

# Estimación de la susceptibilidad a deslizamientos en masa usando redes neuronales basados en el modelo FALCON-ART

A. Viloría,<sup>1</sup> C. Chang,<sup>1</sup> M.C. Pineda y<sup>2</sup> J. Viloría,<sup>2</sup>

<sup>1</sup>Grupo de Inteligencia Artificial, Departamento de Computación y Tecnología de la Información. Universidad Simón Bolívar. Caracas, Venezuela

<sup>2</sup>Instituto de Edafología de la Facultad de Agronomía de la Universidad Central de Venezuela. Maracay, Venezuela

## RESUMEN

*Los deslizamientos en masa son procesos de erosión, de carácter catastrófico, que modifican la morfología del paisaje y afectan a personas, terrenos productivos y obras de infraestructura. Recientemente se han realizado varios intentos de aplicación de redes neuronales para predecir la susceptibilidad del paisaje a los deslizamientos. Sin embargo, el conocimiento de la red neuronal se encuentra expresado en un modelo matemático que no permite establecer, de manera intuitiva, relaciones entre los factores causantes de este tipo de fenómeno. Esto dificulta a los expertos la interpretación de la salida de la red, para soportar los resultados con un conjunto de reglas de inferencia. Esta limitación podría ser superada por medio de un modelo basado en la red neuronal FALCON, la cual permite no sólo realizar una clasificación por agrupamiento de los datos con lógica borrosa o difusa, sino también generar un conjunto de reglas borrosas a partir de los datos de entrenamiento. Por esta razón, se implementó la red neuronal FALCON-ART para crear un conjunto de modelos de susceptibilidad a deslizamientos en masa en la cuenca del Río Caramacate en el estado Aragua. Los datos de entrada al modelo incluyeron un mapa de cicatrices de suelo del año 1992 y de variables derivadas de un modelo digital de elevación y de una imagen satelital SPOT. Por medio de validación cruzada se determinó que el mejor resultado produjo un 74% de acierto en la predicción de aquellas áreas susceptibles a deslizamientos en masa.*

## ABSTRACT

*Landslides are processes of erosion of a catastrophic character which alter the morphology of the landscape and affect people, productive land and infrastructure. Recently, there have been several attempts to apply neural networks to predict landscape susceptibility to landslides. However, the knowledge of the neural network is expressed in a mathematical model that does not allow establishing, intuitively, relationships between the factors causing landslides. This makes it difficult for experts to interpret the output of the network, to support their results with a set of inference rules. This limitation could be overcome by a model based on the neural network FALCON, which allows not only a classification for clustering of data with fuzzy logic, but also generate a set of fuzzy rules from data training. For this reason, the FALCON-ART neural network has been implemented in this study to create a set of models of susceptibility to landslides at the watershed of the Caramacate River in the Aragua state of Venezuela. The input data to the model included a landslide scar map from 1992, and variables derived from a digital elevation model and a SPOT-satellite image. Through cross-validation it was determined that the best result achieved a 74% success in predicting susceptible areas to landslides.*

**Keywords:** Lógica borrosa o difusa, susceptibilidad a deslizamientos en masa, modelos digitales de elevación.

## 1. Introducción

La clasificación de los suelos representa una necesidad para la humanidad, desde el comienzo se buscaban las características comunes del paisaje para determinar el uso apropiado de los terrenos. Con el pasar del tiempo los científicos fueron descubriendo que el comportamiento de la cobertura vegetal variaba según la forma del relieve, clima y de las propiedades del suelo. Por esta razón estudiar las relaciones entre estas variables ha resultado ser de gran interés para el establecimiento de patrones que permitan optimizar

el uso de terrenos. Sin embargo, un problema al cual se han enfrentado los expertos es la variación del paisaje por fenómenos naturales.

Los deslizamientos en masa pueden cambiar de manera drástica la morfología del paisaje y dada su naturaleza catastrófica, representan uno de los problemas más serios en término de daños económicos, afectando a personas, propiedades y terrenos productivos [BTH00, PL10a, PL10b, MMR08, HJB11, Pin11]. Las zonas montañosas tropicales, presentan una gran susceptibilidad a los fenómenos de

deslizamientos en masa, por ejemplo, en Venezuela aproximadamente el 44% del territorio presenta un relieve abrupto, donde la Cordillera de la Costa Central y la Cordillera Andina constituyen unos de los escenarios en los cuales se desarrollan dichos procesos [Pin11].

Debido a la frecuencia con la que ocurren a cada año los deslizamientos en masa, las pérdidas humanas y económicas pueden llegar a ser mayores en comparación con desastres naturales, tales como terremotos o inundaciones. Es por esto que se tiene la gran necesidad de representar en mapas la variación espacial de la susceptibilidad de deslizamiento en masa a diferentes escalas, para apoyar en la toma de decisiones sobre el manejo adecuado de las tierras [MMR08, GK05, LP06]. Para comprender la magnitud de este fenómeno, cabe simplemente recordar dos de los eventos recientes de mayor impacto en la población e infraestructura de Venezuela, el desastre natural de 1987 en el estado Aragua, en la cuenca del Río El Limón y los ocurridos en varias cuencas localizadas en el estado Vargas en 1999, los cuales provocaron numerosas víctimas humanas y cuantiosos daños materiales [Pin11].

En teoría, la generación de los deslizamientos en masa depende de las relaciones existentes entre diferentes propiedades del paisaje, las cuales son el resultado del balance entre procesos individuales. Este balance está determinado por la interacción entre varios factores o elementos del entorno, como se expresa en el siguiente modelo propuesto por Jenny para explicar el estado actual de las propiedades de suelos y ecosistemas [Jen61]:

$$s = f(cl, b, mp, r, t, \dots) \quad (1)$$

De acuerdo a esta ecuación, el estado del suelo ( $s$ ) en un lugar y momento determinado, es función de la acción combinada del clima ( $cl$ ), la biota ( $b$ ), el material parental ( $mp$ ), el relieve ( $r$ ), la edad del paisaje ( $t$ ) y, en casos particulares factores adicionales, como por ejemplo la intervención humana [MMR08, GK05, LYY01, Vil07]. Sin embargo, el desencadenamiento de movimientos en masa depende de la combinación exacta de determinados factores de carácter local, que le confiere a la zona un cierto grado de susceptibilidad. Por tal razón, en diferentes áreas, la combinación de variables desencadenadoras o activadores de movimientos en masa pueden ser distintas o simplemente actuar a una magnitud o intensidad diferente [Pin11, Pér00, ED00, ED03].

