

PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE ESCUELA DE INGENIERIA

DESARROLLO DE UN MODELO DE RED NEURONAL PARA ESTIMAR LA TASA DE ENRIQUECIMIENTO DEL SEDIMENTO EN EVENTOS DE EROSIÓN HÍDRICA

HÉCTOR LEOPOLDO VENEGAS QUIÑONES

Tesis para optar al grado de Magister en Ciencias de la Ingeniería

Profesor Supervisor:

CARLOS BONILLA MELÉNDEZ

Santiago de Chile, (Noviembre, 2016) © MMXVI, Héctor Leopoldo Venegas Quiñones



PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE ESCUELA DE INGENIERIA

DESARROLLO DE UN MODELO DE RED NEURONAL PARA ESTIMAR LA TASA DE ENRIQUECIMIENTO DEL SEDIMENTO EN EVENTOS DE EROSIÓN HÍDRICA

HÉCTOR LEOPOLDO VENEGAS QUIÑONES

Tesis (Proyecto) presentada(o) a la Comisión integrada por los profesores:

CARLOS BONILLA MELÉNDEZ

RODRIGO CIENFUEGO CARRASCO

FELIPE ABURTO GUERRERO

CHRISTIAN DANI GUZMÁN

Para completar las exigencias del grado de Magister en Ciencias de la Ingeniería

Santiago de Chile, (Noviembre, 2016)

A mis padres, hermanas y amigos, que han sido la base de mi formación, aportando grandes cosas a mi vida. Les agradezco por todo.

AGRADECIMIENTOS

Le agradezco a Dios por haberme acompañado y guiado a lo largo de mi carrera, por ser mi fortaleza en los momentos de debilidad y por brindarme una vida llena de aprendizajes, experiencias y sobre todo felicidad.

A mi familia fuente de apoyo constante e incondicional en toda mi vida y más aún en mis duros años de carrera profesional y en especial quiero mi más grande agradecimiento a mi madre que sin su ayuda hubiera sido imposible culminar la presente etapa académica.

Además, debo agradecer al departamento de Ingeniería Hidráulica y Ambiental por el soporte y ayuda entregada en el proceso. Agradezco a mis compañeros por su profesionalismo y camaradería. Quiero agradecer a todos los profesores que me brindaron conocimientos y me ayudaron en mi desarrollo profesional y personal; particularmente al Dr. Carlos Bonilla al cual lo considero un excelente mentor y una meta personal a alcanzar por su excelencia académica y profesional.

INDICE GENERAL

Pág.

DED	ICATORIAiii
AGR	ADECIMIENTOSiv
INDI	CE DE TABLAS
RES	UMEN
ABS	TRACTix
1.	Introducción1
2.	Marco conceptual7
2.1	Redes neuronales7
2.2	Utilización de la tasa de enriquecimiento en modelos de simulación15
3.	Materiales y métodos
3.1	Construcción de la base de datos de tasas de enriquecimiento
3.2	Configuración de la red neuronal
3.3	Eficiencia del modelo
4.	Discusión y resultados25
4.1	Análisis base de datos
4.2	Evaluación de las variables explicativas del modelo
4.3	Modelo de red neuronal para estimar la tasa de enriquecimiento de superficie
	especifica
4.4	Modelo elaborado con la red neuronal
4.5	Evaluación del modelo de red neuronal
4.6	Evaluación de la ecuación de Menzel
5.	Conclusiones
BIBI	LIOGRAFÍA

INDICE DE TABLAS

Tabla 1.1: Datos y características de los recopilados por Menzel (1980) para el desarrollo de su ecuación.
Tabla 2.1: Ejemplo de ecuaciones utilizadas para determinar el número óptimo de nodos en una red neuronal. 10
Tabla 2.2: Método utilizado para estimar la tasa de enriquecimiento en diferentes modelos de simulación. 18
Tabla 3.1: Series de suelo utilizadas en el estudio. 22
Tabla 4.1: Resumen de la variabilidad observada en las propiedades de la base de datos27
Tabla 4.2: Coeficiente de determinación y Pearson asociado con respecto a cada variable y la tasa de enriquecimiento de superficie específica, mediante una regresión lineal y logarítmica
Tabla 4.3: Análisis de significancia de las variables que fueron utilizadas en la red neuronal para estimar la tasa de enriquecimiento de superficie específica
Tabla 4.4: Desempeño de las ecuaciones más utilizadas para estimar el número de nodos ocultos.
Tabla 4.5. Rangos utilizados para normalizar los datos de entrada del modelo de red neuronal
Tabla 4.6: Ecuación construida a través de la red neuronal para estimar la tasaenriquecimiento de superficie específica
Tabla 4.7. Selección aleatoria realizada con MATLAB. 40

INDICE DE FIGURAS

Figura 2.1: Esquema de la configuración de una red neuronal.	7
Figura 2.2: Esquema de una red neuronal	8

Figura 4.2: Eficiencia del modelo de red neuronal con respecto al aumento en la cantidad de nodos ocultos. Los círculos muestran el promedio del coeficiente de determinación (a) y de la raíz del error cuadrático medio (b); las barras de error indican la desviación estándar. Se realizaron 1.000 modelaciones por cada configuración, con un total de 20.000 modelaciones.

Figura 4.3: Eficiencia del modelo de red neuronal con ocho variables de entrada. Se muestra el conjunto de entrenamiento, de verificación, de validación y la totalidad de los datos....35

RESUMEN

La tasa de enriquecimiento, entendida como la relación entre la concentración de un elemento en el sedimento luego de ocurrido un evento de erosión hídrica y su concentración en la matriz del suelo, es un parámetro comúnmente utilizado para modelar el movimiento y destino de los agroquímicos. La medición de la tasa de enriquecimiento, especialmente de superficie específica, es un proceso complejo y requiere medir el tamaño y distribución de las partículas, tanto en el material erodado como en la matriz del suelo. Debido a ello el objetivo de este trabajo fue desarrollar un modelo de red neuronal para estimar la tasa de enriquecimiento y compararlo con el método actualmente más utilizado en base a datos experimentales medidos en estudios previos. Para el desarrollo de la red neuronal se utilizó el Neural Network Toolbox de MATLAB y los resultados de mediciones realizadas en seis estudios previos. La red así construida utiliza ocho variables que responden a las características de suelo, clima y topografía de la superficie del suelo. El modelo de red neuronal permitió obtener un alto nivel de precisión en las estimaciones (r²=0,99 y coeficiente N-S=0,99). Evaluada su eficiencia en relación a las mediciones de cada estudio previo por separado, los resultados muestran estimaciones con valores de r²=0,65-1,00 y N-S=0,56-1,00 para aquellos estudios que presentan 3 o más datos. Así, el modelo de red neuronal probó ser un método adecuado para estimar la tasa de enriquecimiento de superficie específica en eventos de este tipo. Finalmente, y dado que es una de las alternativas más utilizadas, se compararon las estimaciones del modelo de red con las estimaciones de enriquecimiento obtenidas con la ecuación de Menzel (1980) en 54 eventos. Los resultados indican que la ecuación de Menzel muestra una reducida capacidad predictiva ($r^2=0,10$ y N-S<-9,25). En este trabajo se describe la elaboración y validación de la red, y se entrega la información necesaria para su implementación en otros modelos de simulación de sedimentos y de transporte de contaminantes.

Palabras Claves: erosión hídrica, red neuronal, sedimento, tasa de enriquecimiento.

ABSTRACT

The relationship between the concentration of an element in the sediment and its concentration in the soil matrix is called enrichment ratio. This is a key parameter typically used to model the agrochemical movement and destination. Measuring the enrichment ratio -especially from a specific surface area- is a complex process and requires to know the size and distribution of particles in the eroded material and in the soil matrix. Because of this, the aim of this study was to develop a neural network model to estimate the enrichment ratio and evaluate it with the currently most widely used method based on experimental data from previous studies. The MATLAB's Neural Network Toolbox and actual experimental data from six previous studies were used to development of the neural network. The network uses eight variables that respond to the characteristics of soil, climate, and topography of the soil surface. The neural network model showed a high precision for the estimates ($r^2=0.99$ and N-S coefficient =0.99). When tested for each one of the previous studies with 3 or more data points, the results showed estimations with r^2 values from 0.65 to 1,00 and N-S from 0.56 to 1,00. Thus, the neural network model proved to be a suitable method for estimating the enrichment ratio of specific surfaces in such events. Finally, and since it is one of the alternatives most widely used, the estimations of the network model were compared with those obtained with the Menzel's equation in 54 events. The results indicated that the Menzel's equation shows a reduced predictive capacity ($r^2=0.10$ and N-S<-9.25). This study showed the development and validation of the neural network and provides the information necessary for its implementation in other models for sediment and pollutant transport.

Keywords: water erosion, neural network, sediment, enrichment ratio.

1. INTRODUCCIÓN

La tasa de enriquecimiento es la relación entre la concentración de un componente en el sedimento transportado (arcilla, limo, arena o agroquímicos) y la concentración del mismo componente en la matriz del suelo al final de un evento de erosión hídrica (Massey y Jackson, 1952; Menzel, 1980; Sharpley, 1980). En la misma línea diversos trabajos han estudiado la relación agroquímico-sedimento, cuantificando la cantidad de producto transportado en el sedimento durante un evento de erosión hídrica (Pionke y Chesters, 1973; Ghadiri y Rose, 1993; Palma et al., 2004; Nasrabadi, Bidhendi, Karbassi, Grathwohl y Mehrdadi, 2011; Rickson, 2014). En paralelo, se ha identificado la importancia del sedimento fino en el transporte de contaminantes (Walling y Collins, 2008), el cual al tener una alta superficie específica y densidad de cargas (arcilla, limo y materia orgánica), muestra un potencial de absorción mayor (Miller, Quinton, Barberis y Presta, 2009)

En particular el consumo de agroquímicos ha mostrado un aumento constante en la agricultura (Palis, Rose y Saffigna, 1997; Eurostat, 2007; Ramírez-Santana, Iglesias-Guerrero, Castillo-Riquelme y Scheepers, 2014). En el caso de Chile, sólo en el año 2012 se utilizaron 39 mil toneladas de agroquímicos en la agricultura y actividades forestales (SAG, 2012), aumentando el uso de agroquímicos en un 200% desde el año 2001 al 2012 (SAG, 2001; 2012). Debido a esto la tasa de enriquecimiento se ha convertido en un elemento común al momento de estimar el destino y concentración de estos contaminantes en el ambiente.

A nivel de terreno, los principales procesos que controlan el destino y transporte de un agroquímico son la absorción, degradación, volatilización, decaimiento, infiltración, evaporación, drenaje y escorrentía (Singh, Spencer, Van Genuchten y Kookana, 1992; Wauchope et al., 2002; Barra et al., 2005; Köhne, Köhne y Šimůnek, 2009). En el caso particular de la escorrentía, debido a la capacidad del suelo para absorber agroquímicos, los sedimentos erodados se convierten en un sumidero no deseado de productos químicos (Corwin y Farmer, 1984; Müller et al., 2000). En Chile, el 72% de la actividad agrícola se concentra en la zona central, un área altamente vulnerable a la erosión hídrica debido a la combinación de suelos, pendientes, climas y prácticas de manejo (Bonilla y Vidal, 2011; Bonilla y Johnson, 2012). Sobre lo mismo, es importante mencionar que en Chile el 49% de la superficie presenta algún grado de erosión (CIREN, 2010). Debido a lo anterior, se hace necesario estimar el transporte de agroquímicos durante los eventos de erosión hídrica para lo cual es indispensable el cálculo de la tasa de enriquecimiento.

Massey y Jackson (1952) fueron los primeros en formular una ecuación para estimar la tasa enriquecimiento de la materia orgánica, nitrógeno, fósforo y potasio en un evento de erosión hídrica, mediante el estudio de cuatro zonas, reportando que la tasa de enriquecimiento se incrementa cuando disminuye la magnitud del evento de erosión, con una correlación logarítmica negativa. En 1980, Menzel formuló una ecuación de regresión para la tasa de enriquecimiento del fósforo y nitrógeno, a través de datos obtenidos de diferentes suelos y climas, usando la siguiente ecuación:

$$\ln(ER) = a + b \cdot \ln(sed) \tag{1}$$

donde *a* y *b* son constantes de ajuste, y *sed* es la magnitud del evento de erosión (kg ha⁻¹). En esta relación los parámetros se encentran típicamente en los siguientes rangos: 1 < a < 3 y -0.3 < b < -0.1.

