
MODELACIÓN DE LA ESTRUCTURA JERÁRQUICA DE MACROINVERTEBRADOS BENTÓNICOS A TRAVÉS DE REDES NEURONALES ARTIFICIALES

Modeling of the Hierarchical Structure of Freshwater Macroinvertebrates Using Artificial Neural Networks

CLAUDIA RICO¹, Bióloga; MAYERLY PAREDES¹, Bióloga;
NELSON FERNÁNDEZ^{1,2}, Biólogo Marino, M.Sc.Ph,D (c)

¹Centro de Investigaciones en Hidroinformática,
Universidad de Pamplona. Pamplona, Colombia.
<http://hidroinformatica.unipamplona.edu.co>
hidroinformatica@unipamplona.edu.co

²Autor de correspondencia: Profesor Titular Universidad de Pamplona.
Ciudad Universitaria Km 1, vía Bucaramanga. Pamplona, Colombia.
nfernandez@unipamplona.edu.co

Presentado 14 de agosto de 2008, aceptado junio 29 de 2009, correcciones julio 28 de 2009.

RESUMEN

El estudio de la estructura jerárquica de comunidades ecológicas, se ha sintetizado de manera regular a través de técnicas multivariadas de ordenación o clasificación. Sin embargo, al contarse actualmente con herramientas analíticas de computación bioinspirada provenientes de la inteligencia artificial, existe la oportunidad de establecer modelos ecológicos, con características deseables como flexibilidad, exactitud, robustez y confiabilidad. En este contexto, esta investigación utilizó dos métodos computacionales de utilidad en ecoinformática, referidos a redes neuronales artificiales (RNARs) para la modelación de la estructura jerárquica de una comunidad de macroinvertebrados bentónicos en términos de auto-organización y predicción. El primer método de modelación consistió en un mapa de auto-organización (MAU), una herramienta de aprendizaje no supervisado que clasificó las especies de macroinvertebrados; este MAU tomó en la capa de entrada la abundancia de cada taxa, y en la de salida proyectó su clasificación en 15 unidades y cuatro agrupamientos jerárquicos. La segunda RNA, correspondió a un Perceptrón multicapa de alimentación adelantada con algoritmo de retropropagación, que modeló separadamente la riqueza y la abundancia de *Ephemeroptera*, *Coleoptera* y *Trichoptera* (ECT), en función de nueve variables fisicoquímicas; la arquitectura del perceptrón correspondió a una constitución de nueve, siete, y una neurona en las capas de entrada, intermedia y salida, respectivamente. Los resultados sugieren que las RNARs utilizadas evidenciaron tanto los patrones jerárquicos, como los de riqueza y abundancia de ECT de manera adecuada, al tiempo que facilitaron el análisis de los datos y el entendimiento de la dinámica de la comunidad de macroinvertebrados, objeto de estudio.

Palabras clave: ecología computacional, ecología informática, mapa de auto-organización, perceptrón multicapa, Matlab.

ABSTRACT

The study of hierarchical structures of ecological communities has been synthesized in an ordinary way by means of multivariate techniques of ordination or clustering. Currently, analytical tools of bio-inspired computation belonging to the area of artificial intelligence are available to achieve ecological models with desirable characteristics, such as; flexibility, accuracy, robustness and reliability. In this context, this study employed two computational methods useful in ecoinformatics referring to artificial neural networks (ANN) for the modeling of the hierarchical structure of a benthic macroinvertebrate community in self-organization and prediction terms. The first ANN modeling method consisted of a Kohonen self-organization map (SOM), a non-supervised learning tool that classifies the species of macroinvertebrates; this SOM in the input layer gets the abundance of each 'taxa' from the data matrix, while in the output layer was visualized the computational results. Thus, in the output layer the species are organized in fifteen units and four hierarchical clusters. The second ANN method applied consisted of a multilayer feed-forward perceptron net with back-propagation algorithm to predict the three major insect orders; this means, *Ephemeroptera*, *Coleoptera* and *Trichoptera* (ECT) richness and abundance using a set of nine physical-chemical variables. This ANN architecture included a neuron for each environmental variable, a hidden layer with seven neurons and a neuron in the output layer for ECT prediction. The results suggest that both types of ANN used, SOM and perceptron, were correspondingly related to the hierarchical patterns and with the richness and abundance patterns' predictions, and gave the data analysis and understanding of the dynamic of the macroinvertebrates community, in a correct way.

Key words: Computational Ecology, Ecoinformatics, Self-Organisation Map, Multilayer Perceptron, Matlab.

INTRODUCCIÓN

Los macroinvertebrados bentónicos en sistemas lóticos se autoorganizan en ensamblajes heterogéneos de filos animales, en contraste con situaciones de estrés y/o diversos niveles de contaminación. Este hecho, los hace especialmente útiles para revelar, tanto el estado ecológico de los ecosistemas que habitan (Park *et ál.*, 2003a), como para dar una referencia sobre la calidad del agua (Hellawell, 1978; Fernández y Solano, 2005). Para evaluar el cambio de este tipo de comunidades de macroinvertebrados a partir de la variación de los datos de su abundancia en espacio y tiempo, se emplean diferentes tipos de análisis estadísticos tales como los índices de diversidad y análisis multivariados de clasificación u ordenación (Ramírez y Viña, 1998). Estos métodos permiten conjugar un gran número de variables dentro de un único análisis. Sin embargo, debido a la naturaleza compleja y no lineal de las interacciones que ocurren entre las especies, estos análisis pueden presentar efectos de distorsión y mala interpretación del conjunto de datos, a pesar de las posibilidades que brindan en cuanto al estudio e interpretaciones que se puedan dar. Recientemente como alternativa para la solución de este tipo de problema, se han utilizado técnicas de inteligencia artificial, enmarcadas dentro del nuevo paradigma de la

ecoinformática, como las redes neuronales artificiales (RNARs), que han mostrado excelentes resultados en ecosistemas acuáticos, forestales y agrícolas (Lek y Guegan, 2000; Recknagel, 2002).

Las RNARs fueron desarrolladas inicialmente para modelar funciones biológicas, y constituyen sistemas “inteligentes”, considerados máquinas de pensamiento que imitan el funcionamiento del cerebro humano y que pueden aprender de la experiencia, hasta el punto de resolver rápidamente problemas computacionales complejos (Lek y Guegan, 1999). El fundamento del funcionamiento de una red neuronal artificial básica, se inspira en la fisiología misma de las neuronas biológicas, en las cuales el impulso nervioso se propaga desde las dendritas, al cuerpo celular y posteriormente por el axón a las dendritas de otras neuronas, de manera que se conforma una red. Esto ha conducido a generar el artificio de las partes de la neurona biológica para desarrollar modelos computacionales sencillos de comportamiento neuronal como se representa en la figura 1, la cual ilustra una neurona artificial, unidad básica de una RNAR. En este modelo, los estímulos externos que llegan a la neurona, corresponden a diferentes valores de variables (X_i) y son, consecutivamente, multiplicados por una proporción o peso (W_i) que indica la fuerza de la conexión sináptica entre las entradas y las dendritas de las neuronas. Posteriormente, las señales ponderadas llegan al cuerpo celular del modelo, en el que son primero acumulados a través de una suma (Σ) y posteriormente valorados a través de una función de activación (Γ) que define el estado inhibido o excitado de la neurona; a partir de allí se da la trasmisión del resultado o salida a través del axón de la neurona (Y_i) hacia otras.

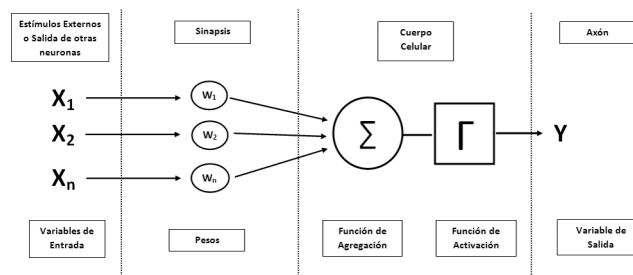


Figura 1. Modelo de neurona artificial inspirada en neurona biológica.

A partir de esta arquitectura sencilla o configuración topológica de modelo, se han dado variantes de manera que diversas investigaciones, han logrado el desarrollo de varios tipos de RNARs, apropiadas para resolver diferentes problemas, como de memoria auto-asociativa, generalización optimización, reducción de datos y control y predicción de tareas en diversos escenarios (Lek y Guegan, 2000). Cabe destacar, que el diseño de muchas RNARs ha sido realizado emulando aquellas que se consiguen en el sistema nervioso alrededor de los centros receptores de los sentidos.

En general los modelos neuronales corresponden a modelos en cascada y modelos realimentados (Colina y Rivas, 2001). En los primeros las neuronas son dispuestas en capas consecutivas, de forma que la entrada de una determinada capa es la salida de la capa precedente, con excepción de la primera capa (Fig. 2). Los modelos en cascada




Figura 2 Arquitectura genérica de redes en cascada, caso perceptrón.

no contemplan interconexiones entre neuronas de la misma capa, ni tampoco interconexiones de retroalimentación. Ejemplos de estas redes son las perceptrónicas multicapa, de base radial y el modelo de control cerebelar de Albus, entre muchos otros. Para el segundo caso, correspondiente a los modelos de retroalimentación se tiene como rasgo, la interconexión de la salida de una determinada capa con la entrada de la misma capa o de neuronas en capas precedentes (Fig. 3). Este evento le concede al modelo características de procesamiento dinámico. Como ejemplo tenemos las redes de Hopfield y las de Elman (Colina y Rivas, 2001.)