La parte más difícil de la evaluación de la susceptibilidad de los deslizamientos en masa, es predecir futuros eventos dado el conocimiento actual de cómo la interacción de los factores contribuyen con la inestabilidad de las laderas. Es por ello, que la predicción de la susceptibilidad a los deslizamientos en masa está basada en relaciones complejas, no lineales e incluso desconocidas, entre los factores condicionantes y la distribución de los movimientos en masa. La habilidad de comprender y aprender las funciones no lineales a partir de los datos es el punto clave para el problema de la clasificación de las áreas susceptibles a estos eventos [MMR08, LYY01, RG03, Ale08]. Sin embargo, la habilidad de los sistemas de información geográficos para manejar un gran volumen de datos, ha permitido evaluar diversas técnicas para poder establecer un modelo de susceptibilidad a deslizamientos en masa [HJB11, CPSS08, NS06].

Entre las principales técnicas empleadas en múltiples estudios se pueden destacar: ecuaciones de regresión lineal, redes bayesianas, redes neuronales y lógica borrosa o difusa [MMR08, HJB11, Pin11, GK05, LYY01, CPSS08, NS06, PVV10, CSAG10].

En [PVV10], se relacionó un mapa de cicatrices de deslizamiento con factores derivados de un modelo digital de elevación (MDE) y la diferencia normalizada del índice de vegetación (NDVI) obtenida de una imagen satelital. Los resultados obtenidos de la aplicación de ambas técnicas son complementarios. Por un lado, el modelo de red bayesiana mostró más claramente el efecto de la interacción entre las variables relacionadas con los deslizamientos y por otro el modelo de regresión logística muestra la distribución espacial de la susceptibilidad a los deslizamientos. En general, el área de estudio muestra una sensibilidad alta o muy alta a los deslizamientos. La regresión logística clasificó correctamente el 80% de los valores observados en los datos de validación, mientras que la red bayesiana clasificó de manera correcta el 87,5% de estos valores.

Las redes neuronales artificiales y los conjuntos borrosos son apropiados para mejorar la inteligencia de sistemas que trabajan en un ambiente incierto, impreciso y con ruido. Por lo tanto, son útiles para modelar procesos complejos no lineales [LL96]. Es por esta razón que se han aplicado de manera exitosa tanto en el estudio de los factores formadores del suelo y del paisaje como en la interacción de estos para determinar la susceptibilidad en un área de estudio a deslizamientos en masa [MMR08, HJB11, LYY01, CPSS08]. Por ejemplo, se ha utilizado la red neuronal perceptron multicapa con retroalimentación hacia atrás para evaluar el potencial de susceptibilidad a deslizamientos en masa [MMR08, GK05, LYY01, CPSS08, NS06, CSAG10]. Para esto se han estimado modelos a partir de diversos factores que influyen en la inestabilidad de las pendientes, derivados de MDE y de imágenes de sensores remotos. Los modelos generados lograron resultados prometedores para futuros estudios correspondientes a la susceptibilidad del paisaje para el deslizamiento en masa. Cabe destacar que en la investigación presentada en el artículo [GK05] fue centrada en el área de estudio que se encuentra ubicada en la cuenca del río Jabonosa en los Andes Venezolanos, logrando un modelo con un 90% de precisión en la predicción de deslizamientos en masa.

En [HJB11] se implementó la red neuronal Adaptive Neuro-Fuzzy Inference Systems (ANFIS), el cual se encuentra basado tanto en conocimiento del experto como en una red neuronal supervisada. El conocimiento del experto se modela a través de un conjunto de reglas de inferencias borrosas. Esta red contó con una precisión del 84.39%, indicando que es una buena aproximación para predecir la susceptibilidad de un área a deslizamiento en masa y a la vez es confiable, ya que se encuentra basado en una interacción conocida de los factores.

Sin embargo, el conocimiento de la red neuronal se encuentra expresado en un modelo matemático y por lo tanto de ella no se puede extraer de manera intuitiva una relación entre los factores, lo cual dificulta a los expertos poder interpretar la salida de la red y así poder soportar los resultados con un conjunto de reglas. Este comportamiento ha generado críticas en la comunidad de científicos sobre el uso de redes neuronales en este tipo de problemas, debido a que el



mecanismo de los deslizamientos en masa es un fenómeno complejo, el cual aún no se ha logrado comprender completamente [NS06, CSAG10]. Por ello, en esta investigación se plantea usar la red neuronal FALCON-ART para brindar un enfoque novedoso a este problema. Ya que, no sólo se generaría un mapa de susceptibilidad a deslizamientos en masa, si no también se crearían un conjunto de reglas en formato IF-THEN donde se lograría observar el detalle de la interacción entre los factores.

## 2. Área de Estudio

Actualmente la Universidad Central de Venezuela, a través del Instituto Edafología de la Facultad de Agronomía conduce investigaciones sobre cómo los factores condicionantes determinan la distribución geográfica de la susceptibilidad a los deslizamientos en masa en la cuenca hidrográfica del río Caramacate. La subcuenca del río Caramacate se ubica entre los municipios Santos Michelena y San Sebastián de los Reyes, Estado Aragua, entre las coordenadas UTM: 1.098.310 - 1.123.583 (norte) y 696.879 - 712.415 (este). El clima de la zona varía desde Bosque Seco Tropical hasta Bosque Húmedo Premontano con el aumento de altitud. La precipitación media anual oscila entre 1200 y 1400 mm [MV04].

