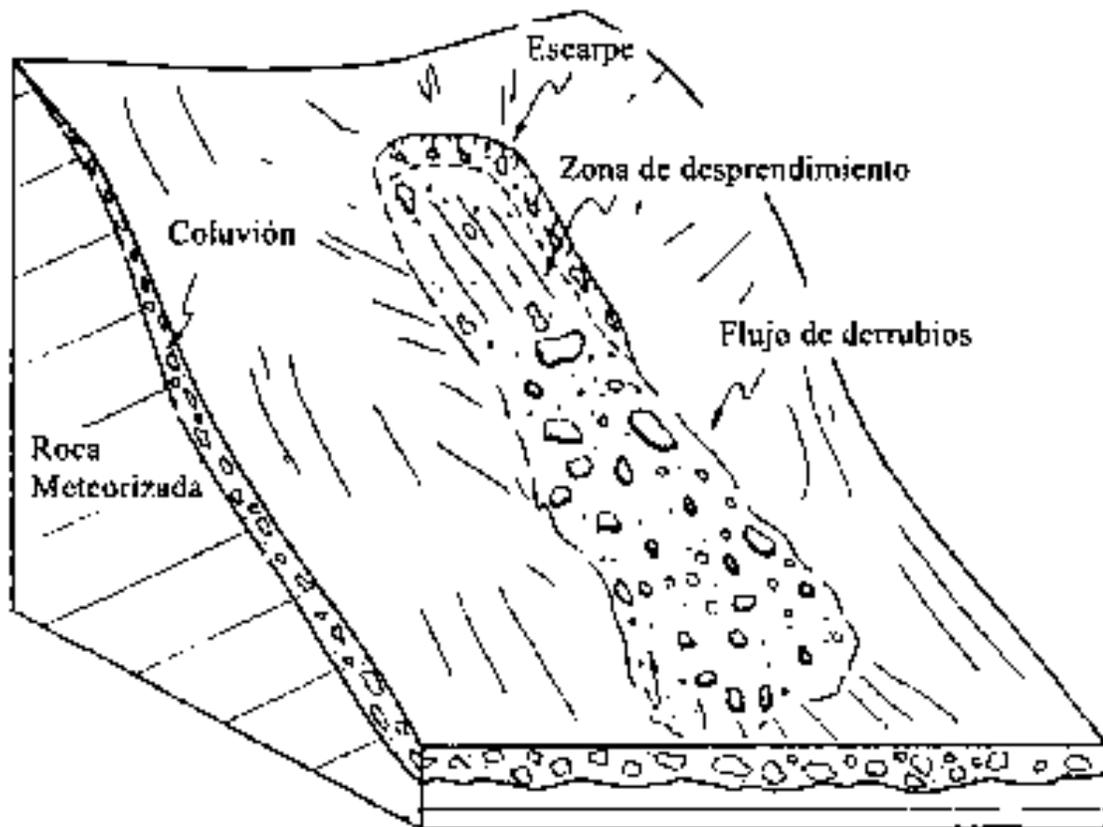


Figura 4. Movimientos de flujo (Tagliaferro y Singer, 2012)

- **Extensión lateral.** Estos movimientos son el resultado de la fracturación y expansión de suelos y masas rocosas, debido a la licuefacción o fluidización del material subyacente (Alcántara, 2000; figura 5). Se clasifican en expansiones laterales en rocas, en derrubios y en suelos. Cuando las masas de suelo o roca son relativamente homogéneas, estas se fracturan en varias unidades y conforman arreglos tipo horst y graben (Alcántara, 2000).

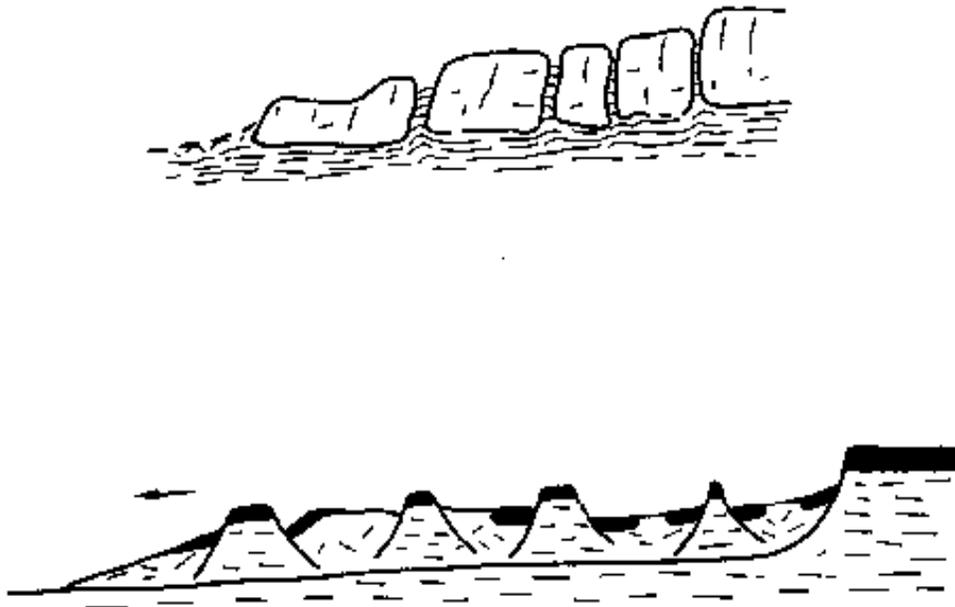


Figura 5. Expansiones laterales. Arriba: por fluencia y extrusión del material subyacente. Abajo: por licuefacción (arcillas rápidas). Según Corominas y García (1997)

- **Complejos.** Es común que los procesos de remoción se combinen o que se conviertan en otro a medida que avanzan y como consecuencia generen un movimiento ladera abajo (Suárez, 1998). Es por ello, que se ha creado el concepto de “complejo”, en el cual se logran identificar dos o más tipos principales de desplazamientos (Suárez, 1998).

### 2.2.1.2 Factores condicionantes y detonantes

#### - Factores condicionantes

Los factores condicionantes son aquellas condiciones que determinan el potencial de inestabilidad de terreno, y condicionan la velocidad y volumen de desplazamiento del material involucrado (Lara y Sepúlveda, 2008). Entre los factores condicionantes se presentan las variables relacionadas con el material parental; el suelo, el relieve y la cobertura vegetal (Lara y Sepúlveda, 2008). Sidle (1991, 1992), sugiere que la magnitud y ocurrencia de movimientos en masa de tipo deslizamientos o flujos de derrubios difieren dependiendo de las condiciones locales (geología, suelo, fisiografía y clima) y las condiciones de la vegetación (especie, condiciones ambientales para su crecimiento, grado de desarrollo de la vegetación existente, así como su densidad, entre otros). En el factor suelo se incluyen como variables: el tipo y la profundidad del suelo, así como, las propiedades hidrológicas y mecánicas del suelo y las rocas (Carrara, 1983). En el caso del factor cobertura, se incluye su extensión, tipo de cubierta vegetal y densidad (Carrara, 1983).

- **Geología.** Define las características o propiedades del suelo o roca, determina la presencia del tipo, la resistencia y discontinuidad de los materiales (Suárez, 1998). Las remociones en masa suelen darse en laderas inestables debido a la presencia de debilidades de tipo geológico-estructural con una alternancia de horizontes, que genera grandes deformaciones sobre la masa rocosa (Capra *et al.*, 2006). Las debilidades estructurales son: planos de estratificación, diaclasas, fallas, planos de esquistosidad y discontinuidad, etc. (Díaz de Terán, 2011). La litología es uno de los principales parámetros que intervienen en la estabilidad o inestabilidad de las laderas, cada material presenta características resistentes específicas: competencia, estado de fracturación, permeabilidad y facilidad de meteorización (Díaz de Terán, 2011). Se ha observado que la alternancia de las litologías con diferente competencia y permeabilidad es un factor importante en la inestabilidad de laderas, si a esto se le agrega la geometría de los horizontes geológicos y la orientación de los planos de discontinuidad se pueden generar condiciones para una posible o no ruptura y movimiento de la ladera (Capra *et al.*, 2006).

- **Geomorfología.** Los rasgos geomorfológicos que condicionan eventos de remociones en masa son principalmente la topografía, grados de inclinación de las laderas, cambios abruptos en las pendientes, orientación de la pendiente, perfil y plano de curvatura, la extensión y altura de las mismas (Popescu, 2002). Estas características inciden en la velocidad, energía y volumen de los deslizamientos que puedan originarse (Popescu, 2002). Por otro lado, los rasgos geomorfológicos influyen en la forma y superficie de las cuencas hidrográficas, orientación de laderas y su consecuente exposición al sol (Lara y Sepúlveda, 2008).

- **Hidrología.** Las características de la red de drenaje, las posiciones y variaciones del nivel freático, caudales, coeficientes de escorrentía y coeficientes de infiltración, son factores hidrológicos e hidrogeológicos que condicionan la generación de remociones en masa ya que están directamente relacionados a la incorporación de agua en los suelos o macizos rocosos (Lara y Sepúlveda, 2008). El aumento en la fluctuación de las aguas subterráneas y la humedad contenida en el suelo aumenta la presión de poro disminuyendo en consecuencia la resistencia al cortante (Guri *et al.*, 2015). Las corrientes de agua producen erosión de tipo lateral y vertical sobre el cauce, lo que ocasiona desestabilidad en la ladera y desprendimiento de material (Suárez, 1992). La corta distancia de las superficies a los afluentes y cauce principal contribuye a una alta probabilidad de ocurrencia de PRM (Yilmaz, 2009).

- **Vegetación.** Contribuye a disminuir el efecto erosivo sobre laderas generado por factores como el clima, propiedades del suelo y topografía (Selby, 1993). La existencia de la vegetación en las laderas permite la absorción de agua disminuyendo el grado de saturación del suelo (Selby, 1993). Además, sus raíces en general ayudan a la estabilización de las laderas actuando como anclajes de reforzamiento, sin dejar de considerar que en algunos casos esta estabilización es sólo superficial (Selby, 1993).

- **Clima.** Los PRM están asociados con mayor frecuencia a zonas con clima cálido húmedo, cálido semihúmedo y climas templados (Herrera, 2002). Las variaciones en el gradiente térmico, el nivel de evaporación de la humedad, la velocidad del viento y la radiación solar ayudan a caracterizar el clima de una región y asociar o

no asociarlos a los PRM (Pineda, 2012). En la actualidad se habla del cambio climático que el hombre ha propiciado, lo que ha provocado que se presenten fenómenos hidrometeorológicos atípicos que se implican o se asocian a variaciones en la temperatura, esto influye directamente en la generación de remociones en masa afectando asentamientos humanos. (De la luz, 2011).

- **Actividad antrópica.** Este factor hace referencia a las perturbaciones o alteraciones que provoca el ser humano al medio natural favoreciendo la generación de las remociones en masa. Algunas de las actividades del hombre que influyen en esto son cambios en el uso del suelo (incluye el crecimiento urbano), excavaciones, rellenos, construcción de estructuras, extracción de materiales y acumulación de escombros, entre otros. Estas afectaciones pueden contribuir de dos maneras: a) desestabilización de las laderas producto de la disminución artificial de la resistencia del material, b) la contribución de material para ser movilizados por futuros eventos y cambios en la escorrentía superficial y en la topografía (Lara y Sepúlveda, 2008).

#### - Factores detonantes

Un agente detonante es un factor externo que genera una respuesta traducida en una remoción en masa mediante el rápido incremento de esfuerzos cortantes o la reducción de la resistencia del material de una ladera (Pineda, 2012). Un agente detonante se caracteriza principalmente por la existencia de un lapso corto entre la causa y su efecto (Lara y Sepúlveda, 2008). Las precipitaciones intensas y prolongadas se consideran como factor activador (Pineda, 2012). Otros incluyen como factores activadores a la intervención humana; la actividad sísmica y la actividad volcánica (Pineda, 2012).

- **Precipitaciones.** Uno de los factores que más contribuyen a la inestabilidad es la precipitación; por el efecto que tiene en la saturación del terreno, en el aumento del peso volumétrico del suelo y de manera más trascendente, en la reducción de la resistencia al esfuerzo cortante de los suelos (por efecto de la presión de poros y fracturas); asimismo, las corrientes extraordinarias propician socavación, deslaves y cambios en la geometría (Castañeda, 2011). Para establecer la relación entre las

precipitaciones y la ocurrencia de PRM se analiza el régimen de las precipitaciones y se utilizan los datos de intensidad, duración y frecuencia (Pineda, 2012).

- **Sismos.** Ocupan un lugar muy importante dentro de las causas que activan o disparan los PRM (Castañeda, 2011). Cuando ocurre un evento sísmico se generan fuerzas inerciales dentro de la ladera, las cuales aumentan los esfuerzos cortantes actuantes (Castañeda, 2011).

- **Causas humanas o antrópicas.** Existen actividades humanas que agudizan o causan de manera directa la ocurrencia de PRM (Castañeda, 2011). La aplicación de cargas sobre la ladera, ya sea por la construcción de obras o por la acumulación de materiales, es un factor determinante en los incrementos de los esfuerzos cortantes actuantes en la potencial superficie de falla (Castañeda, 2011). El desarrollo de asentamientos humanos tiene aspectos negativos en la estabilidad, ya que además del peso que transmiten a la ladera por la construcción de viviendas, se generan otras condiciones como son: fugas en drenajes y en los servicios de agua potable, cortes y terrazas para la construcción de obras y acumulación de cargas accidentales producidas por tránsito de vehículos y por la vibración de maquinaria. (Castañeda, 2011).

- **Vulcanismo.** Las erupciones volcánicas pueden originar deslizamientos o avalanchas de derrubios de gran magnitud y velocidad en las laderas de los volcanes; además el deshielo provocado por el vulcanismo de las partes altas puede originar flujos rápidos. (Cuanalo *et al.*, 2011).

- **Congelación y deshielo.** Factores climáticos que afectan principalmente a regiones frías; este fenómeno produce expansiones, contracciones e infiltración de agua en fisuras y grietas (Cuanalo *et al.*, 2011).

- **Erosión y socavación.** Incluye la acción erosiva de ríos y oleaje, produciendo los siguientes efectos: Socavación del material en el pie de la ladera que modifica el estado tensional y aumenta las fuerzas cortantes actuantes y el deslizamiento puede embalsar un río y después romper súbitamente (Cuanalo *et al.*, 2011).

### 2.1.2.3 Estados de actividad

Los PRM se clasifican según sus diferentes estados de actividad (UWP/WLI, 1993; figura 6):

1. Un movimiento activo tiene un movimiento actual.
2. Un movimiento en suspenso o suspendido ha tenido movimiento en los últimos 12 meses, sin embargo, no es un movimiento activo.
3. Un movimiento reactivado es un movimiento activo, el cual ha estado inactivo.
4. Un movimiento inactivo no ha tenido movimiento en los últimos 12 meses y se puede clasificar como 5, 6, 7 u 8.
5. Un movimiento apagado es un movimiento inactivo, que puede ser reactivado como resultado de los factores desencadenantes que lo originaron o por otros factores.
6. Un movimiento abandonado es un movimiento inactivo, el cual no es afectado por los factores que lo originaron.
7. Un movimiento estabilizado es un movimiento inactivo, el cual ha sido protegido de los factores que lo originaron a través de medidas.
8. Un movimiento relicto es un movimiento inactivo, el cual se desarrolla bajo condiciones climáticas o geomorfológicas totalmente diferentes a sus condiciones actuales.

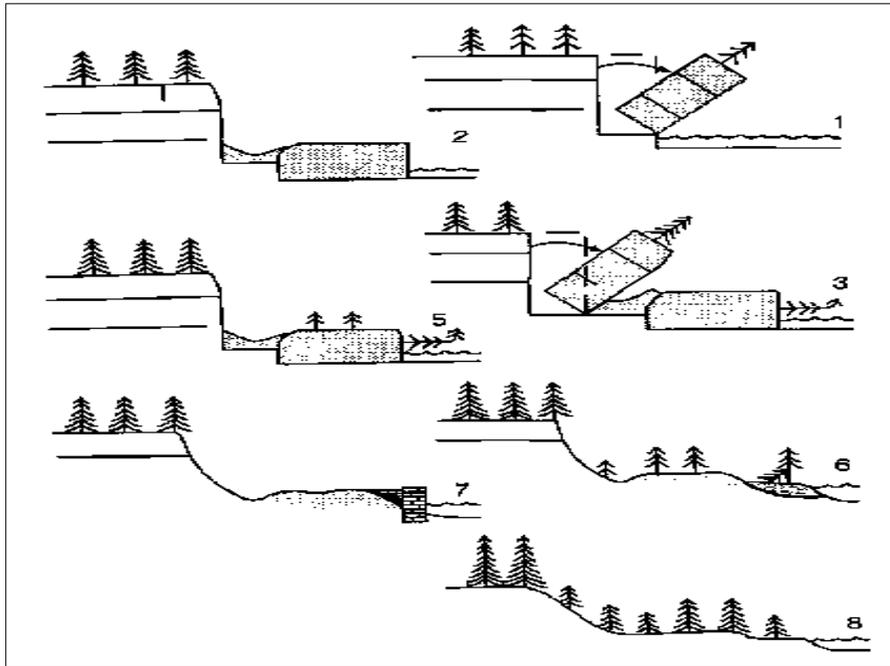


Figura 6. Estados de actividad de los movimientos de ladera (UWP/WLI, 1993)

#### 2.2.1.4 Velocidad

Análogamente a la elaboración de la escala de Mercalli, la cual describe los efectos locales en términos de daños sufridos por un evento sísmico, los autores Cruden y Varnes (1996) presentan una modificación a la escala de Varnes (1978), a partir de la cual describen la velocidad y la naturaleza del impacto causado por los diferentes procesos de ladera (Tabla 2).

Tabla 2. Velocidades de movimientos de ladera (Cruden y Varnes, 1996.)

Clase	Descripción	Velocidad (mm/seg)	Valores típicos	Daños probables
7	Extremadamente rápido	$5 \times 10^3$	5 m/s	Violento y catastrófico. Destrucción de edificios por impacto de masa deslizada. Número elevado de muertos.
6	Muy rápido	$5 \times 10^1$	3 m/min	Es difícil escapar. Algunos muertos. Destrucción de edificios.
5	Rápido	$5 \times 10^{-1}$	1.8 m/h	Algunas estructuras pueden mantenerse temporalmente.
4	Moderado	$5 \times 10^{-3}$	13 m/mes	Pueden tomarse medidas correctoras. Las estructuras y edificios pueden mantenerse.
3	Lento	$5 \times 10^{-5}$	1.6 m/año	Las estructuras permanentes no resultan dañadas en general.
2	Muy lento	$5 \times 10^{-7}$	16 mm/año	Imperceptible si no es con instrumentos.
1	Extremadamente lento			Imperceptible si no es con instrumentos. Es posible la construcción con precauciones.

### 2.2.2 Susceptibilidad a los PRM

En relación con los PRM, al igual que con otros eventos, se emplean términos como peligrosidad, riesgo, susceptibilidad y vulnerabilidad; que generalmente se refiere a ellos de manera confusa (García, 2008). Por ello, se comenzará definiendo y aclarando cada término.

Se define como peligrosidad a la posibilidad de ocurrencia de un evento físico que puede causar algún tipo de daño a la sociedad, es decir, se entiende como la posibilidad de ocurrencia de un acontecimiento natural o antrópico que afecte la vida de los seres humanos (Rojas *et al.*, 2011).

El riesgo se puede definir como la probabilidad de que en un espacio ocurra un determinado peligro y que este pueda generar daños y pérdidas potenciales en las actividades humanas (Rojas *et al.*, 2011). Por ende, el riesgo sólo puede ser definido a partir del cálculo de probabilidades con datos adecuados, ya sean de tipo cuantitativos o cualitativos (Rojas *et al.*, 2011).

La vulnerabilidad es un proceso por el cual se determina la predisposición o susceptibilidad que tiene un elemento u objeto a ser afectado o sufrir una pérdida ante un peligro específico (Rojas *et al.*, 2011). La vulnerabilidad no es estática, sino un proceso dinámico en dependencia de las condiciones tanto naturales como sociales (García, 2008).

El concepto de susceptibilidad puede considerarse como la mayor o menor predisposición a que un evento ocurra sobre un determinado espacio geográfico (Soldano *et al.*, 2007). La susceptibilidad de la superficie en los PRM, se define como el favorecimiento del ambiente natural y de los factores inherentes en un espacio geográfico e indica la predisposición del terreno a desplazarse pero no implica el aspecto temporal del mismo (Navarro, 2012).

### 2.2.3 Modelos para el análisis de la susceptibilidad a PRM

De acuerdo con Van Westen *et al.*, (1997; 2000) y Jiménez (2012) existen tres tipos de modelos en el análisis de la susceptibilidad a PRM, las diferentes metodologías se pueden diferenciar en:

Modelos empíricos, particularmente adecuados para estudios regionales a pequeña escala (Jiménez, 2012). Se basan en la experiencia del responsable del análisis y la producción de mapas de susceptibilidad en base a ello; también son llamados métodos heurísticos (Jiménez, 2012). Un posible inconveniente, es que se basan totalmente en criterios de expertos para clasificar el mapa en clases de susceptibilidad, por lo que la subjetividad inherente a su elaboración es un aspecto importante a tener en cuenta (Bonachea, 2006).

Los modelos basados en parámetros físicos o procesos físicos para estudios de detalle son los modelos deterministas (Jiménez, 2012). Consisten en análisis de estabilidad de laderas generalmente enfocados a la evaluación del factor de seguridad (Jiménez, 2012). Se utilizan principalmente para determinar la estabilidad de un talud o ladera, donde las condiciones geomorfológicas y geológicas son homogéneas, y donde se pueden aplicar las leyes físicas necesarias para aplicar los modelos de estabilidad (Bonachea, 2006). Tienen el inconveniente de que su aplicación a grandes áreas es costoso lo que les hacen económicamente inviables (Bonachea, 2006).

Los modelos estadísticos cuantitativos, o métodos basados en el inventario de movimientos de ladera son adecuados para estudios regionales a mediana escala, se pueden considerar como métodos empíricos más objetivos que el heurístico (Jiménez, 2012). Permiten una mejor comprensión de las relaciones entre los movimientos de ladera y sus factores condicionantes o determinantes (Jiménez, 2012). En el análisis estadístico, la combinación de factores que condiciona los movimientos de ladera en el pasado, son determinados estadísticamente, y las predicciones cuantitativas pueden ser hechas para áreas actualmente libres de movimientos, en las cuales existen unas condiciones similares a las pasadas

(Jiménez, 2012). Las ventajas de los modelos estadísticos son que han demostrado tener un alto grado de éxito para identificar zonas propensas a PRM, un costo económico menor en su ejecución en comparación con el modelo determinístico y una mayor precisión de la relación entre los factores espaciales respecto al heurístico (Komac, 2006). Los métodos estadísticos se dividen, en bivariantes y multivariantes (Jiménez, 2012):

Las metodologías estadísticas bivariantes consideran un factor dependiente, en este caso la ocurrencia de PRM, y uno independiente; La importancia o peso de cada factor independiente es analizada por separado (García, 2008). El método bivalente se basa fundamentalmente en la cuantificación de los factores más influyentes o importantes, que son susceptibles a PRM, mediante el cálculo de la densidad de PRM para cada variable, o el peso específico de cada factor (García, 2008).

Las metodologías estadísticas multivariantes estudian la interacción y dependencia de un conjunto de factores dependientes que actúan simultáneamente a la ocurrencia de PRM para establecer el grado de implicación que tiene cada uno de ellos (García, 2008).

Existen otras metodologías que según García (2008), no se consideran dentro de los métodos que propone Van Westen *et al.*, (1997, 2000), estas metodologías pueden denominarse como metodologías estadísticas alternativas, las más comunes suelen ser las redes neuronales, modelos fuzzy y algoritmos genéticos.

En el siguiente apartado se hablará específicamente de los modelos estadísticos: SPASTMO-SL (estadístico bivalente), regresión logística (estadístico multivariante) y red neuronal artificial (alternativo). Los cuales fueron seleccionados para el análisis de la susceptibilidad en base a los argumentos presentados en el problema de investigación.

### 2.2.3.1 Modelo de análisis espacial para deslizamientos superficiales (SPASTMO-SL)

El modelo SPASTMO-SL de Muñiz-Jáuregui *et al.*, (2014) basado en Morales (2013) zonifica la susceptibilidad a los PRM superficiales como patrón que está en función de las relaciones espaciales que existen entre los PRM registrados en un mapa inventario y los factores que condicionan la inestabilidad de laderas. Otra característica es que regionaliza la superficie de estudio en unidades espaciales que comparten características homogéneas de terreno o de paisaje. El modelo general se explica con la siguiente expresión (Ecuación 1).

$$S_U = \sum_{i=1}^n [WR_i * (f(PR_i))] \quad (1)$$

Donde  $S_U$  = susceptibilidad a PRM por unidad de paisaje,  $WR_i$  = peso de relación  $i$ ,  $f(PR_i)$  = función de preferencia para la relación  $i$ ,  $n$  = número de relaciones que integran el modelo.

El proceso metodológico para la elaboración del modelo y sus insumos se compone de ocho etapas (Tabla 3).

Tabla 3. Modelo metodológico del SPASTMO-SL modificado.

N°	Etapa	Objetivos
1	Elaboración del mapa inventario	*Identificar PRM. *Localizar los PRM. *Obtener la distribución espacial de los PRM
2	Elaboración de unidades de paisaje	*Obtener unidades heterogéneas que compartan características particulares (factor principal en la ocurrencia de PRM). *Obtener unidades heterogéneas.
3	Elaboración de cartografía de factores condicionantes elegidos	*Obtener la cartografía correspondiente a los factores condicionantes elegidos.

4	Evaluación del nivel de significancia	<ul style="list-style-type: none"> <li>* Comprobar para cada unidad de paisaje que los valores correspondientes a los factores condicionantes resulten significativos.</li> <li>*Evaluar el nivel de significancia de los factores condicionantes para cada unidad de paisaje.</li> <li>*Selección de factores condicionantes para cada unidad de paisaje con una significancia menor a 0.05. Pueden emplearse significancias menores de 0.10 o hasta 0.20.</li> </ul>
5	Búsqueda de función de preferencia	*Buscar la función que modela la preferencia de valores donde ocurren los PRM, para cada factor condicionante.
6	Ponderación de factores condicionantes	*Aplicar valores de ponderación a la cartografía de probabilidad de los factores condicionantes usando los valores de significancia normalizados.
7	Integración de mapas por unidad de paisaje	*Elaborar un mapa de susceptibilidad a PRM para cada unidad de paisaje, resultado de la suma de las cartografías ponderadas de los factores condicionantes.
8	Integración del mapa final	*Obtener un solo mapa de susceptibilidad a PRM para toda la zona de estudio.

### 2.2.3.2 Regresión logística

La función de regresión se puede considerar como un proceso para extraer los coeficientes de relaciones empíricas a partir de observaciones (Hosmer y Lemeshow, 2000). Comúnmente los métodos de regresión usados incluyen regresión lineal, regresión logarítmica y regresión logística (RL) (Hosmer y Lemeshow, 2000). La RL es una técnica estadística que involucra una o más variables independientes explicativas lo cual ayuda a predecir la probabilidad con base a una respuesta binaria o categórica (Hosmer y Lemeshow, 2000). Este enfoque de modelización se usa para describir la relación entre varias variables independientes y una variable dependiente dicotómica (Hosmer y Lemeshow, 2000). El objetivo de la RL es encontrar el mejor modelo para describir la relación entre una variable dependiente y múltiple variables independientes que han sido

identificados (Lee, 2005). La RL establece la probabilidad de presencia de un evento de acuerdo con los valores de las variables de predicción que se han observado (Lee, 2005). La variable dependiente de la RL podría ser binaria o categórica, y las variables independientes de la RL podrían ser una mezcla de variables continuas o variables binarias categóricas; el supuesto de normalidad no es necesario para la RL (Lee, 2005). En el caso del estudio de los PRM, la RL establece una relación funcional entre la codificación binaria de la ubicación y distribución espacial de los PRM (es decir, la presencia o ausencia de un PRM) y los distintos factores que han sido identificados como variables condicionantes para el desarrollo de los PRM (Ozdemir y Altural, 2013). La fórmula general de la RL inicia a partir de la ecuación de la regresión lineal (Ecuación 2):

$$z = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_mX_m \quad (2)$$

Donde “z” es una función lineal resultado de la suma de la combinación de las variables explicativas, peso y el valor constante, “a” es un valor constante del modelo, “ $b_1, b_2, \dots, b_m$ ” son los coeficientes de regresión o pesos que deben ser estimados y “ $X_1, X_2, \dots, X_m$ ” son variables independientes explicativas, (Hosmer y Lemeshow, 2000).

$$\text{logit}(P) = \ln \left[ \frac{P}{1-P} \right] = z \quad (3)$$

La función logit (P) es la función de enlace o transformación logística de la función lineal (Ecuación 3) para el cálculo de las probabilidades binomiales limitadas entre 0 y 1. “P” indica la probabilidad del éxito en un suceso, “1-P” la probabilidad de fracaso del suceso.

$$P = \frac{1}{1 + e^{-z}} = \frac{e^{a + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_mx_m}}{1 + e^{a + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_mx_m}} \quad (4)$$

La regresión logística es la derivada de “P” con respecto a “ $X_m$ ” (Ecuación 4), recordando que “P” es igual a f(x). Este último paso la regresión logística trata de explicar la probabilidad de éxito (p) cuando el valor de la variable predictora es  $X_m$ .

### 2.2.3.3 Red neuronal artificial

La metodología estadística de la red neuronal artificial (RNA) tiene algunas ventajas en comparación con otros métodos estadísticos, es independiente de la distribución estadística de los datos (Pradhan y Lee, 2010). La RNA es un "mecanismo computacional capaz de adquirir, representar y calcular una asignación desde un espacio multivariado de información a otro, dado un conjunto de datos que representen esa asignación" (Atkinson y Tatnall, 1997). Son un intento para imitar de manera sencilla el funcionamiento del sistema neuronal del cerebro humano (Kavzoglu y Mather, 2000). La RNA tiene la habilidad de manejar datos imprecisos y difusos, por lo que pueden trabajar con datos continuos, categóricos y datos binarios (Gómez y Kavzoglu, 2005). La RNA de tipo perceptrón multicapa (MLP), es la más frecuentemente utilizada, consta de una capa de entrada, una capa oculta, y una capa de salida (Pradhan, y Lee, 2010). Se compone de un conjunto de nodos que se llaman elementos de proceso (EP), los EP se propagan a través de conexiones que funcionan como caminos unidireccionales y son activados mediante una función de transferencia de una capa a otra (Pradhan, y Lee, 2010). Las neuronas de la capa oculta y la capa de salida procesan sus valores multiplicando cada entrada por un peso correspondiente, sumando el producto para posteriormente activar la suma mediante una función de transferencia no lineal para producir un resultado; lo mismo sucede entre la capa de entrada y la capa oculta (Pradhan y Lee, 2010). En la fase de entrenamiento, una RNA aprende ajustando los valores de ponderación entre las neuronas en respuesta a los errores de los valores de salida de cada una de ellas y los errores de la neurona de salida de destino; al final de esta fase, la RNA proporciona un modelo que debería ser capaz de predecir un valor objetivo de un determinado valor de entrada. (Pradhan y Lee, 2010).

Las salidas de cualquier modelo que adopta la RNA puede ser considerada como el valor de pertenencia de los miembros de cada unidad con respecto a un evento (Ermini *et al.*, 2005). La ecuación (Ecuación 5) define a la capa de salida puede expresarse como:

$$L_s = f(\sum_{r=1}^n w_{ir} f(\sum_{j=1}^m v_{rj} u_j + b_r) + c_y) \quad (5)$$

Donde “ $u$ ” representa los vectores de entrada (variables analógicas o digitales), “ $m$ ” el número de neuronas de la capa de entrada, “ $v_r$ ” el vector de pesos que representan la intensidad de interacción de cada entrada con la neurona, “ $w_i$ ” el vector de pesos que representan la intensidad de interacción de cada capa oculta con la neurona, “ $n$ ” el número de neuronas de la capa oculta, “ $b_r$ ” y “ $c_y$ ” el umbral de error o el nivel mínimo que debe alcanzarse en el combinador lineal para que la neurona se active, “ $f$ ” la función de activación o de transferencia que proporciona el estado de activación actual de la neurona en función del peso post sináptico y el estado anterior de la neurona y “ $L_s$ ” la función de salida (figura 7).

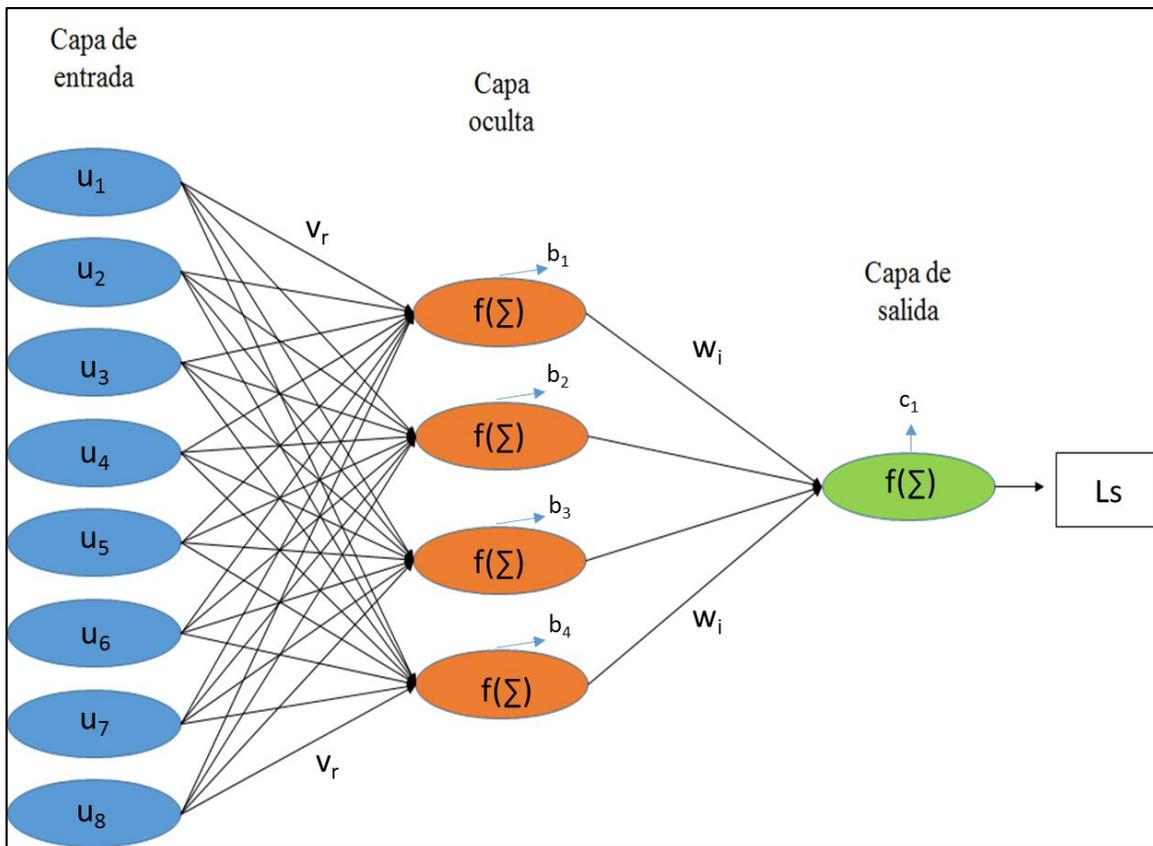


Figura 7. Estructura de Red Neuronal Artificial de tipo perceptrón multicapa

#### 2.2.4 Métodos para la validación de modelos de susceptibilidad

Los métodos aplicados en la validación de los mapas de susceptibilidad a PRM son: el método de precisión, la matriz de confusión, la validación cruzada, el método de predicción, índice de área de celda (SCAI), la validación R y la curva característica operativa del receptor (ROC).

El método de precisión se basa en obtener datos estadísticos a partir de una simple sobreposición entre la existencia o no de polígonos de PRM y las diferentes zonificaciones creadas por el modelo (Sharma *et al.*, 2014; Irigaray *et al.*, 2007; Armaş, 2012).

La validación cruzada (Golub *et al.*, 1979; Kohavi, 1995) es una técnica estadística que crea particiones de una muestra de datos, en subconjuntos tales que el análisis se realiza inicialmente en un único subconjunto, mientras que el otro subconjunto se conserva para su posterior uso en la confirmación y validación del análisis inicial. La validación cruzada genera un gráfico entre la porción de área de PRM de las clases especificadas de susceptibilidad y la porción total de la superficie real de PRM (Davis *et al.*, 2006). En este método los PRM asignados al azar en el grupo de estimación y validación se pueden intercambiar y el procedimiento de validación cruzada se repite para obtener una segunda comparación, que proporciona una medida de la incertidumbre en la validación (Davis *et al.*, 2006).

La matriz de confusión es representada en una tabla que muestra el número de incidencias correctamente clasificados comparándolos contra los casos que son mal clasificados por el modelo (Tsangaratos y Benardos, 2014). Las medidas del rendimiento se basan en cuatro parámetros obtenidos de la aplicación del clasificador para el equipo de prueba, estos parámetros son llamados verdaderos positivos “tp”, falsos positivos “fp”, verdaderos negativos “tn” y falsos negativos “fn” (Tsangaratos y Benardos, 2014; Tabla 4). Dependiendo de la aplicación se calculan datos estadísticos en particular (Tabla 5): Exactitud, precisión, recuperación e índice “F” (Tsangaratos y Benardos, 2014).

Tabla 4. Matriz de confusión. Fuente: Tsangaratos y Benardos, 2014

		PRM en el modelo de susceptibilidad	
		Positivo	Negativo
PRM reales en el terreno	Positivo	tp	fn
	Negativo	fp	tn

Tabla 5. Índices de validación en la matriz de confusión. Fuente: Tsangaratos y Benardos, 2014

Índice estadístico	Ecuación	Descripción
Exactitud	$E = \frac{tp + tn}{tp + fp + tn + fn}$	Se define como la proporción de resultados verdaderos (tanto verdaderos positivos y verdaderos negativos) en la población.
Precisión	$P = \frac{tp}{tp + fp}$	Se define como el número de casos positivos recuperados sobre el total número de casos positivos declarado por el clasificador
Recuperación	$R = \frac{tp}{tp + fn}$	Se define como el número de casos verdaderos positivos recuperados sobre el número total de casos que son positivos en el conjunto
Índice F	$F - m = \frac{2tp}{2tp + fp + fn}$	Una medida única que combina precisión y la recuperación, puede ser se utiliza como un valor de medición del rendimiento global de los modelos.

