

# BIOINDICACIÓN DE LA CALIDAD DEL AGUA CON MACROINVERTEBRADOS ACUÁTICOS EN LA SABANA DE BOGOTÁ, UTILIZANDO REDES NEURONALES ARTIFICIALES

## Bioindication of the water quality with aquatic macroinvertebrates in the Sabana de Bogotá using artificial neural networks

**JUAN DAVID GUTIÉRREZ<sup>1</sup>**

*Departamento de Biología, Universidad Nacional de Colombia, Bogotá, Colombia.  
jdgutierrez1@unal.edu.co*

**WOLFGANG RISS**

*Abt. Limnologie, Universität Münster, Alemania. riss@uni-muenster.de*

**RODOLFO OSPINA**

*Departamento de Biología, Universidad Nacional de Colombia, Bogotá, Colombia.  
rospinat@unal.edu.co*

### RESUMEN

Se presenta una implementación de la metodología de redes neuronales (RN) como herramienta para la estimación de la calidad del agua en la cuenca alta y media del río Bogotá, Colombia. Los datos usados provienen de 55 sitios correspondientes a once cuencas de la sabana de Bogotá. Los resultados obtenidos con la aplicación de la RN fueron comparados con los valores del índice fisicoquímico Cfq y del índice de bioindicación ASPT (Average Score Per Taxon), para comprobar el grado de confiabilidad de la metodología.

**Palabras clave.** Redes neuronales, bioindicadores, macroinvertebrados, calidad del agua, Sabana de Bogotá.

### ABSTRACT

An application of neural networks (RN) is presented as tool in order to calculate the biological water quality in the higher and mid watershed of Bogotá river, Colombia. Data come from 55 sites corresponding to 11 watersheds in the Plain of Bogotá. Results obtained with RN were confronted with values of the Cfq index and ASPT (Average Score Per Taxon) bioindication index, to prove the reliability of neural networks methodology.

**Key words.** Neural networks, bioindicators, macroinvertebrates, water quality, Sabana de Bogotá.

### INTRODUCCIÓN

Los ecosistemas lóticos son típicamente complejos y envuelven muchos fenómenos físicos, químicos y biológicos, dentro de una intrincada dinámica espacial y temporal (Allan

1995; Banarescu 1995) y aunque se conocen detalles de la forma individual cómo las variables influyen la calidad del agua, las interacciones entre dichas variables son pobremente conocidas y no suelen ser fácilmente cuantificables (Bucksteeg 1993).

<sup>1</sup>El presente artículo hace parte del trabajo de tesis doctoral del primer autor.

Los métodos de evaluación de la calidad de las aguas basados en macroinvertebrados acuáticos ofrecen múltiples ventajas tales como: simplicidad metodológica, rapidez en la obtención de los resultados y una alta confiabilidad, lo que hace de estos métodos una herramienta idónea para la vigilancia rutinaria de la calidad del agua en las cuencas y ríos en general (Alba-Tercedor & Sánchez-Ortega 1988, Jonson *et al.* 1992)

Sin embargo, el gran número de interacciones resultantes entre las variables físicas y químicas y los organismos acuáticos, se constituye en un problema matemático de gran complejidad, por lo que se requiere de técnicas robustas para el análisis multivariado de modelos no lineales (Canton & Chadwick 1988; Wagner *et al.* 2000). En este sentido, las RN ofrecen una posibilidad debido a su habilidad para reconocer, clasificar y relacionar patrones y relaciones en una serie de datos y su capacidad para hacer inferencias sobre nuevos datos (DARPA 1988; Freeman & Skapura 1991).

El objetivo de este artículo es presentar y poner a consideración los resultados obtenidos con la implementación de una RN como herramienta para la estimación de la calidad fisicoquímica del agua, empleando un pequeño grupo de taxones de macroinvertebrados como bioindicadores, con el objeto de agilizar el tiempo empleado para la obtención de resultados.

