

APLICACIÓN DE UN MODELO DE RED NEURONAL PARA LA CLASIFICACIÓN DE SISTEMAS LACUNARES PAMPEANOS

FERRATI, R.; VARGAS RUSSO, M.; SAAVEDRA, P. & G. CANZIANI

*Instituto Multidisciplinario sobre Ecosistemas y Desarrollo Sustentable
Facultad de Ciencias Exactas- UNCPBA, Campus Paraje Arroyo Seco, 7000 Tandil*

ABSTRACT

The pampean shallow lakes present different distributions in their trophic chains, the latter being cause and consequence of the state of the lacunar systems. In order to determine how each of the measured variables —climatic, edaphic, morphometric, physicochemical and biological— in contributes to the general state of the lake, an Artificial Neural Network (ANN) model is built. The ANN is capable of processing a large number of variables and returning a classification that will allow determining it's the trophic state. The information from satellite images is one of the input variables. Hence, on a first stage, the construction of a ANN model is intended to obtain a weight for each one of the visible specter bands and near infrared bands from LANDSAT and to pick the most representative value that the image returns. This value will be used as input to the ANN that will be then trained to return a classification of the shallow lakes according to the three observed patterns in the relation between phytoplankton, zooplankton, fish and their link with to nutrient abundance and watershed management.

Key Words: artificial neural network, satellite images, trophic chain

INTRODUCCIÓN

Ubicadas al sur de la Cuenca del Plata, las lagunas pampeanas son los ambientes acuáticos típicos de esta región y desarrollan funciones de carga y descarga de acuíferos, control de inundaciones, provisión de agua, regulación del clima, usos recreacionales, caza y pesca. (<http://www.medioambiente.gov.ar>). Se define a las lagunas pampeanas como lagos de llanura, someros, polimícticos, eutróficos y con tiempo de permanencia del agua y salinidad altamente variables, con elevada biomasa de sus comunidades bióticas (Quirós *et al.*, 2002)

Las lagunas pampeanas constituyen ecosistemas acuáticos complejos y, como tales, poseen un gran número de componentes que interactúan a

diferente escala temporal y espacial (Jorgensen, 1999) haciendo imposible obtener resultados considerando sólo un análisis parcial agrupado de interacciones simples, como lo explica claramente Allen con la frase: el conjunto es más grande que la suma de las partes (Allen, 1988).

El estado trófico de una laguna es el resultado de variables internas y externas: climáticas, geomorfológicas, fisicoquímicas, biológicas y de manejo de la laguna y de su cuenca que afectan la entrada de nutrientes a la misma y condicionan sus propiedades ópticas. Quirós *et al.* (2003) realizaron un análisis sincrónico de las lagunas pampeanas permanentes, proponiendo la siguiente clasificación: **a)** lagunas con abundante desarrollo del fitoplancton pero escaso desarrollo de macrofitia

(lagunas verdes o turbias), **b)** lagunas con relativamente baja biomasa del fitoplancton y abundante desarrollo de la macrofitia acuática (lagunas claras) y **c)** lagunas con alta turbidez inorgánica y escaso desarrollo de la macrofitia y del fitoplancton.

La definición de uno u otro estado trófico y la transición entre dichos estados han sido y son objeto de numerosos estudios y han generado modelos matemáticos y computacionales cuyo objetivo es determinar la incidencia de cada una de las variables que influyen en los sistemas acuáticos leníticos en su estado final. Existen numerosos trabajos de modelos propuestos para analizar relaciones lineales simples de producción primaria en océanos y lagos utilizando imágenes satelitales (Cole & Cloren, 1987; Balch *et al.*, 1989; Eppley *et al.*, 1985), y modelos ecológicos complejos que reflejan el comportamiento dinámico del sistema (Kompare, 1995; Jorgensen, 1995, 1997, 1998; Jorgensen & de Bernardi, 1997; Scardi *et al.*, 1999) utilizando herramientas de modelación fuzzy, caos, fractales, inteligencia artificial, dinámica estructural y redes neuronales.

Modelo de Redes Neuronales

Existen modelos computacionales que intentan copiar el modo de aprendizaje del cerebro humano: la inteligencia computacional y la inteligencia artificial. Los primeros copian el proceso físico que ocurre en el cerebro durante el aprendizaje. Ejemplos de estos son las redes neuronales artificiales, la lógica difusa y los algoritmos genéticos. En el caso de modelos de inteligencia artificial se copia el proceso lógico de aprendizaje de los seres humanos. Algunos de estos modelos son los sistemas expertos, los agentes y el razonamiento basado en casos.