El método de predicción toma en cuenta las frecuencias expresadas en porcentaje de PRM reales en las clases clasificatorias de susceptibilidad; generalmente las clases utilizadas son no evento, bajo, moderado y alto. El porcentaje total de validación lo define la presencia total de PRM en las diferentes categorías (Chu *et al.*, 2009).

El SCAI es una técnica de validación utilizada para evaluar mapas de susceptibilidad a diferentes escalas (Suzen y Doyuran ,2004). Se calcula mediante la normalización de los porcentajes de área para cada clase de susceptibilidad a PRM por los porcentajes de celdas de PRM reales. La colección de celdas de PRM dentro de una clase de susceptibilidad también se denomina celdas semillas. Las clases altas de susceptibilidad tendrán valores bajos SCAI y por el contrario las clases bajas de susceptibilidad tendrán valores altos SCAI. El SCAI se ha utilizado para la validación de mapas de susceptibilidad en estudios previos (Nefeslioglu *et al.*, 2008; Suzen y Kaya, 2012; Yilmaz *et al.*, 2012 y Yilmaz, 2009).

La validación R es un índice de PRM obtenido por el porcentaje de la relación de PRM en cualquier categoría, dividida por la relación total de PRM de la superficie total de área de estudio (Ecuación 6). El índice de PRM se define de la siguiente manera (Van Westen *et al.*, 2002).

$$Li = \left( \frac{Si}{Ai} \right) / \left( \left( \sum_i^n \frac{Si}{Ai} \right) \right) * 100 \quad (6)$$

En la ecuación 4,  $Li$  es el índice de susceptibilidad de PRM,  $Si$  es el área de PRM en cada categoría,  $Ai$  es el área de cada categoría, y  $n$  es el número de categorías de susceptibilidad.

Con el fin de comparar los mapas de zonificación obtenidos, considerado el parámetro para la precisión en la predicción de resultados ( $P$ ) (Ayalew *et al.*, 2005). La precisión de la predicción en los resultados puede ser estimada por la siguiente relación (Ecuación 7).

$$P = \frac{Ks}{S} \quad (7)$$

En la ecuación 7, “ $Ks$ ” es el área de la zona susceptible de PRM y “ $S$ ” es el área de PRM en la región.

Una alternativa más es la curva ROC este método ya se usa ampliamente como una medida del rendimiento de una regla de predicción en los PRM (Yesilnacar y Topal 2005; Van Den Eeckhaut *et al.*, 2006). La técnica de la curva ROC se basa en el trazado de valores del modelo de sensibilidad (fracción verdadera positiva) calculada para diferentes valores de umbral frente a los valores de especificidad de fracción negativa representados en una gráfica (DeLeo, 1993). El modelo de sensibilidad (fracción verdadera positiva) es la relación entre los datos de presencia de PRM correctamente clasificados y todos los datos de presencia de PRM reales, mientras que el modelo especificidad (fracción verdadera negativa) es la relación entre celdas correctamente clasificados sin PRM y todas las celdas sin PRM reales (DeLeo, 1993). El área bajo la curva ROC (AUROC) es un estimador de la exactitud del modelo (Hosmer y Lemeshow, 2000). Esta curva se obtiene mediante el trazado

de todas las combinaciones de sensibilidades y proporciones de falsos negativos (1-especificidad) que pueden estar en el umbral de decisión (Hanley y McNeil 1983). El rango de valores en la zona de la curva ROC es de 0.5 a 1 para un buen ajuste, mientras que valores por debajo de 0.5 representan un ajuste aleatorio (Hanley y McNeil 1983).

## Capítulo 3: Área de estudio

### 3.1 Ubicación geográfica

La delimitación del área de estudio correspondió al municipio de Los Cabos ampliada al parteaguas de las cuencas que delimitan a la reserva de la Biosfera Sierra de la Laguna (figura 8). El área de estudio limita al norte con el municipio de La Paz; al sur y al este con el golfo de California y al oeste con el océano Pacífico. Sus coordenadas geográficas máximas y mínimas son 23° 39' 55", -109° 42' 10" al norte, 22° 52' 20", -109° 57' 48" al sur, 23° 23' 13", -109° 24' 47" al este y 23° 02' 54", -110° 06' 20" al oeste. Las alturas con respecto al nivel medio del mar varían entre 0 y 2082 metros (INEGI, 2016).

La superficie total del área de estudio es de 3,815.63 km<sup>2</sup>. El municipio está dividido en cuatro delegaciones: Santiago, La Ribera, Miraflores y Cabo San Lucas (INEGI, 2016). La cabecera municipal es la ciudad de San José del Cabo.



Figura 8. Ubicación del área de estudio. Fuente: Propia a través de datos de INEGI

### 3.2 Características de las pendientes

Está dominada por un paisaje de valles y planicies que se caracterizan por pendientes ligeras y muy ligeras (45.15 %), menor de 5 grados en promedio. Estos valles y planicies son localmente controlados por un sistema montañoso de pendientes con inclinación fuerte, muy fuerte y abruptas que abarca el 38.14 % de la región, el promedio de inclinación es de 25 grados (figura 9). El perfil y plano de inclinación varía poco, frecuentemente muestran elementos convexos (48.18 % y 51.28 %, respectivamente) y cóncavos (51.28 % y 47.91 % respectivamente). En la orientación de la pendiente existe una predominancia de las direcciones sureste (16.5 %), este (14.8 %) y sur (13.8 %).

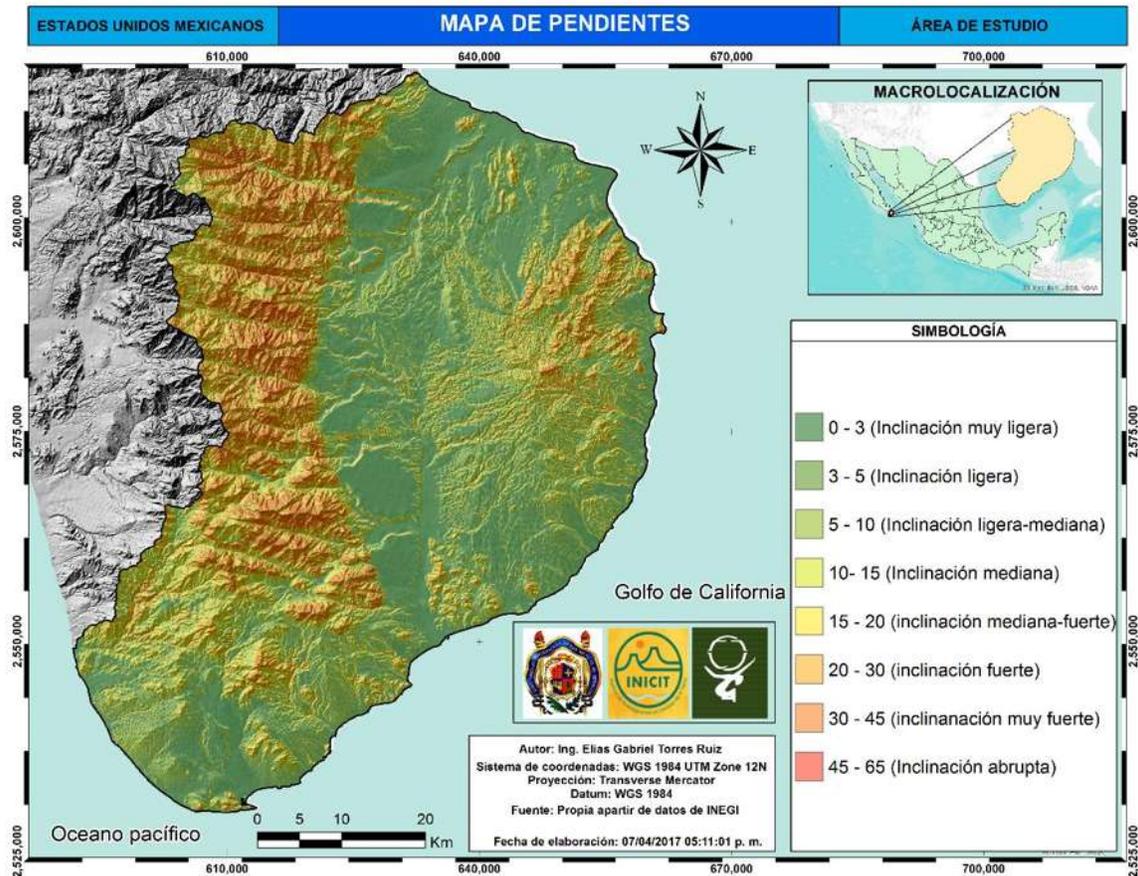


Figura 9. Mapa de pendientes. Fuente: Propia a partir de datos de INEGI

### 3.3 Geología

La geología se ubica en un rango geo cronológico que comprende las eras mesozoica y cenozoica, en la segunda era sobre los periodos plioceno y cuaternario (Mina, 1957; McFall, 1968; Chávez, 1978). Las agrupaciones geológicas más representativas (figura 10) según información del Servicio Geológico Mexicano (2002) son:

- Las rocas ígneas intrusivas (60.78 %) del mesozoico como granitos K (Gr) y granodiorita tonalita K (Gd tn), así como granitos del cenozoico T (Gr).
- Las rocas sedimentarias del cenozoico cuaternario (11.81 %) que representan conglomerados Q (cg), forman abanicos pluviales como depósitos de poca compactación.
- Las areniscas del cenozoico terciario (TmplAr-Cq) que se presentan en forma de abanicos o terrazas aluviales (8.62 %).

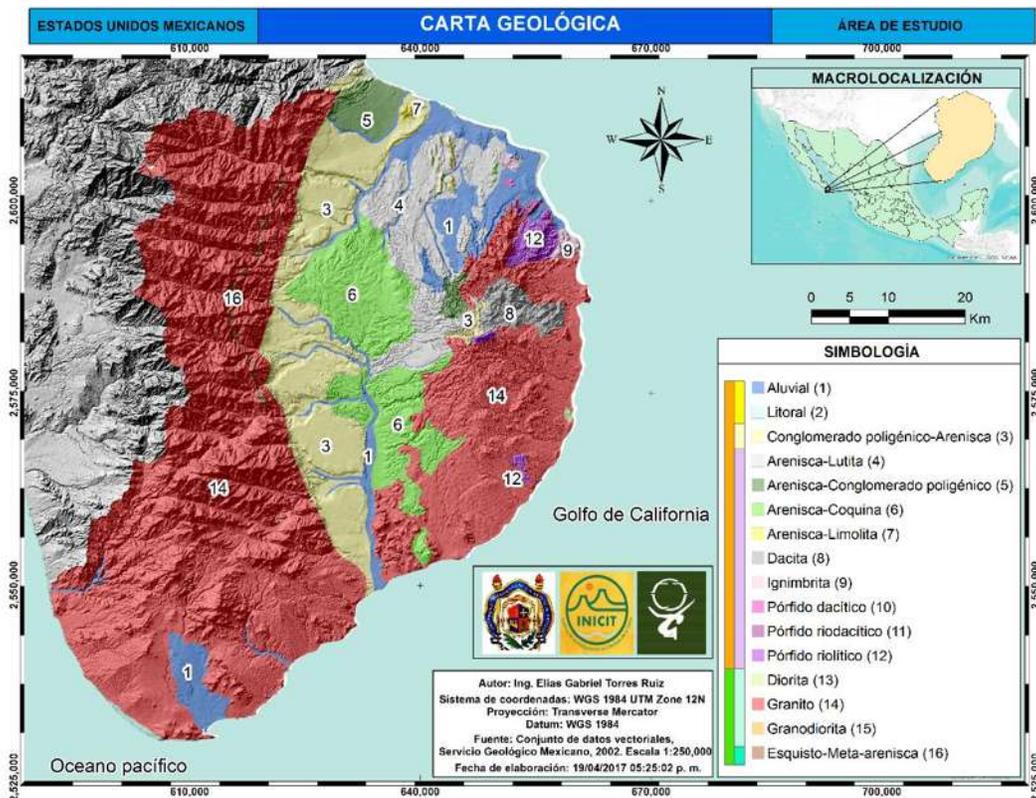


Figura 10. Carta geológica del área de estudio, Fuente: SGM, 2002.

### 3.4 Edafología

Los tipos de suelo predominantes son los Regosoles (49.77 %) y Leptosoles (37.93 %), ambos tienen la principal característica de ser suelos someros y contienen una textura gruesa; los primeros son suelos muy jóvenes, generalmente resultado del depósito de roca y arena productos de la erosión por consiguiente se encuentran en las partes bajas: pie de laderas y planicies; los segundos son suelos no desarrollados y su escasa profundidad los vuelve muy áridos (INEGI, 2004). Otras tipología de suelo (figura 11) que se observan en menor extensión territorial son: Arenosol (0.72 %) y Calcisol (1.28 %); restringidos prácticamente a zonas áridas y semiáridas cubierta por matorrales y pastizales, Fluvisol (9.47 %); situados en las llanuras aluviales o fondos de valles, y pequeñas unidades de Phaeozem (0.69 %) y Solonchak (0.14 %) (INEGI, 2004).

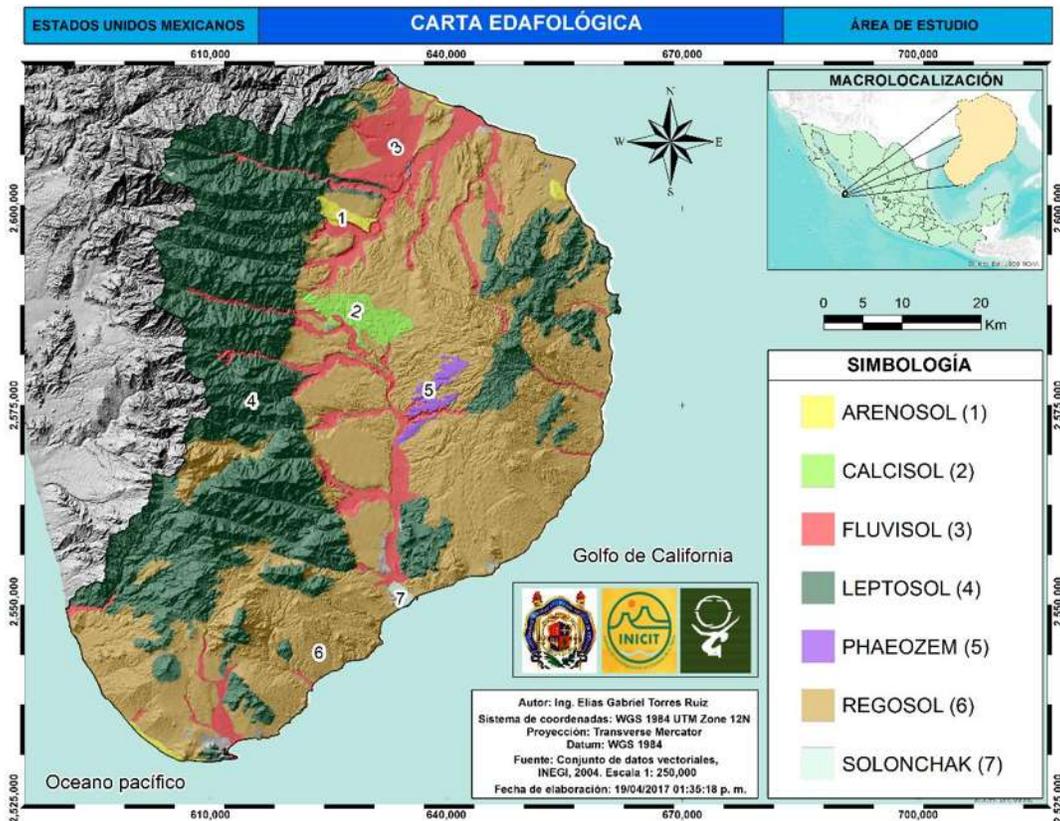


Figura 11. Carta edafológica del área de estudio, Fuente: INEGI, 2004.

### 3.5 Hidrología

En materia de hidrología el área de estudio se encuentra ubicado dentro de la Región Hidrológica RH06 Baja California Sureste y RH03 Baja California Suroeste (figura 12), La Paz y Magdalena respectivamente, dentro de las Subcuencas RH06 Aa Cabo San Lucas (456.87 km<sup>2</sup>), RH06 Ab río San José (1,277.58 km<sup>2</sup>), RH06 Ac Arroyo Santiago (1,569.05 km<sup>2</sup>), RH06 Ad Las Palmas (164.70 km<sup>2</sup>) y RH03 Aa Arroyo Candelaria (348.27 km<sup>2</sup>). Se tienen contabilizadas 7238 corrientes, de las cuales el 95 % se caracterizan por ser de tipo intermitente. Los porcentajes del orden de corriente son: orden 1 = 63.64 %, orden 2 = 21.28 %, orden 3 = 8.69 %, orden 4 = 3.58 %, orden 5 = 2.20 % y orden 6 = 0.62 %.

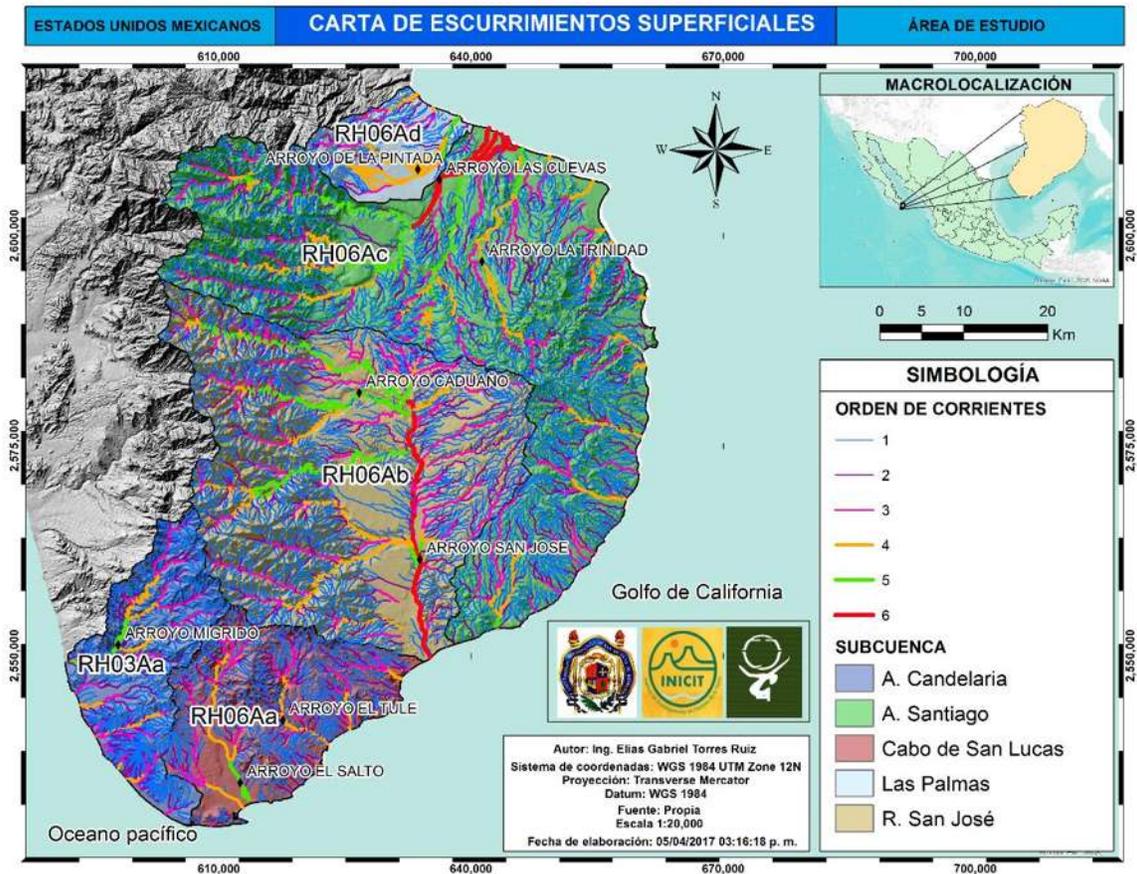


Figura 12. Carta de escurrimientos superficiales del área de estudio, Fuente: Propia

### 3.6 Clima

De acuerdo con el Sistema de Clasificación Climática utilizado por Köppen (1936), modificado por Enriqueta García (1973) y por INEGI (1976), para adaptarlo a las condiciones de México escala 1: 1,000,000 el municipio presenta climas de tipo muy seco cálido (BW(h')hw(x')), muy seco muy cálido (BW(h')w), muy seco semicálidos (BWhw), seco cálido (BS0(h')hw), seco semicálidos (BS0hw), semisecos semicálidos (BS0hw(w)) y templado subhúmedo (C(w1) y C(w0); figura 13). La transición de cálidos a semicálidos hasta llegar a los templados subhúmedos se va generando a medida que aumenta la altura del terreno (INEGI ,1976). El análisis de la temperatura y precipitación se realizó a través de los datos históricos de 20 estaciones meteorológicas de Servicio Meteorológico Nacional (SMN).

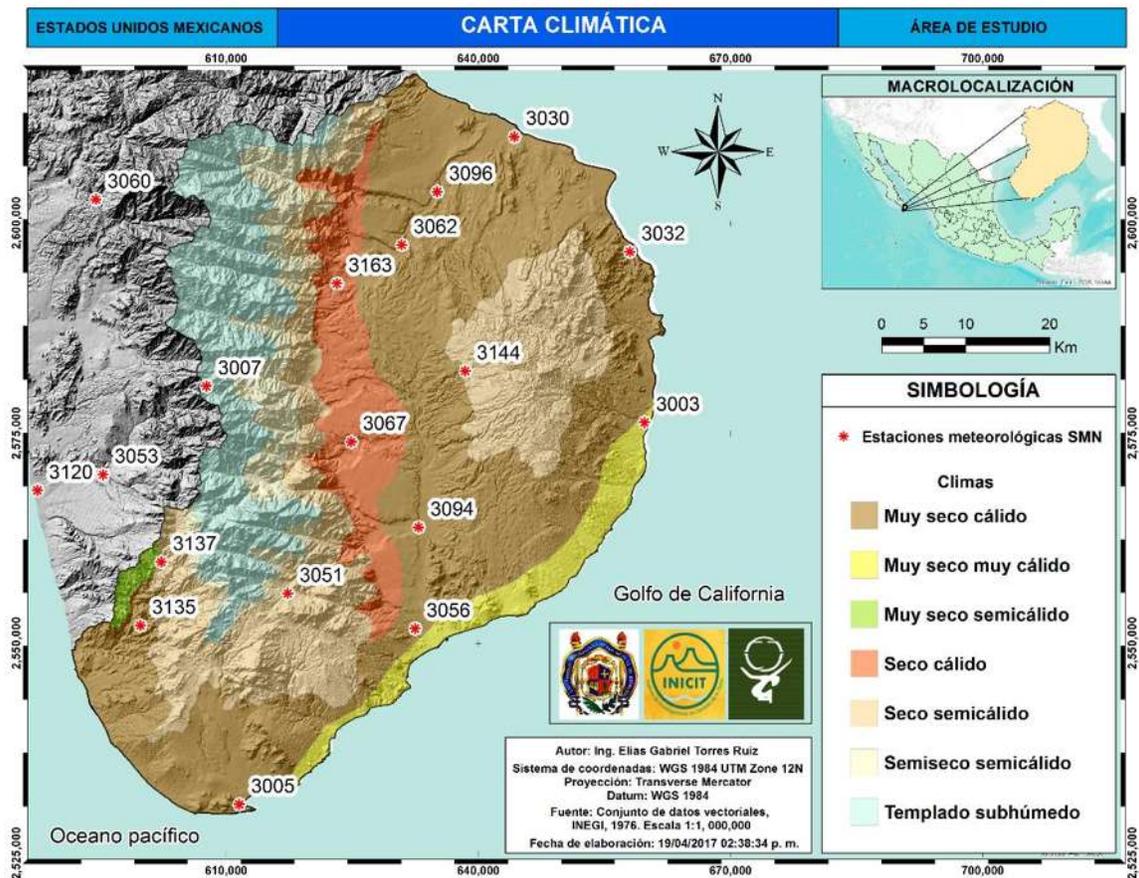


Figura 13. Carta de climas. Fuente: INEGI, 1976.

Las estaciones meteorológicas utilizadas para el análisis fueron: 3163 (Agua Caliente), 3003 (Boca del Salado), 3005 (Cabo San Lucas), 3007 (Caduaño), 3135 (La Candelaria), 3137 (La Soledad Sur), 3032 (Las Barracas), 3096 (Las Cuevas), 3143 (Las Palmas), 3144 (Mangle), 3120 (Plutarco Elías Calles), 3030 (La Ribera), 3050 (San Bartolo), 3051 (San Felipe), 3053 (San Jacinto), 3056 (San José del Cabo), 3094 (Santa Anita), 3060 (Santa Gertrudis), 3062 (Santiago), 3067 (Yeneka).

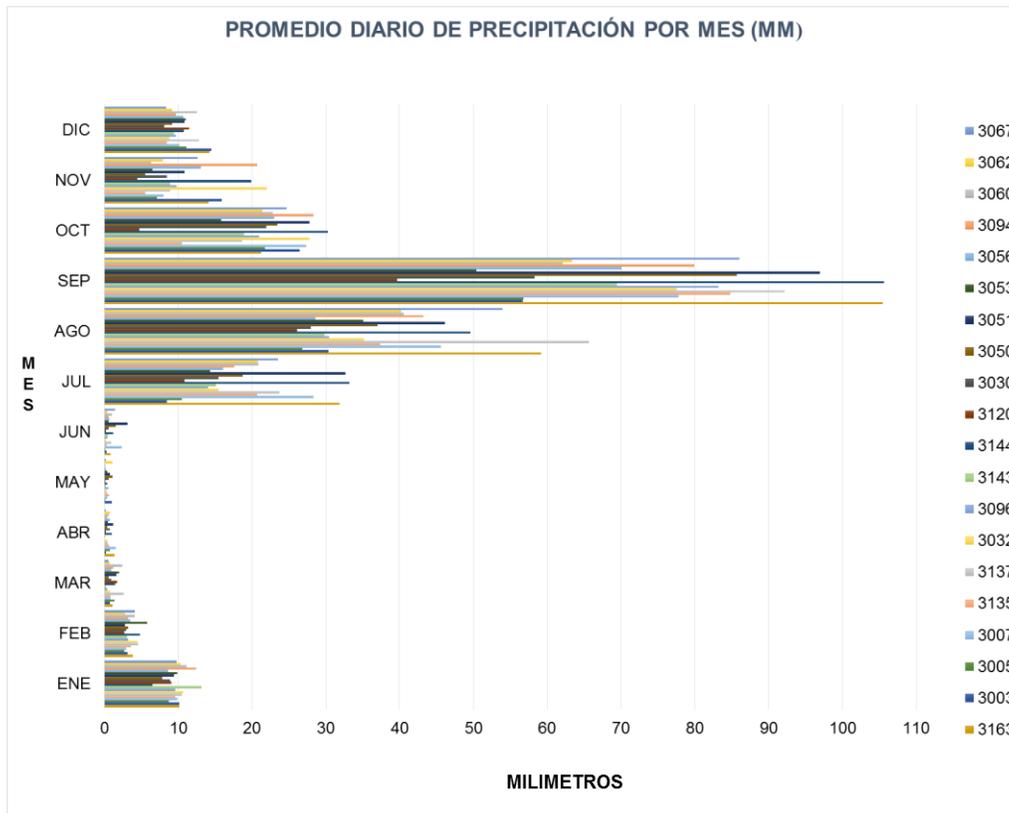


Figura 14. Promedio diario de precipitación por mes

La precipitación máxima promedio en 24 hrs va desde los 0 a los 105.60 mm, para los meses más lluviosos varía de 4.75 a 105.60 mm (figura 14), el promedio de precipitación mensual va de los 0.5 mm a los 141.9 mm (figura 15), siendo los meses más lluviosos julio, agosto, septiembre y octubre; la cantidad mínima de precipitación máxima promedio en 24 hrs para el mes de septiembre es de 39.64 mm. Los gradientes de la temperatura media mensual van de los 17.8° C a los 28.7° C, siendo los meses con mayor promedio mensual de temperatura julio, agosto y septiembre con valores mayores a 27.8 °C (figura 15).

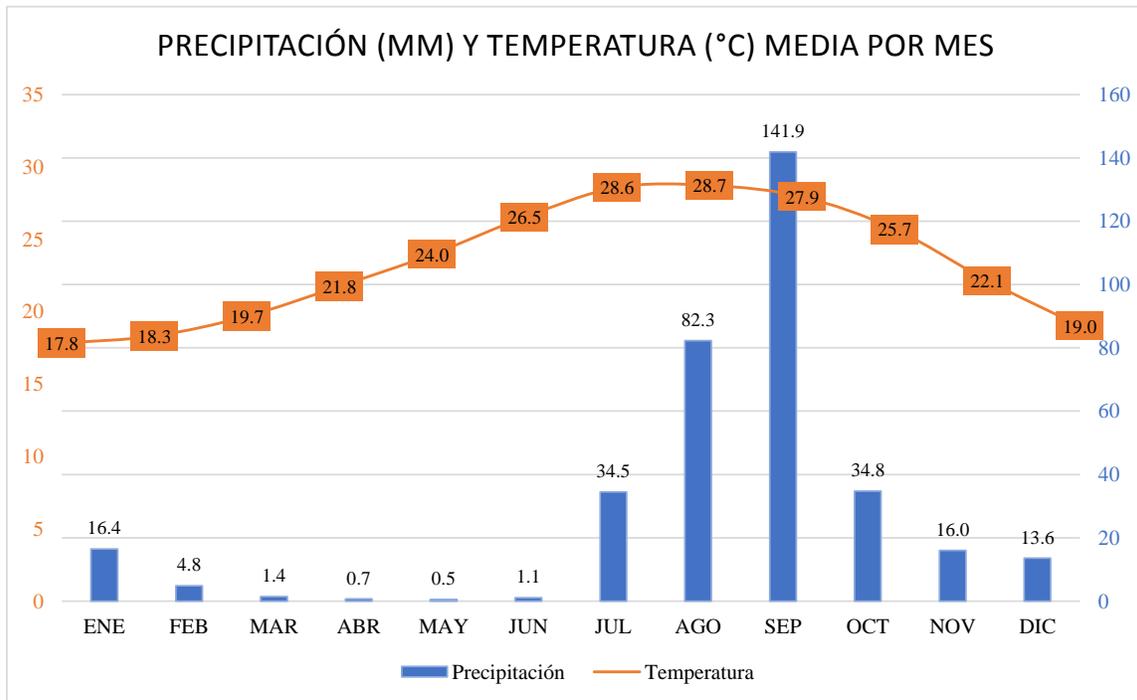


Figura 15. Precipitación y temperatura media por mes

Las temperaturas mínimas van desde los  $-5^{\circ}\text{C}$  a los  $7^{\circ}\text{C}$ , registrándose las menores temperaturas para el mes de enero donde el máximo y mínimo valor es de  $18^{\circ}\text{C}$  y  $-3^{\circ}\text{C}$ , respectivamente. Las temperaturas máximas van de  $39^{\circ}\text{C}$  a  $49.5^{\circ}\text{C}$ , el periodo que se ve afectado por las altas temperaturas comprende de los meses de junio a noviembre (figura 16).

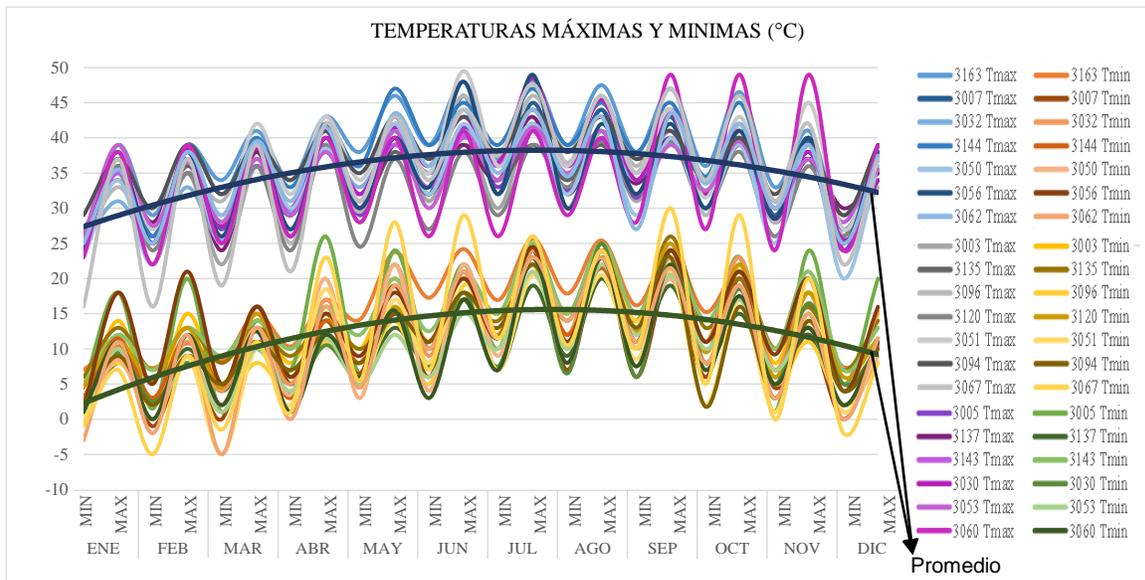


Figura 16. Registro de temperaturas máximas y mínimas

## Capítulo 4: Metodología

### 4.1 Metodología general

A continuación se describe en forma general el esquema metodológico utilizado para realizar este estudio (figura 17)

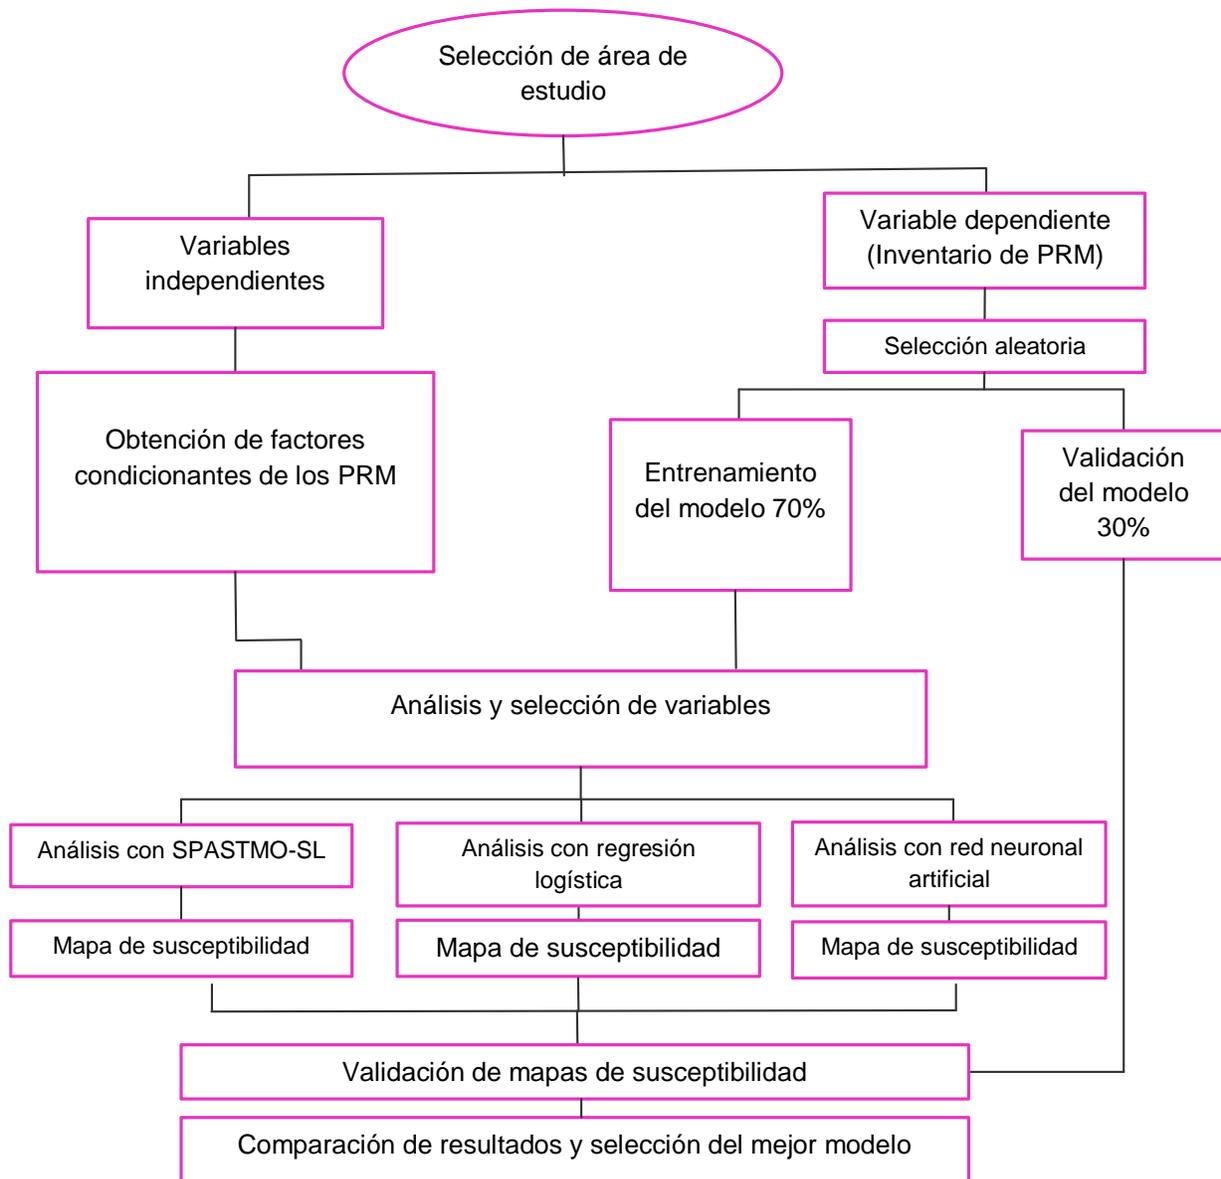


Figura 17. Metodología para evaluar y validar la susceptibilidad a PRM

## 4.2 Mapa inventario de PRM

El inventario de PRM fue el resultado del análisis y digitalización de los PRM en los años 2014, 2015 y 2016 a partir de imágenes satelitales Spot Imagery 2.5 m y Digital Globe 2.5 m ; incluyendo reconocimiento en campo. La escala de interpretación empleada fue 1:2,000.