La ecuación de Menzel (1980) fue calibrada y validada a través de 13 diferentes usos de suelo, todos recopilados de distintos estudios (Tabla 1.1). Estos estudios se pueden dividir en dos grupos. El primer grupo está conformado por seis estudios que tienen más de 20 eventos de tormenta y con un rango mínimo de 100 kg ha⁻¹ de descarga de sedimentos por evento. Este grupo fue considerado como el más confiable para determinar los valores de las constantes de ajuste, permitiendo que la ecuación puede ser utilizada en un amplio espectro de condiciones de suelo y vegetación. El segundo grupo está conformado por los estudios restantes, que fueron utilizados únicamente para evidenciar la eficiencia de la ecuación formulada por Menzel. La investigación reportó que con pocas

excepciones, la relación entre enriquecimiento y magnitud del evento desarrollada por Massey y Jackson (1952) fue adecuada.

Uso de suelo	Estado	Textura	Eventos	Erosión por evento (kg ha ⁻¹)) Nutriente a b r		Correlación *		
Maíz o Soja	Michigan	Arenoso franco	115	0,7-400	Nitrógeno	1,42	-0,02	0,19	Negativa
					Fósforo	1,3	-0,01	0,05	Negativa
Maíz contorneado	Georgia	Franco arenoso	32	0,3-700	Nitrógeno	2,84	-0,34	0,56	Negativa
					Fósforo	2,42	-0,18	0,5	Negativa
Maíz, avena o heno	Wisconsin	Franco limoso	177	5-7500	Nitrógeno	2,22	-0,25	0,77	Negativa
					Fósforo	1,01	-0,05	0,2	Negativa
Algodón	Oklahoma	Franco limoso	137	0,6-1300	Nitrógeno	1,85	-0,2	0,67	Negativa
0					Fósforo	1,57	-0,13	0,5	Negativa
Trigo	Oklahoma	Franco limoso	121	0,5-600	Nitrógeno	2,95	-0,44	0,72	Negativa
C					Fósforo	2,4	-0,33	0,69	Negativa
Range,	Oklahoma	Franco limoso	236	0,4-1500	Nitrógeno	1,5	-0,28	0,78	Negativa
Chickasha					Fósforo	2,32	-0,26	0,64	Negativa
Maíz adosado	Georgia	Franco arenoso	23	2-300	Nitrógeno	1,56	-0,1	0,2	Negativa
	-				Fósforo	1,11	0,1	0,31	Positiva
Sorgo	Texas	Arcilla	11	50-800	Nitrógeno	1,84	-0,16	0,43	Negativa
					Fósforo	3,12	-0,42	0,68	Negativa
Range, El Reno	Oklahoma	Franco limoso	14	2-200	Nitrógeno	2,67	-0,46	0,88	Negativa
					Fósforo	2,98	-0,64	0,93	Negativa
Range, Woodward	Oklahoma	Franco	13	5-500	Nitrógeno	1,81	-0,25	0,25	Negativa
-					Fósforo	0,82	-0,06	0,19	Negativa
Suelo de cultivo	Missouri	Franco y Franco	17	50-5000	Nitrógeno	-	-	-	Negativa
y bosque		arcilloso			Fósforo	1,4	-0,13	0,54	Negativa
Quemado de	California	Franco arcillo arenoso	5	200-5000	Nitrógeno	1,34	-0,14	0,77	Negativa
Chaparral					Fósforo	0,12	-0,02	0,22	Negativa
Residuos de maíz	Indiana	Franco limoso	8	500-25000	Nitrógeno	1,46	-0,13	0,7	Negativa
					Fósforo	1,9	-0,19	0,79	Negativa
Labranza	New York	-	43	60-1800	Nitrógeno	-0,25	0,11	0,58	Positiva
					Fósforo	-0,64	0,16	0,6	Positiva

Tabla 1.1: Datos y características de los recopilados por Menzel (1980) para el desarrollo de su ecuación.

* Correlación logarítmica (+ o -) de la tasa de enriquecimiento con respecto al aumento de la magnitud del evento de erosión.

Sin embargo, la excepción a la relación anterior se origina cuando el suelo no tiene cubierta vegetal (suelo desnudo), condición en la cual existe una correlación logarítmica positiva entre la magnitud del evento de erosión y el enriquecimiento. Dado lo anterior, esta investigación se basa en la hipótesis de que es posible desarrollar una ecuación a partir de redes neuronales para estimar la tasa de enriquecimiento de superficie específica en eventos de erosión hídrica en base a parámetros de fácil medición. Esto con el fin de estimar adecuadamente las tasas de enriquecimiento del sedimento bajo distintas condiciones de suelo, clima y topografía. El objetivo general de este estudio fue desarrollar una red neuronal para estimar con mayor precisión la tasa de enriquecimiento de superficie específica específica del sedimento. Con este propósito se establecieron los siguientes objetivos específicos:

a) Revisar e identificar las ecuaciones que actualmente se utilizan en modelos de transporte de agroquímicos para estimar la tasa de enriquecimiento.

b) Elaborar una base de datos de la tasa de enriquecimiento de superficie específica a través de la recopilación de datos reportados en estudios previos.

c) Evaluar la precisión de las ecuaciones que actualmente se utilizan para estimar el enriquecimiento del sedimento.

d) Formular y validar una ecuación para estimar la tasa de enriquecimiento de superficie específica mediante el uso de redes neuronales y la base de datos recopilada.

En el desarrollo de esta investigación la primera etapa consistió en la elaboración de una base de datos de tasas de enriquecimiento en eventos de erosión. Se identificaron seis artículos científicos que reportan la composición y distribución de las partículas en el sedimento erodado y en la matriz del suelo asociado a las características de suelo, clima y topografía. Así se recopilaron 54 eventos de erosión hídrica y su correspondiente tasa de enriquecimiento de superficie específica. Con los datos recopilados se construyó una red neuronal para estimar el enriquecimiento de superficie específica y se evaluó su precisión y la de la ecuación de Menzel, actualmente la más utilizada para estimar la tasa de enriquecimiento.

Los resultados de este trabajo demuestran que el modelo de red neuronal desarrollado emplea ocho variables que responden a las características de suelo, clima y topografía del lugar, estimando el enriquecimiento de la superficie específica con una alta eficiencia. Los resultados obtenidos evidencian que el modelo elaborado con la red neuronal logra explicar la variabilidad de la tasa de enriquecimiento de superficie específica. Por otra parte, la ecuación de Menzel que ha sido acoplada a modelos del transporte de agroquímicos no fue capaz de estimar el enriquecimiento en suelos sin cubierta vegetal, principalmente debido a que está conformada por una sola variable la cual no permite representar adecuadamente la variabilidad del enriquecimiento.

A partir de este trabajo es posible concluir que la ecuación más utilizada para estimar el enriquecimiento se ha ocupado de ampliamente sin considerar el uso y manejo del suelo generando valores posiblemente erróneos. Sin embargo, con el uso de redes neuronales fue posible desarrollar una ecuación para estimar la tasa de enriquecimiento de superficie específica, la cual está conformada por ocho variables que representan las características de suelo, topografía y clima de la zona, y estimar la tasa de enriquecimiento con una precisión mayor.

2. MARCO CONCEPTUAL

2.1 Redes neuronales

La definición más simple de una red neuronal es la propuesta por el inventor de uno de los primeros neuro-ordenadores, Dr. Robert Hecht-Nielsen, quien la define como un sistema informático compuesto por un número de elementos de procesamientos simples, altamente interconectados, y cuyo proceso de información es en respuesta al estado dinámico de los valores de entrada (Caudill, 1987). La red neuronal consiste en tres elementos: a) la capa de entrada, donde los nodos reciben la información de los valores de entrada; b) la capa oculta, donde los nodos formulan la mejor correlación entre los valores de entrada y salida y procesan la información; y, c) la capa de salida, donde se presentan los resultados. Cada capa está conformada por uno o más nodos representados en la Figura 2.1 mediante círculos. Las líneas entre los nodos indican el flujo de información de un nodo a otro (Schweller y Plagman, 1989; Howard et al., 1998; Demuth, 2006).



Figura 2.1: Esquema de la configuración de una red neuronal.

Hoy en día las redes neuronales pueden ser configuradas para resolver problemas que son difíciles para los ordenadores convencionales o seres humanos (Schmidhuber, 2015). Si bien su origen se remonta a seis décadas atrás, sólo se ha aplicado a problemas de investigación en los últimos 25 años, y se aprecia como el campo de las redes neuronales se va desarrollando rápidamente (Howard, Mark y Martin, 1998).

Existen diversos tipos de redes neuronales y la diferencia en ellas radica en la configuración de la misma y cómo aborda y procesa los valores de entrada para obtener la mejor correlación entre los datos representados (Widrow y Lehr, 1990). Comúnmente la configuración de una red neuronal consiste en que cada nodo de la capa oculta procesa los datos de entrada normalizados y multiplicados por una constante de peso mediante una función (sigmoidea, tangente hiperbólica, polinomial, o gaussiana). Posteriormente se adiciona una constante base para estabilizar el resultado. Finalmente se realiza una sumatoria de los resultados obtenidos por cada nodo de la última capa oculta (Figura 2.2) e inicia su mecanismo de aprendizaje mediante la retro-propagación, minimizando el error cuadrático mediante el ajuste de los pesos y bases. Es necesario poseer datos de entrada y salida medidos para generar una regresión entre ellos por medio de una red neuronal (Caudill, 1987; Howard et al., 1998).



Figura 2.2: Esquema de una red neuronal. Los términos a_i y b_i son las variables de entrada correspondiente al primer y segundo nodo, respectivamente, w_{ij} es el peso de ajuste del primer nodo de la capa de entrada (a_i) , \sum es la sumatoria de todos los valores entregados por los nodos, \int es la función de procesamiento de datos, a_j es el resultado de la función de procesamiento, w_{jk} es el peso de ajuste del primer nodo de la capa oculta, a_k es el valor

estimado por el modelo que fue calculado por la sumatoria de todos los valores entregados por cada nodo de la capa oculta.

El mecanismo de aprendizaje de la red neuronal consiste en dividir la totalidad de los datos en tres conjuntos de forma aleatoria atendiendo a que cada uno de ellos mantenga la representatividad de la población original. El primer conjunto, denominado de entrenamiento (training set), es utilizado para ajustar las constantes de pesos y base con el propósito de desarrollar un modelo que prediga los valores de salida. El segundo conjunto denominado de verificación (validation set), es utilizado para realizar una validación cruzada determinando cuándo se debe detener el proceso de entrenamiento. Cabe mencionar, que el ajuste de las constantes de peso y base en el proceso de entrenamiento finaliza cuando el modelo elaborado con la red neuronal logra una eficiencia satisfactoria en el conjunto de entrenamiento, utilizando como análisis estadístico el error cuadrático. El tercer conjunto, denominado de validación (test set), también se utiliza para evaluar el desempeño del modelo elaborado con la red neuronal pero por un conjunto independiente al ajuste. No existe una regla para determinar la división de la base de datos pero se recomienda utilizar el 70% en el conjunto de entrenamiento, 15% en el conjunto de verificación y 15% en el conjunto de validación (Howard et al., 1998).