Un modelo de Red Neuronal Artificial imita el proceso físico que ocurre en el cerebro durante el aprendizaje. Este modelo está compuesto por neu-

ronas artificiales, que emulan a las neuronas biológicas y las conexiones sinápticas entre ellas, regulándolas en el proceso de resolución de un problema. El objetivo de este trabajo es construir y aplicar un modelo de Red Neuronal Artificial Perceptrón Multicapa (Rosenblatt, 1962; Minsky & Papert, 1969, 1988) que clasifique cuerpos lacunares en los tres estados o patrones propuestos: lagunas claras, verdes y oscuras. Los resultados obtenidos se cotejarán con el trabajo realizado por Dukatz *et al.* (2005).

La arquitectura de una Red Neuronal está formada por elementos no-lineales (neuronas o unidades) ubicados en capas, donde cada neurona realiza la suma pesada de los valores de las entradas y les aplica una función de activación. Esta función de activación debe tener un comportamiento de tipo «escalón», es decir que si el valor de la variable es menor a un valor dado, la salida es cercana a 0 y si la variable es mayor a ese valor la salida será cercana a 1. Esta función puede o no ser continua, pero en general se usan funciones diferenciables, ya que posibilitan la minimización del error. Usualmente es conveniente visualizar las neuronas en arreglos de capas comportándose las neuronas en la misma capa de la misma manera. Los factores importantes que determinan el comportamiento de una neurona son: su función de activación y el patrón de pesos asociados a las conexiones. Las neuronas ubicadas en la misma capa comparten la misma función de activación y el mismo patrón de conexión. Este patrón de conexión consiste en que cada neurona en una capa determinada esta conectada con todas las neuronas de la capa siguiente.

El método de actualización de pesos (entrenamiento) es una característica distintiva importante en las diferentes redes neuronales. Existen dos tipos de entrenamientos: supervisado y no supervisado. El entrena-

miento de la red propuesta se realizó con el algoritmo Back Propagation - retroceso de errores o regla delta generalizada- (Rumelhart, Hinton & Williams, 1986a, 1986b; McClelland & Rumelhart, 1988), procedimiento de aprendizaje supervisado que utiliza un método de descenso por el gradiente para minimizar el error cuadrático global de la salida calculada por una red. Se le entrega una serie de datos (inputs) con su correspondiente salida (outputs) y el modelo «aprende» de los casos, asignando coeficientes de peso a las variables de entrada. De esta forma se modelan las relaciones complejas entre variables. El entrenamiento permitirá que al ingresar una entrada nueva, la red pueda predecir la salida.

La regla de aprendizaje *Perceptrón*, bajo ciertas condiciones, provee convergencia hacia los pesos correctos mediante un procedimiento iterativo. Este proceso consta de tres fases denominadas *feedforward*, cálculo del error, y *backpropagation*. En primer lugar el input o vector de entrada se calcula para obtener en la salida la clasificación; luego se calcula el error de esta clasificación, finalizando con la actualización de los pesos de la red.

Los parámetros importantes del algoritmo de backpropagation son el factor de aprendizaje (*learning rate*) y la cantidad de épocas que se entrena una red. La primera representa la velocidad con la que la red «aprende», mientras que la segunda indica la cantidad de veces que los ejemplos son introducidos en la red para el apren-

dizaje. No es cierto que un valor grande de estos factores indique un aprendizaje mejor, ya que una gran cantidad de épocas puede llevar a un sobreentrenamiento de la red (es decir que aprende sólo para los ejemplos y no generaliza). Un factor de aprendizaje muy alto puede llevar a una oscilación.

MATERIALES Y MÉTODOS

Se trabajó sobre siete imágenes satelitales según se describe en la Tabla 1. Se seleccionaron las tres imágenes que contenían a las lagunas Carpincho, Las Mulitas y Wolfram, representativas de cada una de las clases, verde, marrón y clara.

Las restantes imágenes, correspondientes a las lagunas de Bragado, Gómez, La Segovia y La Barrancosa fueron utilizadas para probar la red ya entrenada.