En primera instancia se definió el contenido del inventario (tipo de evento, tipo de material, fecha de imagen), mismo que se utilizó para generar la base de datos ligada a la cartografía digital. La cartografía digital se construyó de 2 maneras: dato puntual y dato poligonal; el puntual, establece la zona de escarpe principal del PRM y el poligonal representa el área total del PRM. La elaboración se realizó en tres etapas:

- Digitalización de PRM mediante el uso de puntos y polígonos a través de la herramienta de edición del paquete Arcmap 10.3 de ESRI e imágenes satelitales Spot imagery con una resolución espacial de 2.5 m obtenidas a través de su servicio de mapas online.
- Trabajo de campo. Se realizó un recorrido sobre las diferentes unidades de relieve para verificar y actualizar el inventario de PRM. Las coordenadas empleadas en el levantamiento y ubicación de cada PRM fueron UTM zona 12, para lo cual se utilizó un GPS de marca GARMIN con precisión de 3 metros.
- Digitalización de PRM. Se observaron parámetros descriptivos (color, textura, patrón, forma, etc.) de los PRM cartografiados en campo sobre las imágenes satelitales Digital globe 2.5 m, obtenidas del plugin Open layer plugin del Software QGIS 2.14.0 Essen y Google Earth y en base a ello se realizó una nueva digitalización con las herramientas de edición del paquete QGIS 2.14.0.

El inventario se dividió de manera aleatoria en dos grupos, para efecto de los análisis posteriores: entrenamiento y validación, el primer grupo contiene el 70% de los PRM y el segundo grupo el 30% de ellos.

### **4.3 Modelación de la susceptibilidad**

Para realizar la modelación y el análisis con SPATSMO-SL, regresión logística, y red neuronal artificial fue necesario el inventario de PRM; el cual actúa como la variable dependiente en las ecuaciones y también se requirió de un conjunto de variables independiente. Para este aspecto en nuestro estudio inicial se elaboró la cartografía raster de 27 factores condicionantes (Tablas 7 y 8) estandarizada a una resolución espacial de 10 m, para ello fue necesario preparar y generar previamente cartografía vectorial de caminos, escurrimientos, lineamientos geológicos, vegetación y uso de suelo y geomorfología. También fue de vital importancia, obtener información de cartografía geológica, edafológica, Modelo digital de elevación (MDE) en formato raster, curvas de nivel, imágenes satelitales Landsat 8 OLI, imágenes Spot Imagery y Digital Globe.

#### **4.3.1 Insumos cartográficos**

Los insumos fueron obtenidos de diversas fuentes, los datos vectoriales de lineamientos geológicos escala 1:20,000 fueron digitalizados a partir del modelo de sombras proporcionado por el INEGI. Los datos vectoriales de caminos y carreteras escala 1:20,000 fueron digitalizados a partir de imágenes SPOT Imagery 2.5m y Digital Globe 2.5m a 10m aprox. y trabajo de campo. Los datos vectoriales de escurrimientos escala 1:20,000 fueron digitalizados con el mismo método que el insumo anterior.

Los datos vectoriales de vegetación y uso del suelo escala 1:50,000 son una actualización de la carta de vegetación y uso de suelo serie V escala 1:250,000 del INEGI su proceso de elaboración consistió como primer paso en el entrenamiento de 50 puntos por cada clase de vegetación y uso de suelo con respecto a la carta de INEGI, posteriormente la realización de una clasificación supervisada sobre las

imágenes satelitales landsat 8 del mes de junio del 2015 con una resolución espacial de 15m previamente pre procesada. La clasificación supervisada fue tomada como base para realizar la digitalización de las diferentes unidades en imágenes SPOT Imagery 2.5m y Digital Globe 2.5m y como último paso se realizó trabajo campo donde se identificaron las unidades de manera física y se efectuaron las correcciones respectivas en cartografía final de acuerdo a lo observado.

Los datos vectoriales de la geomorfología se digitalizó de manera manual pero con ayuda de la propuesta para la generación semiautomatizada de unidades de paisaje escala 1:250,000 propuesta por Priego *et al.*, 2008, imágenes Digital Globe y SPOT Imagery a 2.5 m, el modelo de elevación digital de 15 m, el modelo de sombreado de 15m obtenido del MDE, las curvas de nivel escala 1:50,000 con una equidistancia de 20m y trabajo de campo; las unidades cartografiadas fueron: Montaña (1era. subdivisión: subcuenca de orden 4, 2da subdivisión: Pendiente suave o ligera (0° a 10°, mediana (10° a 20°) y fuerte, intensa o abrupta (<20°), lomerío (2 subdivisiones: periodo geológico y su tipo de roca), pie de ladera, planicie, valle y lecho actual de río.

#### 4.3.2 Otros insumos cartográficos

Otros insumos cartográficos necesarios para el modelamiento que se recopilaron a través de instituciones como INEGI (Instituto Nacional de Estadística y Geografía) son: Modelo de elevación digital de 15m resolución espacial, conjunto de datos vectorial edafológico escala 1:250,000 Serie II, y del SGM (Servicio Geológico Mexicano) el conjunto de datos vectoriales Geológicos escala 1:250,000.

#### 4.3.3 Generación de capas temáticas de los factores condicionantes

Los 27 factores condicionantes fueron elegidos en base a la revisión previa de 134 trabajos científicos, de los cuales se extrajeron los factores que cada investigador consideró relevante para su investigación. Se encontraron un total de 53 factores condicionantes y se eligieron los 27 factores condicionantes que se observaron viables y factibles en tiempo y costo para nuestra investigación (Tabla 6).

Tabla 6. Factores condicionantes empleados para el estudio de la susceptibilidad a PRM.

ID	Factor	n°	ID	Factor	n°
1	Ángulo de inclinación de la pendiente	131	28	Índice de liquidez de suelo	4
2	Geología (unidades litológicas)	128	29	Densidad de vegetación (copa)	4
3	Orientación de la pendiente	106	30	Distancia de la superficie de escarpe principal	3
4	Vegetación y uso de suelo	105	31	Plasticidad de suelo	3
5	Distancia a ríos	88	32	Tangencial de curvatura	3
6	Elevación	85	33	Dirección de flujo	2
7	Distancia a fallas	77	34	Distancia a ciudades	2
8	Distancia a carreteras	47	35	Distancia a cuerpos de agua	2
9	Curvatura de la pendiente	43	36	Edad de vegetación	2
10	Plano de curvatura	38	37	Grado de intemperismo	2
11	Índice de humedad topográfica	36	38	índice de convergencia	2
12	Edafología	32	39	Aguas subterráneas	1
13	Unidades geomorfológicas	32	40	Áreas de unidad de drenaje	1
14	Perfil de curvatura	29	41	Cohesión de terreno	1
15	NDVI	28	42	Conductividad hidráulica	1
16	Índice de transporte de sedimentos	25	43	Densidad de carreteras	1
17	Densidad de drenaje	19	44	Densidad de construcciones	1
18	Espesor de suelos	11	45	Diámetro de copa de árboles	1
19	Acumulación de flujo	10	46	Distancia a actividades humanas	1
20	Densidad de fallas	10	47	Distancia a cultivos	1
21	Longitud de la pendiente	10	48	Foliación de roca	1
22	Rugosidad del terreno	10	49	Orden de drenaje	1
23	Radiación solar	9	50	Tamaño de vegetación	
24	Índice de transporte de sedimentos	7	51	Unidades hidrogeológicas	1
25	Longitud de flujo	6	52	Volumen de madera por hectárea	1
26	Permeabilidad del suelo	6	53	Resistencia a la compresión del suelo	1
27	Erosión de suelos	5			

#### 4.3.3.1 Factores condicionantes derivados del modelo digital de elevación (MDE)

La resolución raster empleada para la representación de estos factores fue de 10 m y se generaron con las extensiones Spatial Analyst de ArcGIS 10.3, TAUDM de QGIS 2.14.0 y Terrain Analyst de SAGA GIS 2.1.2. Las características morfológicas relacionadas con la caracterización del relieve derivados del MDE fueron (Tabla 7): ángulo de inclinación de la pendiente, orientación de la pendiente, elevación, curvatura de pendiente, plano de curvatura, índice de humedad topográfica (TWI), perfil de curvatura, índice de transporte de sedimentos (STI), índice de posición topográfica (TPI), longitud de pendiente (LS), acumulación de flujo, rugosidad de terreno, longitud de flujo, dirección de flujo, e índice de convergencia. La radiación

solar no es una característica morfológica pero también es un factor que se derivó del MDE y por ello es incluido en este apartado.

El **ángulo de inclinación de la pendiente** se obtiene con la herramienta Spatial Analysis/Surface del software Arcmap 10. 3 y se considera que indica la tangente de las tasas de cambios de la superficie en dirección horizontal ( $dz/dx$ ) y vertical ( $dz/dy$ ) desde una celda central en la pendiente (Esri, 2016).

La **orientación de la pendiente** se crea con el mismo modulo que el factor anterior e identifica la dirección de la pendiente descendente de la tasa de cambio máxima de una celda central hacia sus vecinas. Los valores de cada celda del raster de salida indican la dirección de brújula a la que apunta la superficie en esa ubicación. Se mide en el sentido de las agujas del reloj en grados de 0 (hacia el norte) a 360 (hacia el norte, nuevamente), formando un círculo completo. Las áreas planas que no tienen dirección de pendiente descendente tienen un valor de -1 (Esri, 2016).

La **elevación** representa a los valores originales del DEM y corresponde a los valores de la altura del pixel en unidades de metros con respecto al nivel medio del mar.

La **curvatura estándar** también es obtenida con la herramienta Spatial Analysis/Surface del Arcmap 10.3 y combina tanto curvaturas de perfil como de plano. Si se tienen en cuenta tanto la curvatura de plano como de perfil conjuntamente es posible comprender con más exactitud la corriente por una superficie (Esri, 2016).

La herramienta ya mencionada con anterioridad también ayudó para calcular el **plano de curvatura**, este es perpendicular a la dirección de la pendiente máxima (Esri, 2016). Un valor positivo indica que la superficie es lateralmente convexa en esa celda. Un plano negativo indica que la superficie es lateralmente cóncava en esa celda. Un valor de cero indica que la superficie es lineal (Esri, 2016).

El **perfil de curvatura** fue generado de igual manera que los dos factores anteriores y es paralela a la pendiente e indica la dirección de la pendiente máxima (Esri,

2016). Un valor negativo indica que la superficie es convexa hacia arriba en esa celda y la corriente se desacelerará. Un perfil positivo indica que la superficie es cóncava arriba en esa celda y la corriente se acelerará. Un valor de cero indica que la superficie es lineal (Esri, 2016).

Para el **índice de humedad (TWI)** se recurrió a la herramienta TauDEM/Stream Network Analysis tools del software Qgis 2.14.0 y está relacionado con la humedad del suelo y refleja la tendencia del suelo a la generación de escorrentías. Los mayores valores de TWI (mayor contenido de humedad del suelo) están en la salida de los canales de drenaje, rasgos de mayor humedad, y disminuye hacia los parteaguas (Wilson y Gallant, 2000).

Para la obtención del **índice de transporte de sedimentos (SPI)** se empleó la herramienta TauDEM/Stream Network Analysis tools del software QGIS 2.14.0 y es indicadora de la capacidad del cauce (o de la celda) de producir erosión (Moore *et al.*, 1993). A medida que se incrementa el área de captación y la magnitud de la pendiente, también se incrementa el flujo, la velocidad y la energía del flujo y consecuentemente su potencial de producir erosión.

El **Índice de posición topográfica (TPI)** se realizó con la ayuda del software SAGA GIS 2.1.2 y su herramienta Terrain Analysis -Morphometric/Topographic Position Index, el índice compara la elevación de cada celda en un MDE con un valor promedio de elevación de un área específica adyacente a dicha celda. Los valores de TPI positivos indican áreas o regiones que son más altas que sus inmediaciones (por ejemplo, lomas, serranías), mientras que los valores negativos representan áreas más bajas que sus espacios circundantes (por ejemplo, valles, bajos). Los valores próximos a 0 señalan áreas planas, puede ser también una pendiente constante, aunque con valores de pendiente significativamente mayor a 0 (Weiss, 2001).

La **longitud de pendiente (LS)** corresponde a la distancia de flujo en laderas, relacionada con el factor L en la ecuación USLE (Wischmeier y Smith, 1978) de pérdidas de suelo y es obtenida con la herramienta Spatial Analysis/Hydrology del

software Arcgis 10.3. El cálculo es la sumatoria de longitudes de flujo que se detiene cuando hay un cambio de pendiente pronunciado que indica el fin de un tramo de ladera y el reinicio del cálculo para otro tramo (Olaya, 2006).

La herramienta anterior también ayudó a generar la **acumulación de flujo**, la cual representa el área aportante o área de captación, es la superficie que, situada aguas arriba de un punto de interés, recolecta todo el flujo que recibe y lo transita por dicho punto (Abarca, 2010). Es una superficie proyectada sobre el plano horizontal y en un mapa raster se obtiene sumando todas las celdas que contribuyen con el flujo a la celda de interés, situada aguas abajo, y multiplicando por la superficie de cada celda (Abarca, 2010).

Existen varias maneras de calcular la **rugosidad del terreno**, para este estudio se recurrió al software SAGA GIS 2.1.2 y su herramienta Terrain Analysis-Morphometric /Terrain Ruggedness Index, el factor de rugosidad se refiere a la ondulación del terreno; los valores altos de la desviación estándar indican que el terreno es más irregular alrededor de las celdas que están siendo analizadas y los bajos a terrenos pocos accidentados o suaves. (Hartemink y McBratney, 2009).

La herramienta Spatial Analysis/Hydrology del software Arcgis 10.3 se empleó nuevamente para la creación de la **longitud de flujo**, la cual tiene relación con la tasa de erosión del suelo, la producción de sedimentos y el tiempo de concentración del flujo (Suet y Luan, 2004). Representa la distancia total de flujo que se calcula desde las celdas de origen hasta la celda de interés situada aguas abajo (Abarca, 2010).

La **dirección de flujo** también se obtuvo con la herramienta anterior y está determinada por la dirección del descenso más empinado, o la caída máxima, desde cada celda. La distancia se calcula entre los centros de las celdas. Por lo tanto, si el tamaño de celda es 1, la distancia entre dos celdas ortogonales es 1, y la distancia entre dos celdas diagonales es 1,414 (la raíz cuadrada de 2). Si el descenso máximo de varias celdas es el mismo, la vecindad se agranda hasta que se encuentra el descenso más empinado (Esri, 2016).

El **índice de convergencia** propuesto por Köthe *et al.*, (1996) se elaboró con la herramienta Terrain Analysis –Morphometric / Convergence Index del software SAGA GIS 2.1.2 el cual utiliza los valores del aspecto de las celdas vecinas para calcular la convergencia y divergencia del flujo, por lo que es similar a la curvatura, pero no depende de las diferencias absolutas de las alturas. Los resultados son dados en porcentajes; valores negativos corresponden a convergencia y valores positivos a la divergencia de las condiciones del flujo. Valores de -100 pueden corresponder al pico de un cono, 100 a un hueco o pozo y 0 a una zona en pendiente (Conrad, 2007).

La **radiación solar** potencial se generó con la herramienta Terrain Analysis-Lighting/Radiation Solar del software SAGA GIS 2.1.2, el cual realiza el cálculo basado en la constante solar del planeta ( $1353 \text{ W/m}^2$ ) y correcciones de efectos atmosféricos (1013 milibares). El resultado es generado en unidades de  $\text{kwh/m}^2$ , cabe mencionar que la radiación solar se generó para el mes de septiembre donde la presencia en particular de un factor detonante produce mayor cantidad de eventos.

Tabla 7. Factores condicionantes derivados del Modelo Digital de Elevación de 15 m

N°	Factor	Insumo principal	Algoritmo	Procesamiento
1	Ángulo de la pendiente	MDE	$\tan([\frac{dz}{dy}]^2 + [\frac{dz}{dx}]^2) * 57.29578$	Arcgis (Spatial Analysis/Surface)
2	Orientación de la pendiente	MDE	$57.29578 * \tan([\frac{dz}{dy}] - [\frac{dz}{dx}])$	Arcgis (Spatial Analysis/Surface)
3	Elevación	MDE	Conversión de formato vectorial a raster	Arcgis (Conversion Tools/To raster)
4	Curvatura de la pendiente	MDE	$-2(D + E) * 100$	Arcgis (Spatial Analysis/Surface)
5	Plano de curvatura	MDE	$2(DH^2 - FGH + EG^2) / (G^2 + H^2)^{3/2}$	Arcgis (Spatial Analysis/Surface)
6	Índice de humedad topográfica	MDE	$\ln("f"/"s")$ Donde: f: flow accumulation; s: pendiente	QGIS(TauDEM/Stream Network Analysis tools)
7	Perfil de curvatura	MDE	$2(DG^2 + FGH + EH^2) / (G^2 + H^2) (G^2 + H^2 + 1)^{3/2}$	Arcgis (Spatial Analysis/Surface)
8	Índice de transporte de sedimentos	MDE	$"f" * \tan("s")$ Donde: f: flow accumulation; s: pendiente	QGIS(TauDEM/Stream Network Analysis tools)
9	Índice de posición topográfica	MDE	Elev mean - Elev min / Elev max - Elev min	SAGA GIS(Terrain Analysis - Morphometric/Topographic Position Index)
10	Longitud de la pendiente	MDE	Para >20 $(As/22.13)^{0.6} * (\sin(\text{Slope})/0.0896)^{1.3}$ >1 (0.2), 1-3 (0.3), 3-5 (0.4), 5-20 (0.5) y Para <350m y <20% (Flow Accumulation <sup>0.5</sup> )*(0.0138+0.00965Slope+0.00138Slope <sup>2</sup> ). Para <350 y >20% (Flow Accumulation/22.13) <sup>0.6</sup> *(Slope/9) <sup>1.4</sup>	SAGA GIS(Terrain Analysis - Hydrology/LS Factor)
11	Acumulación de flujo	MDE	Análisis acumulativo celda a celda de la dirección de flujo en un kernel de 3x3	Arcgis (Spatial Analysis/Hydrology)
12	Radiación solar	MDE	$\sum \text{Dir}\theta, \alpha + \sum \text{Dif}\theta, \alpha$	SAGA GIS(Terrain Analysis-Lighting/Radiation Solar)
13	Rugosidad del terreno	MDE	$(\text{"promedio del DEM"} - \text{"DEM"}) / \text{"rango del DEM"}$	SAGA GIS(Terrain Analysis-Morphometric /Terrain Ruggedness Index)
14	Longitud de flujo	MDE	Análisis celda a celda de la dirección de flujo	Arcgis (Spatial Analysis/Hydrology)
15	Dirección de flujo	MDE	máximo = Valor z / distance * 100	Arcgis (Spatial Analysis/Hydrology)
16	Índice de convergencia	MDE	Análisis celda a celda de la dirección de flujo y la orientación en un kernel de 3x3 $CI = ((1/8)(\sum \text{ángulo})) - 90^\circ$	SAGA GIS(Terrain Analysis - Morphometric/Convergence Index)

#### 4.3.3.2 Factores condicionantes derivados de insumos cartográficos

Las características espaciales condicionantes relacionadas con la ocurrencia de los PRM, creadas a partir de insumos cartográficos (Tabla 8) fueron: índice de vegetación de diferencia normalizada (NDVI), geología, distancia a escurrimientos, distancia a carreteras, distancia a lineamientos geológicos, vegetación y uso de suelo, edafología, densidad de escurrimientos, densidad de carreteras, densidad de lineamientos geológicos y la geomorfología. La resolución raster empleada para la estandarización de los factores mencionados con anterioridad fue de 10 m.

El **NDVI** permite identificar el vigor de la vegetación en la superficie y así como caracterizar su distribución espacial. Este índice varía entre -1 y +1. Los valores negativos corresponden a zonas sin vegetación y los positivos a zonas vegetadas. El umbral de la cubierta vegetal se ubica en torno a 0-0.1 y para la vegetación densa entre 0.5 y 0.7 (Chuvienco, 2002; Eastman, 2006). El NDVI fue obtenido por medio de las imágenes Landsat 8 OLI con una resolución espacial de 15m con fecha 10-05-2016. El criterio para la elección de la fecha fue igual al factor de radiación solar, pero por cuestiones de nubosidad y bruma en las imágenes landsat no se pudo obtener el NDVI del mes de septiembre; por lo que en este caso se aseguró de tener las condiciones más cercanas a este mes.

La **geología** se obtuvo de rasterizar las unidades litológicas superficiales establecidas en el conjunto de datos vectorial geológico escala 1:250,000 del INEGI.

La **edafología** es la transformación raster de la carta edafológica 1:250,000 y está conformada por los diferentes tipos de suelos que pueden observarse sobre la superficie.

La **distancia a escurrimientos, carreteras y lineamientos geológicos** es una distancia euclidiana, su función es medir la distancia desde cada celda hasta el origen más cercano (ríos, carreteras y lineamientos). Las distancias se miden en línea recta, en unidades de metros, y se computan desde el centro de una celda

hasta el centro de la otra celda (Esri, 2016). Los 3 factores se generaron con la herramienta Spatial Analysis/Distance del software Arcgis 10.3

La rasterización de la **vegetación y uso de suelo** escala 1:50,000 muestra la distribución de la cobertura natural o antrópica existente en la superficie terrestre, así como las actividades realizadas en ella.

La **densidad de escurrimientos** muestra la relación entre la vecindad de escurrimientos y el área de las cuencas de orden 4 según Strahler, (1957). El valor de la densidad final de cada cuenca es normalizado en base al área total de la zona de estudio y está representada en unidades de m/km<sup>2</sup>. Para su cálculo se empleó la herramienta Raster Calculator del software Arcgis 10.3

La **densidad de lineamientos geológicos** muestra la relación entre la vecindad de lineamientos por unidad de área. El valor de la unidad de área es de 5 km<sup>2</sup>; esta fue asignada después de generar diferentes modelos y se determinó que era la mejor unidad que representaba las vecindades para esta variable.

La **densidad de carreteras** muestra la relación entre la vecindad de lineamientos por unidad de área. El valor de la unidad de área es de 1 km<sup>2</sup>. La herramienta empleada para su obtención fue el Spatial Analysis/density del Software Arcgis 10.3.

La **geomorfología** es la transformación raster de las diferentes formas de relieves de los datos vectoriales de unidades geomorfológicas escala 1:25,000.

Tabla 8. Características espaciales condicionantes relacionadas con la ocurrencia de los PRM

N°	Factor	Insumo principal	Escala o resolución de Insumo	Algoritmo	Procesamiento
1	Edafología	Carta Edafológica	1: 250,000	Conversión de formato vectorial a raster	Arcgis (Conversion Tools/To raster)
2	Geología	Carta Geológica	1:250,000	Conversión de formato vectorial a raster	Arcgis (Conversion Tools/To raster)
3	Unidades geomorfológicas	curvas de nivel, pendiente e imágenes Spot imagery 2016	1:50,000, 1:15:000 y 2.5 m correspondientemente	Digitalización (interpretación visual de imágenes y curvas de nivel)	Arcgis(Editor)
4	Distancia a carreteras	Datos vectoriales de caminos y carreteras	1:20,000	$C^2 = b^2+a^2$	Arcgis (Spatial Analysis/Distance)
5	densidad de carreteras	Datos vectoriales de caminos y carreteras	1:20,000	$((L1 * V1) + (L2 * V2)) /$ (area of circle)	Arcgis (Spatial Analysis/density)
6	Distancia a lineamientos	Datos vectoriales de lineamientos	1:20,000	$C^2 = b^2+a^2$	Arcgis (Spatial Analysis/Distance)
7	Densidad de lineamientos	Datos vectoriales de lineamientos	1:20,000	$((L1 * V1) + (L2 * V2)) /$ (area of circle)	Arcgis (Spatial Analysis/density)
8	Distancia a ríos	Datos vectoriales de ríos	1:20,000	$C^2 = b^2+a^2$	Arcgis (Spatial Analysis/Distance)
9	Densidad de drenaje	Datos vectoriales de ríos y subcuencas hidrológicas	1:20,000	(Número de líneas/ Área de subcuenca)* Área total de estudio	Arcgis (Raster Calculator)
10	NDVI	Landsat OLI 8 (2015)	15m	$(NIR-VIS)/(NIR+VIS)$	Arcgis (Raster Calculator)
11	Vegetación y uso de suelo	Landsat OLI 8 (2015), Digital globe 2014 y 2015, Spot imagery 2016.	15m, 2.5m y 2.5m respectivamente	Digitalización (interpretación visual de imágenes y curvas de nivel)	Arcgis(Editor)

#### 4.3.4. Correlación de factores condicionantes derivados del MDE

Para identificar y eliminar variables redundantes en los 16 factores condicionantes generados a partir del MDE en su formato raster, estos fueron sometidos a un análisis de correlación a través de la herramienta multivariante del módulo Spatial Analysis en el software Arcgis 10.3

#### 4.3.5 Análisis de la susceptibilidad con SPATSMO-SL

Tomando en cuenta los 8 etapas de la tabla 3, la etapa primera está descrita en el capítulo 4.2, en la segunda las unidades de terreno elegidas por criterio propia fueron las proporcionadas por las unidades geomorfológicas descritas en el capítulo 4.3.1, en la tercera la elaboración de cartografía de factores condicionantes se describe en el capítulo 4.3.3.

En la cuarta etapa de la metodología se seleccionaron sólo las unidades de terreno que tuviesen un número igual o mayor a 5 PRM del grupo de entrenamiento del inventario de PRM. Posteriormente se identificó la cantidad de identidades puntuales de PRM en cada unidad de terreno y se generó la misma cantidad de datos puntuales de manera aleatoria en cada una de ellas. Tanto para las identidades puntuales de PRM y las generadas de manera aleatoria se les asignaron los valores correspondientes de cada una de las capas temáticas de los factores condicionantes. La anterior se realiza con la finalidad de comprobar que los valores proporcionados por las capas temáticas de los factores condicionantes no fuesen producto de la generalización o estandarización de los datos en cada unidad de terreno. Para evaluar el nivel de significancia de los valores de las capas temáticas de los factores condicionantes, se tomaron en cuenta los datos obtenidos de las identidades puntuales y fueron analizados mediante pruebas paramétricas (estadísticos t de Student y F de Fisher) y no paramétricas (W de Wilcoxon y D de Kolmogorov-Smirnoff) dependiendo del tamaño de la muestra y la distribución de los datos de cada uno de los factores condicionantes (Tabla 9). En este paso se aplicaron las pruebas estadísticas para comparar dos muestras (identidades puntuales verdaderas vs identidades puntuales aleatorias) y establecer las

diferencias significativas entre ellas. La comparación de la distribución de los valores fue analizada con el software Statgraphics versión 16.1.18.

Tabla 9. Pruebas paramétricas y no paramétricas utilizadas para evaluar el nivel de significancia

	Distribución	< 30 datos	> 30 datos	< 50 datos	> 50 datos
Prueba paramétrica	Normal	t de Student	F de Fisher		
Prueba no paramétrica	No normal			W de Wilcoxon	Kolmogorov-Smirnoff

Como punto de corte para establecer los factores condicionantes significativos para el modelamiento del SPATSMO-SL se estableció por criterio propio a los que presentaron una significancia  $\leq 0.10$ . El criterio consistió no solamente en tomar en cuenta aquellas condiciones que tuviesen una fuerte relación con los eventos ( $\leq 0.05$ ), sino también aquellas condiciones que pudieran presentar una notaría diferencia en sus valores y fuesen cercana a la explicación del evento ( $\leq 0.10$ ).

Para la quinta etapa después de establecer los factores condicionantes significativos para la modelación por unidad de terreno, se determinó a encontrar la función de preferencia que mejor explicará el patrón resultado de la relación espacial entre los valores de cada factor condicionante y los PRM. Para ello se agruparon los valores en rangos de frecuencia, la cantidad de rangos se estableció por criterio propio. El criterio se basa en establecer una cantidad de rangos que pueden ser expresados por medio de una distribución normal, esto se realiza para tener una mayor probabilidad de encontrar funciones matemáticas que expliquen el comportamiento de los datos. Posteriormente se definieron valores de probabilidad con base en el valor de la frecuencia máxima, la cual se estableció como valor de probabilidad = 1 al rango de valores con mayor número de frecuencias; las proporciones de probabilidad de las demás rangos se obtuvieron de la relación entre su valor frecuencia y el valor de la frecuencia máxima. Para determinar la función de preferencia se modelaron los valores de las probabilidades de las frecuencias en el Software TableCurve 2D y se eligieron las funciones matemáticas que mejor

modelaran la relación espacial y que tuviesen un coeficiente de determinación lo más cercano a 1. Las funciones matemáticas elegidas para cada factor condicionante fueron aplicadas usando la calculadora raster del software Arcgis 10.3, generando así cartografía raster del grado de preferencia para cada relación espacial.

Para la ponderación de los factores condicionantes que constituyen la sexta etapa, la ponderación fue definida con base al peso del nivel de significancia expresados en valores de  $\alpha$  como resultado de las pruebas paramétricas y no paramétricas. Se aclara que en este paso se cambió el criterio original para establecer la ponderación, pues Muñiz-Jáuregui *et al.*, (2014) emplean el estadístico D; el motivo del cambio del estadístico D al peso del nivel de significancia procede a que el origen del estadístico D es una técnica no paramétrica que analiza datos que no contienen una distribución normal y aplicar esta técnica a distribuciones normales daría resultados de dudosa validez. Por lo tanto se optó por la significancia resultado de las pruebas de normalidad paramétricas o no paramétricas por lo cual no se estaría quebrantando ninguna ley estadística; por ejemplo los supuestos de normalidad. Los valores de  $\alpha$  fueron transformados a valores de proporción para que su suma final pudiese ser establecida en valores de probabilidad, teniendo como resultado una cartografía de probabilidades de ocurrencia con base en la proporción de su significancia estadística para cada factor condicionante dentro de una unidad de terreno.

En la penúltima etapa se realizó la integración de los mapas de probabilidad por unidad de terreno, esta integración es resultado de la suma de las cartografías ponderadas para cada factor condicionantes. La suma de las cartografías se realiza en el software Arcgis 10.3 y se obtiene un mapa de probabilidad para cada unidad de paisaje.

Por último, para la integración del mapa final se empleó la herramienta mosaico del software Arcgis 10.3, dando prioridad a los valores máximos de probabilidad en el caso de los traslapes. El resultado final es un raster con la distribución espacial de todas las probabilidades de susceptibilidad o no de PRM para el área de estudio.

#### 4.3.6 Análisis de la susceptibilidad con regresión logística

En el análisis raster de Regresión Logística binaria es necesario disponer de una variable categórica que defina dos grupos: celdas no susceptibles (0) y celdas susceptibles (1). Para ello se empleó el grupo de entrenamiento del inventario de PRM como la variable dependiente la cual representa los valores de las celdas donde hay presencia de inicio de PRM y toma el valor de 1, en el caso de las celdas donde no existen presencia de PRM se recurrió a emplear la ecuación 8 de muestras representativas infinitas (Murray y Larry, 2005); puesto que en los modelos raster de los factores condicionantes, el grupo de celdas con inicio de PRM es 5850 veces menor que el grupo de celdas libre de ellos.

$$n = \frac{z^2 * p * q}{i^2} \quad (8)$$

Donde “*n*” = tamaño de muestra, “*z*” = valor correspondiente a la distribución de gauss, “*p*” = prevalencia esperada del parámetro a evaluar, en caso de desconocerse = 0.5, “*q*” = 1-p y “*i*” = error que se prevé cometer

La preparación de los datos muestrales en el sistema de información geográfica (Arcmap 10.3) se efectuó en 3 pasos:

- Generación de puntos aleatorios de no ocurrencia (no susceptibilidad)

Arcmap / Data Management Tools / Feature Class / Create Random Points

- Unión de muestras susceptibles (grupo de entrenamiento del inventario de PRM) y de muestras no susceptibles

Arcmap / Geoprocessing / Union

- Extracción de valores de cada factor condicionante a los puntos muestrales

Arcmap / Spatial Analyst Tools / Extration / Extrac multi values to points

Los valores obtenidos para los datos muestrales fueron exportados en formato .txt y procesados en el software IBM SPSS Statistics 20. De entre las varias opciones que ofrece el procedimiento de regresión logística binaria en el SPSS se optó por el método de Adelante Condicional ya que de forma automática basándose en la

probabilidad de la razón de verosimilitud, incluye en el modelo todas las variables que son significativas ( $\text{Chi}^2 < 0.05$ ) y excluye las que no lo son ( $\text{Chi}^2 > 0.05$ ). Se llaman “adelante” porque parte del modelo nulo (modelo que no incluye ninguna variable independiente) y va incorporando las variables independientes paso a paso hasta que no quedan variables significativas por incorporar. Este método va incorporando una a una las variables independientes y tras incorporar al modelo una nueva variable todas las variables incluidas hasta ese momento son revisadas para determinar si alguna variable ha dejado de ser significativa y por consecuencia es excluida. Como producto final genera una simulación de las combinaciones entre las variables significativas y da opción de elegir a la combinación de variables que mejor resultado pueda presentar.

Posteriormente los coeficientes logísticos B calculados automáticamente por el SPSS son sustituidos en la ecuación de la función lineal, como se ejemplifica en la siguiente función:

$$Z = -12.2303 + (0.1474 * \text{ángulo de inclinación de la pendiente}) + (0.0364 * \text{radiación solar}) + (0.0610 * \text{índice de posición topográfica}) + (-0.0061 * \text{orientación de la pendiente}) + (0.0014 * \text{elevación}) + (-8.632 * \text{NDVI}) + (-0.0001 * \text{distancia a carreteras}) + (-0.0019 * \text{distancia a escurrimientos}) + (1.0007 * \text{densidad de escurrimientos}) + (-0.0004 * \text{distancia de lineamientos}) + (-0.3919 * \text{densidad de carreteras}) + (-0.0046 * \text{dirección de flujo}).$$

Para transformar el valor de “z” a valores de probabilidad, se empleó la escala logística (Ecuación 9).

$$P = \frac{1}{1 + e^{-z}} \quad (9)$$

Las expresiones antes mencionadas fueron realizadas en la calculadora raster del Arcmap 10.3 y se obtuvo como resultado final un raster con la distribución espacial de todas probabilidades de susceptibilidad o no susceptibilidad de PRM para el área de estudio.

#### 4.3.7 Análisis de la susceptibilidad con red neuronal artificial

El modelo de RNA al igual que el modelo de regresión logística requiere disponer de una variable categórica que defina dos grupos: celdas no susceptibles (0) y celdas susceptibles (1). Para las celdas susceptibles se tomó el mismo criterio que el modelo de regresión logística binaria y para el grupo de celdas no susceptibles se decidió que el tamaño de muestra fuese el mismo que el de las celdas susceptibles. Esta decisión se tomó para evitar que el modelo otorgará más peso a las celdas no susceptibles, puesto que lo primordial en nuestro caso es pronosticar correctamente las celdas susceptibles. Además, los programas estadísticos que nos ayudan al análisis de la RNA están configurados para procesar tamaños de muestras idénticas o iguales. Por lo tanto, se seleccionó de manera aleatoria el tamaño de muestra para la RNA en las muestras no susceptibles generadas en el método de regresión logística.

La preparación de los datos muestrales en el sistema de información geográfica (Arcmap 10.3) se efectuó en 3 pasos:

- Selección aleatoria de datos muestrales de no susceptibilidad de PRM  
Arcmap / Geostatistical Analyst Tools / Utilities / Subset features
- Unión de muestras tanto susceptibles como de no susceptibles  
Arcmap / Geoprocessing / Union
- Extracción de valores de cada factor condicionante a los puntos muestrales  
Arcmap / Spatial Analyst Tools/ Extration / Extrac multi values to points

Los valores obtenidos para los datos muestrales fueron exportados en formato .txt y procesados en el software IBM SPSS Statistics 20. De las dos opciones que ofrece el procedimiento de la RNA en el SPSS, se optó por el método de perceptrón multicapa por ser el modelo en la cual se tiene mayor experiencia en su aplicación; las diferencias con el perceptrón de base radial son la extrapolación, interpolación y número de capas ocultas pero ambos métodos poseen la misma capacidad de clasificación. Se empleó un cambio de escala ( $(\text{tipificación} = x - \text{media}) / \text{desviación}$ )

típica) en los valores originales de las variables independientes (factores condicionantes) para normalizar y eliminar la dispersión de los datos. Lo anterior con el propósito de corregir posibles errores de origen o de procesamiento en los valores de los datos de cada variable.

La arquitectura de la red se generó de manera automática, dando al programa la posibilidad de generar de 1 a 50 capas ocultas y elegir las funciones de activación que mejor se ajusten al modelo. El tipo de entrenamiento se realizó por lotes, porque minimiza directamente el error total y el algoritmo de optimización empleado fue el gradiente conjugado escalado por ser el algoritmo diseñado especialmente para el entrenamiento por lotes. El procedimiento se fue realizando de manera manual como si fuese el método de pasos hacia atrás de la regresión logística binaria que consiste en incluir todas las variables e ir eliminando de una en una las variables menos significativas en el modelo, esto con el fin de eliminar las variables que pudiesen causar ruido al resultado final o simplemente no tener relevancia en la ocurrencia o no ocurrencia de un PRM.

Una de las ventajas que posee el software estadístico IBM SPSS Statistics 20, es que cada vez que se corre un modelo de RNA aun teniendo los mismos factores, características y parámetros el resultado suele ser diferente; por lo que se corrió el modelo 50 veces hasta encontrar el resultado que mejor pronóstico pudiese generar. Los parámetros de peso y sesgo son calculados automáticamente por el SPSS para la capa oculta y para la capa de salida. Cada unidad de la capa oculta es la suma ponderada de las entradas con base en los parámetros calculados por la RNA, activados para nuestro caso por la función de la tangente hiperbólica y cada unidad de la capa de salida es la suma ponderada de las capas ocultas, que se activan para nuestro caso con la función de activación softmax.

Con la obtención de la estructura de la RNA en la cual se definen los factores condicionantes significativos, valores de parámetros y funciones de activación de la capa oculta y la capa salida se realiza el siguiente procedimiento en el software Arcgis 10.3:

#### -Tipificación de datos de entrada

Se obtiene la media y desviación estándar de los valores del grupo de píxeles que componen al raster de cada factor condicionante significativo; estos valores se sustituyen en la fórmula de la tipificación, donde el raster de cada factor condicionante toma la forma de  $x$ .

#### -Obtención de valores de unidad de capa oculta

Los valores tipificados de cada factor significativo son multiplicados por su peso, para posteriormente realizar la sumatoria de todos los factores significativos que fueron modificados por sus respectivos pesos y sumarle o restarle el sesgo correspondiente de cada unidad de la capa oculta.

#### -Activación de las unidades de capa oculta

La activación de la capa oculta se realiza utilizando la función de la tangente hiperbólica (Ecuación 10), en la cual los valores de la capa oculta cumplen la función de ser un valor exponencial ( $c$ ) y el número de Euler la base.

$$\frac{e^c - e^{-c}}{e^c + e^{-c}} \quad (10)$$

#### -Obtención de valores de capa de salida

Con los valores de las unidades de la capa oculta activados se calculan los valores de la capa de salida el cual consiste en multiplicar por su peso a las unidades de las capas ocultas activas, para posteriormente realizar la sumatoria de todas las unidades que fueron modificados por sus respectivos pesos y sumarle o restarle el sesgo correspondiente de cada unidad de la capa de salida.