En [PVV10, Pin11] se realizó una clasificación geomorfológica del área de estudio en unidades de paisaje y un análisis de las relaciones entre estas unidades y las propiedades del suelo. Con el propósito de generar un mapa de susceptibilidad a deslizamiento en masa. La clasificación del paisaje se realizó por medio de la interpretación de información procedente de un MDE derivado de las hojas cartográficas a escala 1:25000 y un conjunto de imágenes de percepción remota. EL MDE es una matriz de 400 filas por 800 columnas, donde cada cada píxel de MDE tiene 20 metros de lado. Es decir, que se tienen un total de 320.000 píxeles y se cubre un área de 8.000 por 160.000 metros.

Los MDE contienen dos tipos de información: explícita, referida a datos concretos del atributo altitud, e implícita, referente a las relaciones espaciales entre los datos como la distancia o la vecindad [Fel94]. Ambos tipos de información son complementarias y permiten conocer la morfología del relieve, derivados del carácter digital de los datos y de los procesos de análisis, configurados por algoritmos. Entre los elementos de la morfología del relieve se encuentran la pendiente, la orientación, el plano de la curvatura, entre otras. Las variables utilizadas en este estudio se definen de la manera siguiente [BM98]:

- El gradiente de la pendiente (slope) es la razón máxima de cambio de elevación que influye sobre las tasas de flujo de agua y sedimento.
- La orientación de la pendiente (aspect) en un punto puede definirse como el ángulo existente entre el vector que señala el Norte y la proyección sobre el plano horizontal del vector normal a la superficie en ese punto [Fel94].
- El plano de curvatura (plang), es la porción de cambio de la pendiente en sentido trasversal que afecta la convergencia y divergencia del flujo. Estos últimos atributos son expresados como grados de convexidad y concavidad.
- El índice topográfico de humedad (indhum), es una función que permite inferir la cantidad de agua que puede lle-

gar a un punto dado, influenciado por el área de captación y la pendiente. Se calcula por medio de la ecuación 2

$$\text{indhum} = \ln(\text{catchment} / \text{tag}(\text{slope}^\circ)) \quad (2)$$

Se dispone de una imagen satelital Spot (2008), la cual fue georeferenciada usando las hojas cartográficas a escala 1:25000 del Instituto Geográfico de Venezuela Simón Bolívar y posteriormente fue corregida radiométricamente [Pin11]. A partir de las combinaciones de las bandas espectrales de las imágenes de satélite de una superficie y aprovechando las características únicas del reflejo de la vegetación verde se puede calcular el índice de vegetación (NDVI, por sus siglas en inglés (“Normalized Digital Vegetation Index”). El intervalo de valores obtenido del NDVI, varía entre -1 y 1. Sólo los valores positivos corresponden a zonas de vegetación. Los valores negativos, pertenecen a nubes, nieve, agua, zonas de suelo desnudo y rocas [RHSD74]. El cálculo del NDVI se puede expresar entonces como una operación de bandas (ecuacion 3)

$$\text{NDVI} = \frac{(\text{Banda Infrarroja} - \text{Banda Roja})}{(\text{Banda Infrarroja} + \text{Banda Roja})} \quad (3)$$

Asimismo, se tiene un mapa de cicatrices de suelo correspondiente al año 1992. La identificación se realizó de forma visual, sobre las respectivas imágenes digitales, marcando puntos que identifican la cicatriz y la masa fallada. Posteriormente, parte de los puntos identificados en las imágenes fueron observados en campo. Además por cada uno de los mapas se entregaron un conjunto de puntos donde se certifica que no es susceptible a sufrir un deslizamiento en masa [Pin11]. Para mayor detalle observar la tabla 1.

Año	Puntos con deslizamiento	Puntos sin deslizamiento
1992	183	196

**Tabla 1:** Descripción de los puntos identificados con deslizamiento en masa y sin deslizamiento en masa para el año 1992

Se desea trabajar con un modelo numérico, que permita establecer relaciones cuantitativas entre los atributos del paisaje y la susceptibilidad a un deslizamiento en masa. Para ello, se desea obtener una correlación de los factores condicionantes y las cicatrices de suelo identificados en los diversos mapas de la zona de estudio. Se espera con esto, poder lograr un modelo, que logre predecir de manera confiable la susceptibilidad a deslizamiento en masa del área de estudio.

## 3. Red Neuronal FALCON-ART

En [LL91] se propone el modelo Fuzzy Adaptive Learning Control Network (FALCON), el cual es una red neuronal de 5 capas que se puede apreciar en la figura 1. Entre las características principales de este modelo se encuentra: el aprendizaje “on-line” y la construcción automática de la red a partir de los datos de entrenamiento. En la capa 1 se encuentran los nodos de entrada y en la capa 5 se encuentran los nodos de salida, estas dos capas representan las variables

lingüísticas. Los nodos de la capa 1 son llamados variables lingüísticas de entrada y los nodos de la capa 5 son llamados variables lingüísticas de salida. En las capas 2 y 4 se encuentran los nodos términos, estos nodos representan respectivamente las funciones de membresía de las variables lingüísticas de entrada y de salida. Cada nodo de la capa 3 representa una regla de lógica borrosa, estos nodos son llamados nodos reglas. Al juntar todos los nodos de la capa 3, se obtiene la base de reglas borrosas.

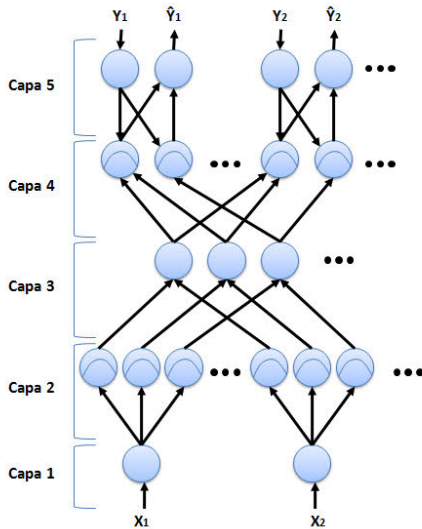


Figura 1: Modelo de la red neuronal FALCON [LL97]

Los enlaces entre las capas 2 y 3 definen las precondiciones de las reglas, mientras que los enlaces entre la capa 3 y 4 definen las consecuencias de las reglas. Los enlaces entre estas 3 capas forman el motor de inferencia de la red neuronal.