Las lagunas seleccionadas fueron recortadas y se les realizó la corrección atmosférica correspondiente según los procedimientos propuestos en Dukatz *et al.* (2005)., Luego de estos procesos se realizó un recorte mediante polígonos permitiendo obtener imágenes individuales de cada laguna. Estas imágenes resultantes, con números digitales (DN) entre 0 y 1, fueron exportadas a dos imágenes con formato TIFF cuyos DN están entre 0 y 255, incluyendo tres bandas de las seis que posee la imagen en cada una de ellas.

El proceso de exportación de las imágenes termina con la construcción de dos conjuntos de muestras por la-

Tabla 1. Adquisición de las imágenes satelitales.

Laguna	path / row	Fecha de Adquisición	Satélite	Clasificación	Uso
Carpincho	226/84	09/09/2004	LANDSAT 5 TM	Verde	Entrenamiento
Las Mulitas	226/85	26/05/2003	LANDSAT 7 ETM ⁺	Marrón	Entrenamiento
Wolfram	227/87	02/10/2004	LANDSAT 5 TM	Clara	Entrenamiento
Bragado	226/84	09/09/2004	LANDSAT 5 TM	Marrón-Verde	Prueba
Gomez	226/84	09/09/2004	LANDSAT 5 TM	Verde	Prueba
La Segovia	227/86	13/10/1999	LANDSAT 7 ETM ⁺	Marrón-Verde	Prueba
La Barrancosa	225/86	02/10/2004	LANDSAT 5	Clara	Prueba

guna. El primer conjunto es de 800 píxeles para las lagunas seleccionadas como modelos de cada estado trófico; a saber Mulitas, Wolfram y Carpincho (Tabla 1). Este conjunto es extraído de un área central del cuerpo de agua para evitar la influencia de las orillas, y se utiliza para el entrenamiento de la red. El segundo conjunto lo forma la totalidad de píxeles de cada laguna y se utiliza para probar la red.

La información que se exporta contiene, para cada píxel de la superficie libre de agua, seis valores correspondientes a las bandas 1 a 5 y 7 (espectro visible e infrarrojo cercano) de los satélites LANDSAT 5 TM y LANDSAT 7 ETM+. En este punto la aplicación que analizará los datos tiene a su disposición los datos de cada laguna.

Construcción de la Red Neuronal

La arquitectura de red, como se muestra en la Figura 1, representa el modelo de *Perceptrón* construido. Este contiene seis neuronas de entrada, una capa oculta de 4 neuronas y la salida de tres neuronas que indican cada una de las tres posibles clasificaciones.

La función de activación seleccionada fue la función sigmoide:

$$\text{Sigmoid} : y(x) = \frac{1}{1 + \exp(-k \cdot x)}$$

que posee un rango de salida comprendido entre 0 y 1 y es utilizada para normalizar la respuesta de los nodos de salida. Esta función actúa como una compuerta de salida que puede estar abierta (1) o cerrada (0). Como la función es continua, es también posible que se encuentre parcialmente abierta. El parámetro k se consideró con valor 1, quedando de esta manera la función derivada expresada por:

$$\frac{dy}{dx} = y(1 - y)$$

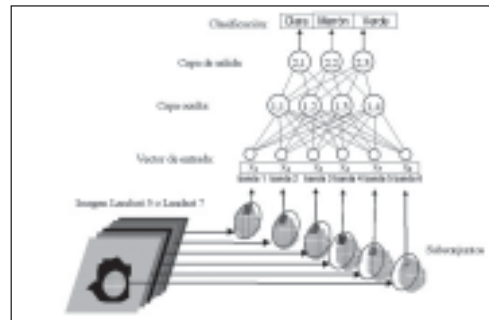


Figura 1. Arquitectura diseñada para la aplicación.

Los modelos que usan esta función de transferencia muestran características de aprendizaje generalmente bueno como se verá en los ensayos, relativo a un error tomado como criterio de evaluación, pero pueden tomar mayor tiempo computacional para lograr el aprendizaje.

En el cálculo del error se utilizó la norma infinito, que considera la componente de mayor valor absoluto del vector diferencia entre los vectores de salida de la red y el resultado esperado obtenido de la clasificación realizada en Dukatz *et al.* (2005).