#### -Activación de unidad de capa de salida

La activación de las unidades de la capa salida se realiza utilizando la función softmax, donde los valores de las unidades de salida forman parte de una función exponencial normalizada (Ecuación 11), esto con la finalidad de calcular la probabilidad de las diferentes unidades de la capa de salida.

$$Probabilidad (unidad_1) = \frac{Exp (unidad_1)}{Exp (unidad_1) + Exp (unidad_0)} \quad (11)$$

Recordado que la salida es binaria, la “unidad<sub>1</sub>” representa a la unidad de salida con valor=1 que corresponde a las zonas susceptibles y “unidad<sub>0</sub>” representa a la unidad de salida con valor=0 que corresponde a las zonas no susceptibles.

Como producto final nos genera un raster con la distribución espacial de todas probabilidades para la susceptibilidad o no susceptibilidad de PRM en el área de estudio.

#### 4.3.8 Clasificación de las probabilidades por modelo

Para establecer la clasificación de las probabilidades de la susceptibilidad a PRM, primero fue necesario establecer un punto de corte en los valores de probabilidad de 0 a 1; para separar las zonas susceptibles de las zonas no susceptibles. El criterio empleado fue el contraste de la proporción que representa cada una de las muestras empleadas para cada modelo estadístico. Es decir, que para cada modelo estadístico se estableció un punto de corte en particular, puesto que los datos muestrales en los tres modelos son de diferente tamaño e incluso en uno de ellos solo se empleó un grupo muestral y no dos como se empleó en la mayoría de ellos.

#### **4.4 Validación de modelos estadísticos empleando la curva ROC**

Una de las pruebas para definir la validez y fiabilidad de los modelos estadísticos creados fue la curva ROC; esta fue generada mediante el software estadístico IBM SPSS Statistics 20. Para ello se empleó como datos muestrales de validez los puntos de PRM de validación para zonas susceptibles (1) y para zonas no susceptibles (0) se generaron la misma cantidad de entidades puntuales que las zonas susceptibles. Posteriormente se extrajo los valores de probabilidad de cada modelo en las entidades puntuales de validación y la información generada se exportó como un archivo de Excel.

El archivo de Excel fue abierto en el software estadístico IBM SPSS Statistics 20 y se analizó mediante herramienta de curva ROC empleando como variable de

contraste los valores de probabilidad y como variable de estado el valor asignado por susceptibilidad (0 no susceptible y 1 susceptible); asimilando que los datos positivos deberían ser 1 y los negativos 0. El procedimiento anterior da como resultado la curva ROC de las probabilidades para cada modelo estadístico.

#### **4.5 Validación de modelos estadísticos empleando una matriz de confusión**

La segunda prueba fue una matriz de confusión, realizada como parámetro para evaluar la exactitud y precisión de los modelos estadísticos. Los datos muestrales de validez empleados en este análisis fueron los mismos que se emplearon en la curva ROC. Para esta prueba los valores de probabilidad fueron clasificados en dos grupos: susceptible (1) y no susceptible (0), en base al punto de corte establecido para cada modelo. Posteriormente se extrajo los valores de los grupos de cada modelo en las entidades puntuales de validación y la información generada se exportó como un archivo de Excel.

El archivo de Excel fue abierto en el software estadístico IBM SPSS Statistics 20 y se analizó mediante herramienta de tablas de contingencia, empleando como fila a los valores reales de PRM y como columna a los valores pronosticados por los modelos. Cabe mencionar que en nuestra matriz de confusión los valores 1 de la fila toman el valor de datos positivos y los valores 0 el valor de datos negativos, para las columnas los valores 1 toman el valor de verdaderos y los valores de 0 toman el valor de falsos. Posteriormente se calcularon los valores de los índices según Tsangaratos y Benardos, 2014 (Tabla 5).

#### **4.6 Comparación de resultados de pruebas de validación**

Los resultados de ambas pruebas de validación fueron sometidos a un análisis comparativo entre los tres modelos, los parámetros de comparación fueron: el rendimiento global del modelo para predecir zonas susceptibles como no susceptibles, la exactitud y precisión que estos poseen en la zonificación de zonas susceptibles así como también la exactitud y precisión que tienen en la distribución de la ocurrencia de PRM pronosticados en los grados de susceptibilidad de clases altas y muy altas.

## Capítulo 5: Resultados

### 5.1 Resultados del mapa inventario de PRM

El inventario de PRM elaborado en esta investigación consta de 934 PRM, los cuales empleando la clasificación de Varnes (1978), se dividieron en las siguientes categorías (figura 18):

- 16 movimientos traslacionales de derrubios
- 8 flujos de roca
- 910 flujos de derrubios

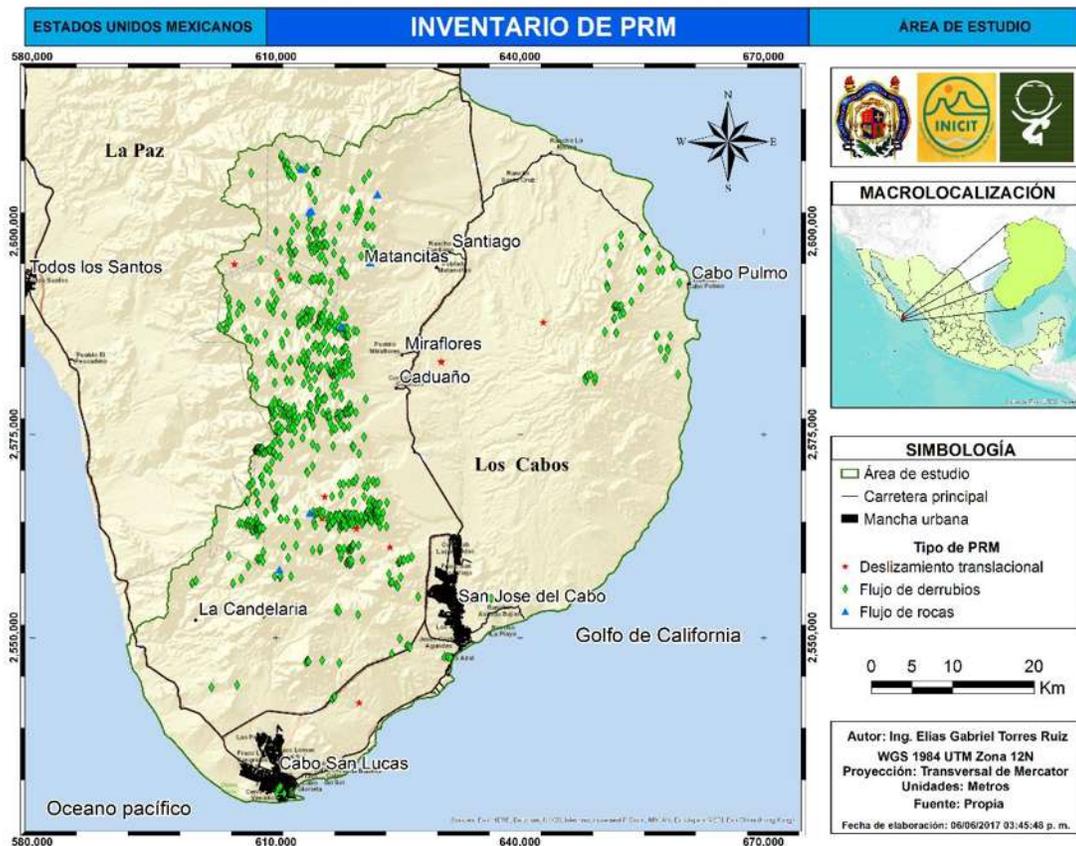


Figura 18. Inventario de PRM

La mayoría de los PRM son flujos de derrubios que inician cerca de la parte superior del parteaguas y se dirigen hacia el canal de desagüe más cercano (figura 19). Contienen en su mayor totalidad fragmentos de roca ígnea intrusiva (granito) y en

menor proporción material fino con presencia de arcillas. La longitud de las cicatrices va de los 50 m a los 600 m aproximadamente.

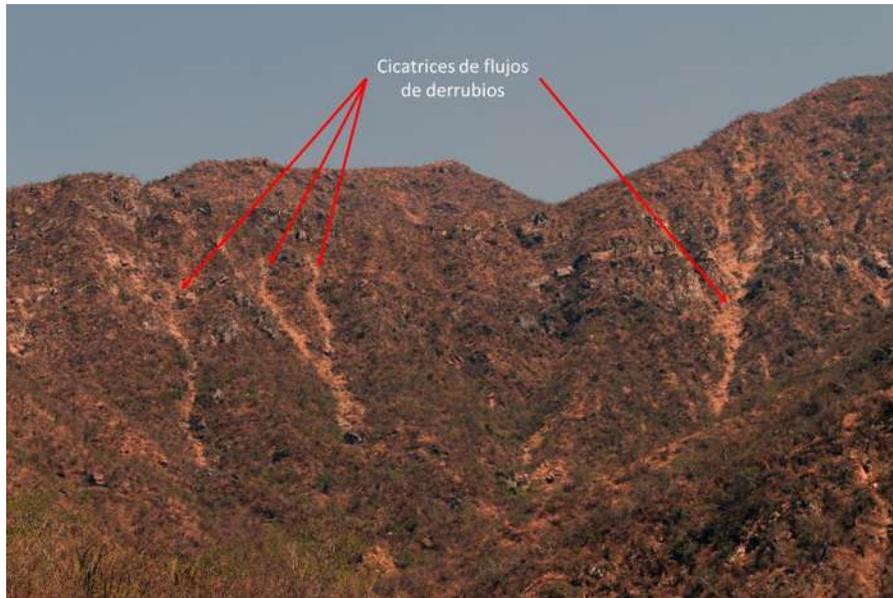


Figura 19. Cicatrices de flujos de derrubios.

Los flujos de roca se componen por rocas ígneas intrusivas (granitos) y rocas metamórficas (esquisto) que tienen un diámetro de 1-2 m aproximadamente, algunos canales de los flujos poseen un ancho variable de 20 a 25 metros (figura 20).

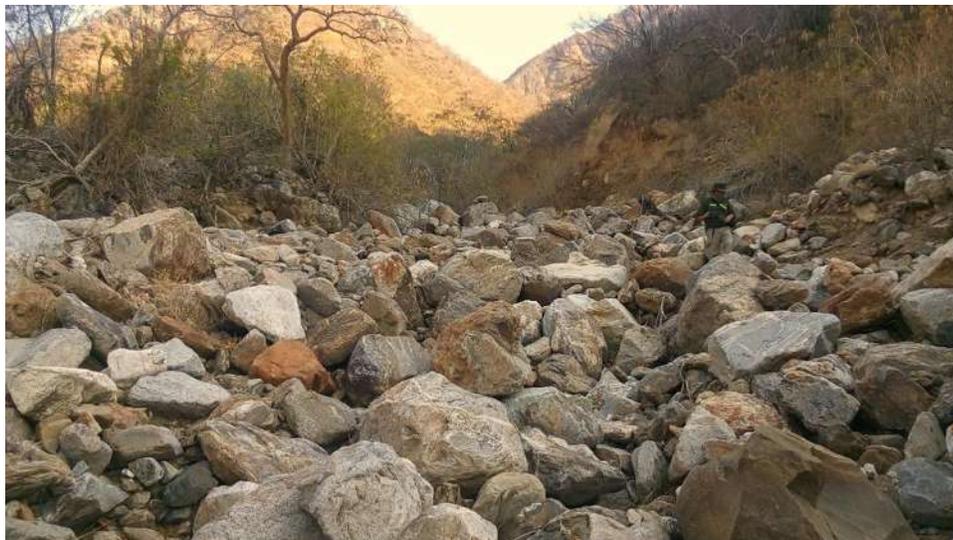


Figura 20. Canal de un flujo de rocas de granito y esquisto metamórfico.

Los deslizamientos son muy pocos usuales y regularmente se encuentran en un estado inactivo: apagado o abandonado (figura 21). Posiblemente son reactivados durante el periodo de lluvias.

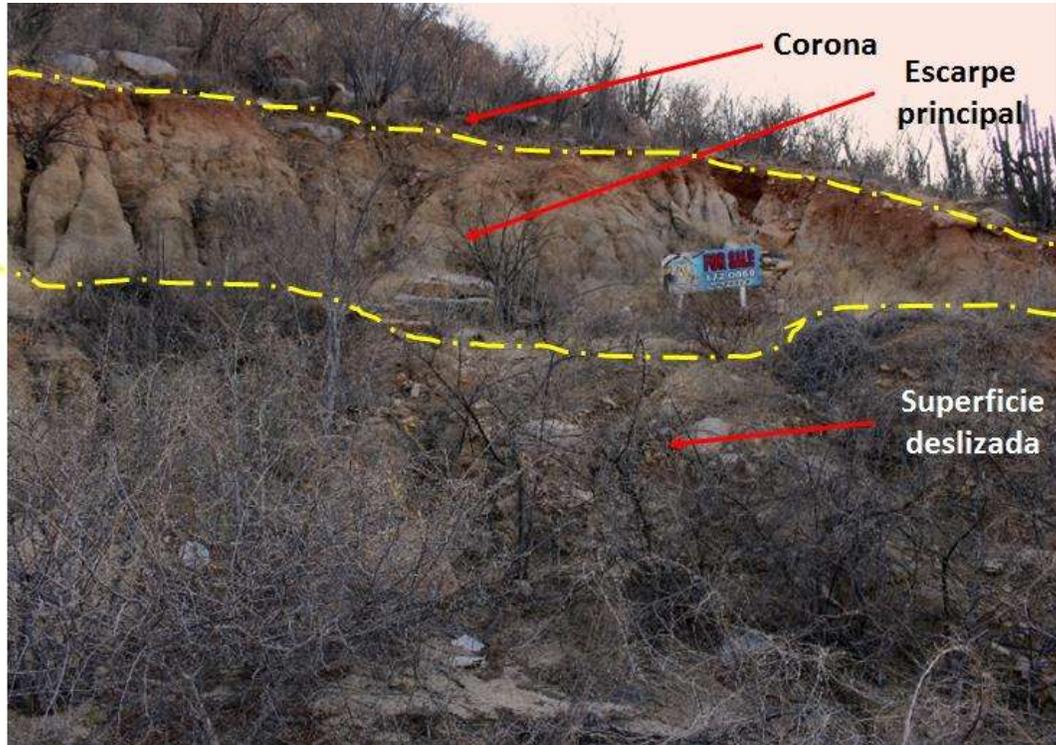


Figura 21. Deslizamiento traslacional

## 5.2 Resultados de la elaboración de insumos cartográficos

En este apartado solo se presentaran los resultados de la vegetación y uso de suelo escala 1:50,000 y la geomorfología escala 1:25,000. Se decidió presentar los datos vectoriales de lineamientos geológicos escala 1:20,000, caminos y carreteras escala 1:20,000 y escurrimientos superficiales escala 1:20,000 en el apéndice B: 1, 2 y 3, pues solo son la representación lineal de esos elementos.

En el análisis de vegetación y uso de suelo actual escala 1:50,000 se determinó que la cobertura vegetal está dominada por (figura 22): Matorral Sarcocaula (MSS) localizados al Sur y Este sobre las zonas de planicie y lomerío con una extensión territorial de 1253.18 km<sup>2</sup> representando un 32.83 % de área de estudio. Vegetación

secundaria arbustiva de bosque de encino (VSA/BQ) ubicados al Oeste sobre la zona sierra en unidades de montaña con una extensión territorial de 819.92 km<sup>2</sup> representando un 21.5 %. El matorral Sarco - crasicaule sin presencia en la zona oeste y la selva Baja caducifolia sin presencia en la zona sur aportan 565.64 y 564.36 km<sup>2</sup> representando un 14.82% y 14.78% respectivamente. En cuanto al uso de suelo de menor extensión son los asentamientos, que ocupan el 2.38 %, seguida por la actividad agrícola de riego anual tanto permanente como semipermanente con 2.16 % y los pastizales cultivados e inducidos con 1.18 %.

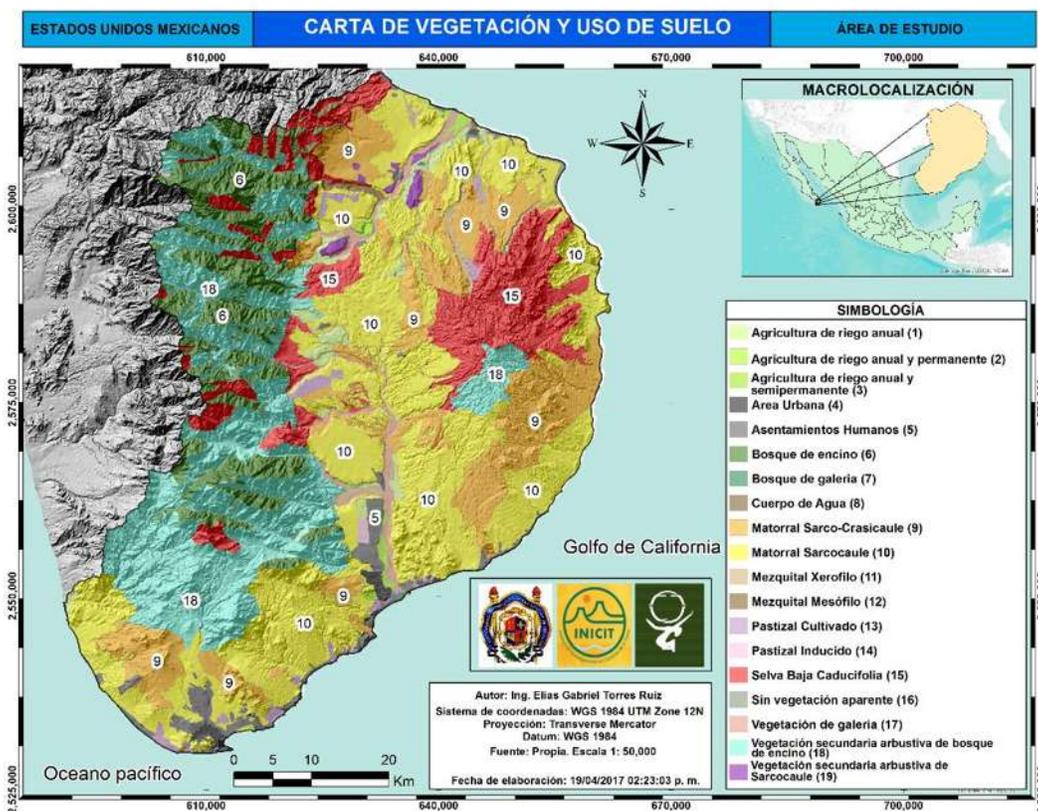


Figura 22. Carta de vegetación y uso de suelo. Fuente: Propia

En la geomorfológica escala 1:25,000, se identificaron los siguientes paisajes y relieves (figura 23): Un sistema montañoso con pendientes abruptas, fuertes, medianas y ligeras (38.14 %) ; lomeríos intrusivos y extrusivos del terciario (0.53 %), lomeríos intrusivos del cretácico (19.5 %), lomeríos sedimentarios [cuaternario (3.86 %), neógeno (1.61 %), neógeno-cuaternario (0.17 %) y terciario (4.73%)], Valle de acumulación ( 5.31 %; poca expresión en montaña y mayor expresión en pie de

ladera); Pie de ladera (4.17%); Planicie con llanura aluvial y sedimentaria (18.8 %) y el desarrollo del lecho actual del río (3.03 %).

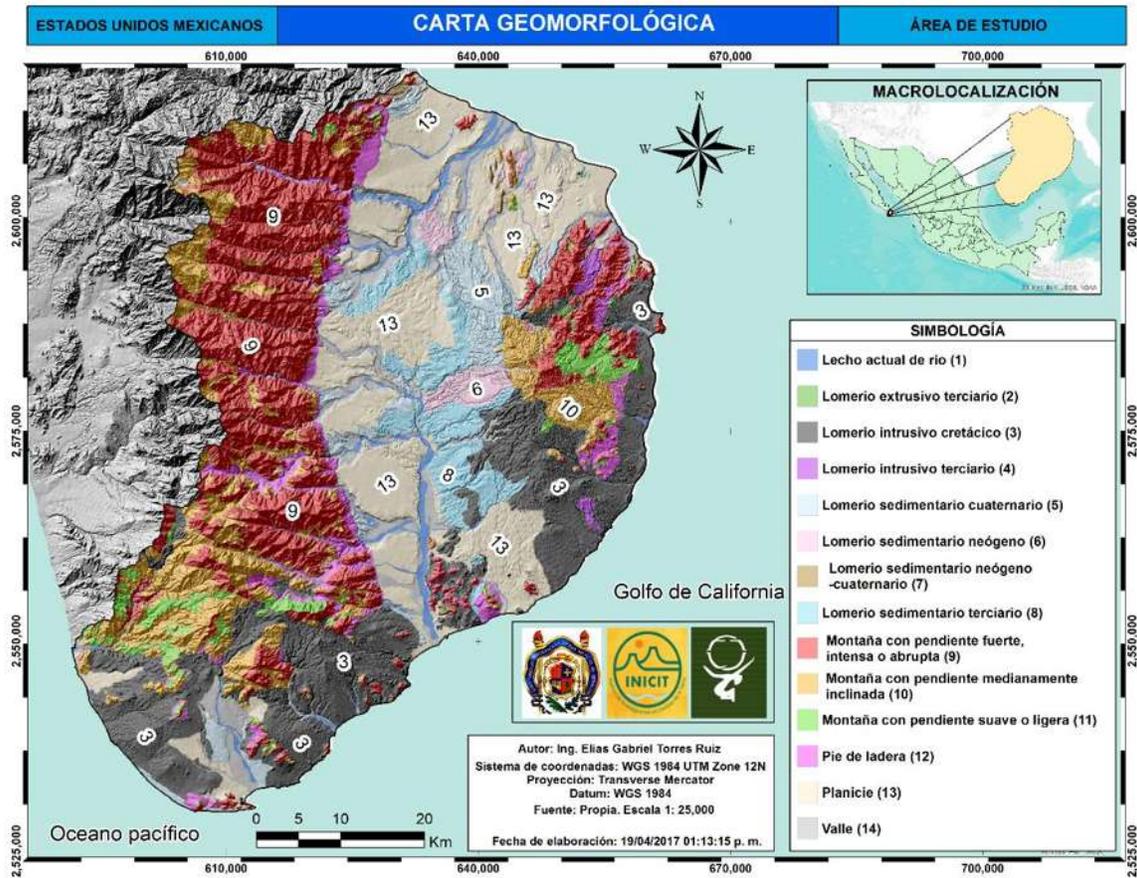


Figura 23. Carta geomorfológica del área de estudio, Fuente: Propia

### 5.3 Resultados de la generación de capas temáticas de factores condicionantes

Los resultados de este apartado se omitieron por considerarse excesiva la presentación cartográfica de 27 factores condicionantes temáticos, en su mayoría valores numéricos. Se consideró de muy poca utilidad la representación cartográfica de los valores de cada factor condicionante siendo un área extensa de estudio, al final resulta irrelevante la representación cartográfica para la investigación.

#### **5.4 Resultados de correlación de factores condicionantes derivados del MDE**

Una de los factores condicionantes eliminados por el modelo de correlación fue el índice de rugosidad que presentó una correlación casi perfecta con el ángulo de inclinación de la pendiente (Tabla 10). El segundo factor condicionante eliminado fue la longitud de la pendiente que presentó la leyenda -1#IND e indica un error en la operación matemática, por lo cual se recurrió a revisar el raster de este factor y se encontró que contenía muchas áreas con pixeles sin información, por lo tanto, era incapaz de aportar información significativa. En el caso del índice de convergencia le determinó la leyenda 1. #QNAN que indica un posible error de valores nulos y que representa un dato no numérico, por lo cual se revisó el raster de este factor y no se encontró ningún error de este tipo, tampoco se determinó una explicación lógica a este problema y se asumió que podría ser un error en el código del programa y se decidió no descartar la variable. En cuanto a las otras correlaciones se indica en color verde claro el máximo positivo que fue de .7953 y en color azul claro el máximo negativo que fue de -0.8459, lo cual no es significativo para el análisis que se pretende realizar; por la cantidad de datos manejado en los modelos raster (3, 826,571 pixeles). En caso de haber discriminado los modelos que están entre el rango de las correlaciones antes mencionadas se hubiesen perdido aproximadamente 589,674 datos.

Tabla 10. Modelo de correlación para factores condicionantes obtenidos del MDE

CAPA	Índice de humedad topográfico	Índice de posición topográfico	Índice de transporte de sedimentos	Radiación Solar	Orientación de pendiente	Longitud de pendiente	longitud de flujo	Índice de rugosidad	Índice de convergencia	Elevación	Dirección de flujo	Plano de curvatura	Perfil de curvatura	Curvatura Standard	Ángulo de la pendiente	Acumulación de flujo
Índice de humedad topográfico	1.0000	-0.2810	-0.0021	0.2296	-0.0078	-1.#IND	-0.2167	-0.4483	1.#QNAN	-0.2635	-0.0463	-0.3198	0.1454	-0.2761	-0.4619	0.1983
Índice de posición topográfico	-0.2810	1.0000	0.0013	-0.0104	0.0051	-1.#IND	0.0376	0.0318	1.#QNAN	0.0590	0.0229	0.6204	-0.5815	0.7293	0.0331	-0.0904
Índice de transporte de sedimentos	-0.0021	0.0013	1.0000	-0.0002	0.0002	-1.#IND	-0.0001	0.0001	1.#QNAN	-0.0004	0.0002	0.0014	-0.0004	0.0010	0.0002	-0.0111
Radiación Solar	0.2296	-0.0104	-0.0002	1.0000	0.0410	-1.#IND	-0.2238	-0.5790	1.#QNAN	-0.2482	-0.4109	-0.0242	-0.0132	-0.0052	-0.5626	0.0142
Orientación de pendiente	-0.0078	0.0051	0.0002	0.0410	1.0000	-1.#IND	-0.0364	0.0033	1.#QNAN	-0.0151	-0.2654	0.0033	-0.0023	0.0034	0.0045	-0.0112
Longitud de pendiente	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	1.0000	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND	-1.#IND
longitud de flujo	-0.2167	0.0376	-0.0001	-0.2238	-0.0364	-1.#IND	1.0000	0.5294	1.#QNAN	0.7355	0.0484	0.0067	-0.0240	0.0193	0.5377	0.0167
Índice de rugosidad	-0.4483	0.0318	0.0001	-0.5790	0.0033	-1.#IND	0.5294	1.0000	1.#QNAN	0.6220	0.0703	0.0503	0.0111	0.0214	0.9962	-0.0120
Índice de convergencia	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN	-1.#IND	1.#QNAN	1.#QNAN	1.0000	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN	1.#QNAN
Elevación	-0.2635	0.0590	-0.0004	-0.2482	-0.0151	-1.#IND	0.7355	0.6220	1.#QNAN	1.0000	0.0629	0.0193	-0.0298	0.0303	0.6305	0.0190
Dirección de flujo	-0.0463	0.0229	0.0002	-0.4109	-0.2654	-1.#IND	0.0484	0.0703	1.#QNAN	0.0629	1.0000	0.0139	-0.0196	0.0206	0.0725	-0.0039
Plano de curvatura	-0.3198	0.6204	0.0014	-0.0242	0.0033	-1.#IND	0.0067	0.0503	1.#QNAN	0.0193	0.0139	1.0000	-0.3495	0.7953	0.0543	-0.1054
Perfil de curvatura	0.1454	-0.5815	-0.0004	-0.0132	-0.0023	-1.#IND	-0.0240	0.0111	1.#QNAN	-0.0298	-0.0196	-0.3495	1.0000	-0.8459	0.0099	0.0312
Curvatura Standard	-0.2761	0.7293	0.0010	-0.0052	0.0034	-1.#IND	0.0193	0.0214	1.#QNAN	0.0303	0.0206	0.7953	-0.8459	1.0000	0.0245	-0.0802
Ángulo de la pendiente	-0.4619	0.0331	0.0002	-0.5626	0.0045	-1.#IND	0.5377	0.9962	1.#QNAN	0.6305	0.0725	0.0543	0.0099	0.0245	1.0000	-0.0150
Acumulación de flujo	0.1983	-0.0904	-0.0111	0.0142	-0.0112	-1.#IND	0.0167	-0.0120	1.#QNAN	0.0190	-0.0039	-0.1054	0.0312	-0.0802	-0.0150	1.0000

## 5.5 Resultados del análisis con SPATSMO-SL

El total de unidades de terreno que fueron analizadas para determinar su idoneidad para el modelamiento en base con el tamaño de muestra especificado en el capítulo 4.3.5 fueron un total de 835 unidades, a estas unidades se le asignó una clave de manera consecutiva mediante un número romano y un número natural (I-1, I-2, I-3, I-n,..., I-835). El número total de unidades de terreno que se encontraron idóneas para el modelamiento fueron 21 unidades (Tabla 11; figura 24).

Tabla 11. Distribución y proporciones de superficie y cantidad de PRM por unidad de terreno

Clave	Subcuenca	Unidad de terreno		Superficie		PRM		Cantidad PRM * Proporción de superficie de unidad	
				Has	Proporción	Cantidad	Proporción	Neta	Normalizada
I-89	3	Montaña	Pendiente alta	12253.84	0.152	31	0.054	4.70	0.142
I-99	4	Montaña	Pendiente alta	4529.97	0.056	16	0.028	0.90	0.027
I-105	5	Montaña	Pendiente alta	4697.78	0.058	35	0.061	2.04	0.062
I-136	6	Montaña	Pendiente alta	5223.57	0.065	20	0.035	1.29	0.039
I-141	7	Montaña	Pendiente alta	3708.23	0.046	57	0.099	2.62	0.079
I-142	7	Montaña	Pendiente alta	4439.98	0.055	11	0.019	0.60	0.018
I-146	8	Montaña	Pendiente alta	984.43	0.012	7	0.012	0.09	0.003
I-194	9	Montaña	Pendiente alta	6887.30	0.085	85	0.148	7.25	0.219
I-213	10	Montaña	Pendiente alta	2945.50	0.036	66	0.115	2.41	0.073
I-224	11	Montaña	Pendiente alta	2639.44	0.033	36	0.063	1.18	0.036
I-250	12	Montaña	Pendiente alta	1869.96	0.023	34	0.059	0.79	0.024
I-251	12	Montaña	Pendiente alta	553.56	0.007	9	0.016	0.06	0.002
I-296	13	Montaña	Pendiente alta	5694.07	0.070	92	0.161	6.48	0.196
I-297	13	Montaña	Pendiente alta	1067.03	0.013	5	0.009	0.07	0.002
I-331	14	Montaña	Pendiente alta	718.34	0.009	27	0.047	0.24	0.007
I-332	14	Montaña	Pendiente alta	1136.05	0.014	6	0.010	0.08	0.003
I-450		Lomerío	Intrusivo-cretácico	17544.21	0.217	9	0.016	1.95	0.059
I-527	24	Montaña	Pendiente alta	880.07	0.011	5	0.009	0.05	0.002
I-630	32	Montaña	Pendiente alta	943.97	0.012	7	0.012	0.08	0.002
I-715	38	Montaña	Pendiente alta	1410.35	0.017	6	0.010	0.10	0.003
I-766	47	Montaña	Pendiente alta	664.77	0.008	9	0.016	0.07	0.002
			Total	80792	1	573	1	33	1

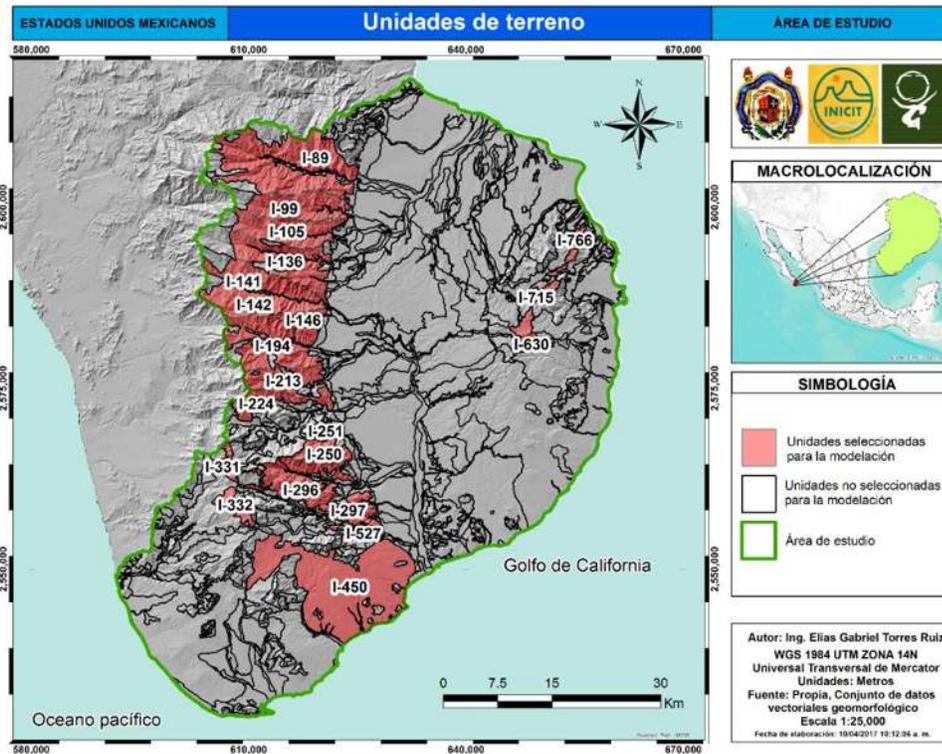


Figura 24. Unidades de terreno para el análisis espacial de la susceptibilidad de los PRM en el municipio Los Cabos, Baja California Sur

En cuanto a los factores condicionantes que se emplearon en el modelamiento como resultado de su significancia estadística obtenida a través de las pruebas paramétricas y no paramétricas para cada unidad de terreno pueden observarse en el Apéndice A: 2, donde se detalla el valor obtenido en su respectiva prueba y su nivel de significancia expresado en  $\alpha$ . Las funciones de preferencia empleadas en la modelación de la susceptibilidad a PRM en cada factor condicionante significativo pueden revisarse en el Apéndice A: 3, donde se observa el coeficiente de determinación  $R^2$  para cada uno de ellos.

Los valores de  $\alpha$  empleados como pesos ponderados para cada factor condicionante como parte de la sexta etapa del procedimiento del SPATSMO-SL se visualizan en el apéndice A: 4, el cual expresa el valor de  $\alpha$  correspondiente a la significancia estadística y el valor de la ponderación obtenida de la relación entre el  $\alpha$  de cada factor condicionante y la sumatoria de los  $\alpha$  de los factores condicionantes en cada unidad de terreno.

## 5.6 Resultados del análisis con regresión logística

Para el caso de las muestras de zonas no susceptibles a PRM se optó por tener un nivel de confianza del 99% y un error máximo del 1%, p y q es igual a 0.5 pues se consideró como desconocida la probabilidad de que una zona sea no susceptible:

$$1-\alpha = 99 \% = 2.58, \quad e = 1\% = 0.01, \quad p = 0.5, \quad q = 0.5$$

$$n = \frac{2.58^2 * 0.5 * 0.5}{0.01^2} = 16,641$$

El total de las muestras recomendadas por el método de Murray y Larry, 2005 para zonas no susceptibles fueron de 16,641 muestras.

En cuanto a los factores condicionantes como primera instancia se introdujeron los factores expuestos en las tablas 7 y 8 ha excepción del índice de rugosidad y la longitud de la pendiente eliminados en la correlación. El total de factores condicionantes como variables significativas producto de la simulación del modelo resultaron ser 12 (Tabla 12) y la mejor combinación de los factores condicionantes por el método de adelante condicional resultó ser la combinación de todas ellas (Tabla 13).

Tabla 12. Estimación y significación de los coeficientes de las variables significativas (RL)

Factor condicionante	Significancia	Valor de B
Ángulo de inclinación de la pendiente	4.394 <sup>-103</sup>	0.1474
Radiación Solar	3.666 <sup>-25</sup>	0.0364
Índice de posición topográfica	8.841 <sup>-21</sup>	0.0610
Orientación de la pendiente	3.827 <sup>-12</sup>	-0.0069
Elevación	8.797 <sup>-10</sup>	0.0014
NDVI	1.033 <sup>-06</sup>	-8.632
Distancia a carreteras	1.513 <sup>-05</sup>	-0.0001
Distancia a escurrimientos	3.771 <sup>-05</sup>	-0.0019
Densidad de escurrimientos	5.082 <sup>-04</sup>	1.0007
Distancia de lineamientos	7.263 <sup>-04</sup>	-0.0004
Densidad de carreteras	2.339 <sup>-03</sup>	-0.3919
Dirección de flujo	2.273 <sup>-02</sup>	-0.0046
<b>Constante</b>	1.907 <sup>-40</sup>	-12.2303

Tabla 13. Simulación y pronóstico para la correcta clasificación del modelo (RL)

Variable introducida	PRM Observado			PRM Pronosticado		Porcentaje correcto
				Valor		
	0	1				
Ángulo de inclinación de la pendiente	Paso 1	Valor	0	13347	3170	80.8
			1	86	568	86.9
		Porcentaje global				81.0
Radiación Solar	Paso 2	Valor	0	14064	2453	85.1
			1	90	564	86.2
		Porcentaje global				85.2
Índice de posición topográfica (TPI)	Paso 3	Valor	0	14106	2411	85.4
			1	86	568	86.9
		Porcentaje global				85.5
Orientación de la pendiente	Paso 4	Valor	0	14089	2428	85.3
			1	83	571	87.3
		Porcentaje global				85.4
Distancia a escurrimientos	Paso 5	Valor	0	14109	2408	85.4
			1	87	567	86.7
		Porcentaje global				85.5
Densidad de carreteras	Paso 6	Valor	0	14072	2445	85.2
			1	80	574	87.8
		Porcentaje global				85.3
Densidad de escurrimientos	Paso 7	Valor	0	14082	2435	85.3
			1	77	577	88.2
		Porcentaje global				85.4
Distancia de lineamientos	Paso 8	Valor	0	14058	2459	85.1
			1	77	577	88.2
		Porcentaje global				85.2
NDVI	Paso 9	Valor	0	14060	2457	85.1
			1	75	579	88.5
		Porcentaje global				85.3
Elevación	Paso 10	Valor	0	14081	2436	85.3
			1	76	578	88.4
		Porcentaje global				85.4
Distancia a carreteras	Paso 11	Valor	0	14094	2423	85.3
			1	79	575	87.9
		Porcentaje global				85.4
Dirección de flujo	Paso 12	Valor	0	14115	2402	85.5
			1	77	577	88.2
		Porcentaje global				85.6

## 5.7 Resultados del análisis con red neuronal artificial

El resultado de la estructura de RNA de tipo perceptrón multicapa fue una capa oculta con 7 unidades que se activan con una función de tangente hiperbólica y una capa de salida con 2 unidades que se activan con una función softmax (figura 25).