Figura 3 Arquitectura genérica de una red con retroalimentación, caso red de Hopfield.

Cronológicamente en el desarrollo de arquitecturas para las RNARs, se tiene en primera instancia el perceptrón (Rosenblatt, 1958), seguido por el elemento lineal adaptativo o ADALINE (Widrow y Hoff, 1960), una generalización del perceptrón, las redes de Hopfield (Hopfield, 1982), las redes de aprendizaje no supervisado como las de Kohonen (Kohonen, 1982a; Kohonen, 1984), las máquinas de Boltzmann (Ackley *et ál.*, 1985), y las redes neuronales artificiales multicapa con algoritmos de retropropagación (Rumelhart *et ál.*, 1986). Mayor descripción de estos métodos puede ser encontrada en libros como Freeman y Skapura, 1993 y Bishop, 1995. Se aclara que la selección del método de red depende de la naturaleza del problema a resolver como lo sugieren Lek y Guegan, 1999.

Recientemente las investigaciones con RNARs han demostrado un amplio crecimiento dada su aplicación, por ejemplo, en investigaciones físicas en el reconocimiento de la voz (Chu y Bose, 1998), en el reconocimiento de imágenes (Kung y Taur, 1995), en el área de la química (Kvasnicka, 1990; Wythoff *et al.*, 1990). En el campo de la biología, la mayoría de las aplicaciones de RNARs han sido en las áreas de medicina y biología molecular (Faraggi y Simon, 1995; Lo *et al.*, 1995). En ciencias ecológicas y ambientales, sin embargo, su uso inició en los noventa con unas cuantas aplicaciones en cuanto a modelaciones del efecto invernadero (Seginer *et al.*, 1994), la predicción de la producción de fitoplancton (Scardi, 1996), la predicción del cociente de producción de biomasa (P/B) en las poblaciones animales (Brey *et al.*, 1996), la dinámica espacial de peces (Giske *et al.*, 1998) y la predicción de la diversidad de peces (Guegan *et al.*, 1998), entre otros.

En cuanto a las RNARs no supervisadas, conocidas también como mapas de auto-organización (MAU; Kohonen, 1982b; Kohonen, 2001), han sido referidos como un método útil para extraer información desde sistemas complejos y no lineales, como los ecológicos. De la misma forma, esta técnica ha sido ampliamente utilizada en variedad de situaciones, como la determinación de relaciones entre comunidades ecológicas (Chon *et al.*, 1996), la modelación de datos de microsátélites (Giraudel *et al.*, 2000), las organizaciones de peces (Brosse *et al.*, 2001), la detección de patrones de diversidad de macroinvertebrados acuáticos (Cereghino *et al.*, 2003), y en la definición de estrategias de conservación para especies de peces endémicos amenazados (Park *et al.*, 2003b). En este sentido los MAU, son un método utilizado comúnmente para proyectar datos multidimensionales en un espacio bidimensional más reducido, que conserva las similitudes y diferencias entre ellos (Gevrey *et al.*, 2006).

Por otra parte, es apreciable la contribución al análisis de los efectos de las variables ambientales sobre los taxa que puede obtenerse a través de la utilización de redes como el perceptrón multicapa con algoritmo de retropropagación, especialmente en cuanto a la explicación de la variación presentada en las abundancias o riquezas de los taxa (Olden y Jackson, 2002). A partir de la implementación de este tipo de perceptrones, es posible predecir la ocurrencia de grupos, como los macroinvertebrados, desde los registros obtenidos de las variables ambientales determinadas en el monitoreo. Muestra de ello, son las investigaciones de Pudmenzky *et al.*, 1998, Walley y Fontama, 1998, Schleiter *et al.*, 1999, Hoang *et al.*, 2001.

En nuestro medio, investigaciones que hayan hecho uso de aplicaciones de RNARs son prácticamente inexistentes dada la novedad de la técnica. No obstante, la iniciativa más relacionada, aunque no expresamente referida al estudio de la estructura de comunidades ecológicas, corresponde al estudio de Gutiérrez *et al.*, 2004, quienes utilizaron herramientas de inteligencia artificial, en este caso lógica difusa neuro-adaptativa, para la evaluación de la bioindicación de la calidad del agua en la Sabana de Bogotá.

En el contexto anteriormente descrito, la actual investigación tuvo como propósito establecer la estructura jerárquica de la comunidad de macroinvertebrados bentónicos de la quebrada “La Tigra” en la granja experimental Villa Marina de la Universidad de Pamplona, ubicada en el municipio de Pamplonita (Norte de Santander), Colombia, a través de la aplicación, a los datos provenientes de seis jornadas de monitoreo, tanto de un mapa de auto-organización como de un perceptrón multicapa, enfocados a establecer la relación estructural de los taxa de dicha comunidad, además de la predicción de la

riqueza y abundancia de ECT a partir de la calidad fisicoquímica del agua, respectivamente. Cabe destacar, que lo aquí expuesto sigue una secuencia metodológica que pretende servir como referente de utilidad para investigaciones que deseen ahondar en este tipo de aproximación de modelación de comunidades biológicas. Al mismo tiempo, es apreciable el aporte de la implementación de nuevos enfoques de modelación ecológica de gran utilidad e interés, en la nueva era de la ecología computacional e informática.

MATERIALES Y MÉTODOS

DESCRIPCIÓN DEL ÁREA Y MONITOREOS

El desarrollo de la investigación se llevó a cabo en la quebrada “La Tigra” ubicada en la granja experimental Villa Marina, municipio de Pamplonita, vereda Matajira, Norte de Santander, Colombia. Su rango altitudinal está entre 1.190 y 2.200 msnm, la localización geográfica es 07°32' 12,78" N y 72°38' 1,61" W. Su temperatura media anual es de 25° C. La zona de vida pertenece al bioma de selva subandina (Camacho y Páez, 1990), que equivale a la zona de vida de bosque húmedo montano bajo (Holdridge, 1967). Allí, se realizaron seis monitoreos fisicoquímicos y biológicos, en tres estaciones ubicadas a 1.200 msnm; los cuales se realizaron en época de sequía en los meses diciembre de 2006 y febrero de 2007, y en época lluviosa en los meses septiembre y octubre de 2006, y abril y mayo de 2007. De esta forma se cubrieron periodos de alta y baja precipitación.

Entre las variables fisicoquímicas se determinaron temperatura, oxígeno disuelto, conductividad y pH, tomadas *in situ*, por medio del multiparámetro de campo Mettler Toledo. Las pruebas *ex situ* se realizaron en el Laboratorio de Control de Calidad de la Universidad de Pamplona de acuerdo con los protocolos de APHA, 1995. Las pruebas de alcalinidad y dureza se llevaron a cabo por métodos de titulación. Los sólidos suspendidos fueron valorados mediante el método de placa de evaporación. Para la demanda bioquímica de oxígeno, se siguió el protocolo del método respirométrico. Para nitritos se tuvo en cuenta el método espectrofotométrico y finalmente para fosfatos, el método del cloruro estagnoso.

Las muestras biológicas fueron colectadas en campo con un muestreador tipo Surber de 500 μm de ojo de malla, separadas fijadas y preservadas para su análisis en laboratorio donde fueron separadas en cajas petri. La identificación se realizó a través de las claves taxonómicas de Edmonson, 1959, Roldán, 1988, Mc. Cafferty, 1981, Needham y Needham, 1962, Brinkhurst y Marchese, 1962 y Pennak, 1978. La inspección se realizó con estereoscopio (Carl Zeiss, modelo DV4), oculares 25X y 10X para clasificar los especímenes a nivel de especie.

MODELACIÓN A TRAVÉS DE REDES NEURONALES ARTIFICIALES (RNARs)

Mapa de auto-organización (MAU). El MAU diseñado consistió de dos capas: una de entrada y otra de salida, conectadas por las intensidades de conexión (pesos). La capa de entrada tomó la información desde la matriz de abundancias de las especies de macroinvertebrados bentónicos colectadas, mientras que en la capa de salida se visualizaron los resultados computacionales correspondientes a los agrupamientos y ubicación de los patrones o especies. Cuando un vector de entrada X (abundancia del

taxa) fue enviado a través de la red, cada neurona, calculó la distancia entre el vector de peso V y el vector de entrada X . La capa de salida consistió en D neuronas de salida, las cuales fueron dispuestas en una grilla bidimensional para mejor visualización. Es de resaltar que al no existir reglas estrictas para escoger el número de neuronas de salida para establecer el tamaño del mapa adecuado, se optó por el entrenamiento del MAU con diferentes tamaños de mapa. El tamaño obtenido, fue de 5×3 unidades de salida; evento que se llevó a cabo sobre la base de los errores de cuantificación y topográfico. Así, para el primero se obtuvo un valor de 1.973, que representó la distancia promedio de cada vector de entrada y su mejor unidad de emparejado (MUE) y que decreció con el tamaño del mapa (Tabla 1). Cabe destacar que una unidad MAU tiene una alta probabilidad de ser ocupada por solo un vector de entrada en un mapa grande más que en uno pequeño, por lo que mapas pequeños tienen errores más bajos entre el vector de entrada y salida. Por su parte el topográfico, que para todos los casos fue bajo, indicó que la primera y segunda MUE de todos los vectores de entrada fueron hexágonos adyacentes y un entrenamiento suavizado se llevó a cabo en el MAU.