RESULTADOS

De cada una de las tres lagunas preprocesadas –Carpincho, Mulitas y Wolfram– se extrajo un subconjunto de 800 píxeles centrales obteniendo un total de 2400 píxeles. Se entrenó a la red utilizando la información mezclada de los 2400 píxeles y modificando los siguientes parámetros de la red: factor de aprendizaje (learning rate) y cantidad de épocas. El error utilizado para determinar la convergencia del entrenamiento se obtuvo calculando la norma infinito del vector diferencia entre la salida producida y la esperada. Se realizó un conjunto de ensayos ordenados de acuerdo al factor de aprendizaje, cada uno de los cuales se dividió en sub-ensayos para distintas épocas. Los valores del factor de aprendizaje elegidos para entrenar la red fueron:




Figura 2. Resultados con $LR = 0.9$ y 1000 épocas.




Figura 3. Resultados con $LR = 0.9$ y 3000 épocas.




Figura 4. Resultados con $LR = 0.9$ y 5000 épocas.

0.9, 0.7, 0.5, y 0.3; el número de épocas: 1000, 3000, y 5000. En todos los casos se usaron las bandas 1 a 5 y la 7.

El resultado que devuelve la red cuando se le introduce un conjunto de píxeles de una laguna es un vector cuyas componentes representan la proporción de ellos clasificados en cada categoría. Así, una salida de (0.97, 0.02, 0.01) significa que el 97% del total de píxeles fueron clasificados como claros, el 2% como marrones y el 1% como verdes.

Luego se probó el aprendizaje alcanzado con los píxeles de las siete lagunas preprocesadas completas. A modo de ejemplo, se muestran los resultados del entrenamiento para un factor de aprendizaje de 0.9 y diferente número de épocas en las Figuras 2, 3 y 4. La red paulatinamente encuentra la clasificación más adecuada en la medida que el algoritmo va aprendiendo de sus errores. En algunos casos, al aumentar el número de

iteraciones el error de la red empieza a aumentar. Dicho comportamiento es causado por el sobreentrenamiento de la red.

En la Tabla 2 se muestra el comportamiento de la red para clasificar, luego de los respectivos entrenamientos. Para un factor de aprendizaje de 0.9 y 5000 épocas, la respuesta de la red es acertada en el 70% de los casos considerando las respuestas incorrectas -lagunas Bragado y Segovia- y en el 89% de los casos cuando no se las considera. En particular, se desprende de la tabla que en el caso de Bragado, la red no logra clasificar bien las entradas sin importar las iteraciones o número de épocas del entrenamiento. En el caso de Segovia se observan mejores resultados de clasificación para un número de épocas mayor o mayor entrenamiento. Existe además un comportamiento interesante cuando se observa el número de épocas junto con el factor de aprendizaje. Para un factor de aprendizaje o paso de mayor magnitud ($LR = 0.9$) la red clasifica correctamente debido, seguramente, a que el paso le permite saltar algún mínimo local. La clasificación mejora con $LR = 0.5 - 0.7$ y un número de épocas igual a 3000. Luego para mayor número de épocas la red finalmente clasifica adecuadamente cualquiera sea el LR.

CONCLUSIONES

Se ha presentado la utilización de una Red Neuronal la clasificación de

Tabla 2. Resultados obtenidos para cada laguna con distintos factores de aprendizaje y cantidad de épocas. Se muestra resaltada la clasificación entregada por la red para cada laguna.