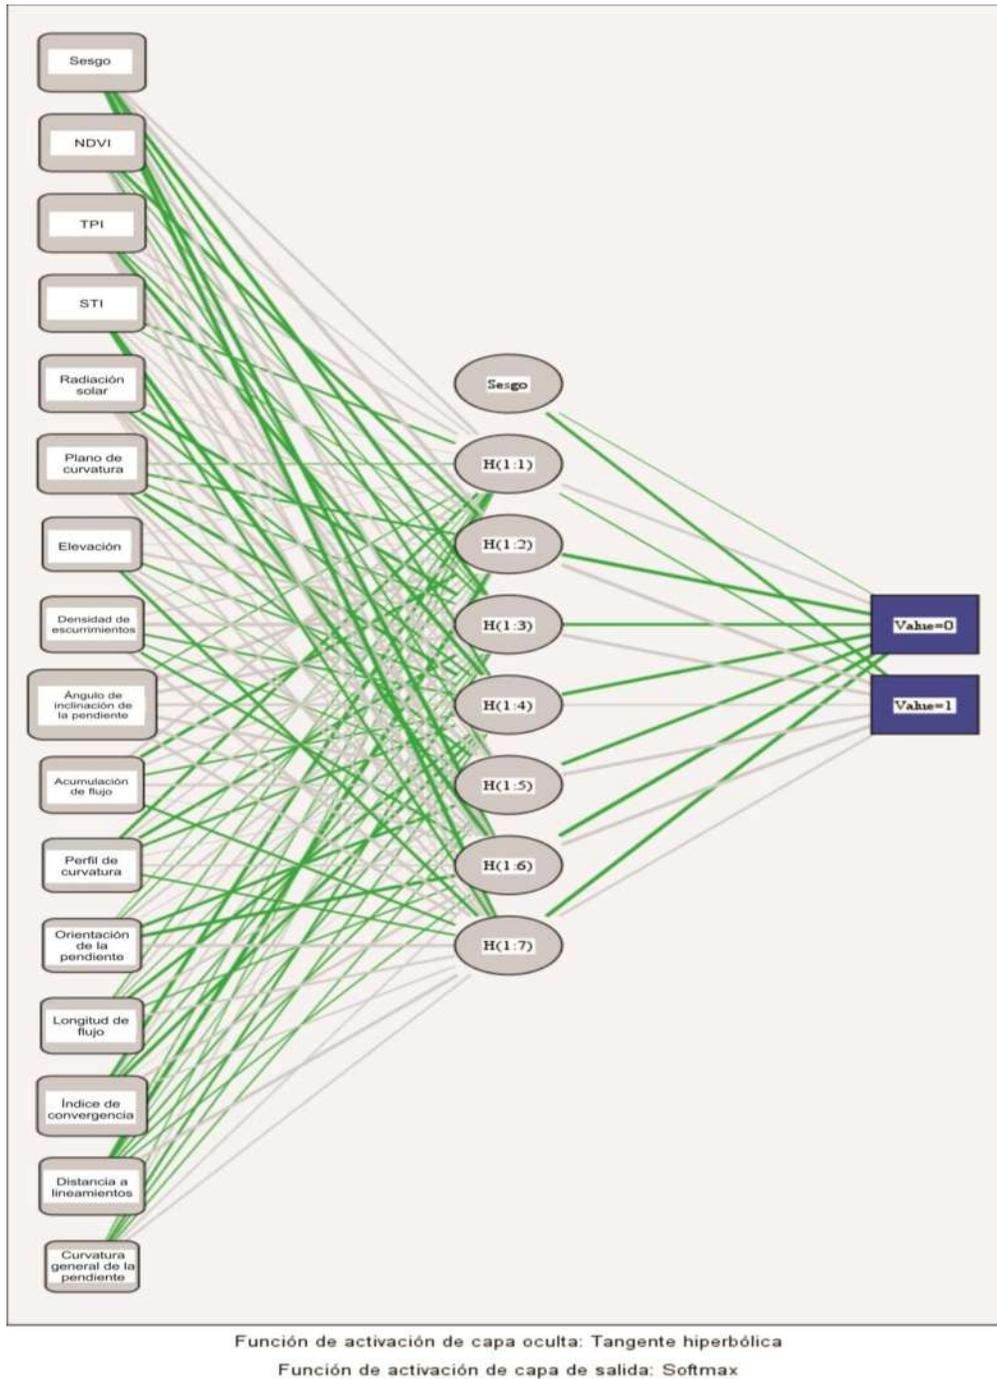


Figura 25. Estructura de RNA para modelo propuesto

La capa de entrada quedó estructurada a partir de las condiciones que el modelo propone para que una zona sea susceptible a PRM, estas condiciones corresponden a 15 factores condicionantes: ángulo de inclinación de la pendiente, orientación de la pendiente, elevación, curvatura de pendiente, plano de curvatura, perfil de curvatura, índice de transporte de sedimentos (STI), índice de posición topográfica (TPI), acumulación de flujo, longitud de flujo, índice de convergencia, radiación solar, NDVI, distancia a lineamientos y densidad de escurrimientos. Los factores condicionantes tuvieron un orden jerárquico según su importancia normalizada que el modelo propuso (figura 26).

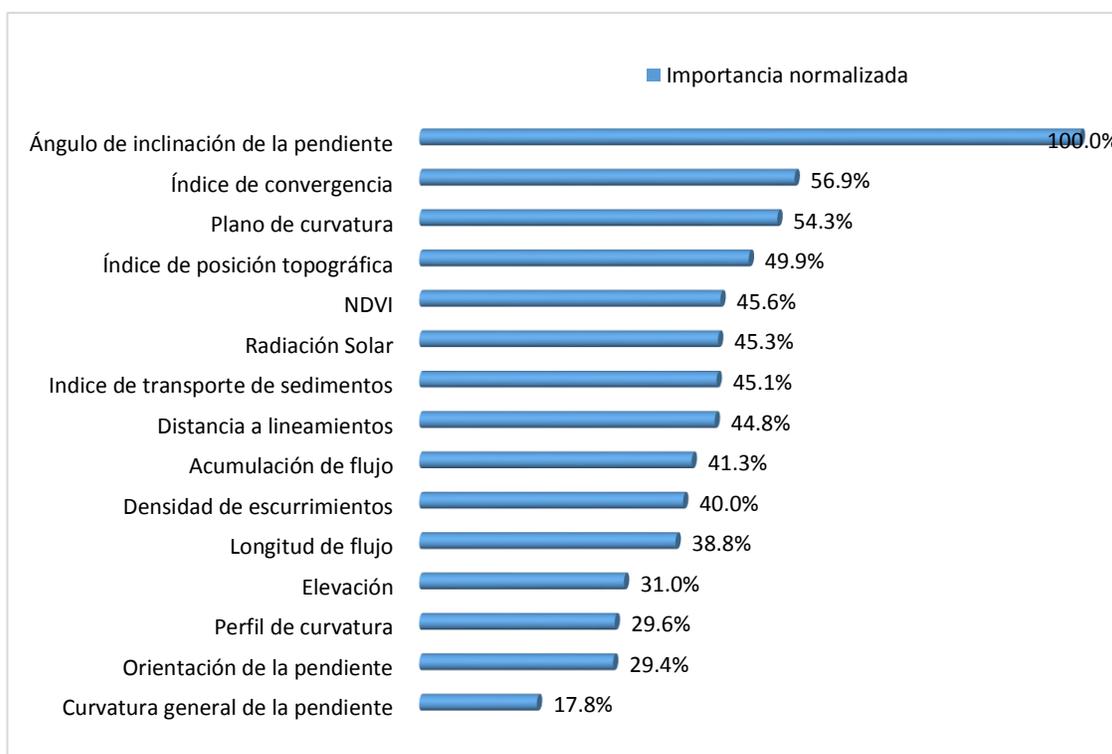


Figura 26. Importancia de factores condicionantes para la susceptibilidad a PRM (RNA)

Los parámetros de sesgo y pesos calculados por el SPSS para la capa de entrada y para la capa de oculta que son utilizados para la modelación pueden visualizarse en las figuras 27 y 28. Los valores a detalle de los sesgos y pesos de la capa oculta pueden observarse en el apéndice A: 5.

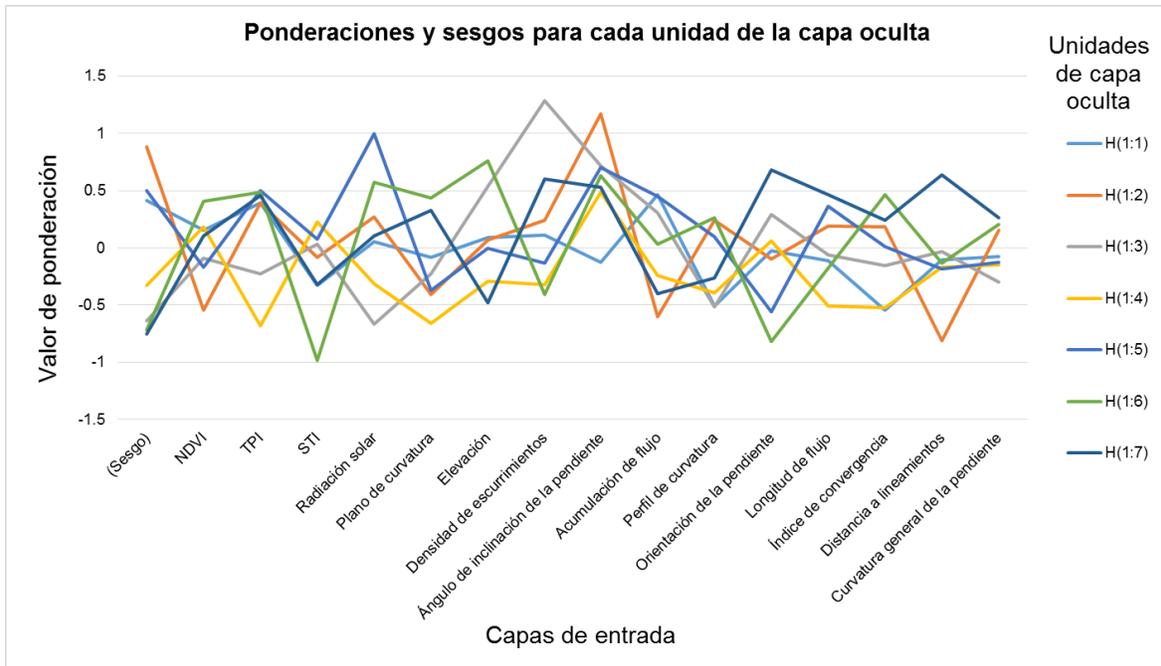


Figura 27. Ponderaciones y sesgos para cada unidad de la capa oculta

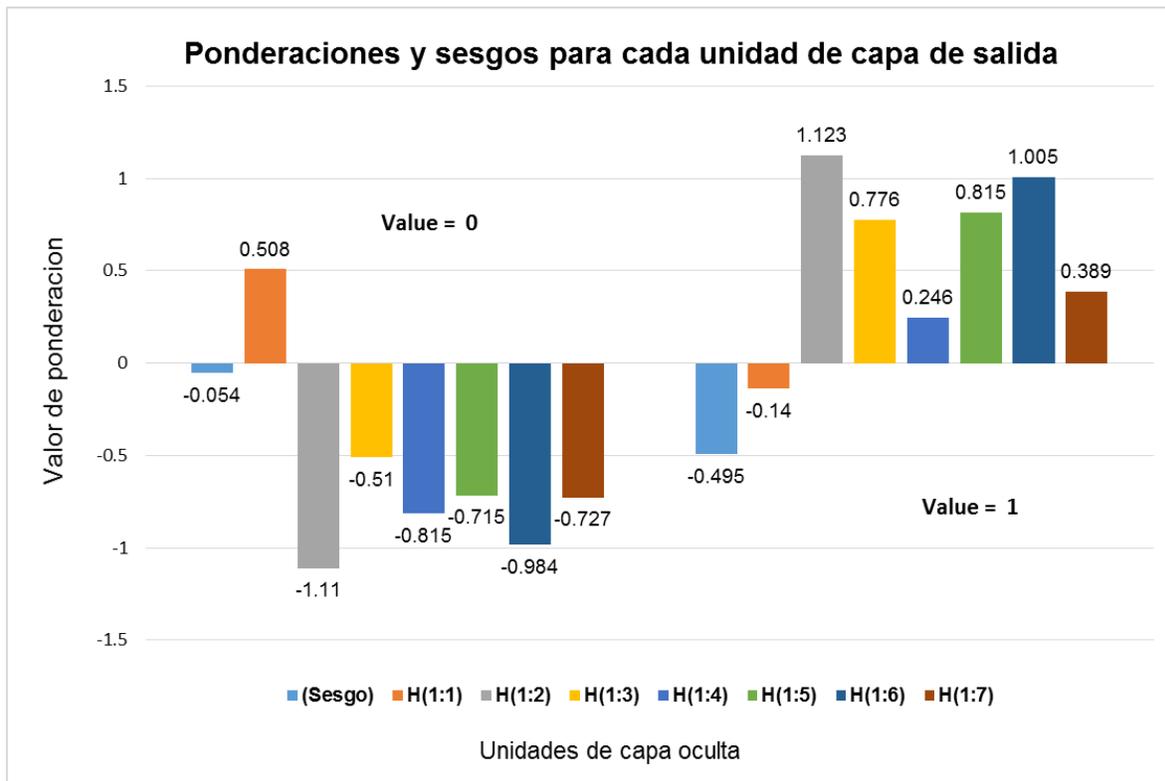


Figura 28. Ponderaciones y sesgos para cada unidad de capa de salida

## 5.8 Resultados de la clasificación de las probabilidades por modelo

En el caso del SPATSMO-SL solo se emplearon datos muestrales de inicio de PRM para el entrenamiento del modelo, por lo que fue imposible la separación de las zonas susceptibles y no susceptibles en base a la proporción; por lo tanto, todas las probabilidades son parte de las zonas susceptibles y se consideró como punto de corte el valor de 0.

En la regresión logística se definió en la base a la proporción el punto de corte en 0.04, que corresponde a la relación de tamaño existente entre el número de celdas con inicios de PRM (susceptibilidad) y el número de celdas totales de muestreo ( $654 / 17,295 = 0.04$ ).

En el caso de la red neuronal artificial se definió en la base a la proporción el punto de corte en 0.5, que de igual manera a la regresión corresponde a la relación de tamaño existente entre el número de celdas con inicios de PRM (susceptibilidad) y el número de celdas totales de muestreo ( $654 / 1,308 = 0.5$ ).

Ya establecido los puntos de corte para cada modelo, los valores de probabilidad de las zonas no susceptibles se han agruparon en una clase (Nula) y los valores de probabilidad de las zonas susceptibles se han agruparon en 5 clases (Muy baja, baja, media, alta y muy alta) por el método de intervalos iguales y se le asignó un color a cada una de ellas (Tabla 14).

Tabla 14. Clasificación de la susceptibilidad para cada modelo estadístico

Clase	Valor de probabilidad			Color
	SPATSMO-SL	Regresión logística binaria	Red neuronal artificial	
Nula	$\leq 0$	$\leq 0.04$	$\leq 0.5$	Gris
Muy baja	0 - 0.2	0.04 - 0.17	0.5 - 0.6	Verde oscuro
Baja	0.2 - 0.4	0.17 - 0.3	0.6 - 0.7	Verde claro
Media	0.4 - 0.6	0.3 - 0.43	0.7 - 0.8	Naranja claro
Alta	0.6 - 0.8	0.43 - 0.56	0.8 - 0.9	Naranja oscuro
Muy alta	0.8 - 1	0.56 - 0.69	0.9 - 1	Rojo

## 5.9 Resultados de la susceptibilidad a PRM

### 5.9.1 Resultados de la susceptibilidad a PRM obtenido con el SPATSMO-SL

Este modelo estadístico sugiere que en el área de estudio las zonas susceptibles a los PRM son 800.42 km<sup>2</sup> que representan el 21% (Tabla 15; figura 30).

Tabla 15. Área establecida para cada clase de grado de susceptibilidad (SPATSMO-SL)

Susceptibilidad	Área en km <sup>2</sup>	Proporción (%)
Nula	3015.21	79.02
Muy baja	63.47	1.66
Baja	183.81	4.82
Media	321.31	8.42
Alta	196.18	5.14
Muy Alta	35.65	0.93

La proporción de las clases dentro de zonas susceptibles fueron media 40.14 %, alta 24.51 %, baja 22.96%, muy baja 7.93% y muy alta 4.45 % (figura 29).

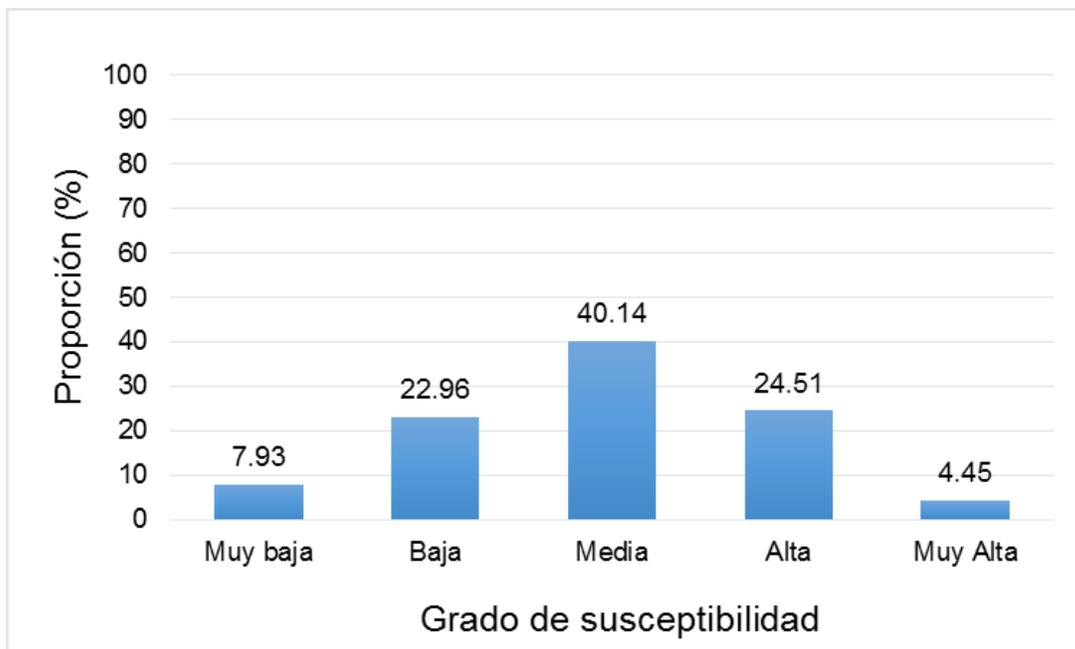


Figura 29. Grado de susceptibilidad dentro de las zonas susceptibles (SPATSMO-SL)

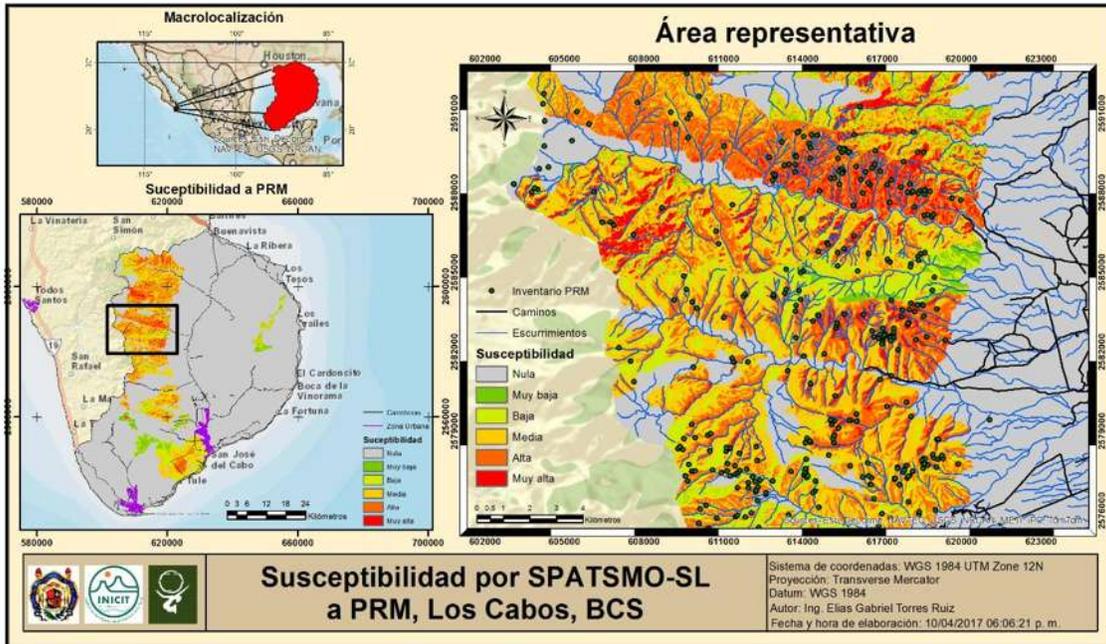


Figura 30. Susceptibilidad por SPATSMO-SL a PRM

Para este modelo es difícil establecer de manera general las condiciones propicias para la ocurrencia de PRM, puesto que el modelo está diseñado para evaluar el comportamiento de los PRM en cada unidad de terreno (Tabla 16). Generalizando los datos en la elaboración del modelo se emplearon 22 factores condicionantes; de los cuales la dirección de flujo y orientación de la pendiente resultaron ser importantes en un número igual o mayor a 10 unidades de terreno (figura 31).

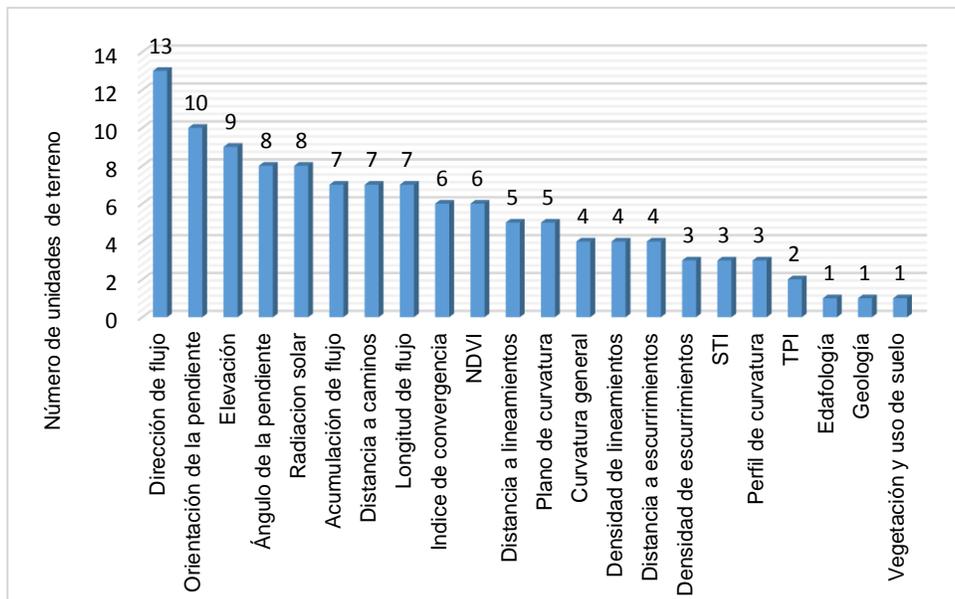


Figura 31. Factores condicionantes relevantes en las unidades de terreno (SPATSMO-SL)

Las condiciones de susceptibilidad a PRM en cada unidad de paisaje pueden verse en la tabla 21 (SBC = Selva Baja Caducifolia). Relativamente las condiciones suelen ser variables según la unidad de terreno que se esté analizando, pero hay condiciones que notablemente ejercen cierta homogeneidad; por ejemplo, los valores de la dirección de flujo, los cuales están entre 1-2. Este rango de valor indica que la dirección del descenso más empinado, o la caída máxima, de una superficie a la superficie susceptible a PRM puede ser este o sureste. Otros factores condicionantes que fueron representativos para la mayor parte de la superficie de la zona de estudio: Orientación de la pendiente (min. =92 grados, máx. =219 grados), Ángulo de inclinación la pendiente (min. =33 grados, máx.= 52 grados), Radiación solar (min. =190 kWh/m<sup>2</sup>, máx. =220 kWh/m<sup>2</sup>), Acumulación de flujo (min. = 0 valor de peso acom., máx. =20 valor de peso acom.) y el NDVI (min = 0.13 valor de índice, máx. = 0.24 valor de índice). Estas homogeneidades son relevantes, pero no pueden ser estandarizadas para la zona de estudio, puesto que la mayoría de estos factores se da en menos de 10 unidades de terreno. Lo que representa entre un 30% y 40% de las unidades de terreno estudiadas.

Tabla 16. Valores de las condiciones para la susceptibilidad a PRM para cada unidad de terreno

Clave	Relaciones espaciales	Rango	Unidades	Clave	Relaciones espaciales	Rango	Unidades	
I-89	NDVI	0.18-0.20	Índice	I-250	Longitud de flujo	4012-5086	Metros	
	Radiación solar	199-220	kwh/m <sup>2</sup>		Elevación	756-930	Metros	
	Orientación de la pendiente	150-205	Grados		Distancia a lineamientos	206-337	Metros	
	Elevación	887-1103	Metros		Distancia a caminos	2209-2870	Metros	
	Distancia a escurrimientos	20-109	Metros		Dirección de flujo	1	Porcentaje	
	Distancia a caminos	139-2780	Metros		Acumulación de flujo	0-15	Peso acom.	
	Dirección de flujo	1-2	Porcentaje		I-251	TPI	-4.69-6.54	Índice
	Acumulación de flujo	0-20	Peso acom.			Plano de curvatura	-0.10-0.57	Índice
I-99	Perfil de curvatura	0.08-1.03	Índice	Índice de convergencia		-3.35-4.19	Índice	
	curvatura general	0.57-1.39	Índice	Curvatura general		1.33-3.09	Índice	
	Ángulo de la pendiente	38-52	Grados	Ángulo de la pendiente	35-37	Grados		
I-105	Plano de curvatura	1.05-1.35	Índice	I-296	Acumulación de flujo	0-18	Peso acom.	
	Orientación de la pendiente	167-204	Grados		Orientación de la pendiente	165-215	Grados	
	Longitud de flujo	5085-5790	Metros		Índice de convergencia	-5.30-4.81	Índice	
	Elevación	1352-1505	Metros		Distancia a caminos	1231-1906	Metros	
I-136	Índice de convergencia	-0.90-1.57	Índice	I-297	Dirección de flujo	1-2	Porcentaje	
	Dirección de flujo	4	Porcentaje		Radiación solar	208-214	Kwh/m <sup>2</sup>	
	Ángulo de la pendiente	35-43	Grados		Orientación de la pendiente	92-125	Grados	

I-141	NDVI	0.16-0.17	Índice	I-331	Dirección de flujo	1-2	Porcentaje
	Plano de curvatura	0.65-1.43	Índice		Densidad de lineamientos	0.10-0.17	m/km <sup>2</sup>
	Orientación de la pendiente	175-219	Grados		NDVI	0.20-0.21	Índice
	Longitud de flujo	1331-2066	Metros		TPI	3.1-8.1	Índice
	Índice de convergencia	-4.20-2.69	Índice		STI	7.9-29	Índice
	Distancia a lineamientos	10-270	Metros		Radiación solar	211-220	Kwh/m <sup>2</sup>
	Distancia a caminos	4747-7550	Metros		Orientación de la pendiente	189-219	Grados
	Dirección de flujo	1-2	Porcentaje		Longitud de flujo	4771-5085	Metros
I-142	Acumulación de flujo	0-11	Peso acom	Edafología	Regosol	Unidad	
	Dirección de flujo	1-2	Porcentaje	Distancia a escurrimientos	84-131	Metros	
I-146	Ángulo de la pendiente	26-36	Grados	Distancia a caminos	1663-2123	Metros	
	Radiación solar	207-219	kwh/m <sup>2</sup>	Dirección de flujo	2	Porcentaje	
	Orientación de la pendiente	133-142	Grados	Densidad de lineamientos	0.50-0.65	m/km <sup>2</sup>	
	Longitud de flujo	2384-5363	Metros	Distancia a lineamientos	1169-1269	Metros	
	Elevación	769-1055	Metros	Densidad de lineamientos	0.87-0.98	m/km <sup>2</sup>	
	Distancia a caminos	2012-2514	Metros	I-332	NDVI	0.18-0.21	Índice
Dirección de flujo	1	Porcentaje	Elevación		207-341	Metros	
I-194	Orientación de la pendiente	139-199	Grados		Densidad de escurrimientos	1.36-1.40	m/km <sup>2</sup>
	Elevación	972-1188	Metros	Curvatura general	0.31-0.38	Índice	
	Distancia a escurrimientos	0-100	Metros	Ángulo de la pendiente	15-21	Grados	
	Distancia a caminos	275-2984	Metros	I-527	Longitud de flujo	3100-3245	Porcentaje
	Dirección de flujo	1-2	Porcentaje		NDVI	0.13-0.15	Índice
I-213	Densidad de escurrimientos	0.95-1.21	m/km <sup>2</sup>	Geología	Granito	Unidad	
	STI	16-67	Índice	Longitud de flujo	1192-2027	Metros	
	Radiación solar	204-216	kwh/m <sup>2</sup>	Elevación	721-753	Metros	
	Perfil de curvatura	-0.18-0.54	Índice	Distancia a lineamientos	30-251	Metros	
	Orientación de la pendiente	162-204	Grados	Dirección de flujo	4	Porcentaje	
	Dirección de flujo	1	Porcentaje	Densidad de lineamientos	0.62-0.74	m/km <sup>2</sup>	
	Acumulación de flujo	0-118	Peso acom	Ángulo de la pendiente	33-35	Grados	
I-224	Vegetación y uso de suelo	SBC	Unidad	I-715	Plano de curvatura	-0.18-0.08	Índice
	STI	8-16	Índice		Perfil de curvatura	0.90-1.1	Índice
	Radiación solar	209-217	kwh/m <sup>2</sup>		Índice de convergencia	-0.92-0.08	Índice
	Orientación de la pendiente	167-199	Grados		Elevación	520-550	Metros
	Índice de convergencia	0.77-4.33	Índice		Curvatura general	-0.79-0	Índice
	Distancia a escurrimientos	0-138	Metros		Ángulo de la pendiente	21-29	Grados
	Distancia a lineamientos	80-403	Metros		Acumulación de flujo	2-8	Peso acom
	Densidad de escurrimientos	1.12-1.15	m/km <sup>2</sup>		Radiación solar	190-199	Kwh/m <sup>2</sup>
	Acumulación de flujo	0-7.20	Peso acom	I-766	Elevación	460-490	Metros
I-250	NDVI	0.21-0.24	Índice		Dirección de flujo	32	Porcentaje
	Radiación solar	208-216	kwh/m <sup>2</sup>		Ángulo de la pendiente	37-42	Grados
	Plano de curvatura	0.19-1.32	Índice				

### 5.9.2 Resultados de la susceptibilidad a PRM obtenido con la regresión logística

El modelo de regresión logística sugiere que en el área de estudio las zonas susceptibles a los PRM son 521.12 km<sup>2</sup> que representan el 14% (Tabla 17; figura 33).

Tabla 17. Área establecida para cada clase de grado de susceptibilidad (RL)

Susceptibilidad	Área en Km <sup>2</sup>	Proporción (%)
Nula	3294.51	86.34
Muy baja	354.32	9.29
Baja	92.19	2.42
Media	41.99	1.10
Alta	19.43	0.51
Muy Alta	13.19	0.35

La proporción de las clases dentro de zonas susceptibles son muy baja 67.99 %, baja 17.69 %, media 8.06%, alta 3.73% y muy alta 2.53 % (figura 32).

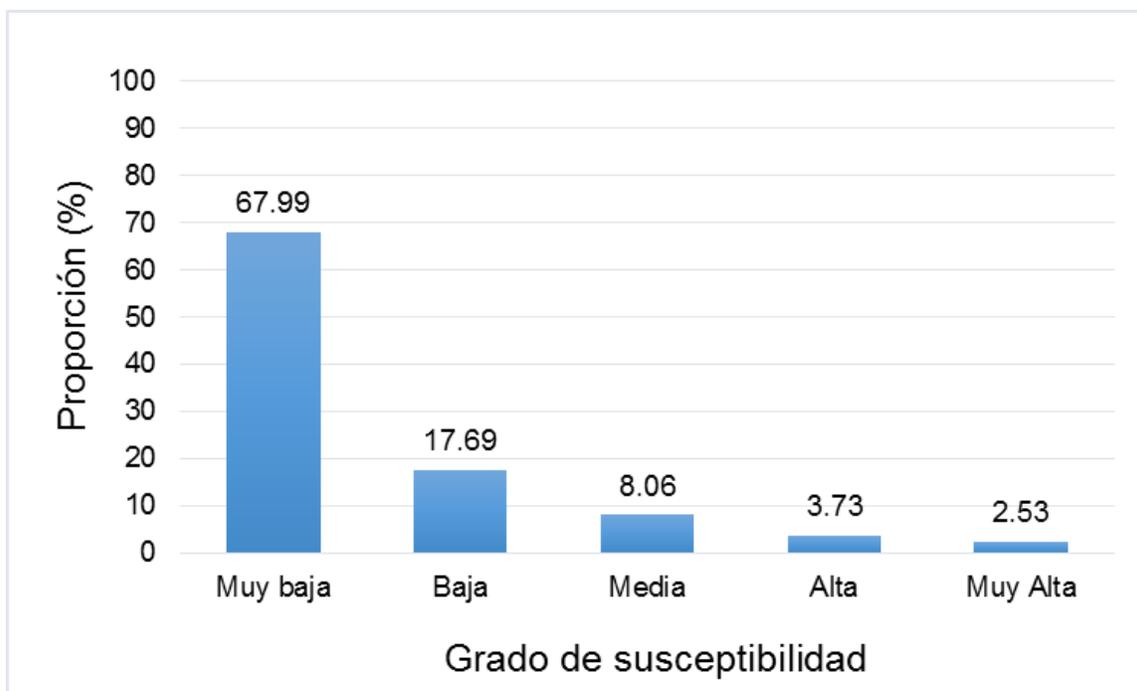


Figura 32. Grado de susceptibilidad dentro de las zonas susceptibles (RL)

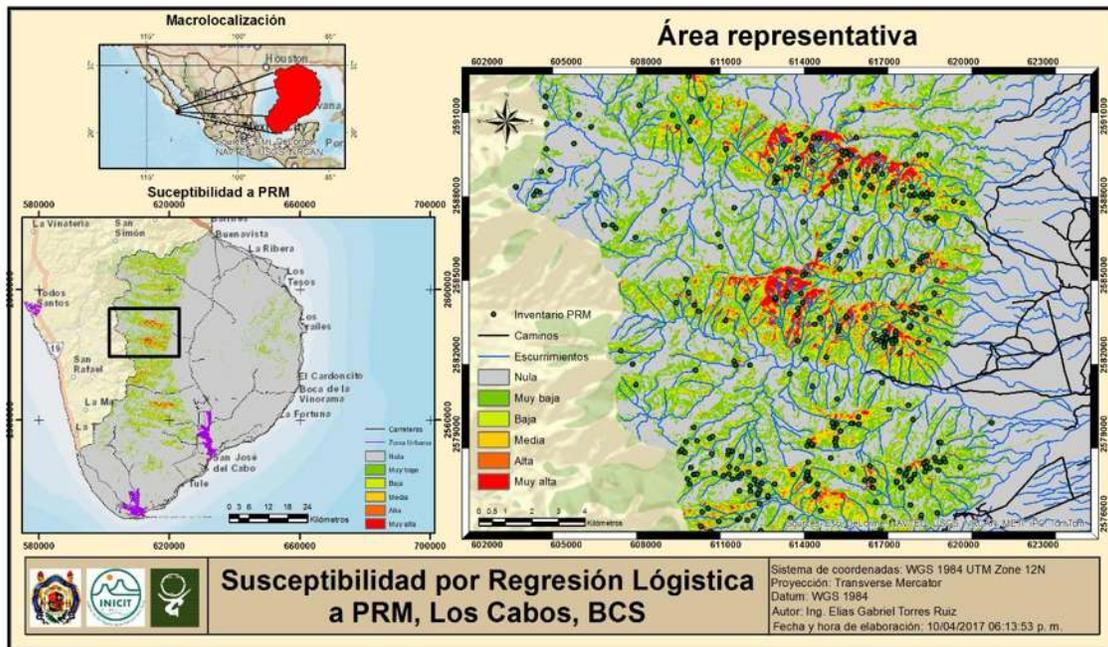


Figura 33. Susceptibilidad por regresión logística a PRM

Las condiciones que propone el modelo para que una zona sea susceptible a PRM son 12 (Tabla 18). Estas condiciones están ordenadas de manera jerárquica según el grado de significancia estadística propuesto por el modelo.

Tabla 18. Factores condicionantes relevantes para la susceptibilidad a PRM (RL)

Factor condicionante	Valor	Unidad	Descripción
Ángulo de inclinación de la pendiente	26 – 40	Grados	
Radiación Solar	193-219	Kwh / m <sup>2</sup>	
Índice de posición topográfica	-2-10	Índice	pendiente media y superior
Orientación de la pendiente	124-214	Grados	Sur, sureste y suroeste
Elevación	727-1141	Metros	
NDVI	0.15-0.20	Índice	Vegetación ligera
Distancia a caminos	240-2720	Metros	
Distancia a escurrimientos	0-200	Metros	
Densidad de escurrimientos	0.91-1.03	m/km <sup>2</sup>	Baja densidad
Distancia de lineamientos	0-627	Metros	
Densidad de carreteras	0-0.04	m/km <sup>2</sup>	Muy baja densidad
Dirección de flujo	1-2	Porcentaje	Sur y sureste

### 5.9.3 Resultados de la susceptibilidad a PRM obtenido con la red neuronal artificial

El modelo de red neuronal artificial sugiere que en el área de estudio las zonas susceptibles a los PRM son 608.11 km<sup>2</sup> que representan el 16% (Tabla 19; figura 35).

Tabla 19. Área establecida para cada clase de grado de susceptibilidad (RNA)

Susceptibilidad	Área en Km <sup>2</sup>	Proporción
Nula	3207.52	84.06
Muy baja	110.41	2.89
Baja	102.40	2.68
Media	104.51	2.74
Alta	130.19	3.41
Muy Alta	160.60	4.21

Las proporciones de las clases de susceptibilidad dentro de zonas susceptibles son muy alta 26.41 %, alta 21.41 %, muy baja 18.16%, media 17.19% y baja 16.84 % (figura 34).