Uno de los principales problemas de la red neuronal es la definición de su configuración, precisando el porcentaje de cada conjunto (entrenamiento, verificación y validación), el número de capas ocultas y de nodos (Howard et al., 1998). Entre más extensa es la arquitectura de una red neuronal, mejor es la solución a problemas complejos, pero esto puede estar asociado a un lento procesamiento de datos, ocasionando problemas de divergencia, o la generación de un sobreajuste que impide estimar con precisión nuevos valores (Onoda, 1995; Sheela y Deepa, 2013). Es importante mencionar que no existe una técnica estandarizada para determinar el número de capas ocultas y de nodos que se deben integrar a una red neuronal (Zhang, Patuwo y Michael, 1998). Sin embargo, se ha abordado este tema en diferentes investigaciones (Robert Hecht-Nielsen, 1987; Masters, 1993; Lachtermacher y Fuller, 1995; Jadid y Fairbairn, 1996; Hunter et

al., 2012; Sheela y Deepa, 2013). Se considera que configurar una red neuronal con una única capa oculta resulta suficiente para resolver problemas complejos; no obstante, para definir el número óptimo de nodos en la capa oculta existen diferentes métodos (Hecht-Nielsen, 1987; Lippmann, 1987; Stathakis, 2009). Primeramente, el método de prueba y error es habitual entre los investigadores consistiendo en la evaluación del desempeño de la red neuronal mediante el aumento o disminución paulatino de nodos (Kalogirou, 2001; Kalteh, 2013; Wang, Zeng y Chen, 2015). Además, existen fórmulas desarrolladas por investigadores para estimar el número óptimo de nodos de una red neuronal, plasmadas en la Tabla 2.1. Sin embargo es importante indicar que no existe un método preferente para definir el número de nodos en una red neuronal, y la decisión dependerá finalmente del investigador (Kalogirou, 2001; Sheela y Deepa, 2013).

en una reu neuronai.	
Referencia	Ecuación para estimar el número de nodos
Sheela y Deepa (2013)	$N_t = (V_e + \sqrt{D_e}) / L$
Sheela y Deepa (2013)	$N_t = V_e + V_s + 0.5$
Hunter et al. (2012)	$N_t = V_e + 1$
Jadid y Fairbairn (1996)	$N_{t} = D_{t} / \left[R \cdot \left(V_{e} + V_{s} \right) \right]$
Lachtermacher y Fuller (1995)	$0,11 \cdot D_t \le N_t \cdot (V_e + 1) \le 0,3 \cdot D_t$

Masters (1993)

Hecht-Nielsen (1987)

Tabla 2.1: Ejemplo de ecuaciones utilizadas para determinar el número óptimo de nodos en una red neuronal.

donde N_t es el número de nodos en la capa oculta, D_t es el número de datos de entrada a procesar, R es una constante de ajuste con un rango entre 5 y 10, V_e es la cantidad de variables de entrada, V_s es la cantidad de variables de salida, D_e es la cantidad de datos de las variables de entrada y L es el número de capas ocultas en la red neuronal.

 $N_t \approx (V_e \cdot V_s)^{0.5}$

 $N_t = (2 \cdot V_e + 1)$

Un aspecto singular y característico de las redes neuronales es la capacidad de aprendizaje a través de los resultados preliminares para determinar el mejor ajuste entre los valores de entrada y salida. El algoritmo de retro-propagación del error (*back-propagation error*) radica en la minimización del error a través del método del gradiente

del descenso, el cual fue elaborado por Rumelhart, Hinton y Williams (1986), muy utilizado en las redes neuronales (Schmidhuber, 2015). La retro-propagación consiste en propagar el error generado al seleccionar los pesos y bases en primera instancia de forma aleatoria hacia atrás, a través de la red neuronal comenzando desde la capa de salida y finalizando en la capa de entrada, con la finalidad de recalibrar los pesos y bases en función de la minimización del error cuadrático (Law, 2000). Cuando la red neuronal logra un error cuadrático definido previamente en su configuración, se termina el proceso de retro-propagación (Howard et al., 1998).

Como se ha indicado en el párrafo anterior y empleando como apoyo la Figura 2.2, el objetivo de la retro-propagación es reducir el error total del conjunto de entrenamiento a través del ajuste de los pesos y bases, mediante el uso de la función del error cuadrático:

$$E = \frac{1}{2} \sum (a_k - t_k)^2$$
 (2)

donde *E* es el error total, t_k es el valor medido, y a_k es el valor estimado por el modelo de la red neuronal. Posteriormente se debe aplicar la derivada parcial del error total con respecto al peso o la base que se quiera ajustar, en este caso el peso seleccionado es w_{jk} , como se muestra en la siguiente ecuación:

$$\frac{\partial E}{\partial w_{jk}} = \frac{1}{2} \cdot \sum (a_k - t_k)^2 = (a_k - t_k) \cdot \frac{\partial}{\partial w_{jk}} (a_k - t_k)$$
(3)

donde w_{jk} es el peso o la base que se quiere ajustar. Finalmente, se actualiza el peso o base a través del gradiente del error y la tasa de aprendizaje, la cual es una constate entre 0 y 1, usando la siguiente relación:

$$w_{jk}^{+} = w_{jk} - \alpha \cdot \frac{\partial E}{\partial w_{jk}}$$
(4)

donde w^+_{jk} es el nuevo peso o base (actualizado), y α es la tasa de aprendizaje. Cada vez que la red neuronal actualiza sus pesos o bases mediante la retro-programación, se define como época. Por cada época realizada se formula la mejor correlación entre los valores de entrada y salida (Rumelhart et al., 1986; Law, 2000).

Cada vez existen más estudios que incorporan la utilización de las redes neuronales por su eficiencia para resolver problemas complejos, debido a que al incorporar más variables de entrada su eficiencia aumenta (Scardi y Harding, 1999). A causa de esto, el método es criticado y llamado "caja negra" por no detallar o cuantificar la interrelación entre las variables, y por lo tanto, no se permitiría entender completamente la contribución individual de cada variable en el modelo de la red neuronal (Özesmi y Özesmi, 1999). Ante este problema, Olden y Jackson (2002) desarrollaron una metodología para analizar estadísticamente la importancia de cada variable proporcionando una técnica objetiva para la eliminación de las variables que tienen una influencia irrelevantes sobre los valores de salida de la red neuronal.

Las redes neuronales han sido aplicadas en distintas áreas de investigación, sistema de reconocimiento de imágenes y audio en el campo de la robótica (Singh, Yadav, Verma y Yadav, 2010; Hinton et al., 2012; Shrivastava, 2012; H. Liu y Zhang, 2013;), análisis de variables en el campo de la medicina (Baxt, 1991; Lisboa, 2002; Al-Shayea, 2011), en el campo financiero y económico (Kaastra y Boyd, 1996; Abdullah y Ganapathy, 2000; Bodyanskiy y Popov, 2006) y en el campo climatológico (Mubiru, 2008; Lee, 2009; Yadav y Chandel, 2014). Independiente del área, los investigadores han concluido que se logran resultados satisfactorios al utilizar las redes neuronales. Así mismo se han aplicado las redes neuronales en investigaciones relacionadas con la ciencia del suelo para estimar y tener un mejor entendimiento de distintas variables, por ejemplo, la humedad y salinidad del suelo (Liu, Chen, Wu y Peng, 2007; Chai et al., 2009; Dai, Huo y Wang, 2011), la magnitud del evento de erosión por escorrentía superficial (Licznar y Nearing, 2003; Kim y Gilley, 2008; de Farias y Santos, 2014; Hassan et al., 2015), la concentración de nutrientes en un evento lluvia-escorrentía-erosión (Kim y Gilley, 2008; Kim, Loucks y Stedinger, 2012; Keshavarzi, Sarmadian, Omran y Iqbal, 2015), transporte y destino de

agroquímicos hacia las aguas subterráneas (Sahoo, Ray y Wade, 2005; Sahoo, Ray, Mehnert y Keefer, 2006) o la estimación de su tiempo de residencia en el suelo (Domine, Devillers, Chastrette y Karcher, 1993), demostrando su efectividad ante variables del medio ambiente. Un estudio a destacar es el realizado por los investigadores Singh, Imtiyaz, Isaac y Denis (2012) que tuvo la finalidad de comparar la eficiencia para cuantificar la erosión hídrica entre un modelo predictivo y la red neuronal, reportando que se obtienen mejores resultados para estimar eventos de erosión al utilizar las redes neuronales y siendo más eficiente al necesitar menos cantidad de variables de entrada. En paralelo se han repetido los análisis para evaluar la eficiencia de la red neuronal en comparación con modelos predictivos o ecuaciones matemáticas comúnmente utilizadas por investigadores, reportando una satisfactoria eficiencia al utilizar las redes neuronales (Sarangi y Bhattacharya, 2005; Merdun, Çınar, Meral y Apan, 2006; Hasanpour Kashani, Ghorbani, Dinpashoh y Shahmorad, 2014). Actualmente, no se ha abordado el tema de la aplicación de redes neuronales para estimar la tasa de enriquecimiento del sedimento en eventos de erosión hídrica.

Existen programas computacionales que tienen incorporado rutinas con las metodologías y ecuaciones necesarias para el desarrollo de redes neuronales. Uno de esos ejemplos es MATLAB, software de programación de alto nivel y entorno interactivo utilizado por ingenieros y científicos que permite resolver matrices, desarrollar y ejecutar algoritmos, crear de interfaces de usuario y visualizar datos (Hunt, Lipsman y Rosenberg, 2014). Además, tiene acoplado una herramienta de redes neuronales, Neural Network Toolbox (Howard et al., 1998) que proporciona funciones y aplicaciones para el modelamiento de sistemas complejos no lineales que son difíciles de resolver, empleado para el ajuste, reconocimiento de patrones y agrupación de datos.

A continuación se describe el funcionamiento de la herramienta Neural Network Toolbox de MATLAB. Como primer paso MATLAB normaliza los valores de entrada y salida para aumentar la eficiencia de la red neuronal (Jayalakshmi y Santhakumaran, 2011). Existen dos tipos de rangos de normalización característicos dependiendo de lo que se quiera modelar. Si los valores de entrada o salida son binarios (sólo dos posibles valores) el rango de normalización es 0 y 1. Si lo valores de entrada o salida son datos numéricos de diferentes magnitudes el rango de normalización es de -1 a 1 utilizando la siguiente ecuación (Howard et al., 1998):

$$y = \frac{(y_{\max} - y_{\min}) \cdot (x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min}$$
(5)

donde y representa el dato normalizado, y_{max} e y_{min} es el rango de valores máximos y mínimos de la normalización (1 y -1), respectivamente, x representa el dato a normalizar, x_{max} y x_{min} es el valor máximo y mínimo de los datos a normalizar, respectivamente.

Luego se debe definir la segregación de la base de datos categorizándola en los diferentes conjuntos (entrenamiento, verificación y validación). Aunque se específica la división de la base de datos, la selección de datos para cada conjunto es aleatoria (Demuth, 2006). Posteriormente, se indica el número de capas ocultas, número de nodos y la función de procesamiento de datos. Luego, se debe definir el objetivo de la retro-propagación, consistiendo en realizar un número determinado de épocas o lograr un error cuadrático medio aceptable para el modelador (Howard et al., 1998). Finalmente, los valores de salida estimados se deben des-normalizar utilizando la siguiente ecuación:

$$t = \frac{(z_{\max} - z_{\min}) \cdot (u - u_{\min})}{(u_{\max} - u_{\min})} + z_{\min}$$
(6)

donde *t* representa el dato des-normalizado, z_{max} e z_{min} es el rango de valores máximos y mínimos de la variable de salida sin normalizar, respectivamente, *u* representa el dato normalizado, u_{max} y u_{min} es el valor máximo y mínimo de los datos normalizados, respectivamente.

2.2 Utilización de la tasa de enriquecimiento en modelos de simulación

Identificar el destino y concentración de los agroquímicos mediante la obtención de muestras en terreno y análisis químico tiene un valor económico elevado, lo cual limita la cantidad de muestras que habitualmente se pueden analizar. A causa de esto se han desarrollado diversas herramientas de simulación y modelos matemáticos, tanto para determinar la ocurrencia de estos fenómenos de contaminación como también para reducir los efectos negativos en el ambiente. Estos modelo proporcionan un método rápido y asequible para estimar las pérdidas que son difíciles de medir en condiciones de terreno, siendo una aproximación matemática a la ocurrencia de eventos complejos (Borah, Bera y Shaw, 2003; Siimes y Kämäri, 2003). Estos modelos permiten integrar simultáneamente procesos físicos, químicos y biológicos que afectan el movimiento y arrastre de agroquímicos (Singh et al., 1992). Así, los modelos predictivos más empleados han sido Groundwater Loading Effects of Agricultural Management Systems GLEAMS (Knisel, Leonard y Davis, 1989), Chemical Runoff and Erosion from Agricultural Management Systems CREAMS (Knisel, 1980), Environmental Policy Integrated Climate Model EPIC (Williams, 1995), Agricultural Policy/Environmental eXtender Model APEX (Williams y Izaurralde, 2006), Opus (Smith, 1992), Soil and Water Assessment Tool SWAT (Neitsch, Arnold, Srinivasan y Grassland, 2002) y Pesticide Root Zone Model PRZM (Suárez, 2005). Una característica común de los modelos de simulación antes mencionados es la utilización de la misma ecuación para cuantificar la cantidad de agroquímico (pesticidas, herbicidas, fósforo o nitrógeno) en el material erodado. Para ello se calcula el producto de la magnitud del evento de erosión por la concentración del agroquímico en la matriz del suelo y la tasa de enriquecimiento:

$$ASED = A \cdot Cs \cdot ER \tag{7}$$

donde *ASED* es la cantidad de agroquímico en el sedimento erodado en un evento de erosión hídrica (t ha⁻¹), A es la magnitud del evento de erosión (t ha⁻¹), Cs es la

concentración del agroquímico en la matriz del suelo antes del evento de escurrimiento (g g^{-1}) y *ER* es la tasa de enriquecimiento (g g^{-1}). Existen dos formas para definir y calcular la tasa de enriquecimiento, una de ellas es la relación entre la concentración del componente de interés en el sedimento erodado y en la matriz del suelo. Menzel (1980) formuló una ecuación empírica para estimar la tasa de enriquecimiento de nitrógeno y fósforo basada en muestreos de terreno y en la recopilación de datos de estudios realizados por otros investigadores. El autor así reportó una correlación logarítmica negativa o positiva entre la magnitud del evento de erosión y la tasa de enriquecimiento, siendo citado por diversos estudios y modelos predictivos del transporte de agroquímicos. Algunos modelos como CREAMS, EPIC, APEX y SWAT incorporan la relación reportada por Menzel para estimar el enriquecimiento de agroquímicos. Esto se debe a que el nitrógeno partículado se asocia principalmente a los materiales orgánicos más ligeros, y el fósforo partículado se asocia esencialmente con los minerales pesados (Smith, Sharpley y Ahuja, 1993). Es decir, el enriquecimiento del nitrógeno y fósforo son indicadores que reflejan la magnitud de adherencia de los agroquímicos a las partículas del sedimento erodado.