## **MATERIALES Y MÉTODOS**

### **La técnica de RN**

Las RN son clasificadas como una técnica de modelamiento derivada de la inteligencia artificial (Maureen & Butler 1990). En esencia esta técnica se basa en el hecho de emplear elementos simples (neuronas) actuando en paralelo; el comportamiento de estos elementos es inspirado por los sistemas nerviosos biológicos. Las RN pueden ser

usadas para dos grandes tipos de problemas: clasificación de datos y predicción de variables. Para problemas de clasificación las RN emplean algoritmos específicos para analizar patrones de similitud en los datos y separar estos dentro de un número predefinido de clases. Para problemas de predicción, las RN aprenden a predecir los valores de una(s) variable(s) respuesta después de analizar un suficiente número de ejemplos (Khanna 1990).

Las unidades de procesamiento o neuronas desarrollan operaciones simples tales como: escalamiento de los datos, ponderación de las entradas, operaciones matriciales, etc. Las neuronas son organizadas en capas donde cada capa desarrolla una función específica. La capa de entrada sirve como una interfase entre los datos de las variables de entrada y el modelo de la red. Adicionalmente, muchos modelos contienen una o varias capas "ocultas", las cuales desarrollan la mayoría de los cálculos dentro de la red. La capa de salida actúa como una interfase entre la red neuronal y el usuario, transformando la información del modelo a los valores de la variable respuesta.

Cada neurona está conectada a las demás neuronas en las capas adyacentes por medio de pesos o ponderaciones, los cuales representan la fuerza de la conexión entre neuronas. Además cada modelo de red neuronal tiene un sistema de interacción que define la forma como las ponderaciones de las conexiones son combinados para producir un determinado valor de la variable respuesta a partir de las variables de entrada.

Como se mencionó anteriormente, la capa de entrada es una interfase entre las variables de entrada y el modelo de la red. En esta capa se emplea una función de escalamiento para transformar los datos desde su rango numérico hasta un rango que facilite los cálculos en la

red neuronal, generalmente en un rango de -1 a 1. Las capas ocultas y de salida contienen una función de activación, la cual define como una entrada recibida en la red produce un cambio de estado (activación o inhibición) en una determinada neurona. Estas funciones de activación son funciones matemáticas, tales como: gaussianas, lineales, sigmoides, etc.

Cada red neuronal tiene un algoritmo de aprendizaje, el cual define como las ponderaciones son modificados para minimizar el error en la predicción. Los algoritmos de aprendizaje son clasificados en dos grandes categorías: aprendizaje supervisado y aprendizaje no supervisado.

En el aprendizaje supervisado, el algoritmo de aprendizaje es suministrado con una serie de datos de ejemplo, los cuales contienen las entradas y los resultados esperados (objetivos) correspondientes, que se desea que la red, en este caso el algoritmo de aprendizaje es usado para ajustar las ponderaciones de las conexiones neuronales con el propósito de aproximar la variable respuesta a los resultados esperados (Widrow & Winter 1988).

En el aprendizaje no supervisado, las ponderaciones son modificados únicamente en respuesta a las entradas de la red y no hay datos de ejemplo. Muchos de estos algoritmos desarrollan operaciones de agrupamiento, los cuales tienden a categorizar los patrones de las entradas dentro de un número finito de clases (Kohonen 1984).

Debido a su constitución y a sus fundamentos, las RN presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, generalizar a partir de casos anteriores a nuevos casos, abstraer características esenciales a partir de ejemplos, etc. Esto hace que ofrezcan ventajas sobre

otras técnicas de modelamiento, que incluyen: aprendizaje adaptativo, autoorganización, tolerancia a fallos e información insuficiente y operación en tiempo real (Kohonen 1988, Wasserman 1989).