Los nodos términos se encuentran completamente conectados con los nodos de las variables lingüísticas, es decir, los nodos de la capa 1 se encuentran completamente conectados con los nodos de la capa 2 y de la misma forma los nodos de la capa 4 con los nodos de la capa 5. Las flechas en la figura 1 indican en cual modo de operación se encuentra la red, la flecha que va de la capa 5 a la capa 4 indica que la red se encuentra en modo arriba-abajo (“up-down”). En caso contrario, la red se encuentra en modo abajo-arriba (“bottom-up”).

Las variables lingüísticas son vectores n dimensionales en  $R^n$  de la forma  $x = (x_1, x_2, \dots, x_n)$ , en FALCON, estos vectores son normalizados usando el código complemento propuesto en fuzzy ART [CGR91]. Este proceso de normalización transforma el vector  $x$  a un vector  $x'$  en  $R^{2n}$  de la forma  $[0, 1]^{2n}$ , tal como se muestra en la ecuación 4.

$$x' \equiv (\bar{x}_1, \bar{x}_1^c, \bar{x}_2, \bar{x}_2^c, \dots, \bar{x}_n, \bar{x}_n^c) = (\bar{x}_1, 1 - \bar{x}_1, \bar{x}_2, 1 - \bar{x}_2, \dots, \bar{x}_n, 1 - \bar{x}_n) \quad (4)$$

Donde  $(\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n) = \bar{x} = x/\|x\|$  y  $x^c$  es el complemento de  $x$ . Esta normalización, evita la proliferación de categorías al usar fuzzy ART durante el agrupamiento borroso y permite preservar la amplitud de los datos.

En [LL97], se propone la red neuronal FALCON-ART,

la cual es una adaptación a los modelos FALCON [LL91] y fuzzy ART [CGR91]. FALCON-ART es un modelo de aprendizaje dividido en tres etapas: aprendizaje de la estructura de la red, aprendizaje de los parámetros de la red y eliminación de reglas.

a) *Aprendizaje de la estructura:* La red neuronal FALCON-ART sólo recibe los datos para entrenamiento, por lo tanto, los nodos de las capas 2, 3 y 4 son creados de manera dinámica durante el entrenamiento, mientras que los nodos de la capa 1 y 5 son creados e inicializados al comenzar el entrenamiento. De este modo, a partir de un conjunto de datos de entrenamiento  $X$  y un conjunto  $Y$  de valores esperados para  $X$ , la red podrá generar las particiones borrosas junto con sus funciones de membresía y además, se crearan las reglas borrosas. En esta etapa del entrenamiento, la red se encuentra en modo abajo-arriba, es decir, que los datos de entrenamiento para las capas 1 y 5 son entregados. Esta etapa consta de tres procesos de aprendizaje: el proceso de agrupamiento borroso de los vectores de entrada, el proceso de agrupamiento de los vectores de los valores esperados y el proceso de mapeo. Los dos primeros procesos ocurren de manera simultánea.

1) *Proceso de agrupamiento borroso de los vectores de entrada:* En este parte del aprendizaje, se utiliza el algoritmo de “fast-learning” o aprendizaje rápido de fuzzy ART, para así encontrar los parámetros  $u_{ij}$  y  $v_{ij}$  de la función de membresía del vector de entrada. Lo cual es equivalente a formar los hiper-rectángulos borrosos en el espacio vectorial del conjunto de entrada. El dinamismo de FALCON-ART se encuentra definido por dos parámetros: el parámetro de selección  $\alpha > 0$ , y el parámetro de vigilancia  $\rho \in [0, 1]$ . El parámetro de selección debe ser un valor muy pequeño, este parámetro es usado para deshacer desigualdades, mientras que el parámetro de vigilancia influye en el número de nodos términos que serán creados. Si  $\rho$  es cercano a uno, entonces, obliga al modelo a buscar un nuevo nodo término en respuesta a pequeñas diferencias entre el vector de entrada y el prototipo esperado, con lo cual el modelo clasifica los patrones de entrada en categorías muy finas. Al contrario, si el valor de  $\rho$  es pequeño, entonces, permite al modelo tolerar discordancias mayores, y agrupa a los patrones de entrada en pocos nodos términos.

Para cada vector de entrada  $x'$  y cada nodo  $j$  de la capa 2 se calcula la función de selección,  $T_j$ , la cual se define en la ecuación 5.

$$T_j(x') = \frac{|x' \wedge w_j|}{\alpha + |w_j|}, \quad j = 1, 2, \dots, N \quad (5)$$

Donde  $N$  es número actual de nodos regla y  $w_j$  es el vector de peso, el cual se define de la siguiente manera:  $w_j \equiv \{[u_{1j}, 1 - v_{1j}], \dots, [u_{ij}, 1 - v_{ij}], \dots, [u_{nj}, 1 - v_{nj}]\}$ . Es importante recalcar, que  $\{[u_{1j}, v_{1j}], \dots, [u_{ij}, v_{ij}], \dots, [u_{nj}, v_{nj}]\}$  es el vector de peso en la asociación de los nodos términos de la capa 2 con el nodo regla  $j$ . El operador mínimo ( $\wedge$ ) de la



teoría de conjuntos borrosos se calcula a través de la ecuación 6

$$(p \wedge q)_i = \min(p_i, q_i) \quad (6)$$

Con la ecuación 7 se calcula la norma de un vector

$$|p| = \sum_{i=1}^m |p_i| \quad (7)$$

Se dice que se ha seleccionado una categoría, si al menos existe un nodo término de la capa 2 activo. De existir más de un nodo de la capa 2 activos, entonces se selecciona aquel cuyo  $T_j$  sea el mayor. Para ello, se aplica la ecuación 8