Combinación	3*2	4*2	5*2	4*3	6*2	7*2	5*3	8*2	6*3	9*2	5*4	10*2
Tamaño	6	8	10	12	12	14	15	16	18	18	20	20
Error Q	2,587	2,251	2,164	2,103	2,052	1,980	1,973	1,941	1,885	1,879	1,877	1,801
Error T	0	0	0	0,03125	0	0	0	0	0	0	0	0

Tabla 1 Errores en diferentes tamaños de mapas.

Algoritmo del mapa de auto-organización. El algoritmo del MAU puede ser descrito como sigue: cuando un vector de entrada X se presenta a la red, las neuronas en la capa de salida compiten con cada una de las otras y se escoge una ganadora (cuyo peso es la mínima distancia desde el vector de entrada). Esto es debido a que este tipo de aprendizaje es no-supervisado, motivo por el cual el algoritmo encuentra la manera en que los patrones se auto-organizan. Seguidamente, la neurona ganadora y sus vecinas predefinen en el algoritmo actualizado el peso de sus vectores acorde con la regla de aprendizaje del MAU de acuerdo a la ecuación 1:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \cdot h_{jc}(t) [x_i(t) - W_{ij}(t)] \quad \text{Ec. (1)}$$

Donde, $W_{ij}(t)$ es el peso entre la neurona i en la capa de entrada y la neurona j en la capa de salida en la iteración del tiempo; es un factor de tasa de aprendizaje el cual es una función decreciente de la iteración en el tiempo t , y $h_{jc}(t)$ es una función de vecindad que define el tamaño de la vecindad de la neurona ganadora (c) a ser actualizada durante el proceso de aprendizaje. La forma explícita de $h_{jc}(t)$ es como sigue (Ecuación 2):

$$h_{jc} = \exp \left[-\frac{|r_j - r_c|}{2\sigma^2(t)} \right] \quad \text{Ec. (2)}$$

Donde el parámetro $\sigma(t)$ es una función de iteración monotónicamente decreciente en el tiempo t y $|r_j - r_c|$ es la distancia (euclidiana para el caso) en el mapa de salida de

la neurona ganadora (c) y su neurona vecina (j). Este proceso es continuo hasta que se halla el criterio para detenerse, usualmente cuando el peso de los vectores se estabiliza o cuando el número de iteraciones es completado. El proceso de aprendizaje resulta en el entrenamiento de la red para los vectores de entrada y preserva la conexión de las intensidades en peso de los vectores. Al ser necesario subdividir el mapa en diferentes grupos acorde a la similaridad de los pesos de los vectores de las neuronas, se utilizó un análisis de agrupamiento con el método de Ward's basado en la medida de distancia euclidiana, evento que se realizó en el aplicativo past (<http://www.folk.uio.no/ohammer/past/download.html>). De manera alterna se aplicó el índice de agrupamiento de Davies-Boulding, previo análisis de la función de K-medias (Vesanto *et ál.*, 1999). El proceso de aprendizaje del MAU fue llevado a cabo usando la caja de herramientas MAU desarrollada por The Laboratory of Computer and Information Science, of Adaptive Informatics Research Centre of Helsinki University of Technology (<http://www.cis.hut.fi/projects/somtoolbox/>) programado en ambiente Matlab. Los métodos de inicialización y entrenamientos del MAU tenidos en cuenta fueron los sugeridos por los autores de la caja de herramientas lo que permitió la optimización del algoritmo (Vesanto *et ál.*, 1999). Las modificaciones hechas a la caja de herramientas para facilitar su implementación y mejorar la visualización de datos y resultados, fueron realizadas en el Centro Investigaciones en Hidroinformática de la Universidad de Pamplona.

MODELACIÓN Y SIMULACIÓN A TRAVÉS DEL PERCEPTRÓN MULTICAPA

El perceptrón utilizado correspondió a una red neuronal de alimentación adelantada, entrenada con un algoritmo de retropropagación (Rumelhart *et ál.*, 1986), con el objeto de modelar y simular posteriormente la proporción de *Ephemeroptera*, *Coleoptera* y *Trichoptera* (ECT), como función de las nueve variables ambientales. La arquitectura de la red (Fig. 4) incluyó una capa de entrada con una neurona por cada variable, una capa oculta con siete neuronas y una neurona en la capa de salida que representó la predicción del número ECT en un sitio. El número óptimo de neuronas en la capa oculta se obtuvo por el cálculo del mínimo error entre el valor observado y esperado, en 1.000 iteraciones. La tasa de aprendizaje n fue de 1^{-20} y el momentum o $\alpha = 0,1$. Con anticipación al entrena-




Figura 4. Arquitectura de la red neuronal.

miento las variables fueron normalizadas a unidades de z para estandarizar las escalas de medida entre las unidades de las variables de entrada. Para mayores detalles obsérvese Olden y Jackson, 2002. El modelo fue completamente programado en Matlab (www.matworks.com) en el centro de Hidroinformática de la Universidad de Pamplona, sobre la base de la caja de herramientas *Neural Networks*, de Matlab.

ENTRENAMIENTO Y SIMULACIÓN DE LA ARQUITECTURA NEURONAL ESTABLECIDA

Una vez realizado el entrenamiento con los datos de los monitoreos cuatro, cinco, dos y tres, tanto para predicción de riqueza como de abundancia ECT, se verificó la eficiencia de la arquitectura de la red en el proceso de simulación. Para tal fin se tuvo en cuenta los datos de los monitoreos uno y seis, evento que reportó altas eficiencias. Para la predicción de riqueza el error acumulado fue de 0,36% (Tabla 2), lo que demostró un ajuste en la modelación de un 99,64% de eficiencia. Igualmente, en la predicción de abundancia ECT (Tabla 3) se obtuvo un error acumulado de 0,05% lo que equivale a un 99,95% de eficiencia de la red. Es de importancia señalar que los monitoreos fueron seleccionados tanto para el entrenamiento como para la simulación de forma aleatoria.

Entrenamiento									
Riqueza ECT	M4		M5		M2		M3		Error
Total	Simulación	Riqueza	ECT	M6	M1	Error Total			
Esperado	0,340	0,410	0,410	0,530			Esperado	0,3800	0,4700
Calculado	0,340	0,410	0,410	0,530			Calculado	0,3797	0,4687
Residual	0	0	0	0	0	Residual 0,0003 0,0013 0,0016			
% error	0,00	0,00	0,00	0,00	0,00	% error 0,08 0,28 0,36			

Tabla 2 Rendimiento de la RNAR para predicción de riqueza ECT.

SIMULACIÓN DE LA CONTRIBUCIÓN DE LAS VARIABLES FÍSICOQUÍMICAS EN LA PREDICCIÓN DE RIQUEZA Y ABUNDANCIA ECT

Análisis de sensibilidad. En primer lugar se llevó a cabo el análisis de sensibilidad, el cual involucró el cambio de una variable en particular de entrada a través de su rango total, mientras todas las demás permanecieron constantes en sus percentiles de 20, 40, 60 y 80, de tal manera fue posible evaluar la contribución de cada variable en primera instancia para la riqueza y posteriormente para la abundancia ECT.

Método de Contribución de las variables. Posteriormente y de acuerdo con (Garson, 1991), se aplicó el método de la contribución de las variables fisicoquímicas en la predicción de ECT basado en la contribución de los pesos de la red neuronal. Este es uno de los enfoques más adecuados para la definición de las variables que mayor influencia tuvieron en la predicción.

Entrenamiento Abundancia ECT									
Total	M4		M5		M2		M3		Error
Total	Simulación	Abundancia	ECT	M6	M1	Error			
Esperado	0,730	0,780	0,780	0,840			Esperado	0,7500	0,8000
Calculado	0,730	0,780	0,780	0,840			Calculado	0,7499	0,7997
Residual	0	0	0	0	0	Residual 0,0001 0,0003 0,0004			
% error	0,00	0,00	0,00	0,00	0,00	% error 0,01 0,04 0,05			

Tabla 3. Rendimiento de la RNAR para predicción de abundancia ECT.

RESULTADOS

MODELACIÓN MEDIANTE EL MAPA DE AUTO-ORGANIZACIÓN (MAU)

Los resultados de la distribución de especies en el MAU, correspondieron a las abundancias de los taxa, registradas en razón a la similitud (basada en la distancia euclidiana) de su composición específica a través del entrenamiento del mismo. Así, se logró un conjunto de quince neuronas de acuerdo a sus relaciones topológicas, en un enrejado con un tamaño de mapa de 5 x 3. Seguidamente, se obtuvo en secuencia la proyección de los datos (Fig. 5), a partir de (i) la generación de un componente principal (Fig. 5a) en el que fue posible observar el número de especies asociadas a cada neurona, y (ii) la composición de un mapa de codificación y asociación de neuronas y especies incluidas en ellas. Así, se pudo establecer en la parte superior del MAU un mayor número de especies en cada neurona, en contraste con la parte media inferior. Igualmente, se ubicaron las unidades interpolativas (neuronas con cero eventos) que fueron útiles en la división de las asociaciones (Fig. 5b).