## Datos

Con el objeto de abarcar un amplio espectro de ríos con diferentes estados de intervención en la cuenca alta y media del río Bogotá, se emplearon los datos reportados por Bohórquez (1989), Soler & Mora (1993), Bohórquez & Ardila (1997), Riss *et al.* (2002), Leython (2003) y los datos sin publicar suministrados por el Laboratorio de Aguas de la Empresa de Acueducto y Alcantarillado de Bogotá (LAEAAB). En total se trabajó con 55 sitios; con esta información se construyó una base de datos, en la que cada sitio tiene un registro de las variables físicas y químicas muestreadas y de los macroinvertebrados encontrados. Las variables físicas y químicas empleadas en el análisis fueron 18, mientras que el número de taxones incluidos fue de 62.

Para la medición de la calidad del agua se empleó el índice de calidad fisicoquímica Cfq (Riss *et al.* 2002), desarrollado específicamente para la región de la sabana de Bogotá y que permite calcular un valor de calidad fisicoquímica del agua, con cualquier número de variables físicas y químicas, con lo que es posible comparar diferentes sitios en los que no todas las variables físicas y químicas han sido monitoreadas. Los valores del índice Cfq fueron transformados a una escala de 0 a 100, al multiplicar el valor del índice por 10, de tal forma que 100 corresponde a aguas extremadamente limpias y 0 corresponde a aguas extremadamente sucias. Para los sitios empleados en este estudio, los valores del índice Cfq variaron entre 94.1 y 8.7, lo que permite abarcar un amplio rango de valores de calidad del agua y facilita el reconocimiento de patrones por parte de la red neuronal.

La mayoría de los sitios corresponde a aguas con calidad muy buena o buena, seguidas por sitios con calidad del agua regular, mientras que los sitios con calidad del agua mala o muy mala son los menos frecuentes (Tabla 1).

**Tabla 1.** Número de sitios para cada tipo de calidad del agua.

Valores del índice Cfq	Calidad del agua	No. de sitios
100 – 80	Muy buena	13
80 – 60	Buena	24
60 – 40	Regular	12
40 – 20	Mala	7
20 – 0	Muy mala	3

### Implementación de la RN

Previo a la implementación se seleccionaron los taxones bioindicadores. El principal criterio empleado para la selección de dichos organismos fue la condición de estenótico (en el área de estudio), para las distintas condiciones de calidad de agua. La información para dicha selección está asociada con la distribución y abundancia de los organismos a lo largo del espectro de calidad del agua. La selección puede hacerse mediante la construcción de los histogramas de frecuencia de la abundancia absoluta vs. la calidad del agua, estimada según el índice Cfq o algún otro índice de calidad del agua. Por razones de velocidad en el cálculo y para facilidad de los usuarios, solo se incluyeron siete taxones

Los organismos seleccionados para la implementación del modelo de RN fueron: las familias Leptoceridae e Hidrobiosidae como indicadores de aguas limpias, la familia Planariidae y el orden Amphipoda como indicadores de aguas contaminadas y como indicadores de aguas muy contaminadas se escogió al orden Oligochaeta y las familias Psychodidae y Syrphidae.

Las abundancias absolutas de los organismos bioindicadores fueron transformadas para ser expresadas en una escala de 0 a 1 (con 1 siendo 100 o más individuos), con excepción de los oligoquetos que fueron expresados en una escala de 0 a 10 (con 10 siendo 1000 o más individuos), debido a su gran abundancia.

El modelo de red neuronal implementado fue el de retropropagación, de aprendizaje supervisado, de tal forma que el conjunto de muestras fue separado aleatoriamente en un grupo para el aprendizaje (33 sitios) y otro para la evaluación del desempeño (22 sitios).

La arquitectura de la red neuronal consistió de tres capas: una capa de entrada con 7 neuronas (una para cada organismo indicador), una capa oculta con 10 neuronas donde se procesa la información de las entradas y una capa de salida con una neurona que devuelve el valor de la calidad del agua (Fig. 1). Debe anotarse que las neuronas de una capa están conectadas a todas las neuronas en la siguiente capa, pero no existen conexiones laterales dentro de las capas ni conexiones hacia la capa anterior.