La segunda forma de estimar el enriquecimiento es mediante la relación entre la superficie específica del sedimento erodado y la de la matriz del suelo (Knisel et al., 1989). Esto permite una mejor estimación del transporte de agroquímicos dado que a mayor superficie específica mayor es el potencial de adsorción del suelo (Miller et al., 2009; Papanicolaou et al., 2015). Los modelos GLEAMS, EPIC, APEX y Opus utilizan como base las ecuaciones formuladas por Foster, Young y Neibling (1985) para calcular la superficie específica del sedimento erodado y así estimar la tasa de enriquecimiento de superficie específica. Desafortunadamente este es un proceso arduo debido a que se utilizan parámetros difíciles de medir, tales como la depositación del sedimento, la erosión en el reguero y el entre-reguero, el esfuerzo de corte del fluido, el coeficiente de transporte del sedimento, y la escorrentía máxima (Flanagan y Nearing, 1995). Además, los modelos esquematizan una ladera como un conjunto de nodos resolviendo las ecuaciones nodo a nodo hasta el final de la misma (Leonard, Knisel y Still, 1987). Por ello es un método más

complejo y difícil de utilizar. En la Tabla 2.2 se muestra cada uno de los modelos mencionados asociados a la forma en la cual estiman el enriquecimiento.

Modelo	Tipo	Escala espacial	Escala temporal	Ecuación para estimar la ER	Referencia
APEX *	Físico	Cuenca	Continuo	Foster et al., 1985	Williams y Izaurralde, 2006
CREAMS	Físico	Parcela	Evento/continuo	$\ln(ER) = a + b \cdot \ln(sed)$	Knisel, 1980
EPIC *	Físico	Ladera	Continuo	$ER = be \cdot CY^{bi}$ $be = 1 \cdot 0.1^{-bi}$ $bi = \log(DR) / 2,699$	Williams, 1995
GLEAMS	Físico	Parcela	Evento/continuo	Foster et al., 1985	Knisel et al., 1989
Opus	Físico	Parcela	Evento/continuo	Foster et al., 1985	Smith, 1992
PRZM	Conceptual	Parcela	Evento	$\ln(ER) = 2 - 0.2 \ln(X_e / A_e)$	Suárez, 2005
SWAT	Conceptual	Cuenca	Continuo	$ER = se \cdot conc^{si}$ $conc = sedt / (10 \cdot area \cdot Q)$	Neitsch et al., 2002

Tabla 2.2: Método utilizado para estimar la tasa de enriquecimiento en diferentes modelos de simulación.

* EPIC y APEX pueden estimar la tasa enriquecimiento de masa y la de superficie específica. El usuario modelador debe definir cuál es de su interés.

donde *CY* es la concentración en el sedimento (g m⁻³), *DR* es la razón de entrega de sedimentos (cociente entre la producción de sedimento y la erosión total del evento); X_e es la magnitud del evento de erosión (ton) y A_w es el área aportante (cm²); *conc* es la concentración de sedimentos en la escorrentía superficial (mg sed/m³), *sedt* es la magnitud del evento de erosión (ton), *area* es la superficie de la cuenca a modelar (ha), *Q* es la magnitud de la escorrentía (mm), y *se* y *si* son constantes de ajuste que varían dependiendo del componente de interés (fósforo mineral y orgánico, nitrógeno orgánico o pesticidas) que se quiera modelar.

Un punto a destacar en lo reportado por Menzel es la correlación logarítmica positiva o negativa entre la magnitud del evento de erosión y la tasa de enriquecimiento, la cual depende del uso y cobertura de suelo (Tabla 1.1). Esto demuestra que en suelos con algún tipo de manejo o cubierta vegetal predomina una correlación logarítmica negativa, en tanto en suelos sin cubierta vegetal se reportó una correlación logarítmica positiva (Menzel, 1980). Lo cierto es que dicha diferencia es relevante debido a que se ha ocupado ampliamente la Ecuación (1) para diversas condiciones de uso y cobertura de suelo sin tomar en cuenta que en suelos descubiertos o en un proceso de laboreo la composición y distribución de partículas en el sedimento responde de diferente forma (Karchegani, Ayoubi, Mosaddeghi y Honarjoo, 2012; Parras-Alcántara, Martín-Carrillo y Lozano-García, 2013). Esto genera que finalmente se sobreestime la cantidad de agroquímicos en el sedimento erodado (Figura 2.3). Desafortunadamente, la mayoría de las formas para estimar la tasa de enriquecimiento se basan en ecuaciones empíricas, generando poco interés en comprender los mecanismos que controlan el desplazamiento de las partículas (Lane, 1983) pero modelos predictivos más complejos han ido incorporando ecuaciones con base física logrando estimar el transporte y destino de las partículas ante diferentes condiciones de suelo, clima, topografía, de manejo y cobertura del suelo (Merritt, Letcher y Jakeman, 2003; Aksoy y Kavvas, 2005). Cabe destacar que Sharpley (1985) reportó una estrecha correlación lineal ($r^2 > 0.74$) entre la tasa de enriquecimiento de nutrientes y la tasa de enriquecimiento de superficie específica.



Figura 2.3: Relación entre la tasa de enriquecimiento de masa de fósforo y nitrógeno con respecto a la magnitud del evento de erosión en suelos sin cubierta vegetal (línea continua) y con cubierta vegetal (línea discontinua). Relaciones extraídas de Menzel (1980).

3. MATERIALES Y MÉTODOS

3.1 Construcción de la base de datos de tasas de enriquecimiento

Basado en una revisión bibliográfica se identificaron seis artículos científicos que reportan la distribución y composición de partículas en el sedimento erodado y la matriz del suelo por cada evento de erosión hídrica (Ben-Hur, 2004; Leguédois y Le Bissonnais, 2004; Miller et al., 2009; Kuhn, 2007; Defersha y Melesse, 2012; Tuo, Xu, Zhao y Gao, 2015). Todos los artículos recopilados miden la erosión a través de simuladores de lluvia y mesas de simulación con suelos sin cubierta vegetal. Las características de suelo son variadas dependiendo de la ubicación geográfica de la zona de estudio; y las características topográficas y de la precipitación fueron definidas por los investigadores de cada artículo según los objetivos propuestos. Cabe destacar, que a través de una comunicación personal se logró recopilar los datos de la investigación realizada por Miller et al. 2009, debido a que sus datos publicados presentaban errores. De esta forma se logró identificar un total de 54 eventos de erosión hídrica. En la presente investigación la clasificación textural del suelo se realizó de acuerdo a la clasificación textural del Departamento de Agricultura de Estados Unidos (USDA), dividiendo las partículas del suelo en arcilla ($< 2 \mu m$), limo (2 - 50 μm) y arena ($> 50 \mu m$). En la Tabla 3.1 se muestran las series de suelos utilizadas en el presente estudio.

Tabla 3.1: Series de suelo utilizadas en el estudio.

Sorio do suelo		Arcilla Limo Arena		ED * Defense eie		Caria da suala		Arcilla Limo Arena			ED *	Deferrereite	
56		(%)			- EKSSA · Kelefencia		Selle de Suelo			(%)		EKSSA	Referencia
1	Tunyai, Kenia	64	24	12	4	1	13	Bonavia, Italia	24	52	24	1	4
2	Neve Ya`ar, Israel	63	26	11	4	1	14	Tetto Fratti, Italia	12	61	27	1	4
3	Netanya, Israel	10	5	85	4	2	15	6 Ritzlhof4, Austria	23	60	17	1	4
4	Normandía, Francia	11	60	29	1	2	16	6 Riva, Italia	20	69	11	1	4
5	Lauragais, Francia	36	39	26	1	2	17	' Turku, Finlandia	48	41	11	1	4
6	Eifel, Alemania	5	86	9	3	3	18	Szent., Hungría	21	71	8	1	4
7	Devon, RU	5	87	9	3	3	19	Rosemaund, RU	25	66	9	1	4
8	Gleadthorpe, RU	10	25	65	1	4	20	Sale, Italia	37	53	10	1	4
9	Villafranca, Italia	13	46	41	1	4	21	Alemaya black, Etiopía	35	41	24	6	5
10) Keszthely, Hungría	22	40	38	1	4	22	Godie, Etiopía	32	16	52	6	5
11	Nagyhorvati, Hungría	20	50	30	1	4	23	Alemaya, Etiopía	19	32	49	6	5
12	2 Olcenengo, Italia	18	55	27	1	4	24	Wuqi county, China	13	19	68	3	6

* ER_{SSA} es la cantidad de eventos de enriquecimientos de superficie específica reportados por cada serie de suelo.

donde las referencias 1, 2, 3, 4, 5 y 6 corresponden a los artículos científicos de Ben-Hur (2004), Leguédois y Le Bissonnais (2004), Kuhn (2007), Miller et al. (2009), Defersha y Melesse (2012) y Tuo et al. (2015), respectivamente.

La tasa de enriquecimiento de superficie específica fue calculada utilizando la siguiente ecuación desarrollada por Foster et al., (1981):

$$ER_{ss} = \frac{SSA_{sed}}{SSA_{soil}} = \frac{frsnd \cdot ssasnd + frslt \cdot ssaslt + frcly \cdot ssacly}{snd \cdot ssasnd + slt \cdot ssaslt + cly \cdot ssacly}$$
(8)

donde SSA_{sed} es la superficie específica del sedimento erodado (m² g⁻¹), SSA_{soil} es la superficie específica de la matriz del suelo (m² g⁻¹); *snd*, *slt* y *cly* corresponden a las fracciones de arena, limo y arcilla de la matriz del suelo, respectivamente; *frsnd*, *frslt* y *frcly* corresponden a las fracciones de arena, limo y arcilla del sedimento erodado, respectivamente; y *ssasnd*, *ssaslt* y *ssacly* corresponden a las superficies específicas de la arena, limo y arcilla de la matriz del suelo, respectivamente. Los valores para la superficie específica de la arena, limo y arcilla son 0,05; 4 y 20 m² g⁻¹, respectivamente (Foster et al., 1981).

3.2 Configuración de la red neuronal

La configuración de la red neuronal se definió mediante la revisión bibliográfica realizada a fin de evitar un sobreajuste de los datos. Con este propósito, la red neuronal está constituida por una capa oculta y el número de nodos que la conforman se determinó mediante la evaluación de los métodos recopilados descritos en la Tabla 2.2 y el análisis de la eficiencia de la red neuronal al aumentar la cantidad de nodos ocultos progresivamente.

La base de datos está conformada por diversas variables, la fracción de arcilla, limo, arena y materia orgánica de la matriz del suelo, precipitación (mm), magnitud del evento de erosión (kg m⁻²), precipitación (mm), precipitación máxima en 30 minutos (mm h⁻¹), largo y ancho de la ladera (m), ángulo de la ladera (%) y superficie específica de la matriz del suelo (m² g⁻¹). En una primera instancia se usaron todas las variables para configurar la red neuronal, pero finalmente se utilizó el análisis estadístico reportado por Olden y Jackson (2002) para dilucidar las variables que generan una contribución mayor para estimar la tasa de enriquecimiento de superficie específica.

Finalmente, en todas las redes desarrolladas se utilizó el 70% de los datos para el conjunto de entrenamiento, el 15% de los datos para el conjunto de verificación y el otro 15% para el conjunto de validación.