Figura 5. Proyección de los datos (a) componente principal de proyección. (Puntos negros: neuronas; cruces: especies) (b) mapa de codificación y agrupamiento. (Números: cantidad de especies agrupadas en cada neurona).

Las unidades definidas con anterioridad, fueron asociadas en cuatro agrupamientos (Fig. 6) establecidos de acuerdo al (i) método de Ward, entre los que se destacó la mayor similitud de los grupos I (neuronas 12, 11, 6, 2, 1 y 13) y II (neuronas 8 y 3) cercanas al 70%, en contraste con los grupos III (neuronas 10, 4 y 5) y IV (neuronas 14, 9 y 15) los cuales fueron mucho más diferentes que parecidas, en un nivel un tanto mayor al 50%. Cabe destacar que estos dos subgrupos tienen similitudes muy bajas inferiores al 10% (Fig. 6a). Lo anterior se confirmó además, a través del índice de agrupamiento de Davies-Boulding, previo análisis de la función de K-medias en el que se obtuvieron las mismas asociaciones establecidas en el método de Ward, con lo que se pudo establecer un plano que reflejó mayor visibilidad en cuanto a las agrupaciones de las unidades MAU obtenidas (Fig. 6b).




Figura 6. Clasificación de acuerdo con el mapa entrenado (a) método de Ward (b) índice de agrupamiento de Davies-Boulding, previo análisis de la función de K-medias. Los números arábigos coinciden con la posición de las neuronas y los romanos con los agrupamientos.

Seguidamente y de acuerdo con los agrupamientos obtenidos, se generó un mapa auto-organizado en el que fue posible visualizar las especies asociadas a cada neurona, y por consiguiente a las asociaciones descritas, lo que permitió determinar las categorías jerárquicas en las que se ubicaron las especies con iguales o similares patrones de abundancia, como se observa en la figura 7 en donde se integró las cantidades de especies en neuronas y patrón de abundancia en el sentido vertical y horizontal.

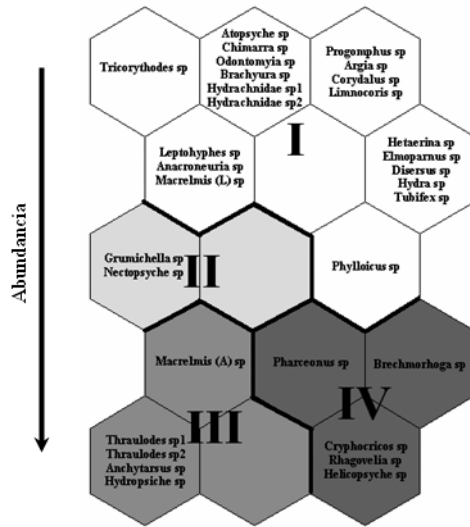


Figura 7. Agrupamientos de las categorías jerárquicas en el MAU.

El anterior evento se hizo más evidente al analizar los agrupamientos en cuanto a los valores arrojados de abundancia y riqueza, y abarcados en cada uno de ellos, de tal suerte que se observaron patrones opuestos; así mientras la abundancia aumentó del grupo I al IV, la riqueza en este mismo sentido disminuyó (Fig. 8). Al tener como base esta distribución se pudo determinar que las neuronas que registraron mayores abundancias y




Figura 8. Grupos MAU vs. abundancia y riqueza.

menores riquezas, específicamente las pertenecientes a los grupos III y IV, presentaron individuos de rasgos muy generalistas o euritípicos (sobre la base del índice de diversidad de Shannon-datos no publicados) entre los que se encuentran *Cryphocricos* sp., *Thraulodes* sp.1, *Thraulodes* sp.2, *Hydropsiche* sp., *Helicopsyche* sp., *Anchytarsus* sp. y *Pharceonus* sp. Contrariamente en las neuronas pertenecientes a los agrupamientos I y II, que registraron bajas abundancias y altas riquezas se observaron individuos estenotípicos o raros como *Progomphus* sp., *Chimarra* sp., *Corydalus* sp., *Limnocoris* sp., *Argia* sp., *Odontomyia* sp. y *Brachyura* sp. Una vez representada la estructura jerárquica de la comunidad de macroinvertebrados bentónicos de la quebrada “La Tigra”, se observó en detalle que en el agrupamiento I se encuentran las especies que exhibieron abundancias más bajas y se distribuyen en las neuronas 1 (*Tricorythodes* sp.), 2 (*Leptohyphes* sp., *Anacroneuria* sp. y *Macrelmis* sp. (L), 6 (*Atopsyche* sp., *Chimarra* sp., *Odontomyia* sp., *Brachyura* sp. e *Hydrachnidae* sp. 1 y sp. 2), 11 (*Progomphus* sp., *Argia* sp., *Corydalus* sp. y *Limnocoris* sp.), 12 (*Hetaerina* sp., *Elmoparnus* sp., *Disersus* sp., *Hydra* sp. y *Tubifex* sp.) y 13 (*Phylloicus* sp.). En la neurona 7 no se registraron especies, lo cual indica que esta separa no solo las neuronas de este agrupamiento, sino que también lo separa de los agrupamientos II y IV. Para este agrupamiento, en términos de trofodinámica se observó que en las neuronas 1, 2, 6 y 12 se ubicaron especies como *Atopsyche* sp., *Odontomyia* sp., *Leptohyphes* sp., *Macrelmis* sp. (L), *Elmoparnus* sp. y *Disersus* sp., entre otras, que son colectoras y se alimentan del perifiton raspado de rocas o de materia orgánica particulada fina y a su vez sirven de alimento a macroinvertebrados predadores como *Progomphus* sp., *Argia* sp., *Corydalus* sp. y *Limnocoris* sp., agrupados en la neurona 11. El agrupamiento dos fue más pequeño y reunió especies con abundancias un poco más elevadas al agrupamiento anterior, pero que igualmente no fueron significativas. Este agrupamiento comprendió las neuronas 3 y 8. En la neurona 3 se registraron especies como *Grumichella* sp. y *Nectopsyche* sp., mientras que en la neurona 8 no se agruparon individuos, dado que esta neurona dividió el agrupamiento II de los tres restantes. Estas especies son colectores y trituradores de algas y de materia orgánica particulada fina y gruesa, y poseen una glándula salival modificada que les permite producir seda, tanto para construir casas o refugios con gran variedad de materiales (arena, hojas y fragmentos pequeños de piedras y palos), como para sostenerse en el sustrato, construir redes para filtrar el agua o para obtener detritus de ella (Roldán, 1988).

El agrupamiento III, según el mapa y las flechas indicadoras (Fig. 7), exhibió las especies con mayores niveles de abundancia registrados. Comprendió las neuronas 4, 5 y 10. En la neurona 4 solo se asoció *Macrelmis* sp. (A), en 5 *Thraulodes* sp.1 y sp.2, *Anchytarsus* sp. e *Hydropsiche* sp., mientras que la neurona 10 no registró especies asociadas dentro de ella y sirvió para separar el agrupamiento en mención del agrupamiento IV. En este grupo se destaca la pertenencia de dos especies al género *Thraulodes* del orden Ephemeroptera, su similitud según el grupo alimenticio y sus coincidencias adaptativas. Las dos especies del género mencionado junto con *Hydropsiche* sp. son individuos colectores y filtradores de materia orgánica particulada fina, mientras que *Anchytarsus* sp. y *Macrelmis* (A) sp. son consumidores de algas, estos individuos poseen partes bucales especializadas con las cuales raspan o arañan de las piedras y rocas el alimento que ingieren. Los individuos registrados en esta asociación pertenecen a los órdenes taxonómicos Ephemeroptera, Coleoptera y Trichoptera, los cuales exhiben mayor representatividad en sistemas lóticos y presentan hábitos sedentarios ya que viven adheridos a gravas, rocas, raíces y vegetación acuática, lo que dificulta su predación (Roldán, 1988).

Finalmente el agrupamiento IV, conformado por las neuronas 9, 14 y 15, mostró abundancias intermedias, menores al agrupamiento III pero con mayores niveles a los agrupamientos I y II. En la neurona nueve solo se presentó *Pharceonus* sp., en la 14 *Brechmorhoga* sp. y en la 15 *Cryphocricos* sp., *Rhagovelia* sp. y *Helicopsyche* sp. Estas especies exhibieron gran similitud en cuanto a adaptación al sustrato y fueron colectadas en los mismos sitios de muestreo, lo cual indica que también comparten sus preferencias tróficas. Las especies registradas en esta agrupación son básicamente predadoras en el caso de *Brechmorhoga* sp., *Cryphocricos* sp. y *Rhagovelia* sp. y consumidoras de algas como *Pharceonus* sp. y *Helicopsyche* sp. Igual al grupo anterior estos individuos pertenecen a órdenes taxonómicos caracterizados por presentar mayores abundancias en sistemas lóticos.