$$T_j = \max\{T_j : J = 1, \dots, N\} \quad (8)$$

La resonancia ocurre cuando la desigualdad de la ecuación 9 se cumple:

$$\frac{|x' \wedge w_j|}{|x'|} \geq \rho \quad (9)$$

De cumplirse la desigualdad, el nodo término  $j$  de la capa 2 se activa como el nodo correspondiente al patrón de entrada  $x'$ , y se produce el proceso de aprendizaje de dicho patrón. En cambio, de no cumplirse la desigualdad, se produce el reajuste, donde se inactiva temporalmente al nodo  $j$  y se vuelve a seleccionar otro nodo término usando la ecuación 8. De no existir otro nodo término que cumpla la ecuación 9, entonces se crea un nuevo nodo término que aprenda el patrón de entrada.

- 2) *Proceso de agrupamiento de los vectores de los valores esperados*: Este proceso es exactamente igual al anterior, con la salvedad que en este caso, el proceso de agrupamiento borroso ocurre entre las capas 4 y 5. Además, cabe señalar que el patrón de entrenamiento es el vector de los valores esperados en código complemento, es decir  $y' = (\bar{y}, \bar{y}^c) = (\bar{y}, 1 - \bar{y})$ .
- 3) *Proceso de mapeo*: Los dos procesos anteriores de agrupamiento borroso, tienen como resultado la selección de un hiper-rectángulo del espacio vectorial de entrada  $J$  y un hiper-rectángulo del espacio vectorial de salida  $K$ . Ahora, se debe realizar el proceso de enlazar estos dos hiper-rectángulos, lo cual define la precondition y la consecuencia de una regla borrosa  $R$ . Este proceso se especifica en el siguiente algoritmo:

*Paso i* : **SI** el nodo término  $J$  se ha creado recientemente **ENTONCES** crear un nuevo nodo regla  $R$  y enlazar el nodo término  $J$  con la precondition de  $R$  y el nodo término  $K$  con la consecuencia de  $R$ .

*Paso ii* : **SI NO**: **SI** la consecuencia del nodo  $R$  no coincide con el nodo término  $K$  para cuando su precondition es el nodo término  $J$  **ENTONCES** para encontrar el siguiente nodo término, se debe realizar nuevamente el proceso de agrupamiento borroso de los vectores de entrada. Luego ir al *Paso I*

*Paso iii* : **SI NO**: no se realiza cambios en la estructura.

En el proceso de mapeo, se ajustan los pesos de los hiper-rectángulos  $J$  y  $K$  de acuerdo a la regla de aprendizaje rápido [CGR91], esta regla es detallada en la ecuación 10.

$$w_j^{(new)} = x' \wedge w_j^{old}, w_k^{(new)} = y' \wedge w_k^{old} \quad (10)$$

Es importante recalcar, que una vez que se haya definido la consecuencia y la precondition de un nodo regla, este no cambiará durante el entrenamiento.

- b) *Aprendizaje de los parámetros de la red*: Luego de haber generado y ajustado la estructura de la red a partir de los datos de entrenamiento, se procede a ajustar los parámetros de las funciones de membresía de manera óptima con el mismo conjunto de entrenamiento. En esta etapa, la red trabaja en modo abajo-arriba. La idea es emplear un algoritmo de retroalimentación para determinar el error de los nodos por cada capa. Luego, se utiliza este error para realizar el ajuste de los parámetros de la red. El objetivo principal es minimizar la función del error de la ecuación 11, donde  $y(t)$  es la salida esperada e  $\hat{y}(t)$  es la salida actual de la red.

$$E = \frac{1}{2} [y(t) - \hat{y}(t)]^2 \quad (11)$$

- c) *Eliminación de reglas*: Una vez creada la estructura de la red y ajustado sus parámetros, es necesario eliminar aquellas reglas que son redundantes, para ello se combinan dos o más reglas similares en una regla significativa. Para determinar la similitud de dos reglas, es necesario realizar un proceso de comparación multidimensional de los hiper-rectángulos. Sean  $[u_{ij}, v_{ij}]$  y  $[u_{ik}, v_{ik}]$  las esquinas de dos hiper-rectángulos  $J$  y  $K$  en la  $i$ -ésima dimensión. Si  $u_{ij} \leq u_{ik}$  y  $v_{ij} \geq v_{ik}$  para todas las dimensiones  $i = 1, 2, \dots, n$ . Entonces, el hiper-rectángulo  $J$  contiene al hiper-rectángulo  $K$ . Si se elimina el hiper-rectángulo  $K$  la función de membresía será más permisiva, en cambio, de eliminarse el hiper-rectángulo  $J$ , la función de membresía será más pequeña.

#### 4. Experimentos y Resultados

Debido a la naturaleza no lineal de los fenómenos de deslizamiento en masa y a las críticas que han obtenido las investigaciones anteriores, por no mostrar como los factores condicionantes interactúan entre sí se implementó la red neuronal FALCON-ART, usando el lenguaje de programación Java. Esta brinda los beneficios de una red neuronal y además genera un conjunto de reglas que revelan la interacción entre los factores condicionantes.

Para confirmar el buen funcionamiento de la red neuronal, se decidió repetir el experimento realizado en [TQ01], donde fue utilizada la base de datos *Iris Setosa*. El resultado, de este ensayo confirmó que la red se encuentra bien implementada, ya que los resultados fueron muy similares a [TQ01]. Un punto importante en este experimento es la naturaleza del conjunto de datos usados, ya que al igual que el problema de la estimación de susceptibilidad a deslizamientos en masa, estos datos no son linealmente separables.