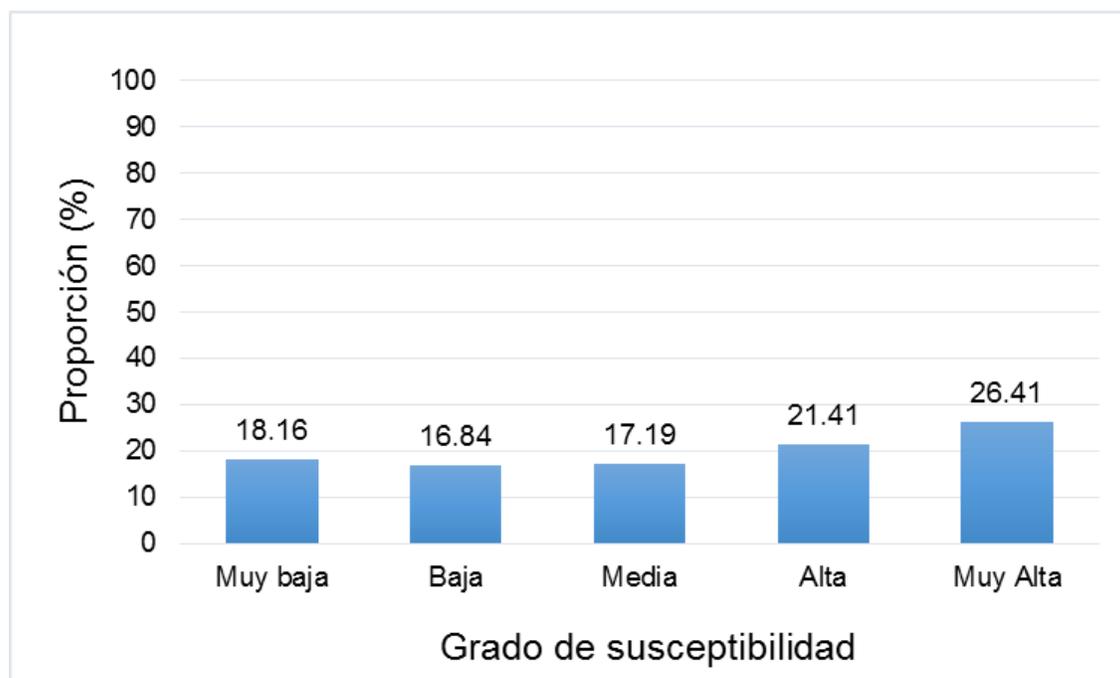


Figura 34. Grado de susceptibilidad dentro de las zonas susceptibles (RNA)

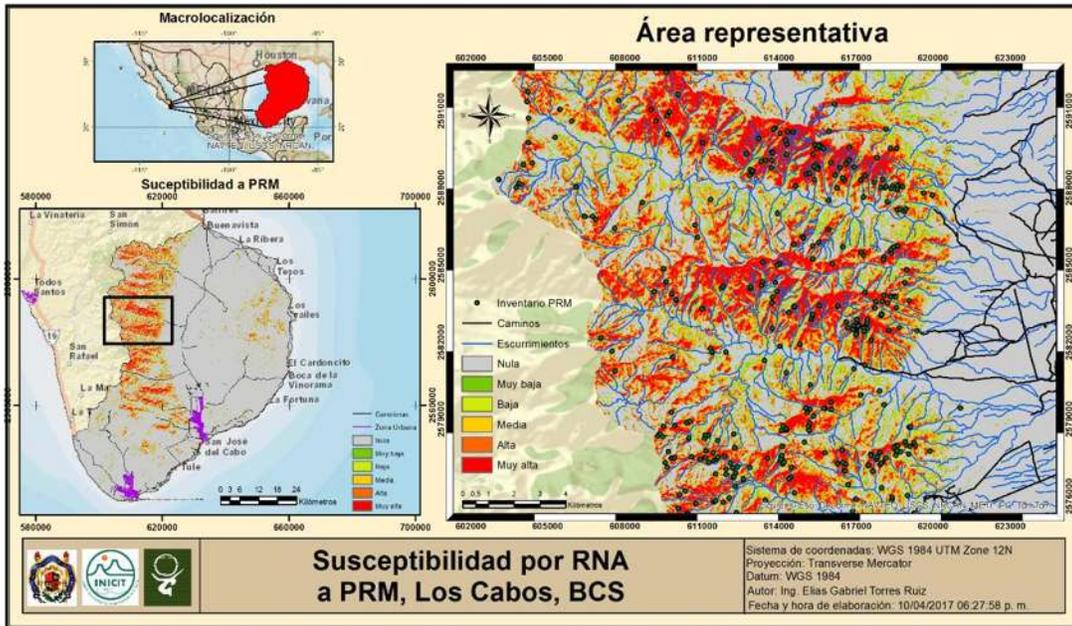


Figura 35. Susceptibilidad por red neuronal artificial a PRM

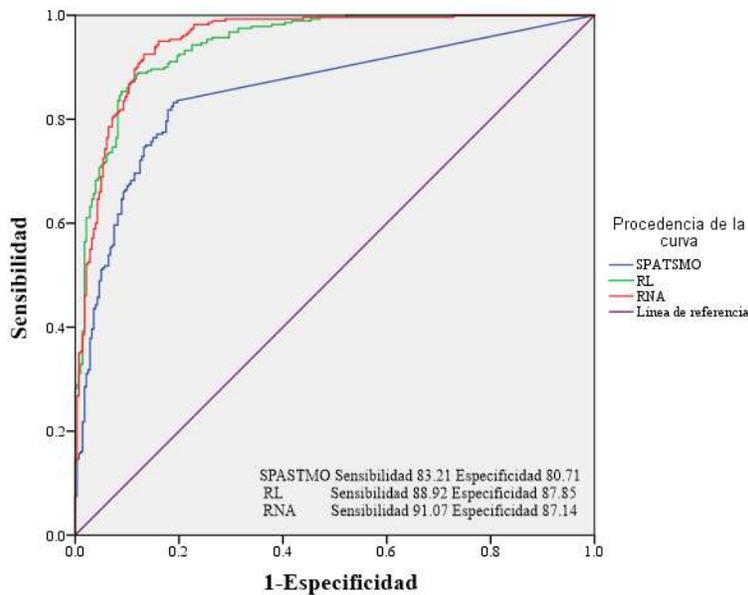
Las condiciones que propone el modelo para que una zona sea susceptible a PRM son 15 (Tabla 20). Estas condiciones están ordenadas de manera jerárquica según su importancia normalizada propuesta por el modelo.

Tabla 20. Factores condicionantes relevantes para la susceptibilidad a PRM (RNA)

Factor condicionante	Valor	Unidad	Descripción
Ángulo de inclinación de la pendiente	26 – 40	Grados	
Índice de convergencia	-3-5	Índice	Zonas en pendiente (intermedias)
Plano de curvatura	-0.72-1.13	Índice	Superficies lineales
Índice de posición topográfica	-2-10	Índice	pendiente media y superior
NDVI	0.15-0.20	Índice	Vegetación ligera
Radiación solar	193-219	Kwh / m <sup>2</sup>	
Índice de transporte de sedimentos	-234-41	Índice	Perdida de suelo de media a alta
Distancia a lineamientos	0-627	Metros	
Acumulación de flujo	0-58	Peso acom.	Zonas de muy baja acumulación
Densidad de escurrimientos	0.91-1.03	m/km <sup>2</sup>	Baja densidad
Longitud de flujo	0-106	Metros	Indica cercanía a los parteaguas
Elevación	727-1141	Metros	
Perfil de curvatura	-0.71-0.52	Índice	Superficies lineales
Orientación de la pendiente	124-214	Grados	Sur, sureste y suroeste
Curvatura general de la pendiente	0-1.11	índice	Superficies lineales

## 5.10 Resultados de la validación con la curva ROC

Los resultados de la evaluación del rendimiento global de los modelos con el método de la curva ROC fueron: área bajo la curva (AUC) del método estadístico SPASTMO-SL 0.854 con un error estándar estimado de 0.17, AUC del método de regresión logística (RL) 0.946 y AUC para el método de red neuronal artificial (RNA) 0.952, ambas con un error estándar estimado de 0.09 (figura 36). El intervalo de confianza para el SPASTMO-SL fue de  $\pm 0.0032$  y para la regresión logística y la red neuronal artificial de  $\pm 0.0017$  (Tabla 21). Por último, los valores de sensibilidad y especificidad para los modelos fueron 83.21 y 80.71, 88.92 y 87.85 y 91.07 y 87.14 respectivamente.



Los segmentos diagonales son producidos por los empates.

Figura 36. Evaluación de la curva ROC para los modelos estadísticos de susceptibilidad

Tabla 21. Resultados del área bajo la curva (ROC) para los modelos de susceptibilidad

Variables resultado de contraste	Área	Error típico	Significancia asintótica	Intervalo de confianza asintótico al 95%	
				Límite inferior	Límite superior
SPASTMO-SL	.854	.017	.000	.822	.887
Regresión logística	.946	.009	.000	.929	.963
Red neuronal artificial	.952	.009	.000	.935	.969

### 5.11 Resultados de la validación con matriz de confusión

Los resultados de la validación por la matriz de confusión evaluando la exactitud y precisión de los modelos son: 82% y 83% para el SPATSMO-SL, 88% y 89% para la regresión logística y 89% y 91 % para la red neuronal artificial, respectivamente (Tabla 22).

Tabla 22. Resultados de la matriz de confusión para los modelos de susceptibilidad

SPATSMO-SL		Pronosticado		Total	Índices SPATSMO-SL	
		Falso	Verdadero		Exactitud	
Real	Negativo	226	54	280	Precisión	0.84
	Positivo	46	234	280	R	0.84
Total		273	287	560	Fm	0.82
Regresión logística		Pronosticado		Total	Índices Regresión logística	
		Falso	Verdadero		Exactitud	
Real	Negativo	246	34	280	Precisión	0.89
	Positivo	31	249	280	R	0.89
Total		277	283	560	Fm	0.88
Red neuronal artificial		Pronosticado		Total	Índices Red neuronal artificial	
		Falso	Verdadero		Exactitud	
Real	Negativo	244	36	280	Precisión	0.91
	Positivo	25	255	280	R	0.91
Total		269	291	560	Fm	0.89

### 5.12 Resultados de la comparación de resultados de pruebas de validación

La comparativa de los tres modelos estadísticos inicia con la distribución de los PRM reales en los grados de susceptibilidad a PRM pronosticados; la cual es totalmente diferente en cada modelo. Los criterios de la regresión logística se inclinan en un 24% a la susceptibilidad muy baja, mientras que para el SPASTMO-SL la mayor predominancia se encuentra en la susceptibilidad alta con 44% y en el caso de la red neuronal artificial la susceptibilidad muy alta representa el indicador más alto con 61% (figura 37). Por otro lado el número de PRM reales mal clasificados en zonas nulas evidencia el error cometido en cada modelo: 46 PRM en el SPATSMO-SL, 31 PRM en la regresión logística y 25 PRM en la red neuronal artificial (Tabla 23).

Tabla 23. Número de PRM en cada clase de susceptibilidad por modelo.

	SPATSMO-SL	Regresión logística	Red neuronal artificial
Nula	46	31	25
Muy baja	3	68	6
Baja	16	52	20
Media	64	49	16
Alta	124	44	42
Muy alta	27	36	171
Total	280	280	280

En esta primera comparación se considera como mejor producto al modelo que discrimina con mayor exactitud y precisión la distribución de los PRM en los grados de susceptibilidad de clases altas y muy altas (Meng *et al.*, 2015; Wang *et al.*, 2013; Tien Bui *et al.*, 2012; Peng *et al.*, 2014 y Baeza *et al.*, 2010); se considera que los PRM con los que se valida son eventos que ya ocurrieron y por lo tanto, la mayoría de ellos debería concentrarse sobre estas clases. La proporción de las zonas con susceptibilidad alta y muy alta es superior en el mapa producido por la red neuronal artificial (76%) en comparación con los resultados de los otros dos métodos (Regresión logística = 29% y SPATSMO-SL = 54%; figura 37).

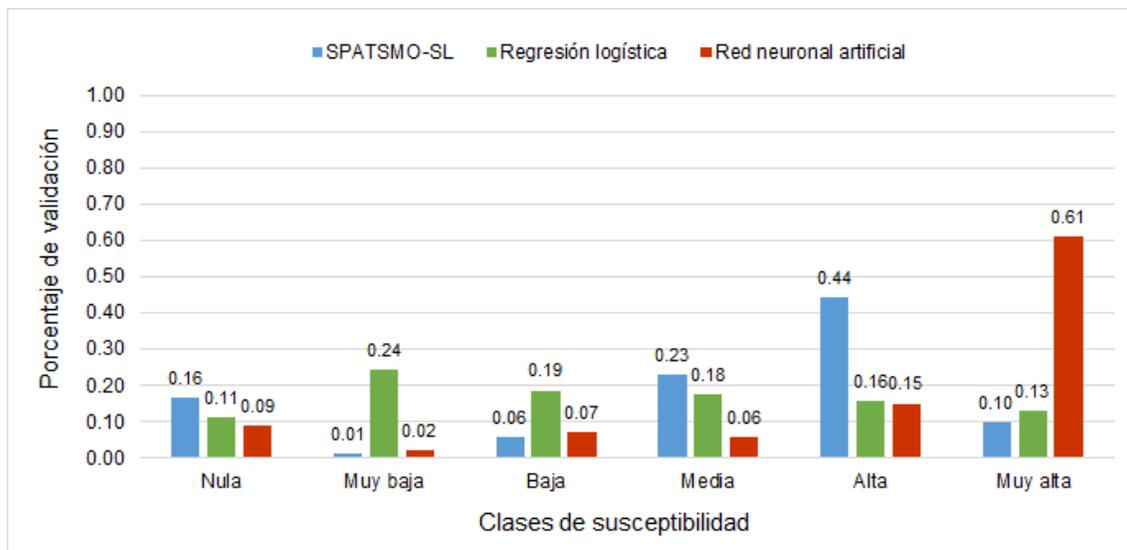


Figura 37. Porcentaje de PRM reales para cada clase de susceptibilidad por modelo estadístico

Reiterando lo anterior, el modelo que predice en un área menor la mayoría de los PRM reales en la clase de susceptibilidad muy alta es la red neuronal artificial (figura 38).

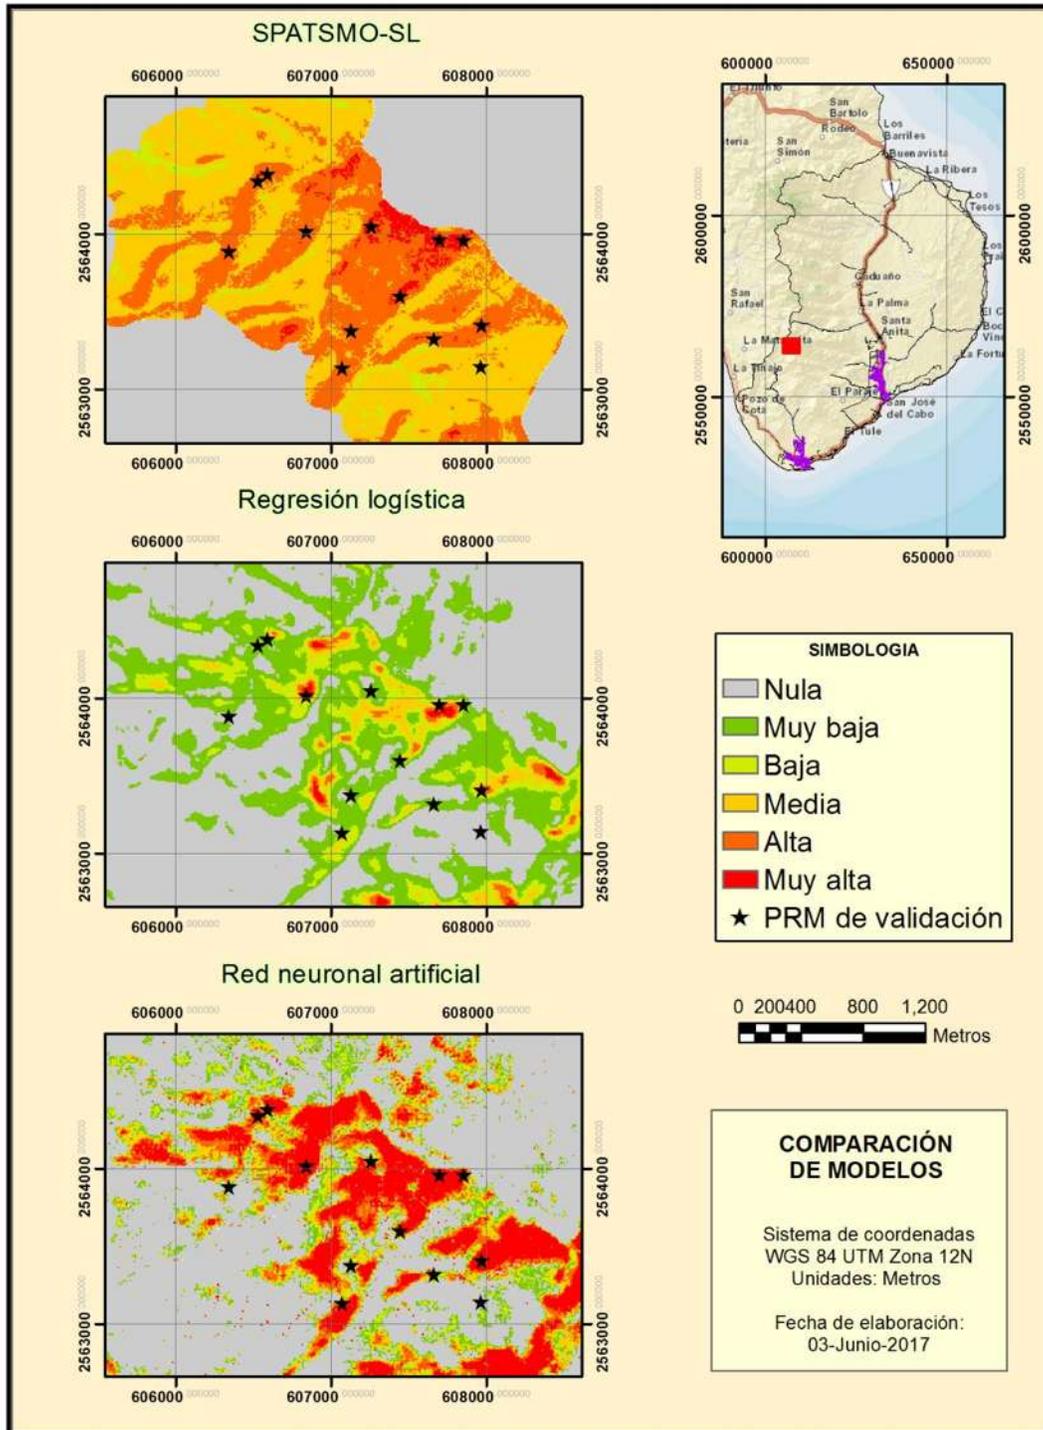


Figura 38. Comparación representativa de los modelos estadísticos

La segunda comparativa consiste en la validación de la curva ROC (Tabla 21), demostrando que el modelo de red neuronal artificial tiene un rendimiento de prueba global de 0.6% por encima de la regresión logística (95.2%-94.6%) y 9.8 % por encima del SPATSMO-SL (95.2%-85.4%). El análisis extenso en este rubro nos indica que la mayor probabilidad de que un modelo pronostique bien las zonas susceptibles es del 91.07% y se encuentra en el modelo de red neuronal artificial, en el caso de la mayor probabilidad de que un modelo pronostique bien las zonas no susceptibles es del 87.85% y esta se encuentra en el modelo de regresión logística. Pero para efectos de este tipo de estudio es más importante la pronosticación correcta de las zonas susceptibles que de las zonas no susceptibles. Por lo tanto, la red neuronal artificial es superior que los dos otros métodos en esta segunda comparativa.

Una tercera comparativa es la validación mediante la matriz de confusión (Tabla 22) la cual establece que la mayor exactitud es del 89% y la mayor precisión del 91%; pronosticando correctamente 255 PRM de 280 PRM reales, estos valores máximos son resultados del mapa de susceptibilidad generado a través de la red neuronal artificial. En la regresión logística se obtiene que el pronóstico correcto de PRM es de 249 PRM de 280 PRM reales, por su cual su valor de exactitud y precisión es de 88% y 89%, respectivamente. Por el último el resultado del SPATSMO-SL nos ofrece una exactitud del 82% y una precisión del 84%, producto de la correcta clasificación de 234 PRM de 280 PRM reales.

Las tres comparaciones efectuadas coinciden en que el modelo de red neural artificial es altamente creíble, porque además de la precisión (91 %), exactitud (89 %) y prueba de rendimiento global mostrada (95.2 %), el método modera las clases de medias a bajas y potencializa las clases altas (figura 37). El método de regresión logística es relativamente bueno, pues sus resultados no son muy distantes de la RNA (precisión =89 %, exactitud = 88%, ROC = 94.6 %) pero el porcentaje obtenido de PRM reales en grados de susceptibilidad de clase baja y muy baja disminuye la confiabilidad de sus resultados (figura 37). Por su parte el SPATSMO-SL resulto ser el método con los resultados menos favorables (precisión =82 %, exactitud = 84%,

ROC = 85.4 %), producto de la generalización de las condiciones en cada unidad de terreno (análisis por áreas geográficas y no de pixel a pixel) reduciendo así su exactitud y precisión.

## Capítulo 6: Discusión

Se puede afirmar el modelo de red neuronal artificial produce estimaciones precisas de la distribución espacial de las zonas susceptibles a PRM. Esta aseveración concuerda con los resultados presentados por Pradhan y Lee, 2010; Tien Bui *et al.*, 2015; Conforti *et al.*, 2014 y Yilmaz, 2009.

De los 12 trabajos revisados donde se aplicó la técnica de la red neuronal artificial ninguno reportó un resultado tan alto como este trabajo (95.2 %), los resultados más cercanos a esta medida fueron de 94 % (Pradhan y Lee., 2010), 90 % (Tien Bui *et al.*, 2015), 90% (Conforti *et al.*, 2014) y 89.03 % (Yilmaz, 2009).

En cuanto a la comparación de la red neuronal artificial y la regresión logística Pradhan y Lee, (2010) coincidieron con este trabajo señalando que la RNA es superior a la RL, Sin embargo Rossi *et al.*, (2010); Murillo y Álcantara, (2015) y Pradhan y Lee, (2010) consideraron que la RL garantiza mejores resultados que la RNA. Los resultados comparativos entre estos dos modelos aún no se pueden considerar concluyentes, pues existen variantes en la forma de abordar la investigación en cada trabajo; número o tipos de factores condicionantes empleados y análisis por unidad espacial o pixel a pixel, también pueden existir diferencias en el algoritmo de procesamiento de cada método, así como el software de manipulación empleado.

Es la primera investigación en la que se compara el SPATSMO-SL contra otros modelos estadísticos así como la primera vez que se evalúa y aunque para este trabajo se encuentra por encima del valor de confiabilidad aceptable establecidos por la curva ROC =75% (Hanley y McNeil, 1983), el modelo actual del SPATSMO-SL no es un modelo recomendable para el análisis de la susceptibilidad a PRM ya que estandariza las unidades de terreno evaluadas considerándolas desde un inicio como unidades susceptibles. Existe la posibilidad de que si se generan modificaciones en la cuarta etapa del modelo este pudiese incrementar su confiabilidad, aunque no es posible afirmarla.

## Capítulo 7: Conclusiones

1. El área susceptible a presentar PRM varía de 521.12 km<sup>2</sup> a 800.42 km<sup>2</sup> que representan de un 14 a 21% del área total de estudio.
2. La susceptibilidad a PRM en el área del estudio no puede ser considerado como un problema menor pues a pesar de que la mayor parte de las zonas susceptibles se concentran en zonas lejanas de la infraestructura pública, ciudades muy importantes como Cabo San Lucas y San José del Cabo interaccionan con zonas susceptibles pronosticadas como clases altas y muy altas en los modelos.
3. Los resultados logrados con los tres modelos son satisfactorios (Rendimiento global = 95.2% - 85.4%, Sensibilidad = 91.07 - 83-21, Especificidad = 87.85 – 80.71, Exactitud = 89% - 82% y una precisión = 91% - 84%).
4. El método estadístico de red neuronal artificial resulto ser el más exacto, preciso y fiable para nuestra área de estudio (Rendimiento global = 95.2%, Sensibilidad = 91.07, Especificidad = 87.14, Exactitud = 89% y una precisión = 91%).
5. El hecho de tener un número mayor de factores condicionantes no influye en la discriminación de las zonas estables/inestables, pero aumenta la posibilidad de tener más factores significativos para la modelación de la susceptibilidad.
6. Los factores condicionantes a PRM de tipo natural obtuvieron un peso mayor que los factores de tipo antropogénico. Esto tomando en cuenta el mejor modelo estadístico el cual sugiere que los factores condicionantes que influyen en la ocurrencia de PRM en el área de estudio son: ángulo de inclinación de la pendiente, índice de convergencia, plano de curvatura, índice de posición topográfica, NDVI, radiación solar, índice de transporte de sedimentos, distancia a lineamientos, acumulación de flujo, densidad de escurrimientos, longitud de flujo, elevación, perfil de curvatura, orientación de la pendiente y curvatura general de la pendiente.
7. Los análisis realizados con SPATSMO-SL, regresión logística y red neuronal artificial revelaron las desventajas que tienen los factores condicionantes que se consideran como variables categóricas (vegetación y uso de suelo, geología,

edafología y geomorfología) ante los factores condicionantes considerados como variables continuas. Ya que los segundos permiten discriminar entre una gama mayor de valores en comparación de los primeros que suelen ser limitados.

8. Aunque los resultados son alentadores para la correcta zonificación de la susceptibilidad a PRM, los modelos de probabilidad y discriminación de las zonas susceptibles puede ser mejorados; incluyendo en el análisis algunas de las posibles variables que no fueron examinadas en esta investigación o realizando un modelo híbrido a base de los modelos trabajados en este proyecto.

## REFERENCIAS CITADAS

Abarca, O. (2010). "Desarrollo de un modelo de geoprocésamiento para la valoración productiva y tributaria de tierras agrícolas en Venezuela". *Tesis Doctoral*. Universidad Politécnica de Madrid. E.T.S. De Ingenieros en Topografía Geodesia y Cartografía.

Ahmed, B. (2015). "Landslide susceptibility modelling applying user-defined weighting and data-driven statistical techniques in Cox's Bazar Municipality, Bangladesh". *Natural Hazards*, 79(3), 1707–1737. <http://doi.org/10.1007/s11069-015-1922-4>

Akgün, A. y Bulut, F. (2007). "GIS-based landslide susceptibility for Arsin-Yomra (Trabzon, North Turkey) region". *Environmental Geology*, 51(8), 1377–1387. <http://doi.org/10.1007/s00254-006-0435-6>

Akgun, A., Dag, S., y Bulut, F. (2008). "Landslide susceptibility mapping for a landslide-prone area (Findikli, NE of Turkey) by likelihood-frequency ratio and weighted linear combination models". *Environmental Geology*, 54(6), 1127–1143. <http://doi.org/10.1007/s00254-007-0882-8>

Alcántara, I. (2000). "Landslides: ¿deslizamientos o movimientos del terreno? Definición, clasificaciones y terminología". *Investigaciones Geográficas*. Boletín del instituto de Geografía, UNAM; 41

Althuwaynee, O. F., Pradhan, B., Park, H. J., y Lee, J. H. (2014). "A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping". *Catena*, 114, 21–36. <http://doi.org/10.1016/j.catena.2013.10.011>

Althuwaynee, O. F., Pradhan, B., Park, H. J., y Lee, J. H. (2014). "A novel ensemble decision tree-based CHi-squared Automatic Interaction Detection (CHAID) and multivariate logistic regression models in landslide susceptibility mapping". *Landslides*, 11(6), 1063–1078. <http://doi.org/10.1007/s10346-014-0466-0>

Armaş, I. (2012). "Weights of evidence method for landslide susceptibility mapping. Prahova Subcarpathians, Romania". *Natural Hazards*, 60(3), 937–950. <http://doi.org/10.1007/s11069-011-9879-4>

Atkinson, P.M. y Tatnall, A.R.L. (1997). "Neural networks in remote sensing". *International Journal of Remote Sensing*, 18(699–709).

Ayalew, L., Yamagishi, H., Marui, H., y Krnao, T. (2005). "Landslides in Sado Island of Japan: part II. GIS-based susceptibility mapping with comparisons of results from two methods and verifications". *Eng Geo*, 81:432–445.

Ayalew, L. y Yamagishi, H. (2005). "The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan". *Geomorphology*, 65(1-2), 15–31. <http://doi.org/10.1016/j.geomorph.2004.06.010>

Baeza, C., y Corominas, J. (2001). "Assessment of shallow landslide susceptibility by means of multivariate statistical techniques". *Earth Surface Processes and Landforms*, 26, 1251–1263.

Baeza, C., Lantada, N., y Moya, J. (2010). "Validation and evaluation of two multivariate statistical models for predictive shallow landslide susceptibility mapping of the Eastern Pyrenees (Spain)". *Environmental Earth Sciences*, 61(3), 507–523. <http://doi.org/10.1007/s12665-009-0361-5>

- Bai, S. B., Wang, J., Thiebes, B., Cheng, C., y Chang, Z. Y. (2014). "Susceptibility assessments of the Wenchuan earthquake-triggered landslides in Longnan using logistic regression". *Environmental Earth Sciences*, 71(2), 731–743. <http://doi.org/10.1007/s12665-013-2475-z>
- Bonachea, P. (2006). "Desarrollo, aplicación y validación de procedimientos y modelos para la evaluación de amenazas, vulnerabilidad y riesgo debidos a procesos geomorfológicos". *Tesis Doctoral*. Departamento de Ciencias de la Tierra y Física de la Materia Condensada. Universidad de Cantabria. Recuperado de <http://hdl.handle.net/10803/10610>
- Bourenane, H., Bouhadad, Y., Guettouche, M. S., y Braham, M. (2015). "GIS-based landslide susceptibility zonation using bivariate statistical and expert approaches in the city of Constantine (Northeast Algeria)". *Bulletin of Engineering Geology and the Environment*, 74(2), 337–355. <http://doi.org/10.1007/s10064-014-0616-6>
- Brunsden, D. (1984). "Mudslides". In *Slope Instability* (eds D. Brunsden and D.B. Prior), Wiley, Chichester, 363-418.
- Capra, L., Lugo, J., y Zambrano, J. (2006). "La importancia de la geología en el estudio de los procesos de remoción en masa: El caso de Totomoxtla, Sierra Norte de Puebla, México". *Boletín de la Sociedad Geológica Mexicana*, 18(2), 205–214.
- Carrara, A. (1983). "A multivariate model for landslide hazard evaluation". *Mathematical Geology*, 15, 403-426.
- Carrara, A. (1989). "Multivariate models for landslide hazard evaluation. A "black box" approach". *Workshop on natural disasters in European Mediterranean Countries*, Perugia, 205-224.
- Carrara, A., Cardinali, M., Detti, R., Guzzetti, F., Pasqui, V., y Reichenbach, P. (1990). "Geographical Information Systems and Multivariate Models in Landslide Hazard Evaluation". *ALPS 90 Alpine Landslide Practical Seminar, 6th International Conference and Field Workshop on Landslides*, Aug. 31- Sept. 12, 1990, Milano, Italy, 17–28.
- Castañeda, F. (2011). "Análisis de Peligros por Procesos de Remoción en Masa en estructuras Volcánicas. Peñón de los baños y peñón del marques, Distrito federal". *Tesis de Maestría*. Instituto Politécnico Nacional. Escuela Superior de Ingeniería y Arquitectura. México, México.
- Chalkias, C., Ferentinou, M., y Polykretis, C. (2014). "GIS Supported Landslide Susceptibility Modeling at Regional Scale: An Expert-Based Fuzzy Weighting Method". *ISPRS International Journal of Geo-Information*, 3(2), 523–539. <http://doi.org/10.3390/ijgi3020523>
- Chacón, J., Irigaray, C. y Fernandez, T. (2007). "Los movimientos de ladera de la provincia de Granada". *Atlas de Riesgos Naturales en la Provincia de Granada*, 1era edición, 45-82.
- Chang, S. H., y Wan, S. (2015). "Discrete rough set analysis of two different soil-behavior-induced landslides in National Shei-Pa Park, Taiwan". *Geoscience Frontiers*, 6(6), 807–816. <http://doi.org/10.1016/j.gsf.2013.12.010>
- Chávez, V. (1978). "Estudio geológico general del área Loreto-Comondu-Bahía Concepción, Estado de Baja California Sur". *Tesis*, Escuela Superior de Ingeniería y Arquitectura, México, D.F.
- Chen, W., Li, W., Hou, E., Bai, H., Chai, H., Wang, D., Cui, X., y Wang, Q. (2015). "Application of frequency ratio, statistical index, and index of entropy models and their comparison in landslide susceptibility mapping for the Baozhong Region of Baoji, China". *Arabian Journal of Geosciences*, 8(4), 1829–1841. <http://doi.org/10.1007/s12517-014-1554-0>

- Chu, C. M., Tsai, B. W., y Chang, K. T. (2009). "Integrating decision tree and spatial cluster analysis for landslide susceptibility zonation". *Engineering and Technology*, 59, 479–483. Retrieved from <http://www.scopus.com/inward/record.url?eid=2-s2.0-78651560559partnerID=tZOtx3y1>
- Chung, C. J., y Fabbri, A. G. (2008). "Predicting landslides for risk analysis - Spatial models tested by a cross-validation technique". *Geomorphology*, 94(3-4), 438–452. <http://doi.org/10.1016/j.geomorph.2006.12.036>
- Chuvienco, E. (2002). "Teledetección ambiental. La observación de la Tierra desde el Espacio". *Ariel Ciencia*. 586 p.
- Conforti, M., Pascale, S., Robustelli, G., y Sdao, F. (2014). "Evaluation of prediction capability of the artificial neural networks for mapping landslide susceptibility in the Turbolo River catchment (northern Calabria, Italy)". *Catena*, 113, 236–250. <http://doi.org/10.1016/j.catena.2013.08.006>
- Conforti, M., Robustelli, G., Muto, F., y Critelli, S. (2012). "Application and validation of bivariate GIS-based landslide susceptibility assessment for the Vittravo river catchment (Calabria, south Italy)". *Natural Hazards*, 61(1), 127–141. <http://doi.org/10.1007/s11069-011-9781-0>
- Conoscenti, C., Ciaccio, M., Caraballo-Arias, N. A., Gómez-Gutiérrez, Á. Rotigliano, E., y Agnesi, V. (2015). "Assessment of susceptibility to earth-flow landslide using logistic regression and multivariate adaptive regression splines: A case of the Belice River basin (western Sicily, Italy)". *Geomorphology*, 242, 49–64. <http://doi.org/10.1016/j.geomorph.2014.09.020>
- Conrad, O. (2007). "Program Structure and Current State of Implementation", *SAGA – Analysis and Modelling Applications*, 115, 39-52.
- Corominas, J. y García, A. (1997). "Terminología de los movimientos de ladera". *IV Simposio Nacional sobre Taludes y Laderas Inestables*, 3, 1051-1072.
- Corominas, J., y Moya, J. (2008). "A review of assessing landslide frequency for hazard zoning purposes". *Engineering Geology*, 102, 193-213.
- Cruden, D. M. y Varnes, D.J. (1996). "Landslide types and processes, in landslides- Investigation and Mitigation". *Special Report 47*, 36-75.
- Cuanalo, O., Oliva, A., y Gallardo R. (2011). "Inestabilidad de laderas. Influencia de la actividad humana". *Elementos*, 84(18), 39-46.
- Dahal, R. K. (2014). "Regional-scale landslide activity and landslide susceptibility zonation in the Nepal Himalaya". *Environmental Earth Sciences*, 71(12), 5145–5164. <http://doi.org/10.1007/s12665-013-2917-7>
- Das, I., Sahoo, S., van Westen, C., Stein, A., y Hack, R. (2010). "Landslide susceptibility assessment using logistic regression and its comparison with a rock mass classification system, along a road section in the northern Himalayas (India)". *Geomorphology*, 114(4), 627–637. <http://doi.org/10.1016/j.geomorph.2009.09.023>
- Das, I., Stein, A., Kerle, N., y Dadhwal, V. K. (2012). "Landslide susceptibility mapping along road corridors in the Indian Himalayas using Bayesian logistic regression models". *Geomorphology*, 179, 116–125. <http://doi.org/10.1016/j.geomorph.2012.08.004>
- Davis, J. C., Chung, C. J., y Ohlmacher, G. C. (2006). "Two models for evaluating landslide hazards". *Computers and Geosciences*, 32(8), 1120–1127. <http://doi.org/10.1016/j.cageo.2006.02.006>
- Dehnavi, A., Aghdam, I. N., Pradhan, B., y Morshed Varzandeh, M. H. (2015). "A new hybrid model using step-wise weight assessment ratio analysis (SWARA) technique and adaptive neuro-fuzzy

inference system (ANFIS) for regional landslide hazard assessment in Iran”. *Catena*, 135, 122–148. <http://doi.org/10.1016/j.catena.2015.07.020>

De la luz, A. (2011). “Análisis y definición de tipos de deslizamientos y sus zonas de susceptibilidad en la microcuenca el ventilador, Angangueo, Michoacán, México”. *Tesis de Maestría*. Universidad Autónoma de Querétaro. Facultad de ciencias naturales, Querétaro, México.

Deleo, J. (1993). “Receiver operating characteristic laboratory (ROCLAB): software for developing decision strategies that account for uncertainty”. *In: Proceedings of the 2nd international symposium on uncertainty modelling and analysis*, 318–325.

Devkota, K. C., Regmi, A. D., Pourghasemi, H. R., Yoshida, K., Pradhan, B., Ryu, I. C., Dhital, M.R., y Althuwaynee, O. F. (2013). “Landslide susceptibility mapping using certainty factor, index of entropy and logistic regression models in GIS and their comparison at Mugling-Narayanghat road section in Nepal Himalaya”. *Natural Hazards*, 65(1), 135–165. <http://doi.org/10.1007/s11069-012-0347-6>

Dewitte, O., Chung, C. J., Cornet, Y., Daoudi, M., y Demoulin, A. (2010). “Combining spatial data in landslide reactivation susceptibility mapping: A likelihood ratio-based approach in W Belgium”. *Geomorphology*, 122(1-2), 153–166. <http://doi.org/10.1016/j.geomorph.2010.06.010>

Díaz de Terán, J. (2011). “Procesos de ladera. Erosión y evolución de laderas. Estabilidad e inestabilidad. Factores condicionantes y desencadenantes. Deslizamientos: mecanismos y tipos. Problemática ingenieril de laderas y taludes.”. *Curso de Geología*. Universidad de Cantabria, España. Recuperado de <http://ocw.unican.es/enseñanzas-tecnicas/geologia/Materiales/tema11.pdf>.