DINÁMICA ESPACIO-TEMPORAL DE LA COMUNIDAD DE MACROINVERTEBRADOS

La dinámica espacio-temporal y por ende los cambios en la estructura de la comunidad, para cada uno de los monitoreos y estaciones, son visibles en los MAUs reportados en la figura 9. En estos mapas se observó el cambio en la abundancia de especies en cada una de las neuronas establecidas anteriormente. Las neuronas más oscuras represen-




Figura 9. Cambios espacio-temporales de la estructura de la comunidad en el MAU.

taron abundancias más bajas, e inversamente las más claras correspondieron a neuronas que asociaron especies con mayores niveles de abundancia.

Dado que la sola inspección visual dificulta la definición de subgrupos y asociaciones de los mapas con sus respectivas características, se hizo necesario realizar un análisis de clasificación nuevamente a través del método de Ward, a partir de la matriz de pesos del MAU entrenado (Tabla 4), el cual se visualiza en la figura 10. Como resultado en este análisis de clasificación se obtuvieron dos grupos principales y cuatro subgrupos en dependencia de la similitud hallada entre cada uno de los monitoreos en las respectivas estaciones.

	M1 E1	M1 E2	M1 E3	M2 E1	M2 E2	M2 E3	M3 E1	M3 E2	M3 E3	M4 E1	M4 E2	M4 E3	M5 E1	M5 E2	M5 E3	M6 E1	M6 E2	M6 E3
N1	-0,43	-0,47	-0,46	-0,42	-0,52	-0,62	-0,46	-0,38	-0,52	-0,34	-0,30	-0,44	-0,27	-0,40	-0,70	-0,40	-0,40	-0,33
N2	-0,28	-0,29	-0,38	-0,28	-0,39	-0,55	-0,27	-0,23	-0,47	-0,31	-0,15	-0,38	-0,26	-0,32	-0,57	-0,29	-0,34	-0,32
N3	0,37	0,24	-0,09	0,34	0,06	-0,29	0,47	0,22	-0,33	0,27	0,33	-0,15	0,17	0,07	-0,41	0,19	-0,03	-0,28
N4	0,92	0,79	0,29	0,96	0,74	0,29	0,88	0,76	0,16	0,79	0,61	0,32	0,64	0,62	0,19	0,74	0,56	0,05
N5	1,61	1,35	0,57	1,65	1,44	0,76	1,22	1,34	0,30	1,37	0,92	0,46	1,48	1,42	0,43	1,45	1,36	0,04
N6	-0,51	-0,56	-0,46	-0,50	-0,55	-0,55	-0,56	-0,50	-0,49	-0,49	-0,43	-0,46	-0,38	-0,44	-0,61	-0,45	-0,39	-0,30
N7	-0,45	-0,44	-0,36	-0,46	-0,44	-0,46	-0,46	-0,44	-0,39	-0,48	-0,36	-0,40	-0,39	-0,40	-0,34	-0,39	-0,39	-0,27
N8	0,01	0,05	-0,15	0,03	-0,06	-0,27	0,10	0,02	-0,18	-0,07	0,07	-0,09	-0,13	-0,14	-0,11	-0,05	-0,18	-0,13
N9	0,28	0,47	0,40	0,34	0,43	0,50	0,46	0,43	0,65	0,27	0,39	0,68	0,04	0,17	0,72	0,21	0,16	0,52
N10	0,97	1,03	0,72	1,05	1,06	0,94	0,95	1,05	0,85	0,93	0,78	0,90	0,75	0,89	0,78	0,87	0,89	0,59
N11	-0,57	-0,63	-0,41	-0,59	-0,57	-0,45	-0,60	-0,61	-0,43	-0,56	-0,52	-0,49	-0,44	-0,46	-0,44	-0,47	-0,38	-0,31
N12	-0,55	-0,54	-0,28	-0,59	-0,47	-0,36	-0,55	-0,58	-0,29	-0,55	-0,50	-0,43	-0,46	-0,44	-0,11	-0,44	-0,44	-0,25
N13	-0,33	-0,18	-0,09	-0,33	-0,18	-0,13	-0,23	-0,27	0,02	-0,36	-0,21	-0,05	-0,36	-0,32	0,30	-0,28	-0,35	0,03
N14	-0,15	0,19	0,53	-0,13	0,17	0,71	0,11	0,11	0,93	-0,07	0,15	0,80	-0,27	-0,08	1,10	-0,12	-0,08	0,79
N15	0,25	0,67	0,99	0,30	0,65	1,31	0,58	0,68	1,54	0,43	0,62	1,41	0,03	0,37	1,31	0,24	0,44	1,27

Tabla 4. Matriz de pesos del MAU entrenado.

A partir de los anteriores hallazgos explícitos en las figuras 9 y 10, fue posible determinar la existencia de dos grandes grupos (I y II) que definieron asociaciones más finas. El agrupamiento I que subdividió las asociaciones A y B, y que presentó dominancias de las especies *Cryphocricos* sp., *Rhagovelia* sp. y *Helicopsyche* sp., registró para el subgrupo A mayores niveles de abundancia de los taxa mencionados seguidos por abundancias intermedias de *Thraulodes* sp. 1 y sp. 2, *Anchytarsus* sp. e *Hydropsiche* sp., en los monitoreos uno y dos en la estación tres, es decir estuvieron favorecidos por época de lluvias ocurridas en el tiempo de su colecta y por las características del sustrato encontrado en la estación tres, caracterizado básicamente por mayor proporción de material vegetal, raíces de plantas acuáticas y en general hojas en descomposición, lo cual facilitó su alimentación y desarrollo según sus estructuras corporales. Para las demás agrupaciones se presentan mínimas abundancias ya que contrariamente a las especies mencionadas la época y el sitio de monitoreo no favoreció su proliferación.

El subgrupo B fue muy similar al anterior, pero en este se dieron máximas abundancias solo para *Cryphocricos* sp., *Rhagovelia* sp. y *Helicopsyche* sp., es decir, no se favorecieron abundancias intermedias de otros taxa debido a variaciones en las épocas climáticas registradas en los monitoreos tres, cuatro, cinco y seis. Igual al subgrupo A, las máximas




Figura 10. Análisis de clasificación a partir de la matriz de pesos del MAU a través del Método de Ward.

abundancias de estos individuos son favorecidas por el tipo de sustrato registrado en la estación 3 en la totalidad de monitoreos.

El grupo II por su parte, se subdividió igualmente en dos asociaciones (C y D); no obstante registró mayores variaciones en cada una de ellas. En general este agrupamiento se caracterizó por la dominancia de *Thraulodes* sp. 1 y sp. 2, *Anchytarsus* sp. e *Hydropsiche* sp. En el subgrupo C se presentó dominancia de las especies mencionadas junto con abundancias intermedias de *Cryphocricos* sp., *Rhagovelia* sp., *Helicopsyche* sp. y *Macrelmis* sp. (A). Estas especies registradas en los agrupamientos III y IV del MAU general (Fig. 7) aumentaron sus niveles de abundancia en los monitoreos tres y cuatro en las estaciones uno y dos, debido a la época de lluvias registrada para dichos muestreos y al sustrato de esta área. En la estación uno el sustrato es totalmente opuesto al descrito para la estación tres, ya que este no presenta ningún tipo de material vegetal, se caracteriza por ser completamente arenoso con corrientes de agua más rápidas. En la estación dos el sustrato presentó características intermedias de las dos estaciones descritas, allí se observó tanto material vegetal como suelos arenosos.

En los agrupamientos I y II del MAU general se observaron abundancias muy mínimas lo cual indicó que a las especies allí clasificadas no fueron favorecidas por la dinámica espacio-temporal registrada en ese momento e igualmente presentan una baja dominancia en la comunidad. En los monitoreos uno, dos y tres, básicamente en la estación dos la dinámica cambió un poco, en los agrupamientos I y II, continuaron las mínimas abundancias registradas, pero el agrupamiento III aumentó el nivel de abundancia específicamente para *Thraulodes* sp.1, *Thraulodes* sp.2, *Anchytarsus* sp. e *Hydropsiche* sp. Lo anterior indicó que aunque estas especies se presentaron en las estaciones uno y dos el sustrato que más les favoreció fue el sustrato intermedio de la estación dos, lo cual perjudicó el nivel de abundancia de especies como *Cryphocricos* sp., *Rhagovelia* sp. y *Helicopsyche* sp. cuyo desarrollo y proliferación se favoreció principalmente en la estación 3.

El subgrupo D igual que el C presentó dominancia de *Thraulodes* sp.1 y sp.2, *Anchytarsus* sp. e *Hydropsiche* sp., pero en este caso acompañada en menor proporción de *Macrelmis* sp. (L). Para la totalidad de monitoreos, igual a los anteriores grupos la dinámica tanto de espacio como de tiempo no favoreció abundancias en los agrupamientos I y II. En las estaciones uno y dos, en el agrupamiento III aumentaron los niveles de abundancia para todos los taxa allí asociados y contrariamente en el agrupamiento IV los niveles de abundancia disminuyeron con respecto a los grupos anteriores. La explicación a este cambio se observó al comparar las estaciones de monitoreo ya que los taxa pertenecientes al agrupamiento IV del MAU general registraron sus mayores abundancias en la estación tres en la totalidad de monitoreos, es decir que su abundancia dependió directamente del tipo de sustrato presente en el hábitat en el cual se desarrollaron y fue independiente de la época climática registrada. Este hecho cambió al observar las estaciones uno y dos ya que en ellas se favoreció la proliferación de los taxa pertenecientes al agrupamiento III, cuya fisiología fue más adaptable a los sustratos de estas estaciones.