El conjunto de datos para el aprendizaje correspondiente a 33 sitios, fue transformado a una representación matricial con 33 vectores de entrada (uno para cada sitio), cada uno con una dimensión de  $1 \times 7$  (un valor de abundancia para los 7 taxones) y 33 vectores de salida, correspondientes a los valores esperados del índice Cfq, cada uno con una dimensión de  $1 \times 1$ . Ambos vectores fueron suministrados a la RN para el aprendizaje.

Con excepción de las neuronas de la capa de entrada, la entrada neta  $A_i$  para cada neurona es la suma de todos los valores de entrada  $X_n$ , cada uno multiplicado por su ponderación  $W_{jn}$ , y un término de tendencia  $Z_j$ , el cual puede ser considerado como la ponderación desde una entrada suplementaria:

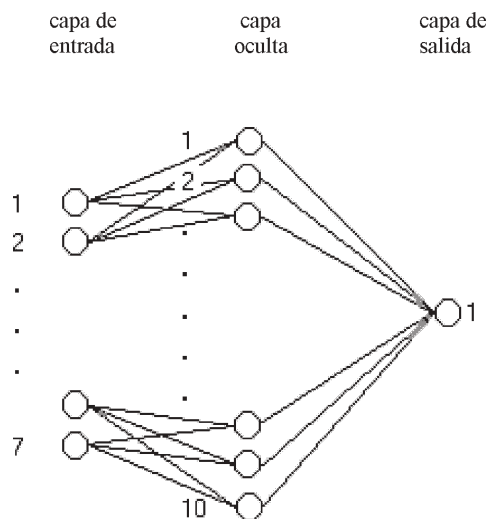
$$A_j = \sum W_{jn} X_n + Z_j \quad (1)$$

El valor de respuesta,  $Y_j$ , puede ser calculado al introducir el valor de la entrada neta dentro de la función de transferencia de la neurona:

$$Y_j = f(A_j) \quad (2)$$

En este caso se incluyeron las funciones sigmoide-tangencial para la capa oculta y positiva lineal para la capa de salida.

Para cada entrada, la RN calcula una salida y se estima un error, al comparar el resultado calculado por la red y el valor esperado. Usando este error, las ponderaciones y las tendencias son ajustados con el objeto de disminuir el error, de tal forma que las futuras salidas tengan mayor probabilidad de ser correctas. Este procedimiento es repetido



**Figura 1.** Arquitectura de la RN implementada. Cada neurona en la capa de entrada corresponde a uno de los organismos bioindicadores y la neurona de la capa de salida corresponde al valor de la calidad del agua. La capa oculta contiene las neuronas que ejecutan la mayoría de los cálculos, a partir de la información suministrada en la capa de entrada.

hasta que los errores lleguen a ser lo suficientemente pequeños o se alcance un número máximo predefinido de interacciones o épocas. En éste caso se empleo como criterio para detener el aprendizaje un umbral de error menor a 10.

Mayores detalles sobre la técnica de RN de retropropagación y los diferentes algoritmos empleados, pueden encontrarse en Dennis & Schnabel (1983), Wasserman (1989), Hecht-Nielsen (1990) y Hagan & Menhaj (1994). Para la implementación de la red neuronal, fue necesario el desarrollo de un programa para computador tipo pc, llamado BACKINV escrito en lenguaje Matlab.

## RESULTADOS Y DISCUSIÓN

### Desempeño de la implementación del modelo de RN

Durante el proceso de aprendizaje el cuadrado del error (diferencia entre los valores esperados suministrados a la RN y los valores calculados por la misma), en el conjunto de datos del aprendizaje, disminuye en la medida que transcurre el aprendizaje (épocas), mediante el ajuste hecho por el programa de las ponderaciones y tendencias de las conexiones entre neuronas (Fig. 2).