Para la obtención de un modelo de susceptibilidad a deslizamientos en masa, se creó un conjunto de datos utilizando las siguientes variables derivados del MDE *aspect*,

*slope*, *indhuan* y *plang*, las cuales fueron usadas exitosamente en otras investigaciones [GK05, LYY01, Pin11, PVV10, CSAG10]. Además, basados en los resultados obtenido por [Pin11, PVV10], se decidió incorporar a este conjunto de datos la variable NDVI generada a partir de la ecuación 3.

Luego, a partir de los datos de cicatrices de deslizamiento del año 1992 (tabla 1) se utilizaron dos estrategias diferentes. Primero, se generó un conjunto de modelos a partir de los datos originales; pero sólo 379 de los 360.000 píxeles del MDE disponen de información sobre si hubo o no deslizamiento en masa. Por esto se decidió ampliar los datos para la segunda estrategia. Para ello, se le asignó el valor correspondiente a cada uno de esos 379 píxeles a los píxeles vecinos inmediatos. Es decir, cada uno de estos píxeles modificó a sus 8 píxeles vecinos, ampliando así el conjunto de datos a 3411 píxeles.

Para evaluar la capacidad predictiva de los modelos de susceptibilidad a deslizamientos en masa obtenidos para las dos estrategias, se utilizó al igual que en las investigaciones [LYY01, PVV10, CPSS08] la técnica de validación cruzada. Para ello, por cada uno de los experimentos, el conjunto de datos fue particionado aleatoriamente en 5 grupos y se calculó el error promedio de todos los píxeles mal clasificados, el error promedio de los píxeles mal clasificados que corresponden a deslizamiento en masa y el número promedio de píxeles no clasificados.

Posteriormente, para determinar cual combinación de los parámetros de la red neuronal FALCON-ART genera el mejor modelo de susceptibilidad a deslizamiento en masa, se decidió aplicar para ambas estrategias lo siguiente: el parámetro de selección ( $\alpha$ ) fue constante en todos los entrenamientos, este valor fue de 0,0001. Mientras que, el valor del parámetro de vigilancia ( $\rho$ ) fue variando gradualmente entre experimentos, esto con la intención de observar cómo se diferencian entre si los modelos con diferentes niveles de tolerancia a discordancia entre las categorías generadas. Los experimentos comenzaron con un  $\rho$  inicial de 0,5 con incrementos sucesivos de 0,02 hasta alcanzar un  $\rho$  máximo de 0,88. Los resultados de estos experimentos se pueden observar en las tablas 2 y 3; aunque en ellas se muestran sólo aquellos experimentos donde el porcentaje de error de los puntos susceptibles a deslizamientos en masa es menor a un 50%. Sin embargo, en las figuras 2 y 3 se puede detallar el comportamiento completo de estos experimentos por cada una de las estrategias aplicadas.

Para determinar cuál modelo es considerado el mejor por cada una de las estrategias bastó con localizar aquel que minimizara tanto el porcentaje de error de clasificación como el porcentaje de desaciertos de los puntos conocidos con deslizamiento en masa.


Al observar la tabla 2, se identifican los  $\rho$  que obtuvieron menor el porcentaje de error de clasificación de los puntos donde hubo un deslizamiento en masa, estos son: 0,52; 0,82; y 0,88. Sin embargo, al contrastar la figura 2 con la tabla 2, se observa, que cuando  $\rho$  es igual a 0,82 se genera el mejor modelo. Esto es debido a que, cuando el  $\rho$  es igual a 0,52 a pesar de tener un porcentaje de puntos de deslizamientos en masa mal clasificados similar al del modelo seleccionado y un porcentaje bajo de puntos sin clasificar, el porcentaje de error del modelo es mayor al 50%. En cambio, cuando

$\rho$	% error	% puntos no clasificados	% error en puntos con deslizamiento en masa
0,52	53,33%	9,33%	39,89%
0,58	45,33%	8%	41,53%
0,60	45,33%	9,33%	41,53%
0,64	40%	14,66%	44,81%
0,68	42,66%	16%	42,08%
0,78	34,66%	17,33%	45,90%
0,82	40%	18,66%	39,34%
0,88	29,33%	49,33%	31,69%

**Tabla 2:** Resultados de la ejecución del algoritmo FALCON-ART usando el conjunto de datos de la primera estrategia, variando el  $\rho$

$\rho$	% error	% puntos no clasificados	% error en puntos con deslizamiento en masa
0,50	46,33%	1,9%	48%
0,58	51,9%	1,61%	8%
0,60	51,9%	1,75%	20%
0,66	45,3%	3,95%	37%
0,68	40,02%	2,93%	26%
0,78	40,17%	6,59%	48%
0,84	37,53%	13,34%	42%
0,86	32,4 %	18,76%	28%
0,88	28,59%	23,6%	36%

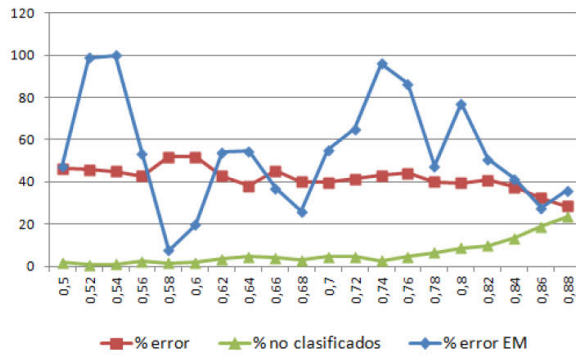
**Tabla 3:** Resultados de la ejecución del algoritmo FALCON-ART usando el conjunto de datos de la segunda estrategia, variando el  $\rho$



**Figura 2:** Comparación del porcentaje de error, porcentaje de puntos no clasificados y el porcentaje de error de los puntos con deslizamiento en masa, por cada uno de los modelos generados variando el  $\rho$  con el conjunto de datos de la primera estrategia.