3.3 Eficiencia del modelo

Para evaluar la eficiencia del modelo se utilizaron las siguientes medidas estadísticas: el coeficiente de determinación (r^2) que indica qué tan bien se ajusta la recta de regresión a los datos; la raíz del error cuadrático medio (RMSE, por su sigla en inglés); y el coeficiente de eficiencia de Nash-Sutcliffe (N-S), el cual indica qué tan bien los puntos observados se ajustan en una línea 1:1 con los datos simulados (Schaefli y Gupta, 2007).

4. DISCUSIÓN Y RESULTADOS

4.1 Análisis base de datos

La variabilidad en textura en los suelos utilizados en el estudio se muestra en la Figura 4.1. Se observa la heterogeneidad de los datos recopilados, no existiendo una composición textural dominante (Tabla 4.1). La base de datos está conformada por 54 eventos de lluvia-escorrentía-erosión en 24 series de suelo y 24 sitios. El número de eventos por sitio es dispar debido a las características propias y objetivos de cada estudio. Debido a ello en algunas series de suelo sólo se reporta un 1 evento. En particular todos los experimentos se realizaron en mesas de simulación por lo cual el largo y la altura de la ladera no exceden los 1,1 m y 0,28 m, respectivamente. Además, se observa un amplio rango de las condiciones de lluvia simuladas (30-148 mm). Uno de los estudios a destacar es el realizado por Defersha y Melesse (2012) que utilizó tres diferentes series de suelo utilizadas en mesa de simulación con diferentes pendientes (9, 25 y 45%), una condición de lluvia intensa (122,5 mm) y un contenido de materia orgánica elevado (4, 6 y 14%) en comparación con la base de datos, a causa de que el objetivo de su investigación fue identificar las variables que más se correlacionan con el trasporte y destino de partículas en eventos erosión hídrica en suelos aptos para uso agrícola. El estudio realizado por Tuo et al. (2015) utilizó la mesa de simulación más extensa (1,1 m) y una condición de lluvia variada (60, 80 y 100 mm) siendo su objetivo de investigación evaluar la erosión hídrica bajo tres velocidades de vientos (0, 11 y 14 m s⁻¹), pero únicamente se recopilaron los datos de erosión cuando la velocidad del viento es nula a causa de no influir en los resultados obtenidos. Cabe destacar, que el estudio con mayor variabilidad de series de suelos fue el realizado por Miller et al. (2009), recolectando 13 series de suelo en 5 países europeos con la finalidad de examinar el destino y transporte de las partículas y asociarlo con la concentración de fósforo total en el sedimento erodado por erosión hídrica. Finalmente, es necesario indicar que la mayoría de las tasas de enriquecimiento de superficie específica reportadas tienen una magnitud menor que 2,1; sin embargo únicamente 4 eventos de erosión hídrica tienen un enriquecimiento con una magnitud mayor que 5 los cuales fueron reportados por la investigación realizada por Ben-Hur (2004).



Figura 4.1: Distribución de los contenidos de arena, limo y arcilla de las series de suelo utilizadas en el estudio. El número en paréntesis representa el número de eventos que tienen la misma distribución de tamaño de partículas.

Variable	Promedi o	Máximo	Mínimo
Magnitud del evento de erosión (kg m ⁻²)	0,93	3,93	0,01
Contenido de arena (%)	33,53	85	8
Contenido de limo (%)	39,20	86,8	5
Contenido de arcilla (%)	27,26	64	4,7
Contenido de materia orgánica (%)	4,46	14	0,9
Precipitación (mm)	84,38	148	30
Intensidad máxima de la precipitación (mm h ⁻¹)	71,93	120	29,6
Ángulo de la ladera (%)	16,41	45	0,17
Largo de la ladera (m)	0,57	1,1	0,45
Altura de la ladera (m)	0,08	0,28	0,002
Superficie específica de la matriz del suelo (m ² g ⁻¹)	7,04	13,76	2,24
Tasa de enriquecimiento de superficie específica	1,62	6,82	0,55

Tabla 4.1: Resumen de la variabilidad observada en las propiedades de la base de datos.

4.2 Evaluación de las variables explicativas del modelo

Antes de generar un modelo para estimar la tasa de enriquecimiento de superficie específica se analizó la relación entre esta variable y su correlación con alguna de las variables estudiadas. Las variables evaluadas fueron la fracción de arcilla, limo, arena y materia orgánica (MO) de la matriz del suelo, precipitación, intensidad de la lluvia máxima en 30 minutos (I₃₀), magnitud del evento de erosión (A) y la superficie específica de la matriz del suelo (SSA_{soil}). Estas variables fueron correlacionadas con la tasa de enriquecimiento en distintas investigaciones (Menzel, 1980; Sharpley, 1980; Young, Olness, Mutchler y Moldenhauer, 1984; Defersha y Melesse, 2012); y además se midieron en todos los artículos científicos recopilados.

Primero se evaluó la respuesta de las variables mediante una regresión lineal simple, y los resultados indican que la fracción de arena en la matriz del suelo es la variable que mejor explica la variabilidad de la tasa de enriquecimiento de superficie específica en un 42%, sin embargo analizando los resultados obtenidos se identificó que los 4 eventos de erosión hídrica que reportaron una magnitud de enriquecimiento superior a 5 ocasionaron una elevación de la pendiente en la regresión lineal condicionando el análisis estadístico (N-S = -27345,15). Así mismo, todas las variables restantes no explican la variabilidad de la tasa de enriquecimiento de superficie específica y muestran un coeficiente de determinación reducido ($r^2 < 0,20$) o un coeficiente de Nash-Sutcliffe insatisfactorio (N-S < 0). Se debe destacar que únicamente la magnitud del evento de erosión y el contenido de arena en la matriz del suelo tienen un coeficiente de Pearson positivo.

Estudios previos han reportado que existe una estrecha correlación logarítmica entre la magnitud del evento de erosión y el enriquecimiento (Menzel, 1980; Quinton, Catt y Hess, 2001; Sharpley, 1985), por consiguiente se evaluaron nuevamente las variables, pero en función de una regresión logarítmica buscando un cambio en comparación con la regresión lineal simple. En general las variables responden de la misma forma al cambiar el tipo de regresión. De acuerdo con los resultados presentados, no se observó una correlación logarítmica robusta entre la magnitud del evento de erosión y la tasa de enriquecimiento de superficie específica en sitios con diferentes características de suelo, lluvia y topografía.

En virtud de lo señalado, los resultados pudieron deberse al resultado del análisis global de los datos recopilados sin considerar cualidades intrínsecas de cada investigación. El tiempo de exposición de los suelos a las lluvias simuladas dependió de las metodologías propuestas por los investigadores, variando desde media hora (Miller et al., 2009) hasta cinco horas (Leguédois y Le Bissonnais, 2004). Además, las investigaciones realizadas por Ben-Hur (2004), Kuhn (2007) y Miller et al. (2009) definieron una intensidad de lluvia constante, en contraparte, las investigaciones realizadas por Leguédois y Le Bissonnais (2004), Defersha y Melesse (2012) y Tuo et al. (2015) definieron una intensidad de lluvia variable a través del tiempo. Así mismo, cada estudio preciso los parámetros físicos que caracterizan a la lluvia tales como, tamaño de la gota, altura de caída y energía cinética de forma distinta. Es decir, la erosividad de lluvia que tiene considerables efectos en la pérdida de suelo por erosión (Mohamadi y Kavian, 2015) pudo ocasionar variación en la distribución y tamaño de las partículas en

el sedimento erodado. Análogamente, la pendiente y el tamaño de las mesas de simulación fueron parámetros definidos por cada investigador, siendo factores que influencian la erosión del suelo (Yao, Yu, Jiang, Sun y Li, 2016) pudiendo afectar la composición del material erodado.

En relación con la base de datos, la mayoría de las tasas de enriquecimiento de superficie específica reportadas tienen una magnitud menor que 2,1 y sólo 4 eventos de erosión hídrica tienen un enriquecimiento con una magnitud mayor que 5 causando que se distingan dos agrupaciones de datos dando como resultado una brecha significativa al momento de correlacionar una variable con el enriquecimiento. Debido a lo anterior es probable que al minimizar la brecha de datos se logre realizar un correcto análisis de correlación, identificando las variables que mejor explican la variabilidad de la tasa de enriquecimiento de superficie específica. Los resultados de los análisis presentados se muestran en la Tabla 4.2.

Tabla 4.2: Coeficiente de determinación y Pearson asociado con respecto a cada variable y la tasa de enriquecimiento de superficie específica, mediante una regresión lineal y logarítmica.

Variable	Regresión lineal	Regresión logarítmica	Pearson
	r^2	r^2	r
А	0,13	0,10	0,36
Arcilla	0,08	0,07	-0,28
Arena	0,42	0,41	0,65
I30	0,06	0,04	-0,25
Limo	0,2	0,19	-0,44
MO	0,07	0,05	-0,26
Precipitación	0,09	0,07	-0,3
SSA soil	0,17	0,16	-0,42

4.3 Modelo de red neuronal para estimar la tasa de enriquecimiento de superficie específica.

Como resultado del análisis se configuró una red neuronal con todas las variables de la base de datos (11 variables), una capa oculta y 21 nodos ocultos (Hecht-Nielsen, 1987), obteniendo una eficiencia de ajuste sobresaliente en el conjunto de entrenamiento $(r^2 = 1,00 \text{ y N-S} = 1,00)$ y en el conjunto de verificación $(r^2 = 0,96 \text{ y N-S} = 0.95)$ pero una respuesta ineficiente con el conjunto de validación ($r^2 = 0.013$ y N-S = -7.84) a causa de utilizar una cantidad abundante de variables y nodos ocultos se generó un sobreajuste de datos. Teniendo en cuenta lo anterior, se aplicó el análisis estadístico desarrollado por Olden y Jackson para medir el aporte individual de las variables de entrada. De acuerdo a este, la magnitud del evento de erosión (kg m⁻²), la precipitación (mm), la altura y el largo de la ladera (m), y las fracciones de arcilla, limo, arena y materia orgánica en la matriz del suelo son las variables que hacen una contribución significativa a la red neuronal (Tabla 4.3). La superficie específica de la matriz del suelo y el ángulo de la ladera son las variables que generan una menor contribución a la red neuronal, esto puede deberse a que las variables nombradas se logran calcular mediante las variables restantes, y en el caso específico de la intensidad máxima de precipitación fue causado porque en la mayoría de las investigaciones no varía a través del tiempo siendo constante y correlacionándose estrechamente con la precipitación. En consecuencia, se configuró nuevamente la red neuronal en función de las 8 variables nombradas. Posteriormente, se utilizaron los métodos más citados (Tabla 2.1) para definir el número adecuado de nodos ocultos a causa de obtener óptimos resultados y asegurar que en el modelo no haya un sobreajuste de datos, los resultados obtenidos se muestran en la Tabla 4.3. No obstante no se logra identificar el número adecuado de nodos ocultos debido a la disparidad de los resultados. A causa de que no existe una técnica estandarizada para determinar el número adecuado de nodos ocultos promoviendo que investigadores desarrollen metodologías para abordar el problema utilizando sus propias bases de datos, por consiguiente cada metodología formulada está condicionada por la correlación existente entre los valores de entrada y salida que se utilizaron. Es por ello que aunque se utilizaron 7 metodologías distintas cada uno sugiere un valor distinto.

Variable	8 variables	11 variables
_	Contribu	ución (%)
Magnitud del evento de erosión	14	15
Contenido de arena	13	10
Contenido de limo	13	11
Contenido de arcilla	10	12
Contenido de materia orgánica	10	9
Precipitación	14	7
Intensidad máxima de precipitación	-	3
Largo de la ladera	11	11
Altura de la ladera	14	13
Ángulo de la ladera	-	4
Superficie específica de la matriz del suelo	-	5

Tabla 4.3: Análisis de significancia de las variables que fueron utilizadas en la red neuronal para estimar la tasa de enriquecimiento de superficie específica.

Tabla 4.4: Desempeño de las ecuaciones más utilizadas para estimar el número de nodos ocultos.