Finalizado el proceso de aprendizaje, se establecieron los valores para las conexiones entre las neuronas. Para comprobar la eficiencia la RN se ingresan como entradas a la red solamente las abundancia de los organismos indicadores de los datos del conjunto de evaluación (los cuales no fueron incluidos en el aprendizaje) y la salidas de la RN se comparan con los valores esperados del índice Cfq.


Existe una regresión lineal significativa ( $R^2=0.63$ ,  $F(1,20)=37.65$ ,  $p<0.01$ ,  $E.E.=12.86$ ), entre los resultados de la RN para los 22 datos del conjunto

de evaluación y los valores esperados del índice Cfq (fig. 3). Debe resaltarse que los valores que más se alejan de la línea de tendencia de la regresión (río Bogotá La Balsa en Bohórquez (1989), río Frío 1 en Bohórquez & Ardila (1997) y río Teusacá La Cabaña en (LAEAAB)), parecen corresponder a vectores con información insuficiente o redundante, es decir sitios donde está presente solo uno o todos los organismos bioindicadores con abundancias generalmente muy escasas, los cuales están asociados a períodos muy lluviosos, donde la comunidad de macroinvertebrados sufre una considerable alteración por el arrastre de un caudal inusualmente alto.

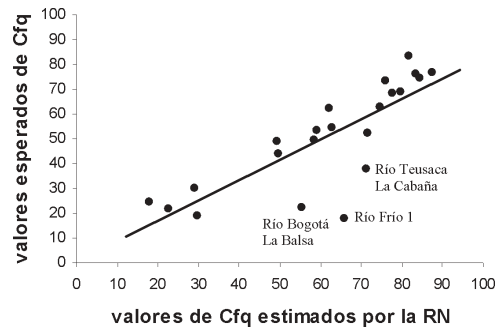
Al comparar los valores calculados por la RN y los valores del índice fisicoquímico Cfq,

exceptuando los tres datos mencionados anteriormente, se observa que no existe una diferencia significativa entre los valores observados y los esperados, para los datos del conjunto de evaluación ( $\chi^2=23.39$ , g.l.=18,  $p<0.176$ ).

Con el objeto de comparar el desempeño de la RN con modelos estadísticos convencionales, se realizó un análisis de regresión lineal múltiple, empleando como variables independientes los organismos y como variable dependiente el índice Cfq. Al igual que en el caso de RN, el modelo de regresión se obtuvo con el mismo conjunto de datos de aprendizaje y para su validación se emplearon los mismos datos del conjunto de evaluación.



**Figura 2.** Disminución del cuadrado del error durante el aprendizaje de la RN. El cuadrado del error corresponde al cuadrado de la diferencia entre los valores del índice Cfq estimados por la RN y los valores esperados, suministrados en el conjunto de datos para el aprendizaje. Note como el error disminuye en la medida que transcurre el aprendizaje, mediante el ajuste hecho por el programa de las ponderaciones y tendencias de las conexiones neuronales.



**Figura 3.** Regresión lineal entre los valores de la RN y el índice fisicoquímico Cfq para el conjunto de datos de validación. La línea continua muestra la recta de mejor ajuste para los valores del índice Cfq estimados por la RN y los valores esperados del mismo índice Cfq. Los sitios más alejados de la línea de tendencia: río Bogotá La Balsa, río Frío 1 y río Teusaca La Cabaña, parecen corresponder a períodos muy lluviosos, donde la comunidad de macroinvertebrados sufre una considerable alteración por el arrastre de un caudal inusualmente alto.