$\rho$  es igual a 0,88 el porcentaje de error y el porcentaje de los puntos con deslizamiento en masa mal clasificados son





**Figura 3:** Comparación del porcentaje de error, porcentaje de puntos no clasificados y el porcentaje de error de los puntos con deslizamiento en masa, por cada uno de los modelos generados variando el  $\rho$  con el conjunto de datos de la segunda estrategia.

menores al del modelo seleccionado, pero el porcentaje de los puntos sin clasificar es mucho más elevado, por lo tanto, se deben descartar estos modelos. En la figura 4 se puede observar el mapa de susceptibilidad a deslizamiento en masa obtenido para cuando  $\rho$  es igual a 0,82.




**Figura 4:** Modelo de susceptibilidad a deslizamiento en masa, utilizando el conjunto de datos de la primera estrategia con variación del parámetro de vigilancia  $\rho = 0,82$

En el otro escenario, se realiza un análisis similar sobre la tabla 3 y el gráfico plasmado en la figura 3. En este caso, los mejores modelos se obtuvieron cuando  $\rho$  tiene los siguientes valores: 0,58; 0,60; 0,66; 0,68 y 0,86. Sin embargo, son descartados los modelos donde el porcentaje de error es mayor que el 50%. Finalmente, el modelo donde  $\rho$  es igual a 0,86 también es descartado, ya que el porcentaje de puntos sin clasificar es superior al modelo obtenido con  $\rho$  igual a 0,68, por lo tanto este último es el mejor modelo del segundo experimento. En la figura 5 se puede observar el mapa de susceptibilidad a deslizamiento en masa obtenido para cuando  $\rho$  es igual a 0,68.

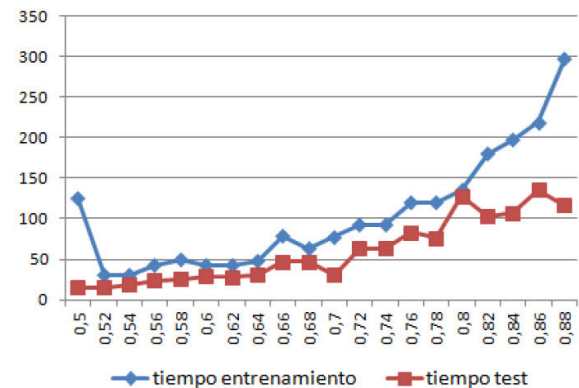
Como se puede observar en las tablas 2 y 3 fue un acierto ampliar el conjunto muestral con la función de vecindad, ya que disminuyó de manera considerable el porcentaje de error de los puntos correspondientes a deslizamientos en masa y al porcentaje de puntos no clasificados.

Se observa en la figura 6 que la ejecución del algoritmo FALCON-ART es considerablemente rápido, ya que, el tiempo más alto reportado durante el entrenamiento de la segunda estrategia fue de aproximadamente 300 milisegundos y el tiempo más alto de prueba fue de aproximadamente



**Figura 5:** Modelo de susceptibilidad a deslizamiento en masa, utilizando el conjunto de datos de la segunda estrategia con variación del parámetro de vigilancia  $\rho = 0,68$

130 milisegundos. Aunque, como también ilustra el gráfico de la figura 6 la variable  $\rho$  incide directamente en el tiempo de ejecución, es decir, entre más se aproxime a 1 más tiempo tardará en generar el modelo. Esto es debido, a que el modelo se vuelve cada vez menos tolerante a las pequeñas diferencias entre el vector de entrada y el prototipo esperado, por lo tanto se van creando más reglas para lograr la clasificación.



**Figura 6:** Tiempo de ejecución del entrenamiento y la prueba del algoritmo FALCON-ART, variando el  $\rho$ , con el conjunto de datos de la segunda estrategia

Finalmente, aunque los resultados iniciales obtenidos con FALCON-ART son prometedores, estos pueden ser mejorados si son transformados a un modelo continuo que prediga un índice de susceptibilidad del paisaje, para así poder apreciar la variabilidad de la susceptibilidad al deslizamiento en masa. Sin embargo, para ello sería necesario transformar la salida de la red neuronal FALCON-ART en un vector de membresía.

## 5. Conclusiones

Usando la red neuronal FALCON-ART se logró obtener un resultado inicial prometedor, donde se generó un modelo de susceptibilidad a deslizamiento en masa con un 74% de acierto en el área de estudio localizada en la cuenca del río Caramacate, estado Aragua. Para ello, el modelo generado consiguió una relación entre los factores condicionantes derivados de un MDE, imágenes satelitales y los puntos de cicatrices de deslizamiento del año 1992. Además se generaron un conjunto de reglas que permiten al experto poder comprender con mayor detalle como la interacción de los factores contribuyen a este fenómeno. Con esto, se propone



una solución a las críticas de la comunidad de científicos sobre el comportamiento de “caja cerrada” de las redes neuronales.

Sin embargo, estos resultados pueden ser mejorados, por lo que será necesario modificar el algoritmo de la red neuronal de FALCON-ART, para transformar la salida discreta de la red a una salida con membresía borrosa. El objetivo de este ajuste es lograr que la red pueda predecir un índice de susceptibilidad del paisaje, en vez de un valor binario (susceptible o no a deslizamiento en masa). Con esto se obtendrá un mapa donde se pueda apreciar la variabilidad de la susceptibilidad a los deslizamientos en masa a lo largo de un continuo.

Finalmente, se realizará un estudio incluyendo un conjunto de mapas de cicatrices de suelo de diversos años, lo que permitirá obtener un modelo más confiable de susceptibilidad a deslizamiento en masa en el área de estudio.

## 6. Agradecimientos

Los autores agradecen al proyecto LOCTI de la Facultad de Agronomía de la Universidad Central de Venezuela titulado “Sistema de información geográfica de la cuenca alta del río Guárico” y al Consejo de Desarrollo Científico y Humanístico de esa universidad, por su apoyo al desarrollo de esta investigación.