Método	Número de nodos ocultos
$N_t = (V_e + \sqrt{D_e}) / L$	15
$N_t = V_e + V_s + 0.5$	10
$N_t = V_e + 1$	9
$N_t = D_t / \left[R \cdot (V_e + V_s) \right]$	2
$0,11 \cdot D_t \le N_t \cdot (V_e + 1) \le 0,3 \cdot D_t$	1
$N_t \approx \left(V_e \cdot V_s\right)^{0.5}$	3
$N_t = (2 \cdot V_e + 1)$	17

_

Con referencia a lo anterior, se evaluó la eficiencia de la red neuronal con respecto al aumento gradual de la cantidad de nodos ocultos replicando cada configuración 1000 veces, logrando un total de 20.000 modelaciones. Los resultados obtenidos indican que el promedio del coeficiente de determinación no varía significativamente con respecto a la cantidad de nodos ocultos utilizados, evidenciando que la red neuronal permite estimar la tendencia de los datos observados con precisión ($r^2 > 0.78$) independientemente de la configuración definida. Sin embargo, la desviación estándar es mayor en los dos primeros nodos ocultos y se mantiene relativamente constante a partir de los 3 nodos ocultos en adelante. Así mismo, se evaluó la raíz del error cuadrático medio para medir la discrepancia entre los valores modelados y los valores observados. De acuerdo a esta, a partir de los 6 nodos ocultos la red neuronal, independiente de su configuración, no varía significativamente su eficiencia y el grado de dispersión. Con una configuración menor a 6 nodos cultos se observa una eficiencia menor y con un mayor grado de dispersión. Es importante destacar, que el grado de dispersión presentado en los resultados es a causa de la escasa cantidad de datos promoviendo que el ajuste del modelo sea inestable. Debido a lo anterior, en la presente investigación se utilizaran 6 nodos ocultos pues la configuración que mostró un punto de transición en ese punto, en el cual la red neuronal se ajusta adecuadamente a los valores observados. En caso de utilizar una mayor cantidad de nodos ocultos no se logra un aumento significativo en la eficiencia del modelo elaborado con la red neuronal. Por otra parte, la disminución de la cantidad de nodos ocultos si afecta de forma negativa la eficiencia del modelo generado con la red neuronal. Los resultados obtenidos se muestran en las Figuras 4.2.

Habiendo determinado la cantidad óptima de nodos ocultos, de las 1.000 modelaciones realizadas se seleccionó el mejor modelo de red neuronal en función de la eficiencia conseguida en el conjunto de calibración. Con motivo de que el modelo evidencia lograr la mejor correlación entre las variables de entrada y la tasa de enriquecimiento de superficie específica.



Figura 4.2: Eficiencia del modelo de red neuronal con respecto al aumento en la cantidad de nodos ocultos. Los círculos muestran el promedio del coeficiente de determinación (a) y de la raíz del error cuadrático medio (b); las barras de error indican la desviación estándar. Se realizaron 1.000 modelaciones por cada configuración, con un total de 20.000 modelaciones.

Los resultados obtenidos no difirieren en comparación con el primer modelo de red neuronal (10 variables de entrada y 21 nodos ocultos), logrando nuevamente una alta eficiencia de ajuste en el conjunto de entrenamiento ($r^2 = 0.99$ y N-S = 0.99), en el conjunto de verificación ($r^2 = 0.98$ y N-S = 0.97) y en la totalidad de datos ($r^2 = 0.99$ y N-S = 0.99). Sin embargo, a diferencia del modelo anterior, si logró estimar con una precisión adecuada el conjunto de validación ($r^2 = 0.61$ y N-S = 0.58). Cabe mencionar que anteriormente al analizar la base de datos se identificaron 4 eventos de erosión que reportaron un enriquecimiento elevado en comparación con los datos restantes causando un condicionamiento en el análisis estadístico. Respecto a esto último, se analizó el conjunto de verificación sin considerar el evento de enriquecimiento de mayor magnitud evidenciando que la eficiencia del modelo decrece ($r^2 = 0.57$ y N-S = -1.09), esto es causado por dos motivos. Primero por la escasa cantidad de eventos (n = 8) que genera una sensibilidad en el análisis estadístico ante cualquier cambio de adición o sustracción de datos; y finalmente porque dos eventos en el conjunto de verificación fueron reportados por el estudio realizado por Miller et al. (2009) que se analizara en detalle posteriormente. Del mismo modo se analizó eficiencia del modelo sin considerar los eventos de mayor magnitud en el conjunto de entrenamiento ($r^2 = 0.92$ y N-S = 0.90) y en la totalidad de datos ($r^2 = 0.78$ y N-S = 0.74) demostrando que no decrece significativamente. En la Figura 4.3 se muestra el desempeño del modelo con respecto a cada conjunto y la totalidad de datos.

En relación a lo anterior, el análisis estadístico y la definición del número de nodos ocultos permiten construir una red robusta para estimar la tasa de enriquecimiento en superficie específica del sedimento. Además, se evaluó la contribución de las 8 variables obteniendo que cada una genera un aporte similar (Tabla 4.3). La eliminación de cualquiera de las variables mencionadas, y el aumento o disminución de los nodos ocultos afecta significativamente la eficiencia del modelo. Finalmente, la ecuación formulada a través del desarrollo de la rede neuronal se presenta en la siguiente sección.



Figura 4.3: Eficiencia del modelo de red neuronal con ocho variables de entrada. Se muestra el conjunto de entrenamiento, de verificación, de validación y la totalidad de los datos.

4.4 Modelo elaborado con la red neuronal.

Con referencia a lo explicado anteriormente, la metodología empleada por MATLAB para aplicar la red neuronal consiste básicamente en tres etapas, preprocesamiento, procesamiento y post-procesamiento de datos. Es por ello, que si el modelador desea utilizar la red construida en la presente investigación es necesario que domine los siguientes párrafos.

Primeramente como parte del pre-procesamiento de datos, los valores de entrada deben ser normalizados, para ello es necesario emplear la Ecuación 5 para cada variable de entrada antes de ser utilizadas en el modelo elaborado con la red neuronal, no obstante eso, cada una tiene sus rangos máximos y mínimos de normalización específicos que fueron definidos a causa de la base de datos recopilada. En la tabla 4.5 se muestran los rangos de normalización asociados a cada variable.

Tabla 4.5. Rangos	utilizados	para	normalizar	los	datos	de	entrada	del	modelo	de	red
neuronal.											

Variable	Unidad	Rango máximo	Rango mínimo
Magnitud del evento de erosión	kg m ⁻²	3,93	0,014
Fracción de arena en la matriz del suelo	-	0,85	0,08
Fracción de limo en la matriz del suelo	-	0,868	0,05
Fracción de arcilla en la matriz del suelo	-	0,64	0,047
Fracción de materia orgánica en la matriz del suelo	-	0,14	0,009
Precipitación	mm	148	30
Largo de la ladera	m	1,1	0,45
Altura de la ladera	m	0,28	0,002

Seguidamente en la etapa de procesamiento de los datos, habiendo normalizado las variables de entrada se continúa a utilizar la ecuación matricial formulada al aplicar las redes neuronales, presentada en la Tabla 4.6.

$ER_{ss} = Z + \sum_{i=1}^{6} Lw_i \cdot \tanh(Y_i + Iw_i^a \cdot A + Iw_1^b \cdot B + Iw_i^c \cdot C + Iw_i^d \cdot D + Iw_i^e \cdot E + Iw_i^f \cdot F + Iw_i^s \cdot G + Iw_i^h \cdot H)$										
	Lw_i	Y_i	Iw_i^a	Iw_i^b	Iw_i^c	Iw_i^d	Iw_i^e	Iw_i^f	Iw_i^g	Iw_i^h
1	0,8463	2,4892	-1,1631	-0,9378	-2,0518	1,2790	0,4427	-0,4705	1,7051	0,5133
2	-1,7457	1,0263	-0,6570	1,0253	-0,5899	-0,8525	0,4067	-1,0961	0,8820	-0,0662
3	1,2082	-2,8976	-0,8099	2,4632	1,4039	-0,3210	0,5394	1,5843	1,7787	-0,4100
4	1,7926	-0,5925	-0,1469	0,8019	0,7274	-0,3903	-1,8619	-2,0260	0,1456	3,8896
5	-1,5985	-3,0939	-5,4210	0,4379	0,2612	0,8851	-1,1317	0,8962	0,2750	3,8367
6	1,4648	3,5100	-0,9090	3,2592	-2,6040	-2,4605	0,3649	-2,2994	1,1606	0,5586

Tabla 4.6: Ecuación construida a través de la red neuronal para estimar la tasa enriquecimiento de superficie específica.

donde *A* es la magnitud del evento de erosión (kg m⁻²), *B*, *C*, *D*, *E* son la fracción de arena, limo, arcilla y materia orgánica en la matriz del suelo, respectivamente, *F* es la precipitación del evento (mm), *G* es la altura de la ladera (m) y *H* es el largo de la ladera (m). El valor de *Z* es igual a -0,3192. Cabe destacar, que las variables de entrada se deben normalizar con anterioridad.

Finalmente en la etapa de post-procesamiento de los datos, los resultados obtenidos al utilizar el modelo construido por la red neuronal deben ser desnormalizados utilizando la Ecuación 6; siendo los rangos máximos y mínimos 6,82 y 0,57, respectivamente. De este modo, es necesario aplicar cada uno de los procesamientos explicados con anterioridad para un correcto uso de la red neuronal para estimar la tasa de enriquecimiento de superficie específica en eventos de erosión hídrica.

4.5 Evaluación del modelo de red neuronal.

El modelo de red neuronal mostró una eficiencia alta en la totalidad de los datos recopilados ($r^2 = 0.99$ y N-S = 0.99). Aun así, se decidido verificar la eficiencia del modelo con respecto a cada artículo científico. Los resultados obtenidos demuestran que el modelo es capaz de explicar la variabilidad de la tasa de enriquecimiento de superficie específica con un alto grado de precisión ($r^2 = 0.65-1$ y N-S = 0.56-1) para el caso de los estudios que reportaron más de 3 datos (Figura 4.4). En el caso contrario se obtuvo una precisión baja ($r^2 = 0.52-1$ y N-S < -0.52) a causa de la reducida cantidad de datos que limitó la generación de una adecuada correlación. Es por ello que el primer análisis está enfocado en los estudios que reportaron más de 3 datos. A partir de los datos provenientes del estudio de Ben-Hur (2004) se obtuvo la mejor estimación con el modelo de red ($r^2 =$ 1,00 y N-S = 1,00). Sin embargo, en este caso los resultados no se debieron a la selección aleatoria de datos ya que la división entre conjuntos fue equitativa y no se utilizó la totalidad de sus datos para el conjunto de entrenamiento. Del mismo modo, el modelo logró estimar adecuadamente ($r^2 > 0.74$ y N-S > 0.69) los datos recopilados de las investigaciones realizadas por Defersha et al. (2012) y Kuhn et al. (2007). En contraste, el modelo estima con un menor grado de precisión ($r^2 = 0.65$ y N-S = 0.24) los datos recopilados de la investigación realizada por Miller et al. (2009). Esta situación no era la esperada debido a que la selección aleatoria también fue equitativa, no obstante esto pudo deberse a la diversidad de series de suelo recolectadas para su investigación causando una incapacidad de la red neuronal para correlacionar las variables de entrada y salida. Además, se observó que el análisis estadístico realizado fue condicionado por dos eventos de enriquecimiento los cuales pertenecen al conjunto de validación. Así mismo se realizó nuevamente un análisis de eficiencia sin considerarlos causando una mejora en la precisión predictiva del modelo ($r^2 = 0.82$ y N-S = 0.81) exponiendo que tiene una sensibilidad ante los análisis estadísticos a causa de la cantidad de datos utilizados. En la Tabla 4.7 se muestra la selección aleatoria realizada con MATLAB.



Figura 4.4: Comparación entre la tasa de enriquecimiento de superficie específica estimada con el modelo de red neuronal y la base de datos proveniente de cada estudio.

Artículo científico	n	Entrenamiento	Verificación	Validación
Miller et al. (2009)	13	8	2	3
Defersha y Melesse (2012)	18	14	3	1
Leguédois y Le Bissonnais (2004)	2	1	0	1
Ben-Hur (2004)	12	7	2	3
Kuhn (2007)	6	5	1	0
Tuo et al. (2015)	3	3	0	0

Tabla 4.7. Selección aleatoria realizada con MATLAB.

Con respecto a las investigaciones que reportaron menos de 3 datos (Leguédois y Le Bissonnais, 2004; Tuo et al., 2015) no se obtuvieron resultados satisfactorios al ser evaluadas con el coeficiente de determinación y el coeficiente de Nash-Sutcliffe. Como se mencionó anteriormente una reducida cantidad de datos imposibilita un análisis estadístico representativo, a causa de que se ve condicionado ante cualquier evento. Pero los datos reportados son de suma importancia dado que complementan la base de datos. La Figura 4.4 muestra la eficiencia del modelo con respecto a cada artículo científico recopilado.