Para la obtención del modelo de regresión, se empleó el programa Statgraphics Plus 2.1<sup>TM</sup>. Dicho modelo se ajusta a la siguiente ecuación ( $R^2=0.64$ ,  $F(6,26)=7.57$ ,  $p<0.01$ ,  $E.E.=13.79$ ):

$$\begin{aligned} \text{Cfq} = & 67.52 + 4.81 * \text{Leptocedae} + \\ & 29.18 * \text{Hidrobiosidae} - \\ & 15.55 * \text{Planariidae} - 0.83 * \text{Amphipoda} - \\ & 1.67 * \text{Oligochaeta} - \quad (3) \\ & 499.42 * \text{Syrphidae} - \\ & 0.015 * \text{Psychodidae} \end{aligned}$$

Al aplicar dicho modelo al conjunto de datos de evaluación, es decir al multiplicar los valores de la abundancia de cada organismo en un determinado sitio por los coeficientes de la ecuación, se obtienen los valores del índice Cfq, estimados a partir de la regresión múltiple.

Al comparar los valores estimados por la regresión lineal múltiple y los valores del índice fisicoquímico Cfq, exceptuando los mismos tres datos correspondientes a condiciones climáticas atípicas, se observa que existe una diferencia altamente significativa entre los valores observados y los esperados, para el conjunto de datos de evaluación ( $\chi^2=168.165$ ,  $g.l.=18$ ,  $p<0.001$ ).

Debe anotarse que la regresión múltiple es la forma como usualmente se podría estimar el índice de calidad fisicoquímica Cfq, a partir de las abundancias de los organismos indicadores. Pero este ofrece limitantes tales como la linealidad del modelo y la multicolinealidad de las variables independientes, que limitan considerablemente la capacidad de predicción.

En este sentido la RN ofrece una alternativa eficiente, debido a su capacidad de aprendizaje adaptativo, que permite a esta técnica aumentar las habilidades para reconocer patrones y relaciones en una serie de datos e incrementar su capacidad de hacer inferencias sobre ellos, además de la tolerancia a información insuficiente, como la que se presenta en este estudio y que suele ocurrir en los estudios de monitoreo biológico de la calidad del agua.


Al comparar los resultados de la RN para los datos del conjunto de evaluación y los valores del índice de bioindicación ASPT (Zamora-Muñoz *et al.* 1995), con base en los valores primarios de indicación reportados por Riss *et al.* (2002), se observa una regresión lineal significativa ( $R^2=0.57$ ,  $F(1,20)=37.65$ ,  $p<0.01$ ,  $E.E.=13.91$ ), aunque ligeramente menor que la observada con el índice Cfq.

En este caso, la mayores desviaciones se presentan en los datos que corresponden a sitios con menor calidad del agua y valores

pequeños del índice ASPT (fig. 4), lo cual obedece a la relativamente poca información disponible en la serie de datos sobre ríos con una baja calidad del agua (tab. 1), que repercute en un proceso de aprendizaje deficiente por parte de la RN para este tipo de ríos.

De tal forma, que se pueden esperar mejores predicciones sí:

- Se trabaja con un conjunto de datos que incluya un número suficiente de estaciones para cada una de las clases de calidad del agua.
- Los muestreos coinciden en el tiempo.
- Los métodos de muestreo son iguales.



**Figura 4.** Regresión lineal entre los valores de la RN y el índice de bioindicación ASPT. La línea continua muestra la recta de mejor ajuste para los datos valores del índice Cfq estimados por la RN y los valores del índice ASPT. Nótese como la mayor desviación ocurre en los datos con valores pequeños del índice ASPT que corresponden a sitios con menor calidad fisicoquímica del agua.

## CONCLUSIONES

En Europa y los Estados Unidos, la asignación de valores de indicación para los macroinvertebrados acuáticos y el desarrollo de índices de bioindicación, ha sido abordada

mediante la calificación a manera de “consenso de expertos”, sustentado por el amplio conocimiento de la fauna, así como de la información física y química de los ríos. Sin embargo, en el neotrópico, son muy pocos los trabajos desarrollados sobre la taxonomía, la biogeografía y la autoecología de los organismos acuáticos por lo que la aplicación del esquema de “consenso de expertos” no resulta viable.