Donati, L., y Turrini, M. (2002). “An objective method to rank the importance of the factors predisposing to landslides with the GIS methodology: Application to an area of the Apennines (Valnerina; Perugia, Italy)”. *Engineering Geology*, 63:277–289.

Dou, J., Yamagishi, H., Pourghasemi, H. R., Yunus, A. P., Song, X., Xu, Y., y Zhu, Z. (2015). “An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan”. *Natural Hazards*, 78(3), 1749–1776. <http://doi.org/10.1007/s11069-015-1799-2>

Dragi cevi, S., Lai, T., y Balram, S. (2014). “GIS-based multicriteria evaluation with multiscale analysis to characterize urban landslide susceptibility in data-scarce environments”. *Habitat International*, 45(P2), 114–125. <http://doi.org/10.1016/j.habitatint.2014.06.031>

Eastman, R. (2006). “Idrisi Andes”. *Guide to GIS and Image Processing*. Worcester, Ma: Clark University. 327 p.

Erener, A., y Düzgün, H. S. B. (2010). “Improvement of statistical landslide susceptibility mapping by using spatial and global regression methods in the case of more and Romsdal (Norway)”. *Landslides*, 7(1), 55–68. <http://doi.org/10.1007/s10346-009-0188-x>

Ermini, L., Catani, F., y Casagli, N. (2005). “Artificial neural networks applied to landslide susceptibility assessment”. *Geomorphology*, 66, 327–343.

Esri (2016). “ArcGIS Pro | ArcGIS for Desktop”. [Online] Available at: <https://pro.arcgis.com/es/pro-app/> [Accessed 21 Jun. 2016].

Faraji Sabokbar, H., Shadman Roodposhti, M., y Tazik, E. (2014). “Landslide susceptibility mapping using geographically-weighted principal component analysis”. *Geomorphology*, 226, 15–24. <http://doi.org/10.1016/j.geomorph.2014.07.026>

Felicísimo, Á. M., Cuartero, A., Remondo, J., y Quirós, E. (2013). “Mapping landslide susceptibility with logistic regression, multiple adaptive regression splines, classification and regression trees, and

maximum entropy methods: A comparative study". *Landslides*, 10(2), 175–189. <http://doi.org/10.1007/s10346-012-0320-1>

García, E. (1973). "Modificaciones al sistema de clasificación climática de köppen". *Instituto de Geografía*. Universidad Nacional Autónoma de México. 90 p.

García, M. J (2008). "Metodologías para la evaluación de peligrosidad a deslizamientos inducidos por terremotos". *Tesis Doctoral*. Universidad de Alcalá, Departamento de matemáticas, 273.

García-Rodríguez, M. J., Malpica, J. A., Benito, B., y Díaz, M. (2008). "Susceptibility assessment of earthquake-triggered landslides in El Salvador using logistic regression". *Geomorphology*, 95(3-4), 172–191. <http://doi.org/10.1016/j.geomorph.2007.06.001>

Generali, M., y Pizziolo, M. (2013). "The Susceptibility Map for Landslides with Shallow Initiation in the Emilia Romagna Region (Italy). In C. Margottini, P. Canuti, & K. Sassa (Eds.)". *Landslide Science and Practice: Volume 1: Landslide Inventory and Susceptibility and Hazard Zoning*, 435–450. [http://doi.org/10.1007/978-3-642-31325-7\\_57](http://doi.org/10.1007/978-3-642-31325-7_57)

Golub, G., Heath, M., y Wahba, G. (1979). „Generalized cross-validation as a method for choosing a good ridge parameter". *Technometrics*, 21 (2), 215-223.

Gómez, H., y Kavzoglu, T. (2005). "Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela". *Engineering Geology*, 78(1-2), 11–27. <http://doi.org/10.1016/j.enggeo.2004.10.004>

Gorum, T., Gonencgil, B., Gokceoglu, C., y Nefeslioglu, H. A. (2008). "Implementation of reconstructed geomorphologic units in landslide susceptibility mapping: The Melen Gorge (NW Turkey)". *Natural Hazards*, 46(3), 323–351. <http://doi.org/10.1007/s11069-007-9190-6>

Greco, R., Sorriso-Valvo, M., y Catalano, E. (2007). "Logistic Regression analysis in the evaluation of mass movement's susceptibility: The Aspromonte case study, Calabria, Italy". *Engineering Geology*, 89(1-2), 47–66. <http://doi.org/10.1016/j.enggeo.2006.09.006>

Gritzner, M. L., Marcus, W. A., Aspinall, R., Custer, S. G. (2001). "Assessing landslide potential using GIS, soil wetness modelling and topographic attributes, Payetti River, Idaho". *Geomorphology*, 37, 149–165.

Guillard, C., y Zezere, J. (2012). "Landslide susceptibility assessment and validation in the framework of municipal pIRNAing in Portugal: The case of loures municipality". *Environmental Management*, 50(4), 721–735. <http://doi.org/10.1007/s00267-012-9921-7>

Günther, A., Van Den Eeckhaut, M., Malet, J. P., Reichenbach, P., y Hervás, J. (2014). "Climate-physiographically differentiated Pan-European landslide susceptibility assessment using spatial multi-criteria evaluation and transnational landslide information". *Geomorphology*, 224, 69–85. <http://doi.org/10.1016/j.geomorph.2014.07.011>

Guri, P. K., Champati ray, P. K., y Patel, R. C. (2015). "Spatial prediction of landslide susceptibility in parts of Garhwal Himalaya, India, using the weight of evidence modelling". *Environmental Monitoring and Assessment*, 187(6). <http://doi.org/10.1007/s10661-015-4535-1>

Guzzetti, F., Cardinali, M. y Reichenbach, P. (1996). "The influence of structural setting and lithology on landslide type and pattern". *Environmental and Engineering Geoscience*, 2(4):531-555.

Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., y Galli, M. (2006). "Estimating the quality of landslide susceptibility models". *Geomorphology*, 81(1-2), 166–184. <http://doi.org/10.1016/j.geomorph.2006.04.007>

- Hanley, J., y McNeil, B. (1983). "A method of comparing the areas under receiver operating characteristic curves derived from the same cases". *Radiology*, 148, 839–843.
- Hartemink, A., y McBratney, A. (2009). "Geomorphometry, Concepts, Software, Applications". *Developments in Soil Science*, 33.
- He, S., Pan, P., Dai, L., Wang, H., y Liu, J. (2012). Application of kernel-based Fisher discriminant analysis to map landslide susceptibility in the Qinggan River delta, Three Gorges, China. *Geomorphology*, 171-172, 30–41. <http://doi.org/10.1016/j.geomorph.2012.04.024>
- Herrera, S. (2002). "Regionalización de los deslizamientos en México". Academia de Ingeniería [online], <http://148.202.45.49/presentacion/regionalizaci%C3%B3n-de-los-deslizamientos-en-m%C3%A9xico> 01-07-2016 11:07 p.m.
- Hosmer, D. y Lemeshow, S. (2000). "Applied Logistic Regression, second ed". *John Wiley and Sons, Inc.*, NewYork, 375.
- Hutchinson, J. (1968). "Mass movement, en Fairbridge. R. W. (Ed.)". *Encyclopedia of Earth Sciences*, Reinhold, New York, 688-695.
- Ilanloo, M. (2011). "A comparative study of fuzzy logic approach for landslide susceptibility mapping using GIS: An experience of Karaj dam basin in Iran". *Procedia - Social and Behavioral Sciences*, 19, 668–676. <http://doi.org/10.1016/j.sbspro.2011.05.184>
- Instituto Nacional de estadística y geografía (INEGI) (2004). "Guía de interpretación de cartografía Edafología". Aguascalientes, Aguascalientes.
- Instituto Nacional de estadística y geografía (INEGI) (2016). "Geografía, Recursos naturales". <http://www.inegi.org.mx/geo/contenidos/reclnat/default.aspx> [Accessed 10 Sep. 2016].
- Irigaray, C., Fernández, T., El Hamdouni, R., y Chacón, J. (2007). "Evaluation and validation of landslide-susceptibility maps obtained by a GIS matrix method: Examples from the Betic Cordillera (southern Spain)". *Natural Hazards*, 41(1), 61–79. <http://doi.org/10.1007/s11069-006-9027-8>
- Jaafari, A., Najafi, A., Pourghasemi, H. R., Rezaeian, J., y Sattarian, A. (2014). "GIS-based frequency ratio and index of entropy models for landslide susceptibility assessment in the Caspian forest, northern Iran". *International Journal of Environmental Science and Technology*, 11(4), 909–926. <http://doi.org/10.1007/s13762-013-0464-0>
- Jiménez, J. (2012). "Movimientos de ladera en la vertiente Meridional de Sierra Nevada (Granada, España): Identificación, análisis y cartografía de Susceptibilidad y peligrosidad mediante SIG". *Tesis Doctoral*. Universidad de Granada. Departamento de Ingeniería Civil. Granada, España.
- Kavzoglu, T. y Mather, P.M. (2000). "Using feature selection techniques to produce smaller neural networks with better generalization capabilities". *Proceedings of the IEEE 2000 International Geoscience and Remote Sensing Symposium (IGARSS'2000)*, Hawaii, 7, (3069– 3071).
- Kavzoglu, T., Kutlug Sahin, E., y Colkesen, I. (2015). "An assessment of multivariate and bivariate approaches in landslide susceptibility mapping: a case study of Duzkoy district". *Natural Hazards*, 76(1), 471–496. <http://doi.org/10.1007/s11069-014-1506-8>
- Kayastha, P., Dhital, M. R., y De Smedt, F. (2013). "Evaluation and comparison of GIS based landslide susceptibility mapping procedures in Kulekhani watershed, Nepal". *Journal of the Geological Society of India*, 81(2), 219–231. <http://doi.org/10.1007/s12594-013-0025-7>

Kohavi, R. (1995). "A study of cross-validation and bootstrap for accuracy estimation and model selection". In: *Proc. of the 14th. Inter. Joint Conf. on A.I. Morgan KaufmRNA*, San Mateo, 2 (12), 1137-1143.

Komac, M. (2006). "A landslide susceptibility model using the Analytical Hierarchy Process method and multivariate statistics in perialpine Slovenia". *Geomorphology*, 74(1-4), 17–28. <http://doi.org/10.1016/j.geomorph.2005.07.005>

Köthe, R., Gehrt, E., y Böhner, J. (1996). "Automatische Reliefanalyse für geowissenschaftliche Anwendungen-derzeitiger Stand und Weiterentwicklungen des Programms SARA". *Arbeitshefte Geologie*, 1, 31–37

Lara, M. y Sepúlveda, S. (2008). "Remociones en Masa", *Apuntes del Curso del año 2008*, Departamento de Geología, Universidad de Chile. Disponible en <https://es.scribd.com/doc/315456751/Apuntes-Remociones-en-Masa-vUniversidad-de-Chile> 05-07-2016 12:17 p.m.

Lee, S. (2005). "Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data". *Int. J. Remote Sens*, 26 (7), 1477–1491.

Lee, S., y Sambath, T. (2006). "Landslide susceptibility mapping in the Damrei Romel area, Cambodia using frequency ratio and logistic regression models". *Environmental Geology*, 50(6), 847–855. <http://doi.org/10.1007/s00254-006-0256-7>

Legorreta Paulín, G., Bursik, M., Hubp, J. L., Mejía, L. M. P., y Aceves Quesada, F. (2014). "A GIS method for landslide inventory and susceptibility mapping in the Río El Estado watershed, Pico de Orizaba volcano, México". *Natural Hazards*, 71(1), 229–241. <http://doi.org/10.1007/s11069-013-0911-8>

Legorreta Paulín, G., Pouget, S., Bursik, M., Aceves Quesada, F., y Contreras, T. (2016). "Comparing landslide susceptibility models in the Río El Estado watershed on the SW flank of Pico de Orizaba volcano, Mexico". *Natural Hazards*, 80(1), 127–139. <http://doi.org/10.1007/s11069-015-1960-y>

Luzi, L., Pergalani, F y Terlien, M. (2000). "Slope vulnerability to earthquakes at subregional scale, using probabilistic techniques and geographic information systems". *Eng Geol*, 58(3), 313–336.

Melchiorre, C., Matteucci, M., Azzoni, A., y Zanchi, A. (2008). "Artificial neural networks and cluster analysis in landslide susceptibility zonation". *Geomorphology*, 94(3-4), 379–400. <http://doi.org/10.1016/j.geomorph.2006.10.035>

Melchiorre, C., Castellanos Abella, E. A., van Westen, C. J., y Matteucci, M. (2011). "Evaluation of prediction capability, robustness, and sensitivity in non-linear landslide susceptibility models, Guantánamo, Cuba". *Computers and Geosciences*, 37(4), 410–425. <http://doi.org/10.1016/j.cageo.2010.10.004>

Meng, Q., Miao, F., Zhen, J., Wang, X., Wang, A., Peng, Y., y Fan, Q. (2015). "GIS-based landslide susceptibility mapping with logistic regression, analytical hierarchy process, and combined fuzzy and support vector machine methods: a case study from Wolong Giant Panda Natural Reserve, China". *Bulletin of Engineering Geology and the Environment*, 75 (3), 923–944. <http://doi.org/10.1007/s10064-015-0786-x>

Meten, M., Bhandary, N. P., y Yatabe, R. (2015). "Application of GIS-based fuzzy logic and rock engineering system (RES) approaches for landslide susceptibility mapping in Selekula area of the Lower Jema River Gorge, Central Ethiopia". *Environmental Earth Sciences*, 74(4), 3395–3416. <http://doi.org/10.1007/s12665-015-4377-8>

- Meten, M., PrakashBhandary, N., y Yatabe, R. (2015). "Effect of Landslide Factor Combinations on the Prediction Accuracy of Landslide Susceptibility Maps in the Blue Nile Gorge of Central Ethiopia". *Geoenvironmental Disasters*, 2(1). <http://doi.org/10.1186/s40677-015-0016-7>
- McFall, C. (1968). "Reconnaissance geology of the Concepcion Bay area, Baja California, Mexico. Stanford University Publications", *Geological Sciences*, 10 (5), 25.
- Mina, F. (1957). "Bosquejo geológico del territorio sur de la Baja California". *Boletín de la Asociación Mexicana de Geólogos Petroleros*, 9, 139-270.
- Mohammady, M., Pourghasemi, H. R., y Pradhan, B. (2012). "Landslide susceptibility mapping at Golestan Province, Iran: A comparison between frequency ratio, Dempster-Shafer, and weights-of-evidence models". *Journal of Asian Earth Sciences*, 61, 221–236. <http://doi.org/10.1016/j.jseaes.2012.10.005>
- Moore, I., Gessler, P., Nielsen, G., y Peterson, G. (1993). "Soil Attribute Prediction Using Terrain Analysis". *Soil Science Society of America Journal*, 57 (2), 443-452.
- Morales, L. (2013). "The Definition Of A Minimum Set Of Spatial Relations: Morelia, México, Universidad Nacional Autónoma de México", *Tesis doctoral*, 164 p.
- Muñiz-Jáuregui, J. A., Morales, L. M., Madrigal-Hernández, V. M., Mendoza-Cantú, M. E., y Mora-Chaparro, J. C. (2014). "Modelo estadístico espacial para el análisis multifactorial de los procesos de remoción en masa: el caso del municipio de Francisco León, Chiapas". *Tesis doctoral*, Universidad Nacional Autónoma de México. Centro de Investigaciones en Geografía Ambiental, (3), 55-89 p.
- Murillo-García, F. G., y Alcántara-Ayala, I. (2015). "Landslide Susceptibility Analysis and Mapping Using Statistical Multivariate Techniques: Pahuatlán, Puebla, Mexico". *In W. Wu (Ed.), Recent Advances in Modeling Landslides and Debris Flows*, 179–194. [http://doi.org/10.1007/978-3-319-11053-0\\_16](http://doi.org/10.1007/978-3-319-11053-0_16)
- Murray, S. y Larry, S. (2005). *Estadística 4ta. Edición*. México, D.F. Mc Graw-Hill, 601.
- Nandi, A. y Shakoor, A. (2009). "A GIS-based landslide susceptibility evaluation using bivariate and multivariate statistical analyses". *Engineering Geology*, 110(1-2), 11–20. <http://doi.org/10.1016/j.enggeo.2009.10.001>
- Navarro, J. (2012). "Susceptibilidad y amenaza de deslizamientos de ladera mediante S.I.G. en el municipio de Berlín, El Salvador". *Tesis de Maestría*. Universidad complutense de Madrid. España.
- Nefeslioglu, H., Duman, T., y Durmaz, S. (2008). "Landslide susceptibility mapping for a part of tectonic Kelkit Valley (Eastern Black Sea region of Turkey)". *Geomorphology*, 94, 401-418.
- Nefeslioglu, H. A., Gokceoglu, C., Sonmez, H., y Gorum, T. (2011). "Medium-scale hazard mapping for shallow landslide initiation: The Buyukkoy catchment area (Cayeli, Rize, Turkey)". *Landslides*, 8(4), 459–483. <http://doi.org/10.1007/s10346-011-0267-7>
- Neuhäuser, B. y Terhorst, B. (2007). "Landslide susceptibility assessment using "weights-of-evidence" applied to a study area at the Jurassic escarpment (SW-Germany)". *Geomorphology*, 86(1-2), 12–24. <http://doi.org/10.1016/j.geomorph.2006.08.002>
- Neuhäuser, B., Damm, B., y Terhorst, B. (2012). "GIS-based assessment of landslide susceptibility on the base of the Weights-of-Evidence model". *Landslides*, 9(4), 511–528. <http://doi.org/10.1007/s10346-011-0305-5>

Oh, H. J., y Lee, S. (2011). "Cross-application used to validate landslide susceptibility maps using a probabilistic model from Korea". *Environmental Earth Sciences*, 64(2), 395–409. <http://doi.org/10.1007/s12665-010-0864-0>

Oh, H.-J., y Lee, S. (2011). "Landslide susceptibility mapping on Panaon Island, Philippines using a geographic information system". *Environmental Earth Sciences*, 62(5), 935–951. <http://doi.org/10.1007/s12665-010-0579-2>

Oh, H.-J., Lee, S., Chotikasathien, W., Kim, C. H., y Kwon, J. H. (2009). "Predictive landslide susceptibility mapping using spatial information in the Pechabun area of Thailand". *Environmental Geology*, 57(3), 641–651. <http://doi.org/10.1007/s00254-008-1342-9>

Olaya, V. (2006). "Fundamentos de Análisis Geográfico con SEXTANTE" [en línea]. [Citado el 21/06/2016]. Disponible en: <https://www.yumpu.com/es/document/view/14547218/fundamentos-de-analisis-geografico-con-sextante-la-salle>

Ohlmacher, G. y Davis, J. (2003). "Using multiple logistic regression and GIS technology to predict landslide hazard in northeast Kansa, USA". *Engineering Geology*, 69,331–343.

Othman, A. A., Gloaguen, R., Andreani, L., y Rahnama, M. (2015). "Landslide susceptibility mapping in Mawat area, Kurdistan Region, NE Iraq: a comparison of different statistical models". *Natural Hazards and Earth System Sciences Discussions*, 3(3), 1789–1833. <http://doi.org/10.5194/nhessd-3-1789-2015>

Ozdemir, A. (2011). "Landslide susceptibility mapping using Bayesian approach in the Sultan Mountains (Aksehir, Turkey)". *Natural Hazards*, 59(3), 1573–1607. <http://doi.org/10.1007/s11069-011-9853-1>

Ozdemir, A., y Altural, T. (2013). "A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey". *Journal of Asian Earth Sciences*, 64, 180–197. <http://doi.org/10.1016/j.jseaes.2012.12.014>

Peng, L., Niu, R., Huang, B., Wu, X., Zhao, Y., y Ye, R. (2014). "Landslide susceptibility mapping based on rough set theory and support vector machines: A case of the Three Gorges area, China". *Geomorphology*, 204, 287–301. <http://doi.org/10.1016/j.geomorph.2013.08.013>

Piacentini, D., Troiani, F., Soldati, M., Notarnicola, C., Savelli, D., Schneiderbauer, S., y Strada, C. (2012). "Statistical analysis for assessing shallow-landslide susceptibility in South Tyrol (south-eastern Alps, Italy)". *Geomorphology*, 151-152, 196–206. <http://doi.org/10.1016/j.geomorph.2012.02.003>

Pineda, M. (2012). "Evaluación de riesgo de movimientos en masa en la subcuenca del río Caramacate (Estado Aragua) a través de un análisis temporal multivariado". *Tesis doctoral*. Universidad Central de Venezuela, Facultad de Agronomía. Maracay, Venezuela.

Popescu, M. (2002). "Landslide Causal Factors and Landslide Remedial Options". *Keynote Lecture, Proceedings 3rd International Conference on Landslides, Slope Stability and Safety of Infra-Structures, Singapore*, 61-81.

Potter, P. (2007). "Exploring the geology of the Cincinnati/Northern Kentucky Region". *Kentucky Geological Survey. Special publications*, 128.

Poudyal, C. P., Chang, C., Oh, H. J., y Lee, S. (2010). "Landslide susceptibility maps comparing frequency ratio and artificial neural networks: A case study from the Nepal Himalaya". *Environmental Earth Sciences*, 61(5), 1049–1064. <http://doi.org/10.1007/s12665-009-0426-5>

- Pourghasemi, H. R., Moradi, H. R., y Fatemi Aghda, S. M. (2013). "Landslide susceptibility mapping by binary logistic regression, analytical hierarchy process, and statistical index models and assessment of their performances". *Natural Hazards*, 69(1), 749–779. <http://doi.org/10.1007/s11069-013-0728-5>
- Pourghasemi, H. R., Mohammady, M., y Pradhan, B. (2012). "Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin, Iran". *Catena*, 97, 71–84. <http://doi.org/10.1016/j.catena.2012.05.005>
- Pourghasemi, H. R., Pradhan, B., y Gokceoglu, C. (2012). "Application of fuzzy logic and analytical hierarchy process (AHP) to landslide susceptibility mapping at Haraz watershed, Iran". *Natural Hazards*, 63(2), 965–996. <http://doi.org/10.1007/s11069-012-0217-2>
- Pradhan, B. (2010). "Remote sensing and GIS-based landslide hazard analysis and cross-validation using multivariate logistic regression model on three test areas in Malaysia". *Advances in Space Research*, 45(10), 1244–1256. <http://doi.org/10.1016/j.asr.2010.01.006>
- Pradhan, B. (2011). "Use of GIS-based fuzzy logic relations and its cross application to produce landslide susceptibility maps in three test areas in Malaysia". *Environmental Earth Sciences*, 63(2), 329–349. <http://doi.org/10.1007/s12665-010-0705-1>
- Pradhan, B. (2013). "A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS". *Computers and Geosciences*, 51, 350–365. <http://doi.org/10.1016/j.cageo.2012.08.023>
- Pradhan, B. y Lee, S. (2010). "Landslide susceptibility assessment and factor effect analysis: back propagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling". *Environmental Modelling and Software*, 25(6), 747–759. <http://doi.org/10.1016/j.envsoft.2009.10.016>
- Pradhan, B. y Lee, S. (2010). "Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models". *Environmental Earth Sciences*, 60(5), 1037–1054. <http://doi.org/10.1007/s12665-009-0245-8>
- Prasannakumar, V. y Vijith, H. (2012). "Evaluation and validation of landslide spatial susceptibility in the Western Ghats of Kerala, through GIS-based weights of evidence model and area under curve technique". *Journal of the Geological Society of India*, 80(4), 515–523. <http://doi.org/10.1007/s12594-012-0171-3>
- Priego, A., Bocco, G., Mendoza, M., y Garrido, A. (2008). "Propuesta para la generación semiautomatizada de unidades de paisaje". *Fundamentos y métodos. INE-SEMARNAT-CIGA-UNAM*, 98.
- Raghuvanshi, T. K., Negassa, L., y Kala, P. M. (2015). "GIS based Grid overlay method versus modeling approach - A comparative study for landslide hazard zonation (LHZ) in Meta Robi District of West Showa Zone in Ethiopia". *Egyptian Journal of Remote Sensing and Space Science*, 18(2), 235–250. <http://doi.org/10.1016/j.ejrs.2015.08.001>
- Ramesh, V. y Anbazhagan, S. (2015). "Landslide susceptibility mapping along Kolli hills Ghat road section (India) using frequency ratio, relative effect and fuzzy logic models". *Environmental Earth Sciences*, 73(12), 8009–8021. <http://doi.org/10.1007/s12665-014-3954-6>
- Regmi, N. R., Giardino, J. R., McDonald, E. V., y Vitek, J. D. (2014). "A comparison of logistic regression-based models of susceptibility to landslides in western Colorado, USA". *Landslides*, 11(2), 247–262. <http://doi.org/10.1007/s10346-012-0380-2>

Regmi, N. R., Giardino, J. R., y Vitek, J. D. (2010). "Modeling susceptibility to landslides using the weight of evidence approach: Western Colorado, USA". *Geomorphology*, 115(1-2), 172–187. <http://doi.org/10.1016/j.geomorph.2009.10.002>

Regmi, N. R., Giardino, J. R., y Vitek, J. D. (2010). "Assessing susceptibility to landslides: Using models to understand observed changes in slopes". *Geomorphology*, 122(1-2), 25–38. <http://doi.org/10.1016/j.geomorph.2010.05.009>

Rojas, Octavio y Martínez, Carolina. (2011). "Riesgos naturales: evolución y modelos conceptuales". *Revista Universitaria de Geografía*, 20(1), 83-116.

Roslee, R., Jamaluddin, T. A., y Talip, M. A. (2012). "Landslide Susceptibility Mapping (LSM) at Kota Kinabalu, Sabah, Malaysia using Factor Analysis Model (FAM)". *Journal of Advanced Science and Engineering Research*, 2(June 2015), 80–103. Retrieved from <https://www.sign-ific-ance.co.uk/dsr/index.php/JASER/article/view/134>

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

Saito, H., Nakayama, D., y Matsuyama, H. (2009). "Comparison of landslide susceptibility based on a decision-tree model and actual landslide occurrence: The Akaishi Mountains, Japan". *Geomorphology*, 109(3-4), 108–121. <http://doi.org/10.1016/j.geomorph.2009.02.026>

Schicker, R., y Moon, V. (2012). "Comparison of bivariate and multivariate statistical approaches in landslide susceptibility mapping at a regional scale". *Geomorphology*, 161-162, 40–57. <http://doi.org/10.1016/j.geomorph.2012.03.036>

Selby, M. J. (1993). "Hillslope materials and processes". *Second Edition, Oxford University Press*, 451.

Shahabi, H., Ahmad, B. B., y Khezri, S. (2013). "Evaluation and comparison of bivariate and multivariate statistical methods for landslide susceptibility mapping (case study: Zab basin)". *Arabian Journal of Geosciences*, 6(10), 3885–3907. <http://doi.org/10.1007/s12517-012-0650-2>

Shahabi, H., Hashim, M., y Ahmad, B. Bin. (2015). "Remote sensing and GIS-based landslide susceptibility mapping using frequency ratio, logistic regression, and fuzzy logic methods at the central Zab basin, Iran". *Environmental Earth Sciences*, 73(12), 8647–8668. <http://doi.org/10.1007/s12665-015-4028-0>

Shahabi, H., Khezri, S., Ahmad, B. Bin, y Hashim, M. (2014). "Landslide susceptibility mapping at central Zab basin, Iran: A comparison between analytical hierarchy process, frequency ratio and logistic regression models". *Catena*, 115, 55–70. <http://doi.org/10.1016/j.catena.2013.11.014>

Sharma, L. P., Patel, N., Ghose, M. K., y Debnath, P. (2014). "Development and application of ShRNAon's entropy integrated information value model for landslide susceptibility assessment and zonation in Sikkim Himalayas in India". *Natural Hazards*, 75(2), 1555–1576. <http://doi.org/10.1007/s11069-014-1378-y>

Servicio Geológico Mexicano (SGM) (2002). Geoinfomex, <http://mapasims.sgm.gob.mx/GeoInfoMexDb/> [Accessed 10 Sep. 2016].

Sidele, R. (1991). "A conceptual model of changes in root cohesion in response to vegetation management". *Journal of Environmental Quality*, 20, 43–52.

- Sidele, R. (1992). "A theoretical model of the effects of timber harvesting on slope stability". *Water Resource Research*, 28, 1897–1910.
- Soeters, R., y Van Westen, J. (1996). "Slope instability recognition, analysis, and zonation. In: Turner AK, Schuster RL (eds) Landslides: investigation and mitigation". *National Academic Press*, 247, 129-177.
- Solaimani, K., Mousavi, S. Z., y Kavian, A. (2013). "Landslide susceptibility mapping based on frequency ratio and logistic regression models". *Arabian Journal of Geosciences*, 6(7), 2557–2569. <http://doi.org/10.1007/s12517-012-0526-5>
- Soldano, A., Giraut, M., y Goniadzki, D. (2007). "Mapa de Susceptibilidad Urbana Ante Inundaciones, Caso: Ciudad de Goya, Provincia de Corrientes. Hacia un mejor entendimiento de la dinámica global y regional". *Teledetección*, 449-456. ISBN: 9789875431263.
- Sorriso-Valvo, M., Greco, R., y Catalano, E. (2008). "Spatial prediction of regional-scale mass movement using Logistic Regression analysis and GIS— Calabria, Italy". *Isr. J. Earth Sci*, 57, 263–280.
- Strahler, A. (1957). "Quantitative analysis of watershed morphology". *Transactions of the American Geophysical Union*, 38, 913-920.
- Suárez J. (1992). "Manual de Ingeniería para el control de erosión". *Bucaramanga*, 318.
- Suárez, J. (1998). "Deslizamientos y estabilidad de taludes en zonas tropicales. *U. Industrial de Santander*, 548. ISBN: 9583308005
- Suet, C. y Lam, Y. (2004). "Comparison of flow routing algorithms used in Geographic Information Systems". *Thesis of Master*, University of Southern California, Faculty of the Graduate School. 97.
- Suh, J., Choi, Y., Roh, T. D., Lee, H. J., y Park, H. D. (2011). "National scale assessment of landslide susceptibility to rank the vulnerability to failure of rock-cut slopes along expressways in Korea". *Environmental Earth Sciences*, 63(3), 619–632. <http://doi.org/10.1007/s12665-010-0729-6>
- Summaryono., Arifianti, Y., Dasa Triana, Y., Ika, W., y Irawan, W. (2014). "The Application of Landslide Inventory Data Base of Indonesia (LIDIA) For Supporting Landslide Susceptibility Mapping in Cianjur Regency, West Java, Indonesia". *GSTF International Journal of Geological Sciences (JGS)*, 1(2), 1-9.
- Suzen, M. y Doyuran, V. (2004). "A comparison of the GIS based landslide susceptibility assessment methods: multivariate versus bivariate". *Environmental Geology*, 45, 665-679.
- Suzen, M. y Kaya, B. (2012). "Evaluation of environmental parameters in logistic regression models for landslide susceptibility mapping". *International Journal of Digital Earth*, 5, 338-355.
- Tagliaferro, M., y Singer, A. (2012). "Los deslizamientos ocurridos el 20 de noviembre del 2008 en las colinas del sur de Caracas: una visión general de su impacto geotécnico". *Revista de la Facultad de Ingeniería Universidad Central de Venezuela*, 27(1), 31-40.
- Taleai, R. (2014). "Landslide susceptibility zonation mapping using logistic regression and its validation in Hashtchin Region, northwest of Iran". *Journal Geological Society of India*, 84(July), 68–86.
- Tangestani, M. H. (2009). "A comparative study of Dempster-Shafer and fuzzy models for landslide susceptibility mapping using a GIS: An experience from Zagros Mountains, SW Iran". *Journal of Asian Earth Sciences*, 35(1), 66–73. <http://doi.org/10.1016/j.jseaes.2009.01.002>

Thierry, Y., Malet, J. P., Sterlacchini, S., Puissant, A., y Maquaire, O. (2007). "Landslide susceptibility assessment by bivariate methods at large scales: Application to a complex mountainous environment". *Geomorphology*, 92(1-2), 38–59. <http://doi.org/10.1016/j.geomorph.2007.02.020>

Tien Bui, D., Pradhan, B., Lofman, O., y Revhaug, I. (2012). "Landslide susceptibility assessment in vietnam using support vector machines, decision tree, and nave bayes models". *Mathematical Problems in Engineering*, 2012,26. <http://doi.org/10.1155/2012/974638>

Tien Bui, D., Pradhan, B., Lofman, O., Revhaug, I., y Dick, O. B. (2012). "Landslide susceptibility assessment in the Hoa Binh province of Vietnam: A comparison of the Levenberg-Marquardt and Bayesian regularized neural networks". *Geomorphology*, 171-172, 12–29. <http://doi.org/10.1016/j.geomorph.2012.04.023>

Tien Bui, D., Tuan, T. A., Klempe, H., Pradhan, B., y Revhaug, I. (2015). "Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree". *Landslides*, 13, 361. <http://doi.org/10.1007/s10346-015-0557-6>

Timilsina, M., Bhandary, N. P., Dahal, R. K., y Yatabe, R. (2014). "Distribution probability of large-scale landslides in central Nepal". *Geomorphology*, 226, 236–248. <http://doi.org/10.1016/j.geomorph.2014.05.031>

Torizin, J. (2015). "Elimination of informational redundancy in the weight of evidence method: an application to landslide susceptibility assessment". *Stochastic Environmental Research and Risk Assessment*, 30(2), 635–651. <http://doi.org/10.1007/s00477-015-1077-6>

Tsangaratos, P, y Benardos, A. (2014). "Estimating landslide susceptibility through a artificial neural network classifier". *Natural Hazards*, 74(3), 1489–1516. <http://doi.org/10.1007/s11069-014-1245-x>

UNESCO Working Party On World Landslide Inventory (1993). "A suggested method for describing the activity of a landslide". *Bulletin of the international Association of Engineering geology*, 47, 53-57.

Van Den Eeckhaut, M., Vanwalleghem, T., Poesen, J., Govers, G., Verstraeten, G., y Vandekerckhove, L. (2006). "Prediction of landslide susceptibility using rare events logistic regression: A case-study in the Flemish Ardennes (Belgium)". *Geomorphology*, 76(3-4), 392–410. <http://doi.org/10.1016/j.geomorph.2005.12.003>

Van Westen, C. (2000). "The modelling of landslide hazards using GIS". *Surv Geophys*, 21, (2-3):241-255.

Van Westen, C., Rengers, N., Terlien, M., y Soeters, R. (1997). "Prediction of the occurrence of slope instability phenomena through GIS based hazard zonation". *Int J Earth Sci (Geologische Rundschau)*, 86(2):404-414

Van Westen, C., Rangers, N., Terlien, T., y Soeters, R. (2002). „Prediction of the occurrence of slope instability phenomena through GIS based hazard zonation. Instability Zonation". *Part 1: Exercise, ITC, and Publication Number 15*.

Varnes, D. (1978). "Slope movement types and processes. In R.L. Schuster y R. J. Krizek (Eds.). Landslides: analysis and control. Transportation Research Board". *Special report*, 176, 11-33.

Vijith, H., Rejith, P. G., y Madhu, G. (2009). "Using InfoVal method and GIS techniques for the spatial modelling of landslide susceptibility in the upper catchment of river Meenachil in Kerala". *Journal of the Indian Society of Remote Sensing*, 37(2), 241–250. <http://doi.org/10.1007/s12524-009-0028-4>

- Von Ruetten, J., Papritz, A., Lehmann, P., Rickli, C., y Or, D. (2011). "Spatial statistical modeling of shallow landslides-Validating predictions for different landslide inventories and rainfall events". *Geomorphology*, 133(1-2), 11–22. <http://doi.org/10.1016/j.geomorph.2011.06.010>
- Wang, L. J., Guo, M., Sawada, K., Lin, J., y Zhang, J. (2015). "Landslide susceptibility mapping in Mizunami City, Japan: A comparison between logistic regression, bivariate statistical analysis and multivariate adaptive regression spline models". *Catena*, 135, 271–282. <http://doi.org/10.1016/j.catena.2015.08.007>
- Wang, L.-J., Sawada, K., y Moriguchi, S. (2013). "Landslide susceptibility analysis with logistic regression model based on FCM sampling strategy". *Computers y Geosciences*, 57, 81–92. <http://doi.org/10.1016/j.cageo.2013.04.006>
- Weiss, A. (2001): "Topographic position and landforms analysis". *Poster Presentation*, ESRI Users Conference, San Diego, CA.
- Wilson, J., y Gallant, J. (2000). "Terrain Analysis: Principles and Applications". *Wiley*, New York, 303.
- Wischmeier, W. y Smith, D. (1978). "Predicting rainfall erosion losses". Guide to conservation planning. Agriculture Handbook N° 537. Washington DC: US Department of Agriculture". *Science and Education Administration, U.S. Department of Agriculture, 1978, 58.*
- Wu, S., L. Shi, R. Wang, C. Tan, D. Hu, Y. Mei, and R. Xu. (2001). "Zonation of the landslide hazards in the fore-reservoir region of the Three Gorges Project on the Yangtze River". *Engineering Geology*, 59, 51–58.
- Xu, C., Xu, X., Dai, F., Xiao, J., Tan, X., y Yuan, R. (2012). "Landslide hazard mapping using GIS and weight of evidence model in Qingshui River watershed of 2008 Wenchuan earthquake struck region". *Journal of Earth Science*, 23(1), 97–120. <http://doi.org/10.1007/s12583-012-0236-7>
- Xu, C., Xu, X., Lee, Y. H., Tan, X., Yu, G., y Dai, F. (2012). "The 2010 Yushu earthquake triggered landslide hazard mapping using GIS and weight of evidence modeling". *Environmental Earth Sciences*, 66(6), 1603–1616. <http://doi.org/10.1007/s12665-012-1624-0>
- Yesilnacar, E., y Topal, T. (2005). "Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey)". *Eng Geol*, 79(3–4), 251–266.
- Yilmaz, I. (2009). "The effect of the sampling strategies on the landslide susceptibility mapping by conditional probability and artificial neural networks (2009b)". *Environmental Earth Sciences*, 60(3), 505–519. <http://doi.org/10.1007/s12665-009-0191-5>
- Yilmaz, C., Topal, T., y Suzen, M. L. (2012). "GIS-based landslide susceptibility mapping using bivariate statistical analysis in Devrek (Zonguldak-Turkey)". *Environmental Earth Sciences*, 65, 2161–2178.
- Youssef, A. M., Al-Kathery, M., y Pradhan, B. (2015). "Landslide susceptibility mapping at Al-Hasher area, Jizan (Saudi Arabia) using GIS-based frequency ratio and index of entropy models". *Geosciences Journal*, 19(1), 113–134. <http://doi.org/10.1007/s12303-014-0032-8>
- Youssef, A. M., Pourghasemi, H. R., Pourtaghi, Z. S., y Al-Katheeri, M. M. (2015). "Erratum to: Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia". *Landslides*, (July), 1–3. <http://doi.org/10.1007/s10346-015-0667-1>

Youssef, A. M., Pradhan, B., Pourghasemi, H. R., y Abdullahi, S. (2015). "Landslide susceptibility assessment at Wadi Jawrah Basin, Jizan region, Saudi Arabia using two bivariate models in GIS". *Geosciences Journal*, 19(3), 449–469. <http://doi.org/10.1007/s12303-014-0065-z>

Zhuang, J., Peng, J., Iqbal, J., Liu, T., Liu, N., Li, Y., y Ma, P. (2015). "Identification of landslide spatial distribution and susceptibility assessment in relation to topography in the Xi'an Region, Shaanxi Province, China". *Frontiers of Earth Science*, 9(3), 449–462. <http://doi.org/10.1007/s11707-014-0474-3>

Zhou, C., Lee, C., Li, J y Xu, Z. (2002). "On the spatial relationship between landslides and causative factors on Lantau Island, Hong Kong". *Geomorphology*. 43,197–207.