PREDICCIÓN DE RIQUEZA Y ABUNDANCIA (ECT)

Esta predicción se realizó sobre la base de los valores reportados para un conjunto de nueve variables, de las que se listan sus correspondientes estadísticas descriptivas en la tabla 5.

Variable	Unidades	Mínimo	Máximo	Promedio	Desviación típica
pH	Unidades de pH	6,300	8,700	7,750	0,834
Conductividad	µSm/cm	114,300	147,600	136,533	12,543
Sólidos Suspendidos	mg/L	0,900	4,110	2,295	1,443
Dureza	mg/L	58,000	71,000	63,500	4,416
Alcalinidad	mg/L	65,000	105,000	74,500	15,215
Oxígeno disuelto	% Saturación	53,000	129,000	91,833	32,183
Nitritos	mg/L	0,001	0,006	0,003	0,002
Fósforo	mg/L	0,020	0,050	0,037	0,014
Temperatura	T °C	17,500	21,300	19,267	1,479

Tabla 5. Estadísticas descriptivas de las variables fisicoquímicas.

ANÁLISIS DE SENSIBILIDAD

Este análisis permitió obtener las curvas de respuesta en la predicción de riqueza y abundancia ECT, y correspondieron, para el primer caso, en su mayoría a relaciones de tipo lineal indirecto (de pendiente negativa) en las que se involucraron las variables pH, sólidos suspendidos, dureza, alcalinidad y temperatura, lo que quiere decir que valores altos de todas ellas no aumentaron significativamente la proporción en riqueza de ECT, cuando las demás variables se mantuvieron en el percentil del 60, excepto la temperatura ya que en este caso las demás variables se mantuvieron en el percentil del 80. Por su parte la conductividad fue la única variable del proceso de mineralización del que la riqueza ECT dependió de manera directa (Fig. 11), es decir aumentó proporcionalmente cuando ella también lo hizo, así los mayores valores de riqueza 0,4187 se alcanzaron a valores de conductividad de 147 mg/L, cuando las demás variables permanecieron en el percentil de 40. Para las variables restantes se hallaron curvas de respuesta con pendientes




Figura 11. Contribución directa de la conductividad a la riqueza ECT desde el análisis de sensibilidad ilustrando las curvas de respuesta de la red neuronal a los cambios en esta variable con todas las otras variables sostenidas en sus percentiles de 20 (línea recta), 40 (asteriscos), 60 (triángulos) y 80 (puntos negros).

cercanas a cero, lo que demostró su mínima influencia, como el caso del oxígeno disuelto, nitritos y fósforo.

Las curvas de respuesta observadas en la predicción de la abundancia mostraron que variables como conductividad, sólidos suspendidos, dureza, alcalinidad, oxígeno disuelto y temperatura, no influenciaron significativamente dicha predicción. Inversamente, la variable de la cual la abundancia ECT dependió de manera directa fue el pH (Fig. 12), es decir aumentó proporcionalmente cuando el también lo hizo, así los mayores valores de abundancia (0,79) se alcanzaron a valores de pH de 8,7, cuando las demás variables permanecieron en el percentil del 40%. Para las demás variables se obtuvieron curvas de respuesta con pendientes cercanas a cero.




Figura 12. Contribución directa del pH a la abundancia ECT desde el análisis de sensibilidad ilustrando las curvas de respuesta de la red neuronal a los cambios en esta variable con todas las otras variables sostenidas en sus percentiles de 20 (línea recta), 40 (asteriscos), 60 (triángulos) y 80 (puntos negros).

CONTRIBUCIÓN DE LAS VARIABLES FISCOQUÍMICAS EN LA PREDICCIÓN A PARTIR DE LOS PESOS DE LA RED NEURONAL

En la figura 13, se hace evidente que la conductividad, es la variable que presentó mayor contribución en la predicción de la riqueza ECT, con un valor porcentual de 56,5% del total de la predicción. Este resultado presenta coherencia con lo observado en el análisis de sensibilidad, en el que esta variable registró mayor peso en la predicción. Muy cerca

a la conductividad se presentaron variables fisicoquímicas como alcalinidad y dureza, que en conjunto con esta representan procesos de mineralización en corrientes acuáticas. Entre las variables que presentaron porcentajes de contribución más bajos estuvieron la temperatura, el pH, el fósforo y los nitritos, cuyos rangos de predicción de riqueza ECT se dieron entre el 7 y el 10%.




Figura 13 Importancia de las variables fisicoquímicas en la predicción de la riqueza ECT.

Igualmente, en la figura 14, se distingue que las variables que generaron mayor importancia en la predicción de abundancia de ECT, fueron temperatura y pH con un valor de importancia de 32,7%. En este caso se observó similitud entre los dos métodos en cuanto a que la variable determinante de la predicción de la abundancia ECT fue el pH, sin embargo, las demás variables presentaron porcentajes de importancia muy similares en los dos procedimientos. Así, entre las variables que registraron menor porcentaje de predicción se encontraron los nitritos con 7%, los sólidos suspendidos con 9,8% y el oxígeno disuelto con 10% de predicción.




Figura 14. Importancia de las variables fisicoquímicas en la predicción de la abundancia ECT.

DISCUSIÓN

En cuanto a la estructura de las categorías jerárquicas reveladas en el MUA, y al tener como base, en primer lugar el tamaño del mapa obtenido que facilita y hace más explícita la visualización de los resultados, y en segundo lugar, la disposición de cada uno de los taxa en dicho mapa, producto de la relación de sus abundancias en los

respectivos muestreos y estaciones, se pudieron observar los cuatro agrupamientos representantes de la estructura jerárquica de la comunidad de macroinvertebrados bentónicos de la quebrada “La Tigra”, los cuales presentaron características bioecológicas que sustentaron su asociación, como el hecho de pertenecer a un mismo orden taxonómico o poseer adaptaciones tróficas particulares definidas por el medio en el cual se encuentran y por su fisiología. Estos agrupamientos en términos de la estructura definen el flujo de materia y energía que se da en el sistema producto del autoensamble e interacción de unos y otros taxa a partir de sus adaptaciones tróficas, como se muestra en la figura 15. En esta figura, es notable como en todos los grupos se da la presencia de especies colectoras bien sea raspadoras o colectoras que son la base de los consumidores primarios que definen la ruta de pastoreo y que coexisten, o mejor son el soporte de consumidores de segundo orden como los hallados en los grupos I y IV. Por su parte los invertebrados colectores, filtradores o trituradores de los grupos II y III, son quienes transforman la energía proveniente de la materia orgánica particulada gruesa y fina, así como de las plantas para el caso de los trituradores del grupo II. Cabe destacar que en este flujo, todos los grupos contribuyen a la generación de materia orgánica particulada fina como producto de procesos de egestión, como lo refiere Oertli, 1993.

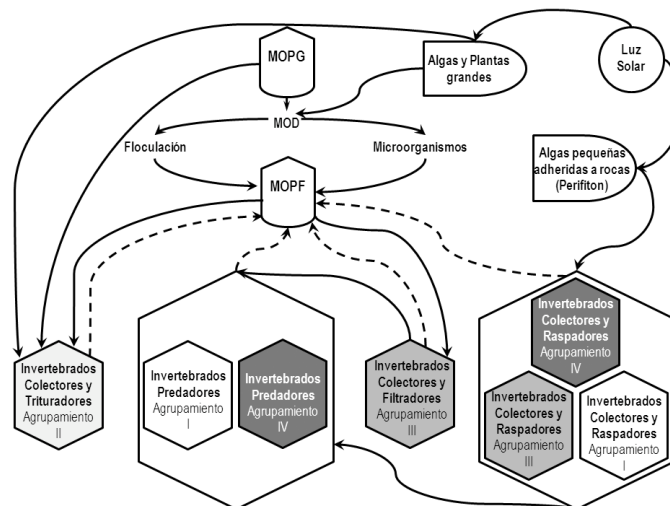


Figura 15. Modelo de flujo de materia y energía para la comunidad de macroinvertebrados, a partir de los resultados obtenidos del MAU. MOPG: materia orgánica particulada gruesa; MOPF: materia orgánica particulada fina; MOD: materia orgánica disuelta.

Lo anterior es una clara muestra del conjunto de procesos que se dan en el ecosistema sobre la base de las retro-alimentaciones entre y dentro de las especies, que regulan a su vez la propia estructura de la comunidad de macroinvertebrados. Todo esto se da en un contexto de la emergencia de una estructura y función global, representados, en la generación de los patrones de abundancia y diversidad observados, que vienen desde las interacciones locales entre las especies de macroinvertebrados hallados, y los cuales han sido correctamente representados a nivel estructural en el MAU implementado.

En cuanto a la variación espacio-temporal registrada en la figura 9, es apreciable que los cambios espacio-temporales de la comunidad se sustentaron principalmente en la secuencia intercalada de periodos de lluvias y de sequía, con la consecuencia de que para los periodos lluviosos siempre fue hallada la mayor diversidad y riqueza de especies. Este hecho es de especial importancia si se considera que autores como Lytle y Poff, 2004, han manifestado la importancia de las precipitaciones y su influencia directa en los regímenes de caudales que generan patrones estacionales, como un factor de selección natural que a la postre puede definirse como un factor evolutivo entre las especies de macroinvertebrados. Adicionalmente, el sustrato constituyó otra variable esencial como se pudo desprender de las agrupaciones en el MAU espacio-temporal ya que se observó su influencia en la composición espacial de los taxa, como en el caso de la estación 3 mantuvo la dominancia de las mismas especies con independencia de la época climática y de los factores fisicoquímicos.