En Colombia la gran mayoría de los trabajos sobre bioindicación han adaptado “a priori” los mismos o casi los mismos valores de indicación reportados para alguno de los sistemas de bioindicación empleados en otras regiones, en especial el sistema BMWP (Biological Monitoring Working Party).

La implementación de una RN como herramienta de análisis de la calidad del agua con base en macroinvertebrados acuáticos, ofrece una alternativa frente al esquema de “consenso de expertos” y es más eficiente que el uso de técnicas estadísticas convencionales (Lek *et al.* 1996). Igualmente esta metodología ofrece las mismas ventajas de la bioindicación, tales como: simplicidad metodológica y rapidez de los resultados, pero adicionalmente proporciona una considerable disminución del tiempo dedicado a las determinaciones taxonómicas (siete taxones) y proporciona una alta confiabilidad de los resultados.

Sin embargo, el margen de precisión obtenido en este estudio, en las estimaciones de la calidad del agua a partir de la abundancia de los taxones de macroinvertebrados, está restringido a la aplicación de esta metodología en la región de la sabana de Bogotá. Debido a que las ponderaciones de las conexiones neuronales del modelo de red implementado, pueden experimentar variaciones significativas de las requeridas para este mismo fin en otras regiones, más aún si se trata de niveles taxonómicos como familia u



orden, pues la sola presencia de un género cuya tolerancia a la contaminación es significativamente mayor o menor que la de los demás dentro de una misma familia, es muy probable que se necesite modificar la magnitud de las interacciones neuronales. Por lo que se requiere de la selección detallada de los organismos indicadores, el diseño de la arquitectura de la RN y del correspondiente proceso de aprendizaje.

### AGRADECIMIENTOS

Este trabajo es parte de los resultados del Proyecto «Quironómidos de la Sabana», financiado por COLCIENCIAS. (Contrato 065/96 Colciencias - Universidad Nacional). Los autores del trabajo agradecen a esta entidad el efectivo apoyo técnico y financiero. Al Servicio Alemán de Intercambio Académico (DAAD) por el apoyo al primer autor mediante una beca de investigación. A la Fundación Alexander von Humboldt (AvH) por el apoyo al tercer autor mediante una beca de investigación, a la agencia alemana GTZ por la donación de equipos y apoyo general al proyecto, a la Facultad de Ciencias y al Departamento de Biología de la Universidad Nacional de Colombia por la construcción y dotación de laboratorios y apoyo al proyecto. A los demás miembros del equipo de trabajo por su ayuda en la identificación de la fauna bentónica.