4.6 Evaluación de la ecuación de Menzel

Dado que a la fecha existe una ecuación que ha sido ampliamente utilizada para la estimación de las tasas de enriquecimiento, uno de los objetivos de este estudio fue evaluar la eficiencia de la ecuación desarrollada por Menzel (1980) y los supuestos sobre los cuales ésta descansa. En particular, el principio de que el enriquecimiento se puede explicar fundamentalmente por la magnitud del evento de erosión independiente de las características de suelo, precipitación y topografía de la zona. No obstante los datos recopilados no cuantifican el enriquecimiento de fósforo o nitrógeno, como se ha mencionado anteriormente el enriquecimiento de nutrientes posee una estrecha relación

lineal con la tasa de enriquecimiento de superficie específica (Sharpley, 1985). En consecuencia se utilizó la ecuación formulada por Menzel (Ecuación 1) con las constantes de ajuste para suelos sin cubierta vegetal (labranza), con el propositivo de analizar la respuesta de la ecuación ante características de suelo, precipitación y topografía heterogéneas. Los resultados obtenidos muestran un bajo coeficiente de correlación ($r^2 = 0,1$ y N-S < -9,25) entre el enriquecimiento de nutrientes (nitrógeno y fósforo) y el enriquecimiento de superficie específica (Figura. 4.5).



Figura 4.5: Relación entre la tasa de enriquecimiento de nitrógeno (N – Menzel) y fósforo (P – Menzel) calculadas con la ecuación de Menzel (1980) y la red neuronal construida con las tasas de enriquecimiento de superficie específica medidas experimentalmente.

Con referencia a lo anterior, los resultados obtenidos muestran que no existe una diferencia significa al utilizar la ecuación de Menzel ajustada para estimar el enriquecimiento del nitrógeno o fósforo demostrando una similar eficiencia para estimar los enriquecimientos medidos. Así mismo la ecuación de Menzel presenta períodos de sobreestimación y subestimación, situación inapropiada a causa de ser una de las alternativas más utilizadas para estimar el enriquecimiento. Esto puede ser debido principalmente porque la ecuación no interioriza como variable la pendiente de la ladera siendo un parámetro relevante que tiene efecto en la erodabilidad del suelo, la magnitud del evento de erosión y de la composición del sedimento erodado (Cerdà y García-Fayos, 1997). Esta condición evidencia la necesidad de emplear más de una variable para explicar la variabilidad del enriquecimiento, tal como se logra en este estudio con el uso de la red neuronal.

Al comparar la eficiencia del modelo generado por la red neuronal ($r^2 = 0.99$ y N-S = 0.99) y la ecuación de Menzel ($r^2 = 0.1$ y N-S < -9.25) se observa una diferencia significativa. Los resultados obtenidos constatan la robustez del modelo para estimar el enriquecimiento en sitios con características heterogéneas. Sin embargo, se debe mencionar que los óptimos resultados conseguidos son causados por utilizar los enriquecimientos medidos para ajustar el modelo de la red neuronal.

5. CONCLUSIONES

En el presente estudio se analizaron los resultados provenientes de 54 eventos de erosión hídrica recolectados de 6 artículos científicos. Se demuestra que ninguna de las variables evaluadas logra explicar la variabilidad de la tasa de enriquecimiento con un alto grado de precisión ($r^2 < 0.42$ y N-S < 0); y además es un proceso arduo a causa de ser necesario conocer la distribución y composición de las partículas en el sedimento erodado y en la matriz del suelo.

El modelo de red neuronal desarrollado para estimar la tasa de enriquecimiento de superficie específica permite superar de forma adecuada las limitaciones observadas en la ecuación de Menzel. Para no generar un sobreajuste de datos en la red se aplicó el análisis estadístico desarrollado por Olden y Jackson para dilucidar el aporte individual de las variables de entrada. De acuerdo esto se puede ver que la magnitud del evento de erosión, la precipitación, la altura y largo de la ladera, y las fracciones de arcilla, limo, arena y materia orgánica en la matriz del suelo son las variables que hacen el mayor aporte a la red neuronal. Respecto al número de nodos ocultos requeridos para construir la red, el análisis del efecto de incrementar gradualmente el número de nodos permite concluir que para obtener resultados óptimos y no caer en un sobreajuste de datos, el número apropiado de nodos ocultos es de seis. Con esto fue posible estimar la tasa de enriquecimiento de superficie específica con un alto grado de precisión ($r^2 = 0.99$ y N-S = 0.99). Así mismo, se evaluó la eficiencia del modelo con respecto a cada artículo científico, obteniendo en ello una precisión adecuada ($r^2 = 0.65-1$ y N-S = 0.56-1) para los datos provenientes de investigaciones que reportaron más de 3 datos. Sin embargo, para aquellos con menos datos, se obtuvo un nivel de precisión inadecuado ($r^2 = 0.52-1$ y N-S < -0.52). Esto último se debió a la reducida cantidad de datos.

Finalmente, se evaluó la eficiencia de la ecuación desarrollada por Menzel por de ser una de las alternativas más utilizadas en la actualidad. Los resultados obtenidos demuestran que no predice bien la variabilidad de la tasa de enriquecimiento de nutrientes en suelos sin cubierta vegetal ($r^2 = 0,1$ y N-S < -9,25) con respecto a distintas características edáficas, topográficas y climáticas, a causa de utilizar únicamente una variable.

A modo de síntesis, el modelo elaborado con la red neuronal conformado por 8 variables provee un mejor entendimiento y mayor precisión en la predicción de la tasa de enriquecimiento del sedimento en suelos sin cubierta vegetal, y constituye un avance para la modelación de la calidad de aguas y suelos.

BIBLIOGRAFÍA

Abdullah, M. H. L. B. y Ganapathy, V. (2000). Neural network ensemble for financial trend prediction. 2000 TENCON Proceedings. Intelligent Systems and Technologies for the New Millennium, 3, 157–161.

Aksoy, H. y Kavvas, M. L. (2005). A review of hillslope and watershed scale erosion and sediment transport models. *Catena*, 64, 247–271.

Al-Shayea, Q. (2011). Artificial Neural Networks in Medical Diagnosis. *Journal of Computer Science Issues*, 8(2), 150–154.

Barra, R., Popp, P., Quiroz, R., Bauer, C., Cid, H. y Tümpling, W. Von. (2005). Persistent toxic substances in soils and waters along an altitudinal gradient in the Laja River Basin, Central Southern Chile. *Chemosphere*, 58(7), 905–915.

Baxt, W. G. (1991). Use of an artificial neural network for the diagnosis of myocardial infarction. *Annals of Internal Medicine*, 115(11), 843–848.

Ben-Hur, M. (2004). Soil mineralogy and slope effects on infiltration, interrill erosion, and slope factor. *Water Resources Research*, 40(3), 1–8.

Bodyanskiy, Y. y Popov, S. (2006). Neural network approach to forecasting of quasiperiodic financial time series. *European Journal of Operational Research*, 175(3), 1357–1366.

Bonilla, C. A. y Johnson, O. I. (2012). Soil erodibility mapping and its correlation with soil properties in Central Chile. *Geoderma*, 189–190, 116–123.

Bonilla, C. A. y Vidal, K. L. (2011). Rainfall erosivity in Central Chile. *Journal of Hydrology*, 410(1–2), 126–133.

Borah, D. K., Bera, M. y Shaw, S. (2003). Water, sediment, nutrient, and pesticide measurements in an agricultural watershed in Illinois during storm events. *Transactions of the American Society of Agricultural Engineers*, 46(3), 657–674.

Caudill, M. (1987). Neural Networks Primer, Part I. AI Expert, 2(12), 46-52.

Cerdà, A. y García-Fayos, P. (1997). The influence of slope angle on sediment, water and seed losses on badland landscapes. *Geomorphology*, 18(2), 77–90.

Chai, S.-S., Walker, J. P., Makarynskyy, O., Kuhn, M., Veenendaal, B. y West, G. (2009). Use of Soil Moisture Variability in Artificial Neural Network Retrieval of Soil Moisture. *Remote Sensing*, 2(1), 166–190.

CIREN. (2010). Determinación de la Erosión Actual y Potencial de los suelos de Chile. Centro de Información de Recursos Naturales.

Corwin, D. L. y Farmer, W. J. (1984). An assessment of the significant physicochemical interactions involved in pesticide diffusion within a pesticide-sediment-water system. *Chemosphere*, 13(12), 1295-1317.

Dai, X., Huo, Z. y Wang, H. (2011). Simulation for response of crop yield to soil moisture and salinity with artificial neural network. *Field Crops Research*, 121(3), 441–449.

de Farias, C. A. S. y Santos, C. A. G. (2014). The use of Kohonen neural networks for runoff--erosion modeling. *Journal of Soils and Sediments*, 14(7), 1242–1250.

Defersha, M. B. y Melesse, A. M. (2012). Effect of rainfall intensity, slope and antecedent moisture content on sediment concentration and sediment enrichment ratio. *CATENA*, 90, 47–52.

Demuth, H. (2006). Neural networks. Neural Networks, 19(1), 1–7.

Domine, D., Devillers, J., Chastrette, M. y Karcher, W. (1993). Estimating pesticide field half-lives from a backpropagation neural network. *SAR and QSAR in Environmental Research*, 1(2-3), 211-219.

Eurostat. (2007). The use of plant protection products in the European Union: data 1992–2003. Statistical Book. European Communities Luxembourg.

Flanagan, D.C. y Nearing, M.A. (1995). USDA-Water Erosion Prediction Project: Hillslope Profile and Watershed Model Documentation. NSERL Report No. 10. USDA-ARS National Soil Erosion Research Laboratory, West Lafayette, Ind.

Foster, G. R., Lane, L. J., Nowlin, J. D., Laflen, J. M. y Young, R. A. (1981). Estimating erosion and sediment yield on field-sized areas. *Transactions of the American Society of Agricultural Engineers*, 24(5), 1253–1262.

Foster, G. R., Young, R. A. y Neibling, W. H. (1985). Sediment composition for nonpoint source pollution analyses. *Transactions of the American Society of Agricultural Engineers*, 28(1), 133–139.

Ghadiri, H. y Rose, C. W. (1993). Water erosion processes and the enrichment of sorbed pesticides. Part 1. Enrichment mechanisms and the degradation of applied pesticides. *Journal of Environmental Management*, 37(1), 23–35.

Hassan, M., Ali Shamim, M., Sikandar, A., Mehmood, I., Ahmed, I., Ashiq, S. Z. y Khitab, A. (2015). Development of sediment load estimation models by using artificial neural networking techniques. *Environmental Monitoring and Assessment*, 187(11), 1–13.

Hecht-Nielsen, R. (1987). Kolmogorov's Mapping Neural Network Existence Theorem. In *Proceedings of the IEEE First International Conference on Neural Networks, San Diego, CA, USA* (11–13).

Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A., Jaitly, N., Kingsbury, B. (2012). Deep Neural Networks for Acoustic Modeling in Speech Recognition. *IEEE Signal Processing Magazine*, 29(6), 82–97.

Howard, D., Mark, B. y Martin, H. (1998). Neural network toolbox for use with MATLAB. User's Guide Version, 3.

Hunt, B. R., Lipsman, R. L. y Rosenberg, J. M. (2014). A guide to MATLAB: for beginners and experienced users. Cambridge University Press. International Ltd. Padstow Cornwall. UK.

Hunter, D., Yu, H., Member, S., Pukish, M. S., Kolbusz, J. y Wilamowski, B. M. (2012).
Selection of Proper Neural Network Sizes and Architectures — A Comparative Study.
IEEE Transactions on Industrial Informatics, 8(2), 228–240.

Jadid, M. N. y Fairbairn, D. R. (1996). Neural-network applications in predicting momentcurvature parameters from experimental data. *Engineering Applications of Artificial Intelligence*, 9(3), 309–319.

Jayalakshmi, T. y Santhakumaran, D. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 3(1), 89–93.

Kaastra, I. y Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215–236.

Kalogirou, S. a. (2001). Artificial neural networks in renewable energy systems applications: a review. *Renewable and Sustainable Energy Reviews*, 5(4), 373–401.

Kalteh, A. M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. *Computers & Geosciences*, 54, 1–8.

Karchegani, P. M., Ayoubi, S., Mosaddeghi, M. R. y Honarjoo, N. (2012). Soil organic carbon pools in particle-size fractions as affected by slope gradient and land use change in hilly regions, western Iran. *Journal of Mountain Science*, 9(1), 87–95.

Keshavarzi, A., Sarmadian, F., Omran, E.-S. E. y Iqbal, M. (2015). A neural network model for estimating soil phosphorus using terrain analysis. *The Egyptian Journal of Remote Sensing and Space Science*, 18(2), 127–135.