Zumpano, V., Hussin, H. Y., Reichenbach, P., Balteanu, D., Micu, M., y Sterlacchini, S. (2014). "A landslide susceptibility analysis for Buzău County, Romania". *Romanian Journal of Geography/Revue Roumaine de Geographie*, 58(1), 9–16.

## APÉNDICE A

### 1. Antecedentes de modelos estadísticos empleados en el análisis de la susceptibilidad en el período de 2005 a 2015.

N°	Autor	Lugar	Año	Modelos Estadísticos
1	Gómez, H., y Kavzoglu, T.	Venezuela	2005	Red Neuronal Artificial
2	Ayalew, L., y Yamagishi, H.	Japón	2005	Regresión Logística
3	Komac, M.	Eslovenia	2006	Análisis multivariante
4	Guzzetti, F., <i>et al</i>	Italia	2006	Análisis discriminante
5	Lee, S., y Sambath, T.	Camboya	2006	Relación de frecuencia y Regresión Logística
6	Van Den Eeckhaut, M., <i>et al</i>	Bélgica	2006	Regresión Logística
7	Davis, J. C., <i>et al</i>	USA	2006	Regresión Logística
8	Irigaray, C., <i>et al</i>	España	2007	Matrix y Regresión múltiple
9	Akgün, A., y Bulut, F.	Turquía	2007	Regresión Logística con combinación ponderada lineal
10	Thiery, Y., <i>et al</i>	Francia	2007	Pesos de evidencia
11	Neuhäuser, B., y Terhorst, B.	Alemania	2007	Pesos de evidencia
12	Greco, R., <i>et al</i>	Italia	2007	Regresión Logística
13	Melchiorre, C., <i>et al</i>	Italia	2008	Red Neuronal Artificial y Análisis de conglomerados
14	Gorum, T., <i>et al</i>	Turquía	2008	Regresión Logística
15	Akgun, A., <i>et al</i>	Turquía	2008	Relación de frecuencia, relación lineal ponderada
16	Chung, C. J., y Fabbri, A. G.	Portugal	2008	Fuzzy
17	García-Rodríguez, M. J., <i>et al</i>	El salvador	2008	Regresión Logística
18	Sorriso-Valvo, M., <i>et al</i>	Italia	2008	Regresión Logística
19	Tangestani, M. H.	Irán	2009	Fuzzy y Dempster-Shafer
20	Nandi, A., y Shakoor, A.	USA	2009	Regresión Logística, fuzzy
21	Saito, H., <i>et al</i>	Japón	2009	Árbol de decisiones
22	Chu, C. M., <i>et al</i>	Asia	2009	Árbol de decisiones
23	Oh, H.-J., <i>et al</i>	Tailandia	2009	Relación de frecuencia y Regresión Logística
24	Vijith, H., <i>et al</i>	India	2009	Pesos de evidencia
25	Yilmaz, I.	Turquía	2009	Probabilidad condicional y Red Neuronal Artificial
26	Regmi, N. R., <i>et al</i>	USA	2010	Combinación: Pesos de evidencia, Relación de frecuencia y Fuzzy
27	Dewitte, O., <i>et al</i>	Bélgica	2010	Función de distribución empírica
28	Pradhan, B., y Lee, S.	Malaysia	2010	Relación de frecuencia, Regresión Logística y Red Neuronal Artificial
29	Erener, A., y Düzgün, H. S. B.	Noruega	2010	Regresión Logística y Regresión espacial
30	Pradhan, B., y Lee, S.	Malaysia	2010	Red Neuronal Artificial, Relación de frecuencia y Regresión Logística
31	Das, I., <i>et al</i>	India	2010	Regresión Logística
32	Poudyal, C. P., <i>et al</i>	Nepal	2010	Relación de frecuencia, Red Neuronal Artificial
33	Regmi, N. R.,	USA	2010	Pesos de evidencia
34	Rossi, M., <i>et al</i>	Italia	2010	Análisis discriminante, Análisis discriminante cuadrado, Regresión Logística y Red Neuronal Artificial

35	Pradhan, B.	Malaysia	2010	Regresión Logística
36	Baeza, C., <i>et al</i>	España	2010	Regresión Logística y Análisis discriminante
37	Oh, H.-J., y Lee, S.	Filipinas	2011	Pesos de evidencia
38	Oh, H. J., y Lee, S.	Corea	2011	Relación de frecuencia
39	Ilanloo, M.	Irán	2011	Fuzzy
40	Melchiorre, C., <i>et al</i>	Cuba	2011	Red Neuronal Artificial
41	Ozdemir, A.	Turquía	2011	Pesos de evidencia
42	Nefeslioglu, H. A., <i>et al</i>	Turquía	2011	Red Neuronal Artificial
43	Suh, J., <i>et al</i>	Corea del Sur	2011	Pesos de evidencia, Jerarquía analítica y Fuzzy
44	Von Ruetten, J., <i>et al</i>	Suiza	2011	Regresión Logística
45	Pradhan, B. <i>et al</i>	Malasia	2011	Fuzzy
46	Tien Bui, D., <i>et al</i>	Vietnam	2012	Índice estadístico y Regresión Logística
47	Conforti, M., <i>et al</i>	Italia	2012	Valores de ponderación por factor (experto)
48	Pourghasemi, H. R., <i>et al</i>	Irán	2012	Fuzzy y jerarquía analítica
49	He, S., <i>et al</i>	China	2012	Análisis lineal discriminante de Fisher (LFDA), Análisis discriminante Fisher basado en el kernel (KFDA) y Regresión Logística.
50	Schicker, R., y Moon, V.	Nueva Zelanda	2012	Regresión Logística y Pesos de evidencia.
51	Prasannakumar, V., y Vijith, H.	India	2012	Pesos de evidencia
52	Neuhäuser, B., <i>et al</i>	Austria	2012	Pesos de evidencia
53	Xu, C., <i>et al</i>	China	2012	Pesos de evidencia
54	Guillard, C., y Zezere, J.	Portugal	2012	Valor de información
55	Tien Bui, D., <i>et al</i>	Vietnam	2012	Red neuronal artificial y Regresión Logística
56	Tien Bui, D., <i>et al</i>	Vietnam	2012	Máquina de vector, Árbol de decisiones y modelo de bayes
57	Roslee, R., <i>et al</i>	Malaysia	2012	Análisis de factor
58	Das, I., <i>et al</i>	India	2012	Regresión Logística
59	Mohammady, M., <i>et al</i>	Irán	2012	Relación de frecuencia, Dempster-Shafer y Pesos de evidencia
60	Pourghasemi, H. R., <i>et al</i>	Irán	2012	Probabilidad condicional e Índice de entropía
61	Piacentini, D., <i>et al</i>	Italia	2012	Pesos de evidencia
62	Xu, C., <i>et al</i>	China	2012	Pesos de evidencia
63	Armaş, I.	Rumania	2012	Pesos de evidencia
64	Solaimani, K., <i>et al</i>	Irán	2013	Relación de frecuencia y Regresión Logística
65	Shahabi, H., <i>et al</i>	Azerbaiján	2013	Valor de información, Densidad del área, Regresión lineal y Análisis discriminante
66	Ozdemir, A., y Altural, T.	Turquía	2013	Relación de frecuencia, Peso de evidencia y Regresión Logística
67	Pradhan, B.	Malaysia	2013	Árbol de decisiones, máquina vectorial, sistema adaptable (ANFIS) de inferencia de neuro - fuzzy
68	Kayastha, P., <i>et al</i>	Nepal	2013	Clasificación sencilla (método heurístico), índice estadístico y Análisis de susceptibilidad
69	Wang, L.-J., <i>et al</i>	Japón	2013	Regresión Logística
70	Pourghasemi, H. R., <i>et al</i>	Irán	2013	Regresión Logística binaria, Índice estadístico y Jerarquía analítica
71	Devkota, K. C., <i>et al</i>	Nepal	2013	Factor de certeza, Índice de entropía y Regresión Logística
72	Felicísimo, Á. M., <i>et al</i>	España	2013	Múltiple Regresión Logística, Regresión splines, CART e Índice de entropía

73	Generali, M., y Pizzolo, M.	Italia	2013	Regresión Logística
74	Günther, A., <i>et al</i>	Europa	2014	Multicriterio espacial heurística combinada con jerarquía analítica
75	Legorreta Paulín, G., <i>et al</i>	México	2014	Múltiple Regresión Logística
76	Bai, S. B., <i>et al</i>	China	2014	Regresión Logística
77	Dahal, R. K.	Nepal	2014	Regresión Logística
78	Jaafari, A., <i>et al</i>	Irán	2014	Relación de frecuencia y modelo de entropía
79	Conforti, M., <i>et al</i>	Italia	2014	Red Neuronal Artificial
80	Regmi, N. R., <i>et al</i>	USA	2014	Regresión Logística
81	Zumpano, V., <i>et al</i>	Romania	2014	Pesos de evidencia
82	Althuwaynee, O. F., <i>et al</i>	Corea del Sur	2014	Dempster - Shafer, Jerarquía analítica, Pesos de evidencia y Regresión Logística
83	Althuwaynee, O. F., <i>et al</i>	Corea del Sur	2014	Método CHAID combinado con Regresión Logística: 2 modelos
84	Conoscenti, C., <i>et al</i>	Italia	2014	Regresión Logística, Regresión multivariante de adaptación splines (MARS)
85	Timilsina, M., <i>et al</i>	Nepal	2014	Regresión Logística
86	Tsangaratos, P y Benardos, A	Grecia	2014	Red Neuronal Artificial
87	Chalkias, C., <i>et al</i>	Grecia	2014	Fuzzy basada en modelo experto
88	Dragi cevi, S., <i>et al</i>	Canadá	2014	Fuzzy
89	Shahabi, H., <i>et al</i>	Irán	2014	Jerarquía analítica, Relación de frecuencia, y Regresión Logística
90	Peng, L., <i>et al</i>	China	2014	Combinación: Máquina de soporte vectorial y set bruto
91	Faraji Sabokbar, H., <i>et al</i>	Irán	2014	Regresión geográficamente ponderada
92	Taleai, R.	Irán	2014	Regresión Logística
93	Sumaryono <i>et al</i>	Indonesia	2014	Pesos de evidencia
94	Sharma, L. P., <i>et al</i>	India	2014	Entropía de Shrnson
95	Chen, W., <i>et al</i>	China	2015	Relación de frecuencia, Índice estadístico e Índice de entropía
96	Youssef, A. M., <i>et al</i>	Arabia Saudita	2015	Relación de frecuencia e Índice de entropía
97	Ramesh, V., y Anbazhagan, S.	India	2015	Relación de frecuencia, efecto relativo y Fuzzy
98	Zhuang, J., <i>et al</i>	China	2015	Regresión Logística
99	Bourenane, H., <i>et al</i>	Argelia	2015	Modo experto e índice estadístico
100	Kavzoglu, T., <i>et al</i>	Turquía	2015	Vector de regresión multivariado, Regresión Logística, Árbol de decisiones, Relación de frecuencia, índice estadístico y Pesos de evidencia
101	Dehnavi, A., <i>et al</i>	Irán	2015	Relación de peso de evaluación por etapas Método (Swara), Sistema de inferencia neuro-fuzzy adaptativo (ANFIS)
102	Dou, J., <i>et al</i>	Japón	2015	Red Neuronal Artificial
103	Meten, M., <i>et al</i>	Etiopía	2015	Fuzzy: Y, difusa O, difuso gamma, suma borrosa y difusa de productos operadores.
104	Chang, S. H., y Wan, S.	Taiwan	2015	Lógica Booleana combinada con el método DRS
105	Meten, M., <i>et al</i>	Etiopía	2015	Relación de frecuencia
106	Torizin, J.	Indonesia	2015	Pesos de evidencia modificado

107	Raghuvanshi, T. K., <i>et al</i>	Etiopia	2015	Overlay y Builder
108	Meng, Q., <i>et al</i>	China	2015	Regresión Logística, Jerarquía analítica y Maquina de vectores
109	Youssef, A. M., <i>et al</i>	Arabia Saudita	2015	Relación de frecuencia y Pesos de evidencia
110	Othman, A. A., <i>et al</i>	Irán	2015	Relación de frecuencia, Pesos de evidencia, Regresión Logística y regresión ponderada
111	Wang, L. J., <i>et al</i>	Japón	2015	Regresión Logística, Estadística bivalente y Regresión adaptativa spline
112	Youssef, A. M., <i>et al</i>	Arabia Saudita	2015	Random forest (RF), Boosted regression tree (BRT), Classification and regression tree (CART), y General linear (GLM)
113	Ahmed, B.	Bangladesh	2015	Jerarquía analítica, Ponderación lineal, Regresión Logística y Múltiple Regresión Logística
114	Shahabi, H., <i>et al</i>	Irán	2015	Relación de frecuencia, Regresión Logística y Fuzzy
115	Tien Bui, D., <i>et al</i>	Vietnam	2015	Máquina de vector, Red neuronal multicapa, Red neuronal radial, Regresión Logística y modelo de árbol
116	Guri, P. K., <i>et al</i>	India	2015	Pesos de evidencia
117	Legorreta Paulín, G., <i>et al</i>	México	2015	Modelo de mapeo Índice de Estabilidad y Múltiple Regresión Logística
118	Murillo y Alcántara	México	2015	Análisis discriminante lineal, Análisis discriminante cuadrático, Regresión Logística, Red Neuronal Artificial

## 2. Factores condicionantes significativos para cada unidad de terreno

Donde “*t*” representa valor de la prueba de Student, “*p de t*” el valor de significancia de la prueba de Student, “*F*” el valor de la prueba de Fisher, “*p de F*” el valor de significancia de la prueba de Fisher, “*W*” el valor de la prueba de Wilcoxon, “*p de W*” el valor de significancia de la prueba de Wilcoxon, “*D*” valor de la prueba de Kolmogorov-Smirnoff, “*p de D*” valor de significancia de la prueba Kolmogorov-Smirnoff y  $\alpha$  valor de alfa.

Los valores de significancia están ordenados de mayor a menor sobre cada unidad de terreno.

Clave	Relaciones espaciales	Pruebas paramétricas				Pruebas no paramétricas				$\alpha$
		t	p de t	F	p de F	W	p de W	D	p de D	
I-89	Orientación de la pendiente			0.28	0					1
	Distancia a ríos			0.3	0					1
	Elevación			0.39	0.01					0.99
	Dirección de flujo					647.5	0.02			0.98
	NDVI					632	0.03			0.97
	Distancia a caminos			0.48	0.05					0.95

	Acumulación de flujo					351	0.07			0.93
	Radiación solar			0.54	0.1					0.9
I-99	Ángulo de la pendiente					50	0			1
	Perfil de curvatura	-1.96	0.06							0.94
	Curvatura general	1.92	0.06							0.94
I-105	Orientación de la pendiente			0.29	0					1
	Plano de curvatura			2.19	0.02					0.98
	Longitud de flujo					442.5	0.05			0.95
	Elevación			0.52	0.06					0.94
I-136	Dirección de flujo	-3.7	0							1
	Ángulo de la pendiente					79	0			1
	Índice de convergencia					137	0.09			0.91
I-141	NDVI							1.97	0	1
	Plano de curvatura			2.23	0					1
	Índice de convergencia							1.97	0	1
	Distancia a caminos							2.53	0	1
	Dirección de flujo							2.72	0	1
	Acumulación de flujo							4.21	0	1
	Orientación de la pendiente			0.48	0.01					0.99
	Distancia a lineamientos							1.5	0.02	0.98
Longitud de flujo			0.55	0.03					0.97	
I-142	Dirección de flujo					93.5	0.03			0.97
	Ángulo de la pendiente	1.85	0.08							0.92
I-146	Orientación de la pendiente	5.37	0							1
	Radiación solar	3.08	0.01							0.99
	Distancia a caminos	3.18	0.01							0.99
	Longitud de flujo	2.24	0.04							0.96
	Elevación	2.12	0.06							0.94
	Dirección de flujo					38	0.07			0.93
I-194	Distancia a ríos							1.92	0	1
	Dirección de flujo							3.6	0	1
	Densidad de ríos							4.37	0	1
	Orientación de la pendiente							1.61	0.01	0.99
	Distancia a caminos							1.46	0.03	0.97
	Elevación			0.68	0.08					0.92
I-213	Índice de transporte de sedimentos							1.74	0	1
	Radiación solar							2.35	0	1
	Perfil de curvatura							1.74	0	1
	Orientación de la pendiente			0.2	0					1

	Dirección de flujo							3.57	0	1
	Acumulación de flujo							2.26	0	1
I-224	Radiación solar					355	0			1
	Orientación de la pendiente			0.15	0					1
	Distancia a lineamientos					331.5	0			1
	Densidad de ríos					342	0			1
	Vegetación y uso de suelo					846	0.01			0.99
	Acumulación de flujo					891.5	0.01			0.99
	Distancia a ríos			1.92	0.06					0.94
	STI					806.00	0.08			0.92
	Índice de convergencia			1.83	0.08					0.92
I-250	NDVI					856	0			1
	Radiación solar					227	0			1
	Dirección de flujo					848.5	0			1
	Longitud de flujo			0.38	0.01					0.99
	Distancia a lineamientos					790	0.01			0.99
	Acumulación de flujo					762.5	0.02			0.98
	Elevación			0.46	0.03					0.97
	Distancia a caminos					399	0.03			0.97
	Plano de curvatura					441	0.09			0.91
I-251	Acumulación de flujo					77	0			1
	Índice de posición topográfica	2.56	0.02							0.98
	Ángulo de la pendiente	2.64	0.02							0.98
	Plano de curvatura	2.29	0.04							0.96
	Índice de convergencia					17	0.04			0.96
	Curvatura general	2.04	0.06							0.94
I-296	Distancia a caminos			0.42	0					1
	Dirección de flujo							4.87	0	1
	Orientación de la pendiente							1.4	0.04	0.96
	Índice de convergencia							1.33	0.06	0.94
I-297	Densidad de lineamientos	-5.55	0							1
	Dirección de flujo	-2.83	0.02							0.98
	Radiación solar	2.71	0.03							0.97
	Orientación de la pendiente	-1.99	0.08							0.92
I-331	Orientación de la pendiente					536	0			1
	Dirección de flujo					541	0			1
	Índice de transporte de sedimentos					231	0.02			0.98
	Longitud de flujo					225.5	0.02			0.98

	Densidad de lineamientos	-2.4	0.02						0.98
	Radiación solar					251	0.05		0.95
	Distancia a caminos	-2	0.05						0.95
	Índice de posición topográfica	1.92	0.06						0.94
	NDVI	1.82	0.07						0.93
	Edafología					445.5	0.09		0.91
	Distancia a ríos	1.76	0.09						0.91
I-332	Distancia a lineamientos					7	0.09		0.91
	Densidad de lineamientos					29	0.09		0.91
I-450	NDVI					81	0		1
	Ángulo de la pendiente	3.91	0						1
	Curvatura general					11	0.01		0.99
	Elevación	-2.49	0.02						0.98
	Densidad de ríos					19.5	0.05		0.95
I-527	Longitud de flujo	2.21	0.06						0.94
I-630	Elevación					3	0.01		0.99
	Distancia a lineamientos					45	0.01		0.99
	Densidad de lineamientos					4	0.01		0.99
	Longitud de flujo	2.59	0.02						0.98
	Ángulo de la pendiente	2.5	0.03						0.97
	Geología					10.5	0.04		0.96
	NDVI	-2	0.07						0.93
	Dirección de flujo	-2	0.07						0.93
I-715	Elevación	4.86	0						1
	Curvatura general	-3.41	0.01						0.99
	Perfil de curvatura	2.46	0.03						0.97
	Índice de convergencia	-2.15	0.06						0.94
	Ángulo de la pendiente	2.11	0.06						0.94
	Plano de curvatura	-2.04	0.07						0.93
	Acumulación de flujo					7	0.09		0.91
I-766	Ángulo de la pendiente					7	0		1
	Dirección de flujo	-2.65	0.02						0.98
	Radiación solar	-2.04	0.06						0.94
	Elevación	2.03	0.06						0.94

### 3. Funciones de preferencia y coeficiente de determinación R<sup>2</sup> para cada relación espacial

Clave	Relaciones espaciales	Función de preferencia	Coefficiente de determinación R <sup>2</sup>
I-89	Orientación de la pendiente	$y^{-1} = a + bx \ln x + cx^{1.5}$	0.892
	Distancia a ríos	$\ln(y) = a + bx^{2.5}$	0.956
	Elevación	$y^{-1} = a + bx + cx^{0.5} \ln x$	0.974
	Dirección de flujo	$y = a + b/x$	0.992
	NDVI	$y^{-1} = a + bx + c/x$	0.999
	Distancia a caminos	$y^{-1} = a + bx + cx^2 + dx^3$	0.989
	Acumulación de flujo	$y^{-1} = a + bx^{2.5}$	0.982
	Radiación solar	$y^{-1} = a + bx^{2.5} + cx^3$	0.933
I-99	Ángulo de la pendiente	$y^{-1} = a + bx + cx^{2.5}$	0.984
	Perfil de curvatura	$y = a + bx^3 + ce^{-x}$	1.000
	Curvatura general	$y = a + bx + cx^3$	0.966
I-105	Orientación de la pendiente	$y^{-1} = a + bx^2 + cx^{2.5}$	0.850
	Plano de curvatura	$y = a + bx + cx^2 + dx^3$	0.980
	Longitud de flujo	$y = a + bx^2 + cx^4$	0.936
	Elevación	$\ln(y) = a + bx + cx^{2.5}$	0.987
I-136	Dirección de flujo	$\ln(y) = a + bex$	0.973
	Ángulo de la pendiente	$y^{-1} = a + b/x^{1.5} + c/x^2$	0.865
	Índice de convergencia	$y^{-1} = a + bx + ce^{-x}$	0.985
I-141	NDVI	$y^{-1} = a + bx + c/x^{1.5}$	0.982
	Plano de curvatura	$y = (a + cx) / (1 + bx + dx^2)$	0.977
	Índice de convergencia	$y^{-1} = a + bx + cx^3$	1.000
	Distancia a caminos	$y^{-1} = a + bx^{1.5} + cx^{2.5}$	0.992
	Dirección de flujo	$y^{-1} = a + bx + cx^2 + dx^3 + ex^4$	0.996
	Acumulación de flujo	$y^{-1} = a + bx^2$	0.995
	Orientación de la pendiente	$y^{-1} = a + bx^2 + cx^{2.5}$	0.999
	Distancia a lineamientos	$y^{-1} = a + bx + cx^{2.5}$	0.990
I-142	Longitud de flujo	$y = a + bx^3 + c/x^{1.5}$	0.978
	Dirección de flujo	$y^{-1} = a + bx$	0.837
	Ángulo de la pendiente	$y^{-1} = a + bx^{0.5} + c/x^{0.5}$	0.968
I-146	Orientación de la pendiente	$y = a + be^{-x}$	1.000
	Radiación solar	$\ln(y) = a + bx^{2.5} + cx^3$	1.000
	Distancia a caminos	$y = a + bx + c/x + dx^2 + e/x^2 + fx^3$	0.925
	Longitud de flujo	$y^{-1} = a + b/x^2$	0.988
	Elevación	$y = a + bx + cx^3$	0.993
	Dirección de flujo	$y^{-1} = a + bx + cx^{0.5}$	0.915
I-194	Distancia a ríos	$y^{-1} = a + bx + cx^3$	0.930
	Dirección de flujo	$y = a + bx + cx^3 + d/x^{1.5}$	1.000
	Densidad de ríos	$y = a + bx^3 + ce^x + d/x^{0.5}$	1.000
	Orientación de la pendiente	$\ln(y) = a + bx^{1.5} + cx^2$	0.995
	Distancia a caminos	$y^2 = a + bx + cx^2 + dx^3$	0.997
	Elevación	$y^{-1} = a + bx^2 + cx^{2.5}$	0.988
I-213	STI	$\ln(y) = a + bx + cx^3$	0.999
	Radiación solar	$\ln(y) = a + bx + c/x$	0.914
	Perfil de curvatura	$\ln(y) = a + bx + cx^2 + dx^3$	0.997
	Orientación de la pendiente	$\ln(y) = a + bx^2 + cx^{2.5}$	1.000
	Dirección de flujo	$y = a + bx + cx^3 + d/x^2$	1.000
	Acumulación de flujo	$y^{-1} = a + bx$	0.995
I-224	Radiación solar	$\ln(y) = a + b/x + c/x^{1.5}$	0.891
	Orientación de la pendiente	$y^{-1} = a + bx^2 + cx^3$	0.992
	Distancia a lineamientos	$y = a + bx + cx^3 + dx^{0.5}$	1.000
	Densidad de ríos	$y = a + bx^2 + cx^{2.5} + dx^3$	0.990
	Vegetación y uso de suelo	$y = a + b/x^2 + ce^{-x}$	0.993
	Acumulación de flujo	$y = a + bx^2 + cx^3 + de^{-x}$	0.997
	Distancia a ríos	$\ln(y) = a + bx + cx^2 + dx^3$	0.999
	STI	$y = a + bx + cx^2 + dx^3$	0.995

	Índice de convergencia	$y^1 = a + bx^2 + cx^3$	0.940	
I-250	NDVI	$\text{Ln}(y) = a + bx^{1.5} + cx^3$	0.989	
	Radiación solar	$\text{Ln}(y) = a + bx^{2.5} + cx^3$	0.971	
	Dirección de flujo	$y = a + bx + cx^3 + d/x^2$	0.999	
	Longitud de flujo	$y^1 = a + bx^2 + cx^{2.5}$	0.983	
	Distancia a lineamientos	$\text{Ln}(y) = a + bx + cx^2$	0.930	
	Acumulación de flujo	$y = a + bx^{1.5} + cx^{0.5} + de^{-x}$	1.000	
	Elevación	$y^1 = a + bx^3 + c/x^{0.5}$	0.978	
	Distancia a caminos	$y^1 = a + bx + cx^2 + dx^3$	0.998	
	Plano de curvatura	$\text{Ln}(y) = a + bx + cx^2$	0.948	
I-251	Acumulación de flujo	$y = a + bx^{2.5} + cx^3 + dx^{0.5}$	0.997	
	Índice de posición topográfica	$y = a + bx$	1.000	
	Ángulo de la pendiente	$y = a + bx + cx^2 + dx^3 + ex^4 + fx^5 + gx^6$	0.928	
	Plano de curvatura	$y = a + bx^3 + ce^x + de^{-x}$	0.917	
	Índice de convergencia	$y = a + bx + cx^3$	0.918	
	Curvatura general	$y = a + bx + cx^3$	0.889	
I-296	Distancia a caminos	$\text{Ln}(y) = a + bx^{2.5} + cx^{0.5}$	0.986	
	Dirección de flujo	$y = a + b/x^{1.5}$	1.000	
	Orientación de la pendiente	$y^1 = a + bx + cx^{1.5}$	0.999	
I-297	Índice de convergencia	$\text{Ln}(y) = a + bx + cx^2$	0.988	
	Densidad de lineamientos	$y = a + bx^{2.5} + cx/\text{ln}(x) + de^{-x}$	0.857	
	Dirección de flujo	$\text{Ln}(y) = a + bx^{2.5} + ce^x$	1.000	
	Radiación solar	$y = a + bx + cx^2 + dx^3$	0.993	
	Orientación de la pendiente	$y = a + bx^2 + cx^4 + dx^6$	0.999	
I-331	Orientación de la pendiente	$y^1 = a + bx^{1.5} + cx^3$	0.946	
	Dirección de flujo	$\text{Ln}(y) = (a + cx) / (1 + bx + dx^2)$	1.000	
	STI	$\text{Ln}(y) = a + bx^2 + cx^3$	0.966	
	Longitud de flujo	$y^1 = a + bx + cx^2 + dx^3$	1.000	
	Densidad de lineamientos	$\text{Ln}(y) = a + bx + cx^2 + dx^3 + ex^4$	0.978	
	Radiación solar	$y = a + bx + cx^{0.5} + d/x$	0.999	
	Distancia a caminos	$y^1 = a + bx^{2.5} + cx^3$	0.837	
	Índice de posición topográfica	$y^1 = a + bx + cx^2 + dx^3$	0.968	
	NDVI	$y^1 = a + bx + cx^2 + dx^3$	0.937	
	Edafología	$y = a + bx^3 + c/\text{ln}(x) + d/x^{1.5}$	0.999	
	Distancia a ríos	$y = a + bx^{2.5} + cx^3 + dx^{0.5}$	0.997	
	I-332	Distancia a lineamientos	$y = a + bx^2 + cx^{2.5} + dx^3$	0.958
		Densidad de lineamientos	$\text{Ln}(y) = a + bx^{1.5} + cx^3$	1.000
I-450	NDVI	$y^1 = a + bx^2$	0.965	
	Ángulo de la pendiente	$y^2 = (a + cx) / (1 + bx + dx^2)$	1.000	
	Curvatura general	$y = a + bx^{0.5} + c/x^{0.5} + d/x^2$	0.944	
	Elevación	$y = a + bx^{2.5} + cx^3 + dx^{0.5}$	1.000	
	Densidad de ríos	$y^1 = a + bx^3$	0.920	
I-527	Longitud de flujo	$y^1 = a + bx^{2.5} + cx^3$	0.991	
I-630	Elevación	$y = a + bx^2 + cx^4 + dx^6$	0.978	
	Distancia a lineamientos	$y = a + bx^{1.5} + cx^2 + dx^{2.5}$	1.000	
	Densidad de lineamientos	$y = a + bx + \text{cln}(x)$	0.961	
	Longitud de flujo	$y = a + bx^2 + cx^4$	0.991	
	Ángulo de la pendiente	$y = a + bx + cx^{0.5} + d/x + ee^{-x}$	0.937	
	Geología	$y = a + bx^2 + cx^4$	1.000	
	NDVI	$\text{Ln}(y) = a + bx$	1.000	
	Dirección de flujo	$y = a + bx^2 + cx^{2.5} + d/x^{0.5}$	0.998	
I-715	Elevación	$y = a + bx + c/x^{0.5}$	1.000	
	Curvatura general	$\text{Ln}(y) = a + bx^3 + ce^x$	0.938	
	Perfil de curvatura	$y = a + bx^2 + cx^4 + dx^6$	0.920	
	Índice de convergencia	$\text{Ln}(y) = a + bx^2 + c/x^2$	0.997	
	Ángulo de la pendiente	$y^1 = a + b/x^2$	0.993	
	Plano de curvatura	$y = a + bx + ce^{-x}$	0.936	
	Acumulación de flujo	$y = a + bx + cx^{2.5} + dx^{0.5}$	0.961	
I-766	Ángulo de la pendiente	$y = a + bx^{1.5} + cx^{2.5} + dx^3$	0.961	
	Dirección de flujo	$y = a + bx^2 + cx^{2.5} + dx^3$	0.999	
	Radiación solar	$y = a + bx + cx^2 + dx^3 + ex^{0.5}$	0.939	
	Elevación	$y = a + bx + cx^2 + dx^3 + ex^4 + fx^5$	0.986	

#### 4. Ponderación asignada al nivel de significancia (SPATSMO-SL)

Clave	Relaciones espaciales	Sig.	Ponderación	Clave	Relaciones espaciales	Sig.	Ponderación	
I-89	Orientación de la pendiente	1.00	0.129	I-250	Dirección de flujo	1	0.113	
	Distancia a ríos	1.00	0.129		Longitud de flujo	0.99	0.113	
	Elevación	0.99	0.128		Distancia a lineamientos	0.99	0.112	
	Dirección de flujo	0.98	0.127		Acumulación de flujo	0.98	0.111	
	NDVI	0.97	0.125		Elevación	0.97	0.11	
	Distancia a caminos	0.95	0.123		Distancia a caminos	0.97	0.11	
	Acumulación de flujo	0.93	0.121		I-251	Acumulación de flujo	1	0.171
	Radiación solar	0.90	0.117			Ángulo de la pendiente	0.98	0.169
I-99	Ángulo de la pendiente	1	0.347	TPI		0.98	0.168	
	Perfil de curvatura	0.94	0.327	Plano de curvatura		0.96	0.166	
	curvatura	0.94	0.326	Índice de convergencia		0.96	0.164	
I-105	Orientación de la pendiente	1	0.258	Curvatura	0.94	0.162		
	Plano de curvatura	0.98	0.252	I-296	Distancia a caminos	1	0.256	
	Longitud de flujo	0.95	0.247		Dirección de flujo	1	0.256	
	Elevación	0.94	0.243		Orientación de la pendiente	0.96	0.246	
I-136	Dirección de flujo	1	0.344		Índice de convergencia	0.94	0.241	
	Ángulo de la pendiente	1	0.344	I-297	Densidad de lineamientos	1	0.258	
	Índice de convergencia	0.91	0.313		Dirección de flujo	0.98	0.253	
I-141	NDVI	1	0.112		Radiación solar	0.97	0.252	
	Plano de curvatura	1	0.112		Orientación de la pendiente	0.92	0.237	
	Índice de convergencia	1	0.112	I-331	Orientación de la pendiente	1	0.095	
	Distancia a caminos	1	0.112		Dirección de flujo	1	0.095	
	Dirección de flujo	1	0.112		STI	0.98	0.093	
	Acumulación de flujo	1	0.112		Longitud de flujo	0.98	0.093	
	Orientación de la pendiente	0.99	0.111		Densidad de lineamientos	0.98	0.093	
	Distancia a lineamientos	0.98	0.109		Radiación solar	0.95	0.09	
	Longitud de flujo	0.97	0.109		Distancia a caminos	0.95	0.09	
I-142	Dirección de flujo	0.97	0.514		TPI	0.94	0.089	
	Ángulo de la pendiente	0.92	0.486		NDVI	0.93	0.088	

I-146	Orientación de la pendiente	1	0.172		Edafología	0.91	0.087
	Radiación solar	0.99	0.17		Distancia a ríos	0.91	0.087
	Distancia a caminos	0.99	0.171	I-332	Distancia a lineamientos	0.91	0.5
	Longitud de flujo	0.96	0.164		Densidad de lineamientos	0.91	0.5
	Elevación	0.94	0.162	I-450	NDVI	1	0.255
	Dirección de flujo	0.93	0.16		Ángulo de la pendiente	1	0.255
I-194	Distancia a ríos	1	0.17		Curvatura	0.99	0.253
	Dirección de flujo	1	0.17		Elevación	0.98	0.249
	Densidad de ríos	1	0.17	Densidad de ríos	0.95	0.243	
	Orientación de la pendiente	0.99	0.168	I-527	Longitud de flujo	0.94	1
	Distancia a caminos	0.97	0.165	I-630	Elevación	0.99	0.128
	Elevación	0.92	0.156		Distancia a lineamientos	0.99	0.128
I-213	Radiación solar	1	0.167		Densidad de lineamientos	0.99	0.128
	Orientación de la pendiente	1	0.167		Longitud de flujo	0.98	0.126
	Dirección de flujo	1	0.167		Ángulo de la pendiente	0.97	0.126
	Acumulación de flujo	1	0.167		Geología	0.96	0.123
	STI	1	0.166		Dirección de flujo	0.93	0.12
	Perfil de curvatura	1	0.166	NDVI	0.93	0.12	
	I-224	Radiación solar	1	0.114	I-715	Elevación	1
Orientación de la pendiente		1	0.114	Curvatura		0.99	0.149
Distancia a lineamientos		1	0.114	Perfil de curvatura		0.97	0.145
Densidad de ríos		1	0.114	Índice de convergencia		0.94	0.141
Vegetación y uso de suelo		0.99	0.113	Ángulo de la pendiente		0.94	0.141
Acumulación de flujo		0.99	0.113	Plano de curvatura		0.93	0.139
Distancia a ríos		0.94	0.108	Acumulación de flujo		0.91	0.136
STI		0.92	0.105	I-766		Ángulo de la pendiente	1
Índice de convergencia		0.92	0.105		Dirección de flujo	0.98	0.254
I-250		Radiación solar	1		0.114	Radiación solar	0.94
	NDVI	1	0.113	Elevación	0.94	0.244	
	Plano de curvatura	0.91	0.103				

## 5. Estimación de parámetros para la RNA

Predictor		Pronosticado								
		Capa oculta 1							Capa de salida	
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	[Value=0]	[Value=1]
Capa de entrada	(Sesgo)	.414	.886	-.636	-.324	.498	-.713	-.754		
	NDVI	.152	-.545	-.087	.181	-.166	.406	.107		
	TPI	.390	.390	-.223	-.681	.503	.484	.456		
	STI	-.330	-.082	.036	.228	.079	-.985	-.322		
	Radiación solar	.054	.270	-.663	-.311	.998	.571	.107		
	Plano de curvatura	-.080	-.408	-.230	-.657	-.374	.433	.331		
	Elevación	.089	.067	.538	-.292	.000	.759	-.477		
	Densidad de escurrimientos	.115	.245	1.284	-.319	-.135	-.410	.599		
	Angulo de inclinación de la pendiente	-.124	1.172	.719	.487	.705	.633	.530		
	Acumulación de flujo	.463	-.601	.304	-.242	.451	.036	-.396		
	Perfil de curvatura	-.504	.240	-.513	-.393	.097	.264	-.265		
	Orientación de la pendiente	-.023	-.094	.293	.065	-.555	-.817	.679		
	Longitud de flujo	-.112	.188	-.064	-.509	.364	-.174	.464		
	Índice de convergencia	-.546	.185	-.151	-.524	.011	.466	.245		
	Distancia a lineamientos	-.105	-.807	-.029	-.167	-.185	-.131	.635		
	Curvatura general de la pendiente	-.077	.152	-.295	-.149	-.124	.207	.260		
Capa oculta 1	(Sesgo)								-.054	-.495
	H(1:1)								.508	-.140
	H(1:2)								-1.110	1.123
	H(1:3)								-.510	.776
	H(1:4)								-.815	.246
	H(1:5)								-.715	.815
	H(1:6)								-.984	1.005
	H(1:7)								-.727	.389

## APÉNDICE B



1. Caminos y carreteras del área de estudio, Fuente: Propia.



2. Lineamientos geológicos del área de estudio, Fuente: Propia.



**3. Escurrimientos superficiales del área de estudio, Fuente: Propia.**