Por otra parte, y para el caso de la influencia de los factores ambientales del que se hizo mención en el apartado de análisis de sensibilidad, la conductividad, fue la única variable fisicoquímica que tuvo relación directa con el aumento de riqueza en la quebrada “La Tigra” (Fig. 11), niveles altos de alrededor de 147 mS/cm, favorecieron el aumento de taxa de los órdenes Ephemeroptera, Coleoptera y Trichoptera con valores de riqueza de 0,4187. Una de las razones que podría sustentar la incidencia de la conductividad en el aumento de la riqueza ECT, estaría dada por la ocurrencia de algunos aniones (p.e. cloruro, nitrato, sulfato, y aniones del fosfato) o cationes (sodio, magnesio, calcio, hierro, y aluminio), producto de la escorrentía y los impactos antropogénicos que tienen las actividades cercanas a la quebrada como el ecoturismo, hecho que coincide con lo hallado por Azrina *et ál.*, 2006, quien encontró correlaciones altamente significativas ($p < 0,001$) con valores de $r = 0,73$ entre la conductividad y el índice de equitabilidad (N4), en niveles bajos e intermedios de contaminación. Autores como Park *et ál.*, 2007, han reportado riquezas intermedias de macroinvertebrados bentónicos a niveles de conductividad altos e intermedios que favorecen principalmente a especies del orden Ephemeroptera, evento que coincide con la predicción del perceptrón para este y otros dos órdenes como fueron Coleoptera y Trichoptera. Paralelamente, en el análisis de la evaluación de la contribución de variables fisicoquímicas en la predicción de la riqueza ECT, se observó, más allá del efecto separado de la conductividad, la incidencia de la alcalinidad y dureza, que en conjunto con la primera denotaron un proceso de mineralización en las aguas de la quebrada “la Tigra”. Lo que demostraría que los taxa de ECT de la quebrada se beneficiaron en cuanto a su número por el proceso de mineralización. Este evento se daría como producto de oxidación-reducción de la materia orgánica, lo que proporcionaría un ambiente más favorable. El oxígeno disuelto, también evidenció un efecto importante en la riqueza ECT, con un porcentaje de contribución del 79%, el papel biológico de esta variable es fundamental, pues define la presencia o ausencia potencial de todas las especies acuáticas (Ramírez y Viña, 1998).

En lo atinente al análisis de sensibilidad que determinó la predicción para la abundancia de ECT (Fig. 12), se dio la influencia marcada del pH de manera directa, es decir su aumento en un rango de 6,3 a 8,7 unidades favoreció el aumento en número de individuos de los diferentes taxa de este grupo mayoritario. El sustento de ello se hallaría de manera lógica en que este rango se halla dentro de las condiciones cercanas a la neutralidad (pH

7), lo que a su vez favoreció, más que afectar, los procesos osmorregulatorios de iones como el sodio y el calcio, entre otros (Okland y Okland, 1986), la fisiología y la cantidad y distribución de individuos de macroinvertebrados bentónicos. En este sentido, Allan y Castillo, 2007, encontraron que a pH menores a 5,7 unidades, se presenta una fauna macrobéntica muy característica y limitada, consistente de muy pocos individuos de los órdenes Plecoptera, Trichoptera y Diptera (PTD); de manera paralela a niveles de pH mayores de 5,7 unidades, se dieron taxa de los órdenes PTD, junto con nuevos órdenes entre los que se encuentran Ephemeroptera y Amphipoda. Consecuentemente, los resultados obtenidos en el análisis de contribución definieron al pH en conjunto con la temperatura como las variables de mayor importancia en la predicción, con valores de 14,5% y 17,5%, respectivamente. En cuanto a la temperatura se tiene que es uno de los factores ambientales que más influyen en la reproducción proliferación y supervivencia de organismos especialmente cuando aumentan las tasas de reproducción (Allan y Castillo, 2007), evento que podría ser el sustento del aumento en la abundancia de los macroinvertebrados bentónicos de la quebrada “la Tigra”. De otra lado, se pudieron observar las variables que denotan el proceso de mineralización (dureza, conductividad, alcalinidad), las cuales presentaron contribuciones entre el 10% y el 11% aproximadamente, valores muy cercanos al obtenido para el pH, por lo que de manera subyacente se podría estimar que poseen además un efecto significativo en términos de sinergia sobre la abundancia. Sobre la base de esta última apreciación se podría sugerir que las variables relacionadas con procesos de mineralización, en pHs tendientes a la neutralidad y temperaturas entre 17 °C y 20 °C fueron los promotores y predictores de la riqueza y abundancia para ECT. Finalmente se tiene que, en cuanto a la técnica es importante reconocer que redes de retropropagación, como la utilizada, son más competentes al realizar predicciones que los modelos de regresión (Lek *et ál.*, 1996, Paruelo y Tomasel, 1997), de manera que se puede estimar mayor confiabilidad en los resultados discutidos con anterioridad.

CONCLUSIONES

Los resultados sugieren que la aplicación de técnicas de inteligencia artificial, específicamente de redes neuronales, como el caso de la técnica de aprendizaje no supervisado o MAU y la técnica para la predicción o perceptrón multicapa con alimentación adelantada y algoritmo de retropropagación, constituyen una aproximación robusta y eficaz de modelación de comunidades biológicas como el caso de los macroinvertebrados bentónicos, del cual se pudo lograr el establecimiento de la estructura y clasificación jerárquica de dicha comunidad, así como el entendimiento de su dinámica a partir de las variables ambientales. En este sentido el presente trabajo exhibió un enfoque metodológico detallado desde una perspectiva didáctica de secuencialidad que puede servir como referente para futuras aplicaciones en el estudio de la ecología de comunidades. En cuanto al MAU utilizado, fue apreciable que este mostró un alto rendimiento en cuanto a la visualización y abstracción de datos, a la vez que se constituyó como un enfoque práctico en cuanto a su análisis. Esta red entrenada clasificó eficientemente las especies de macroinvertebrados bentónicos para lo cual se estableció como patrón sus abundancias en espacio y tiempo y a partir de ellas la generación de las agrupaciones que para el caso estuvieron dadas por el gradiente de menor a mayor abundancia y

mayor a menor riqueza en el mapa en sentido vertical. Adicionalmente el MAU permitió observar la dinámica espacio-temporal de la comunidad, reflejada en los cambios de abundancia en cada monitoreo y en cada estación, como producto de la auto-organización de la comunidad.

Referente al evento de la predicción realizada a través del perceptrón multicapa, de los dos descriptores de la estructura de la comunidad como lo fueron la riqueza y la abundancia de los órdenes ECT, se pudo establecer que al realizar los respectivos entrenamientos y simulaciones el porcentaje de error disminuyó hasta obtener eficiencias óptimas de predicción. A partir de este ajuste, se obtuvieron influencias que confirmaron la incidencia de variables especialmente relacionadas con la mineralización, de manera que se sugiere que esta metodología puede ser utilizada como herramienta para observar las relaciones que se presentan entre comunidades biológicas y las condiciones del medio en el cual estas se presentan de manera más ajustada de lo que podría hallarse a través de modelos de regresión, sobre todo al hacer utilización de el análisis de sensibilidad y el enfoque de la contribución de los pesos que explican de mejor manera las relaciones entre el componente biológico y las características fisicoquímicas de su entorno.

AGRADECIMIENTOS

Los autores desean expresar sus agradecimientos a los ingenieros del Centro de Hidroinformática de la Universidad de Pamplona, Edgar Pérez (Paul) y Cristian Suárez por su apoyo en el diseño de las redes. Igualmente a los Biólogos Alberto Ramírez en la Universidad Javeriana y Diego Lizcano en la Universidad de Pamplona por sus consideraciones al manuscrito.

BIBLIOGRAFÍA

ACKLEY DH, HINTON GE, SEJNOWSKI TJ. A learning algorithm for Boltzmann machines. *Cogn Sci.* 1985;9:147-169.

ALLAN D, CASTILLO M. *Stream Ecology*. Dordrecht, The Netherlands. 2 ed; 2007.

APHA, AWWA, WCPF. *Standard methods for the examination of water and wastewater*, 19 ed. APHA, American Public Health Association, Washington, DC; 1995.

AZRINA MZ, YAP CK, RAHIM-ISMAIL A, ISMAIL A, *et al.* Anthropogenic impacts on the distribution and biodiversity of benthic macroinvertebrates and water quality of the Langat River, Peninsular Malaysia. *Ecotoxicol Environ Saf.* 2006;64(3):337-347.

BISHOP CM. *Neural networks for pattern recognition*. Oxford: Oxford University Press; 1995.

BREY T, JARRE-TEICHMANN A, BORLICH O. Artificial neural network versus multiple linear regression: predicting P:B ratios from empirical data. *Mar Ecol Prog Ser.* 1996;140:251-256.