Kim, M. y Gilley, J. E. (2008). Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Computers and Electronics in Agriculture*, 64(2), 268–275.

Kim, R. J., Loucks, D. P. y Stedinger, J. R. (2012). Artificial Neural Network Models of Watershed Nutrient Loading. *Water Resources Management*, 26(10), 2781–2797.

Knisel, W. (1980). CREAMS: A Field-Scale Model for Chemicals, Runoff and Erosion from Agricultural Management Systems, Conservation Research Report 26. Department of Agriculture, US.

Knisel W., Leonard R. y Davis F. (1989). GLEAMS user manual. Southeast Watershed Research Laboratory, USDA-ARS, Tifton, GA.

Köhne, J. M., Köhne, S. y Šimůnek, J. (2009). A review of model applications for structured soils: b) Pesticide transport. *Journal of Contaminant Hydrology*, *104*(1-4), 36–60.

Kuhn, N. J. (2007). Erodibility of soil and organic matter: Independence of organic matter resistance to interrill erosion. *Earth Surface Processes and Landforms*, *32*(5), 794–802.

Lachtermacher, G. y Fuller, J. D. (1995). Back propagation in time-series forecasting. *Journal of Forecasting*, *14*(4), 381–393.

Lane, L. J. (1983). Watershed erosion and sediment yield affecting contaminant transport. *Proc. of the USDOE*, 1, 193–223.

Law, R. (2000). Back-propagation learning in improving the accuracy of neural networkbased tourism demand forecasting. *Tourism Management*, 21(4), 331–340.

Lee, T. L. (2009). Predictions of typhoon storm surge in Taiwan using artificial neural networks. *Advances in Engineering Software*, 40(11), 1200–1206.

Leguédois, S. y Le Bissonnais, Y. (2004). Size fractions resulting from an aggregate stability test, interrill detachment and transport. *Earth Surface Processes and Landforms*, 29(9), 1117–1129.

Leonard, R. A., Knisel, W. G. y Still, D. A. (1987). GLEAMS: Groundwater Loading Effects of Agricultural Management Systems. *Transactions of the American Society of Agricultural Engineers*, 30 (5), 1403–1418.

Licznar, P. y Nearing, M. A. (2003). Artificial neural networks of soil erosion and runoff prediction at the plot scale. *Catena*, 51(2), 89–114.

Lippmann, R. P. (1987). Introduction To Computing With Neural Nets. *IEEE ASSP Magazine*, 4(2), 4-22.

Lisboa, P. J. G. (2002). A review of evidence of health benefit from artificial neural networks in medical intervention. *Neural Networks*, 15(1), 11–39.

Liu, H. y Zhang, T. (2013). Neural network-based robust finite-time control for robotic manipulators considering actuator dynamics. *Robotics and Computer-Integrated Manufacturing*, 29(2), 301–308.

Liu, X., Chen, X., Wu, W. y Peng, G. (2007). A neural network for predicting moisture content of grain drying process using genetic algorithm. *Food Control*, 18(8), 928–933.

Massey, H. F. y Jackson, M. L. (1952). Selective Erosion of Soil Fertility Constituents. *Soil Science Society of America Journal*, *16*, 353–356.

Masters, T. (1993). Practical Neural Networks Recipes in C++, Reino Unido: Morgan

Menzel, R. G. (1980). Enrichment ratios for water quality modeling. *CREAMS: A Field-Scale Model for Chemicals, Runoff, and Erosion from Agricultural Management Systems Conservation Research,* 486-492.

Merdun, H., Çınar, Ö., Meral, R. y Apan, M. (2006). Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90(1–2), 108–116.

Merritt, W. S., Letcher, R. A. y Jakeman, A. J. (2003). A review of erosion and sediment transport models. *Environmental Modelling and Software*, 18, 761-799.

Miller, N., Quinton, J. N., Barberis, E. y Presta, M. (2009). Variability in the Mobilization of Sediment and Phosphorus across 13 European Soils . *Journal of Environmental Quality*, 38, 742–750.

Mohamadi, M. A. y Kavian, A. (2015). Effects of rainfall patterns on runoff and soil erosion in field plots. *International Soil and Water Conservation Research*, 3(4), 273–281.

Mubiru, J. (2008). Predicting total solar irradiation values using artificial neural networks. *Renewable Energy*, 33(10), 2329–2332.

Nasrabadi, T., Bidhendi, G. N., Karbassi, A., Grathwohl, P. y Mehrdadi, N. (2011). Impact of major organophosphate pesticides used in agriculture to surface water and sediment quality (Southern Caspian Sea basin, Haraz River). *Environmental Earth Sciences*, 63(4), 873–883.

Neitsch, S. L., Arnold, J. G., Srinivasan, R. y Grassland, S. (2002). Pesticides Fate and Transport Predicted by the Soil and Water Assessment Tool (SWAT). Grassland, Soil and Water Research Service, Texas.

Olden, J. D. y Jackson, D. A. (2002). Illuminating the "black box": A randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, *154*(1-2), 135–150.

Özesmi, S. L. y Özesmi, U. (1999). An artificial neural network approach to spatial habitat modelling with interspecific interaction. *Ecological Modelling*, *116*(1), 15–31.

Palis, R. G., Rose, C. W. y Saffigna, P. G. (1997). Soil erosion and nutrient loss. IV. *Soil Research*, 35(4), 907–924.

Palma, G., Sánchez, A., Olave, Y., Encina, F., Palma, R. y Barra, R. (2004). Pesticide levels in surface waters in an agricultural–forestry basin in Southern Chile. *Chemosphere*, 57(8), 763–770.

Papanicolaou, A. N., Wacha, K. M., Abban, B. K., Wilson, C. G., Hatfield, J. L., Stanier, C. O. y Filley, T. R. (2015). From soilscapes to landscapes: A landscape-oriented approach to simulate soil organic carbon dynamics in intensively managed landscapes. *Journal of Geophysical Research G: Biogeosciences*, 120(11), 2375–2401.

Parras-Alcántara, L., Martín-Carrillo, M. y Lozano-García, B. (2013). Impacts of land use change in soil carbon and nitrogen in a Mediterranean agricultural area (Southern Spain). *Solid Earth*, 4(1), 167–177.

Pionke, H. B. y Chesters, G. (1973). Pesticide-sediment-water interactions. *Journal of Environmental Quality*, 2(1), 29–45.

Quinton, J. N., Catt, J. A. y Hess, T. M. (2001). The selective removal of phosphorus from soil. *Journal of Environmental Quality*, *30*(2), 538–545.

Ramírez-Santana, M., Iglesias-Guerrero, J., Castillo-Riquelme, M. y Scheepers, P. T. J. (2014). Assessment of Health Care and Economic Costs Due to Episodes of Acute Pesticide Intoxication in Workers of Rural Areas of the Coquimbo Region, Chile. *Value in Health Regional Issues*, 5, 35–39.

Rickson, R. J. (2014). Can control of soil erosion mitigate water pollution by sediments? *Science of the Total Environment*, 468–469, 1187–1197.

Rumelhart, D. E., Hinton, G. E. y Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.

SAG. (2001). Declaración de ventas de plaguicidas de uso agrícola año 2001. Ministerio de Agricultura. Sub-Departamento de Plaguicidas y Fertilizantes, Santiago, Chile.

SAG. (2012). Declaración de ventas de plaguicidas de uso agrícola año 2012. Ministerio de Agricultura. Sub-Departamento de Plaguicidas y Fertilizantes, Santiago, Chile.

Sahoo, G. B., Ray, C., Mehnert, E. y Keefer, D. A. (2006). Application of artificial neural networks to assess pesticide contamination in shallow groundwater. *Science of the Total Environment*, 367(1), 234–251.

Sahoo, G. B., Ray, C. y Wade, H. F. (2005). Pesticide prediction in ground water in North Carolina domestic wells using artificial neural networks. *Ecological Modelling*, 183(1), 29–46.

Sarangi, A. y Bhattacharya, A. K. (2005). Comparison of Artificial Neural Network and regression models for sediment loss prediction from Banha watershed in India. *Agricultural Water Management*, 78(3), 195–208.

Scardi, M. y Harding, L. W. (1999). Developing an empirical model of phytoplankton primary production: A neural network case study. *Ecological Modelling*, 120(2–3), 213–223.

Schaefli, B. y Gupta, H. V. (2007). Do Nash values have value? *Hydrological Processes*, 21(5), 2075-2080.

Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, *61*, 85-117.

Schweller, K. G. y Plagman, A. L. (1989). Neural Nets and Alphabets: Introducing Students to Neural Networks. *SIGCSE Bull.*, *21*(3), 2–7.

Sharpley, A. N. (1980). The enrichment of soil phosphorus in runoff sediments. *Journal of Environmental Quality*, 9(3), 521–526.

Sharpley, A. N. (1985). The selective erosion of plant nutrients in runoff. *Soil Science Society of America Journal*, 49(6), 1527–1534.

Sheela, K. G. y Deepa, S. N. (2013). Review on methods to fix number of hidden neurons in neural networks. *Mathematical Problems in Engineering*, 2013, 1-11.

Shrivastava, V. (2012). Artificial Neural Network Based Optical Character Recognition. *Signal & Image Processing : An International Journal*, 3(5), 73–80.

Siimes, K. y Kämäri, J. (2003). A review of available pesticide leaching models: Selection of models for simulation of herbicide fate in Finnish sugar beet cultivation. *Boreal Environment Research*, 8(1), 31–51.

Singh, A., Imtiyaz, M., Isaac, R. K. y Denis, D. M. (2012). Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. *Agricultural Water Management*, 104, 113–120.

Singh, G., Spencer, W. F., Van Genuchten, M. T. y Kookana, R. S. (1992). Predicting pesticide transport in soil. *Pesticide Research Journal*, 4(1), 1–10.

Singh, R., Yadav, C. S., Verma, P. y Yadav, V. (2010). Optical Character Recognition (OCR) for Printed Devnagari Script Using Artificial Neural Network. *International Journal of Computer Science & Communication*, 1(1), 91–95.

Smith, R. E. (1992). OPUS: An Integrated Simulation Model for Transport Model of Nonpoint-source Pollutants at the Field Scale. Volume 1, Documentation. Department of Agriculture, Agricultural Research Service, U.S.

Smith, S. J., Sharpley, A. N. y Ahuja, L. R. (1993). Agricultural Chemical Discharge in Surface Water Runoff. *Journal of Environment Quality*, *22(3)*, 474-480.

Stathakis, D. (2009). How many hidden layers and nodes? *International Journal of Remote Sensing*, 30(8), 2133–2147.

Suárez, L. A. (2005). PRZM-3, a model for predicting pesticide and nitrogen fate in the crop root and unsaturated soil zones: users manual for release 3.12. 2. Environmental Protection Agency (EPA), Washington, DC.

Tuo, D., Xu, M., Zhao, Y. y Gao, L. (2015). Interactions between wind and water erosion change sediment yield and particle distribution under simulated conditions. *Journal of Arid Land*, 7(5), 590–598.

Walling, D. E. y Collins, A. L. (2008). The catchment sediment budget as a management tool. *Environmental Science and Policy*, 11(2), 136–143.

Wang, L., Zeng, Y. y Chen, T. (2015). Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 42(2), 855–863.

Wauchope, R. D., Yeh, S., Linders, J. B. H. J., Kloskowski, R., Tanaka, K., Rubin, B., Lane, M. (2002). Pesticide soil sorption parameters: theory, measurement, uses, limitations and reliability. *Pest Management Science*, 58(5), 419–445.

Widrow, B. y Lehr, M. (1990). 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, 78(9), 1415–1442.

Williams, J. R. (1995). The EPIC model. In Computer models of watershed hydrology. Water Resources Publications, Highlands Ranch, Colorado.

Williams, J. R. y Izaurralde, R. C. (2006). The APEX model. *Watershed Models*, 437–482.

Yadav, A. K. y Chandel, S. S. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*, 33, 772-781.

Yao, X., Yu, J., Jiang, H., Sun, W. y Li, Z. (2016). Roles of soil erodibility, rainfall erosivity and land use in affecting soil erosion at the basin scale. *Agricultural Water Management*, 174, 82–92.

Young, R. A., Olness, A. E., Mutchler, C. K. y Moldenhauer, W. C. (1984). Chemical and physical enrichments of sediment from cropland. *Transactions of the American Society of Agricultural Engineers*, 29(1), 165–169.

Zhang, G. P., Patuwo, E. B. y Michael Y., H. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35–62.