## Referencias

- [Ale08] ALEXANDER D.: A brief survey of gis in mass-movement studies, with reflections on theory and methods. *Geomorphology* 94 (2008), 261–267.
- [BM98] BURROUGH P., MCDONNELL R.: Principles of geographical information systems. *Oxford University Press* (1998), 333.
- [BTH00] BLASCHKE P., TRUSTRUM N., HICKS D.: Impacts of mass movement erosion on land productivity: a review. *Progress in Physical Geography* 24 (2000), 21–52.
- [CGR91] CARPENTER G., GROSSBERG S., ROSEN D.: Fuzzy art: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *IEEE transactions on Fuzzy System*. 4 (1991), 759–771.
- [CPSS08] CANIANI D., PASCALE S., SDAO F., SOLE A.: Neural networks and landslide susceptibility: A case study of the urban area of potenza. *Natural Hazards* 45 (2008), 55–72.
- [CSAG10] CHAUHAN S., SHARMA M., ARORA M., GUPTA N.: International journal of applied earth observation and geoinformation. *Natural Hazards* 12 (2010), 340–350.
- [ED00] ELIZALDE G., DAZA M.: Evaluación de amenazas de movimientos en masa en paisajes montañosos ejemplos en el estado vargas. *Venezuelos* 8 (2000).
- [ED03] ELIZALDE G., DAZA M.: Procedimiento para evaluar amenazas de movimientos en masa con información restringida en paisajes montañosos. *Revista. Facultad de Agronomía* 29 (2003), 197–208.
- [Fel94] FELICÍSIMO A.: *Modelos Digitales del Terreno. Introducción y aplicaciones en las ciencias ambientales*. Pentalfa ediciones, Oviedo, España., 1994.
- [GK05] GÓMEZ H., KAVZOGLU T.: Assessment of shallow landslide susceptibility using artificial neural networks in jaborosa river basin, venezuela. *Engineering Geology* 78 (2005), 11–27.
- [HJB11] HYUN-JOO O., BISWAJEET P.: Application of a neuro-fuzzy model to landslide-susceptibility mapping for shallow landslides in a tropical hilly area. *Computers Geosciences* 37 (2011), 1264–1276.
- [Jen61] JENNY H.: Derivation of state factor equation of soils and ecosystems. *Soil Science Society of America Proceedings* 25 (1961), 385–388.
- [LL91] LIN C., LEE C.: Neural-network-based fuzzy logic control and decision system. *IEEE Transactions on Computers* 40, 12 (1991), 1320–1336.
- [LL96] LIN C., LEE C.: *Neural fuzzy systems*. Prentice Hall, New Jersey, USA., 1996.
- [LL97] LIN C., LEE C.: An art-based fuzzy adaptive learning control network. *IEEE Transactions on Computers* 5, 4 (1997), 477–496.
- [LP06] LEE S., PRADHAN B.: Probabilistic landslide risk mapping at penang island, malaysia. *Journal of Earth System Sciences*. 115, 6 (2006), 661–672.
- [LYY01] LEE C., YE H., YEUNG M.: Aigis-based methodology for natural terrain landslide susceptibility mapping in hong kong. *Episodes*. 24 (2001), 150–159.
- [MMR08] MELCHIORRE C., MATTEUCCI M., REMONDO J.: Artificial neural networks and cluster analysis in landslide susceptibility zonation. *Geomorphology*. 94 (2008), 379–400.
- [MV04] MORALES A., VILORIA J.: *Clasificación borrosa de puntos del terreno y su relación con las propiedades de los suelos en la subcuenca del río Caramacate, estado Aragua*. Tech. rep., Facultad de Agronomía. Universidad Central de Venezuela., Maracay, Venezuela, 2004.
- [NS06] NANDI A., SHAKOOR S.: Preparation of a landslide susceptibility map of summit county, ohio, usa, using numerical models. In *Proceedings of the 10th Congress of the International Association of Engineering Geology and the Environment*. (Nottingham, United Kingdom., 2006), pp. 174–185.
- [Pin11] PINEDA M.: Evaluación de la susceptibilidad a movimientos en masa y erosión laminar en la cuenca del río caramacate, estado aragua. Trabajo de Ascenso. Universidad Central de Venezuela, Facultad de Agronomía, Instituto de Edafología. En elaboración., 2011.
- [PL10a] PRADHAN B., LEE S.: 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 (2010), 1037–1054.
- [PL10b] PRADHAN B., LEE S.: 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 Software*. 25, 6 (2010), 747–759.
- [Pér00] PÉREZ D.: Procesos geomorfo-fluviales asociados al evento catastrófico del estado vargas, venezuela. diciembre 1999. In *Multivariate En Geología y Geomorfología. Jornadas de Investigación. JIFI 2000. Segundo encuentro académico EAH-UCV*. (Universidad Central de Venezuela. Facultad de Ingeniería. Caracas, Venezuela., 2000).
- [PVV10] PINEDA M., VILORIA A., VILORIA J.: Assessment of susceptibility to mass erosion by logistic regression and bayesian networks in mountainous landscapes of north-central venezuela. In *College on soil physics in International Centre for Theoretical Physics (ICTP)*. (Trieste, Italia., 2010).
- [RG03] REICHENBACH P., GUZZETTI F.: Landslide risk assessment and mapping. *Natural Hazards and Earth Systems Sciences* 3 (2003), 403–486.
- [RHSD74] ROUSE J., HAAS R., SCHELL J., DEERING D.: *Monitoring vegetation systems in the Great Plains with ERTS*. Tech. rep., Goddard Space Flight Center, NASA SP-351, Science and Technical Information Office, NASA, Washington, D. C., 1974.
- [TQ01] TUNG W., QUEK C.: A novel approach to the derivation of fuzzy membership functions using the falcon-mart architecture. *Pattern Recognition Letters*. 22 (2001), 941–958.
- [Vil07] VILORIA A.: *Estimación de modelos de clasificación de paisaje y predicción de atributos de suelos a partir de imágenes satelitales y Modelos Digitales de Elevación*. Master's thesis, Facultad de Ciencias, Universidad Central de Venezuela, Caracas, Venezuela, 2007.