BRINKHURST RO, MARCHESE M. *Guía para la identificación de Oligoquetos acuáticos continentales de sur y Centroamérica*. Asoc. Cienc. Nat. Litoral. Colección Climax N.º 6. 2 ed; 1962.

BROSSE S, GIRAUDEL JL, LEK S. Utilisation of non-supervised neural networks and principal component analysis to study fish assemblages. *Ecol Modell.* 2001;146:159-166.

CAMACHO JH, PÁEZ SH. Biomás terrestres de Colombia. Halffter, G. Compilador. La diversidad biológica de Iberoamérica I. Acta Zoológica Mexicana. Instituto de Ecología; 1990.

CEREGHINO R, PARKYS, COMPIN A, LEK S. Predicting the species richness of aquatic insects in streams using a restricted number of environmental variables. J North Am Benthol Soc. 2003;22:442-456.

CHON TS, PARKYS, MOON KH, CHA EY. Patternizing communities by using an artificial neural network. Ecol Modell. 1996;90:69-78.

CHU WC, BOSE NK. Speech Signal Prediction Using Feedforward Neural Network. Electron Lett. 1998;34:999-1001.

COLINA E, RIVAS F. Redes Neuronales Artificiales. En: Aguilar J, Rivas F, editores. Introducción a las técnicas de computación inteligente. 262 pp. Universidad de los Andes, Mérida, Venezuela. ISBN 980-292-928; 2001.

EDMONSON WT. Freshwater Biology. 366pp. Wiley, New York; 1959.

FARAGGI D, SIMON R. A neural network model for survival data. Stat Med. 1995;14:73-82.

FERNÁNDEZ N, SOLANO F. Índices de Calidad y de Contaminación del Agua. Vicerrectoría de Investigaciones. 142 pp. Universidad de Pamplona. ISBN 958-33-7810-0; 2005.

FREEMAN JA, SKAPURA DM. Redes Neuronales: Algoritmos, aplicaciones y técnicas de propagación. Addison-Wesley; 1993.

GARSON GD. Interpreting neural-network connection weights. Artif Intell Expert. 1991;6:47-51.

GEVREY M, DIMOPOULOS I, LEK S. Two-way interaction of input variables in the sensitivity analysis of neural network models. Ecol Modell. 2006;195:43-50.

GIRAUDEL JL, AURELLE D, LEK S. Application of the self-organizing mapping and fuzzy clustering microsatellite data: how to detect genetic structure in brown trout (*Salmo trutta*) populations. En: Lek S, Gueguan JF, editors. Artificial Neuronal Networks: Application to Ecology and Evolution, Environmental Science. Springer, Berlin; 2000.

GISKE J, HUSE G, FIKSEN O. Modelling spatial dynamics of fish. Rev Fish Biol Fish. 1998;8:57-91.

GUEGAN JF, LEK S, OBERDORFF T. Energy availability and habitat heterogeneity predict global riverine fish diversity. Nature. 1998;391:382-384.

GUTIÉRREZ JD, RISS W, OSPINA R. Bioindicación de la calidad del agua en la Sabana de Bogotá - Colombia, mediante la utilización de la lógica difusa neuroadaptativa como herramienta. Caldasia. 2004;28(1):45-56.

HELLAWELL JM. Biological Surveillance of Rivers. Water Research Center, Stevenage Laboratory, England; 1978.

HOANG H, RECKNAGEL F, MARSHALL J, CHOY S. Predictive modelling of macroinvertebrate assemblages for stream habitat assessments in Queensland (Australia). Ecol Modell. 2001;195:195-206.

HOLDRIDGE LR. Life Zone Ecology. Ed. San José. Tropical Science Center; 1967.

HOPFIELD JJ. Neural networks and physical systems with emergent collective computational abilities. Proc Natl Acad Sci USA. 1982;79:2554-2558.

KOHONEN T. Analysis of a simple self-organizing process. Biol Cybern. 1982a;44(2):135-140.

KOHONEN T. Self-organized formation of topologically correct feature maps. *Biol Cybern.* 1982b;43:59-69.

KOHONEN T. Self-organization and associative memory. Springer-Verlag, Berlin (Germany); 1984.

KOHONEN T. Self-Organizing Maps. Vol. 30. Springer, Berlin; 2001.

KUNG SY, TAUR JS. Decision-Based Neural Networks with Signal Image Classification Applications. *Neural Netw.* 1995;6:170-181.

KVASNICKA V. An application of neural networks in chemistry. *Abstr Pap Am Chem Soc.* 1990;44(6):775-792.

LEK S, DELACOSTE M, BARAN P, DIMOPOULOS I, *et al.* Application of neural networks to modeling nonlinear relationships in ecology. *Ecol Modell.* 1996;90:39-52.

LEK S, GUEGAN JF. Artificial neural networks as a tool in ecological modelling, an introduction. *Ecol Modell.* 1999;120(99):65-73.

LEK S, GUEGAN JF. Artificial neuronal networks: application to ecology and evolution. 262 pp. Berlin: Springer; 2000.

LO JY, BAKER JA, KORNGUTH PJ, FLOYD CE. Application of Artificial Neural Networks to Interpretation of Mammograms on the Basis of the Radiologists Impression and Optimized Image Features. *Radiology.* 1995;197:242-242.

LYTLE D, POFF L. Adaptation to natural flow regimes. *Trends Ecol Evol.* 2004;19(2):94-95.

MC. CAFFERTY P. Aquatic Entomology. En: Jones and Bartlett editors. *The Fishermen's and Ecologists' Illustrated Guide to Insects and Their Relatives.* 448pp. Boston; 1981.

NEEDHAM JG, NEEDHAM PR. A guide to the study of Fresh-Water Biology. 5 ed. 108pp. Holden-Day, Inc; 1962.

OERTLI B. Leaf Litter Processing and Energy Flow through Macroinvertebrates in a Woodland Pond (Switzerland). *Oecologia.* 1993;96(4):466-477.

OKLAND J, OKLAND KA. The effects of acid deposition on benthic animals in lakes and streams. *Experientia.* 1986;42:471-486.

OLDEN JD, JACKSON DA. Illuminating the 'black box': Understanding variable contributions in artificial neural networks. *Ecol Modell.* 2002;154:135-150.

PARK YS, CEREGHINO R, COMPIN A, LEK S. Applications of artificial neural networks for patterning and predicting aquatic insect species richness in running waters. *Ecol Modell.* 2003a;160(3):265-280.

PARKYS, CHANG J, LEK S, CAO W, BROSSE S. Conservation strategies for endemic fish species threatened by the Three Gorges Dam. *Conserv Biol.* 2003b;17(6):1748-1758.

PARK YS, SONG MY, PARK YCH, OH KH, *et al.* Community patterns of benthic macroinvertebrates collected on the national scale in Korea. *Ecol Modell.* 2007;203:26-33.

PARUELO JM, TOMASEL F. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. *Ecol Modell.* 1997;98:173-186.

PENNAK RW. *Fresh-Water Invertebrates of the United States.* 2 ed. 803pp. John Wiley & Sons. ISBN: 0-471-04249-8; 1978.

PUDMENZKY A, MARSHALL J, CHOY S. Preliminary application of artificial neural networks model for predicting macroinvertebrates in rivers. *Freshwater Biological*

Monitoring Report No. 9, The State of Queensland, Department of Natural Resources, Queensland; 1998.

RAMÍREZ A, VIÑA G. Limnología Colombiana. Aportes a su conocimiento y estadísticas de análisis. 1 ed. 293 pp. Formas e Impresos S.A. Bogotá; 1998.

RECKNAGEL F. Ecological informatics: Understanding ecology by biologically inspired computation. 398pp. Berlin: Springer; 2002.

ROLDÁN G. Guía para el estudio de los macroinvertebrados acuáticos del departamento de Antioquia. 217pp. Universidad de Antioquia. Medellín-Colombia; 1988.

ROSENBLATT F. The Perceptron: a probabilistic model for information storage and organization in the brain. Psychol Rev. 1958;65:386-408.

RUMELHART DE, HINTON GE, WILLIAMS RJ. Learning representations by back-propagating errors. Nature. 1986;323:533-536.

SCARDI M. Artificial neural networks as empirical models for estimating phytoplankton production. Mar Ecol Prog Ser. 1996;139:289-299.

SCHLEITER IM, BORCHARDT D, WAGNER R, DAPPER T, SCHMIDT K, SCHMIDT H, *et al.* Speech Signal Prediction Using Feedforward Neural-Network. Electron Lett. 1999;34:999-1001.

SEGINER I, BOULARD T, BAILEY BJ. Neural network models of the greenhouse climate. J Agric Eng Res. 1994;59:203-216.

VESANTO J, HIMBERG J, ALHONIEMI E, PARHANKANGAS J. Self-organizing map in Matlab: the SOM toolbox. En: Proceedings of the Matlab DSP Conference. Finland; 1999. p. 35-40.

WALLEY WJ, FONTAMA VN. Neural network predictors of average score per taxon and using neural networks. Ecol Modell. 1998;120:271-286.

WIDROW B, HOFF ME. Adaptive switching circuits. Ecol Modell. 1960;4:96-104.

WYTHOFF BJ, LEVINE SP, TOMELLINI SA. Spectral peak verification and recognition using a multilayered neural network. Anal Chem. 1990;62(24):2702-2709.