### LITERATURA CITADA

- ALBA-TERCEDOR, J. & A. SÁNCHEZ-ORTEGA. 1988. Un método rápido y simple para evaluar la calidad de las aguas corrientes basado en el de Hellowell (1978). *Limnética* 4: 51-56.
- ALLAN, J. D. 1995. Stream ecology. Structure and function of running waters. Chapman & Hall. Londres.
- BANARESCU, P. 1995. Zoogeography of freshwaters. Bd. 1-3. Aula. Wiesbaden.
- BOHÓRQUEZ, A. 1989. Contribución al estudio limnológico por bioindicadores con macroinvertebrados bentónicos en aguas continentales. Proyecto Limnología Unincca - Colciencias. IP 1227-09004-89. Bogotá.
- BOHÓRQUEZ, A. & J.L. ARDILA. 1997. Monitoreo limnológico con macroinvertebrados en cuatro estaciones localizadas en los ríos Barandillas y Frio. *Unisalle Dep. Quim. Biol. Diógenes* 4: 37-59.
- BUCKSTEEG, K. 1993. Vorstellungen der Wasserwirtschaft zur Fließgewässerqualität. Págs. 12-38 en: Bayerisches Landesamt für Wasserforschung (ed). *Auswirkungen von Abwassereinleitungen auf die Gewässerökologie*, Oldenburg, Munich.
- CANTON, S.P. & J.W. CHADWICK. 1988. Variability in benthic invertebrate density estimates from stream samples. *Journal of Freshwater Ecology* 4: 291-297.
- DARPA. 1988. Neural Network Study. M.I.T. Lincoln Laboratory. Lexington, MA.
- DENNIS, J.E. & R.B. SCHNABEL. 1983. Numerical Methods for Unconstrained Optimization and Nonlinear Equations. Englewood Cliffs. Prentice-Hall. NJ.
- FREEMAN, J.A. & D.M. SKAPURA. 1991. Neural Networks, Algorithms, Applications and Programing Techniques. Addison-Wesley. MA.
- HAGAN, M.T. & M. MENHAJ. 1994. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks* 5: 989-993.
- HECHT-NIELSEN, R. 1990. Neurocomputing. Addison-Wesley. Reading.
- JONSON, R. K., T. WIEDERHOLM & D. M. ROSENBERG. 1992. Freshwater biomonitoring using individual organisms, populations, and species assemblages of benthic macroinvertebrates. Págs. 40-158 en: D. M. Rosenberg & V. H. Resh (eds). *Freshwater biomonitoring and benthic macroinvertebrates*. Chapman & Hall, Nueva York.

- KHANNA, T. 1990. *Foundations of Neural Networks*. Addison-Wesley. Reading.
- KOHNEN, T. 1984. *Self-organization and Associative Memory*. V. 8 de Springer Series in Information Sciences. Springer-Verlag. Nueva York.
- KOHNEN, T. 1988. An Introduction to Neural Computing. *Neural Networks* 1: 3-16.
- LEK, S., M. DELACOSTE, P. BARAN, I. DIMOPOULOS, J. LAUGA & S. AULAGNIER. 1996. Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Modelling* 90: 39-52.
- LEYTON, M. 2003. Caracterización de macroinvertebrados acuáticos en algunas quebradas orientales de Bogotá. Tesis (Biólogo) Universidad Nacional de Colombia. Facultad de Ciencias. Departamento de Biología.
- MAUREEN, C. & C. BUTLER. 1990. *Naturally Intelligent Systems*. MIT Press. Cambridge.
- RISS, W., R. OSPINA & J.D. GUTIÉRREZ. 2002. Establecimiento de valores de bioindicación para los macroinvertebrados acuáticos de la Sabana de Bogotá. *Caldasia* 24: 135-156.
- SOLER, M.X. & A.Y. MORA. 1993. Estudio limnológico con énfasis en los macroinvertebrados béticos de la parte alta del río Bogotá (Quebrada del valle, planta de tratamiento de Tibito). Tesis (Biólogo). Facultad de Ciencias. Departamento de Biología, Universidad Nacional de Colombia, Bogotá.
- WIDROW, B. & R. WINTER. 1988. Neural nets for adaptative filtering and adaptative pattern recognition. *Computer* 21: 25-39.
- WAGNER, R., T. DAPPER & H.H. SCHMIDT. 2000. The influence of environmental variables on the abundance of aquatic insects: a comparison of ordination and artificial neural networks. *Hydrobiologia* 422: 143-152.
- WASSERMAN, P. 1989. *Neural Computing: Theory and Practice*. Van Nostrand Reinhold. Nueva York.
- ZAMORA-MUÑOZ, C., C.E. SÁINZ, A. SÁNCHEZ-ORTEGA & J. ALBA-TERCEDOR. 1995. Are biological indices BMWP and ASPT and their significance regarding water quality seasonally dependent? Factors explaining their variations. *Wat. Res.* 29: 285-290.

Recibido: 13/05/2003

Aceptado: 19/04/2004