Lagunas		Épocas											
		1000				3000				5000			
		Factor de aprendizaje											
clasificación		0,3	0,5	0,7	0,9	0,3	0,5	0,7	0,9	0,3	0,5	0,7	0,9
Carpincho (verde)	Clara	0,00	0,00	0,00	0,01	0,05	0,00	0,00	0,00	0,01	0,04	0,02	0,00
	Marrón	0,07	0,06	0,06	0,06	0,09	0,09	0,08	0,08	0,08	0,10	0,07	0,09
	Verde	0,93	0,94	0,93	0,93	0,86	0,91	0,92	0,92	0,91	0,86	0,90	0,90
La Barrancosa (clara)	Clara	0,19	0,21	0,48	0,56	0,24	0,34	0,36	0,46	0,25	0,26	0,23	0,20
	Marrón	0,75	0,73	0,51	0,36	0,75	0,30	0,02	0,28	0,39	0,43	0,37	0,02
	Verde	0,06	0,06	0,02	0,08	0,01	0,36	0,63	0,27	0,36	0,31	0,40	0,79
Wolfram (clara)	Clara	0,95	0,95	0,98	0,98	0,98	0,97	0,97	0,98	0,97	0,98	0,98	0,97
	Marrón	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	Verde	0,04	0,04	0,02	0,02	0,02	0,03	0,03	0,02	0,03	0,02	0,02	0,03
Mulitas (marrón)	Clara	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01
	Marrón	0,83	0,79	0,80	0,79	0,87	0,86	0,85	0,84	0,86	0,87	0,85	0,86
	Verde	0,17	0,21	0,19	0,20	0,13	0,13	0,14	0,15	0,13	0,12	0,14	0,13
Bragado (marrón)	Clara	0,33	0,26	0,90	0,93	0,78	0,89	0,92	0,91	0,86	0,90	0,90	0,91
	Marrón	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,01	0,00	0,01
	Verde	0,66	0,73	0,09	0,07	0,21	0,11	0,08	0,08	0,13	0,10	0,10	0,08
Gómez (verde)	Clara	0,00	0,00	0,03	0,02	0,10	0,01	0,01	0,01	0,01	0,02	0,04	0,01
	Marrón	0,06	0,05	0,05	0,05	0,06	0,06	0,06	0,06	0,06	0,06	0,05	0,06
	Verde	0,94	0,95	0,92	0,93	0,84	0,93	0,93	0,93	0,94	0,92	0,91	0,93
Segovia (verde)	Clara	0,01	0,02	0,44	0,76	0,04	0,05	0,01	0,85	0,00	0,01	0,01	0,00
	Marrón	0,95	0,94	0,51	0,08	0,91	0,05	0,02	0,03	0,07	0,06	0,03	0,02
	Verde	0,04	0,04	0,05	0,16	0,05	0,89	0,97	0,12	0,93	0,93	0,96	0,98

cuerpos de agua mediante información proveniente de imágenes LANDSAT. Los resultados obtenidos permiten considerar que los modelos de Redes Neuronales (MRN) son una herramienta adecuada en el procesamiento de los datos provenientes de la teledetección para determinar el estado general de una laguna.

La ponderación de cada una de las bandas del espectro visible e infrarrojo cercano de LANDSAT queda implícitamente resuelta durante el entrenamiento de la red. Para decidir si la configuración de la red es la más adecuada y evitar además el sobreentrenamiento observado al aumentar el número de épocas, es necesario contar con mayor cantidad de ejemplos supervisados para alimentar la red en el período de entrenamiento. La determinación de la mejor arquitectura de una red neuronal no es una tarea sen-

cilla y no existe, hasta el momento, una teoría que avale tal decisión. Por esta razón se hace doblemente necesario realizar ensayos de prueba y error para encontrar la configuración que logre el menor error global en la clasificación.

El entrenamiento realizado y las clasificaciones obtenidas fueron, en todos los casos, tomados y cotejados con los resultados no supervisados del trabajo realizado por Dukatz *et al.* (2005). Los muestreos periódicos a realizarse en quince lagunas por un período de un año en el marco del proyecto de trabajo, permitirán aumentar y mejorar el número de ejemplos para el entrenamiento y optimizar las clasificaciones.

La red así obtenida se incluirá en un segundo modelo generalizado que permitirá vincular las variables causales del estado de una laguna –nu-

trientes, luz, nivel hidrométrico, temperatura- con la cadena trófica resultante.

AGRADECIMIENTOS

Los autores agradecen a la CONAE por haber provisto gentilmente las imágenes satelitales necesarias para la realización del trabajo. Al Mg. Fabian Grosman y al M. V. Pablo Sanzano por el aporte de conocimientos y la supervisión a través de las tareas de campo. Al Ing. Federico Dukatz por compartir las técnicas que desarrolló y colaborar en el avance que propone este trabajo. Al Ing. Diego Ruiz Moreno por su detallada lectura e interesantes aportes. Al Sr. Mauro Chaparro y a la Sra. Florencia Castets por su apoyo incondicional.

Trabajo realizado con financiamiento de ANPCyT, Programa de Modernización Tecnológica, BID 1201/OC-AR, 13-502.

BIBLIOGRAFÍA

- Allen, P. M.** 1988. Evolution: Why the whole is greater than the sum of the parts. En: W. Wolff, D.; J. Soeder & F.R. Drepper (eds.). *Ecodynamics: Contribution to Theoretical Ecology*. Part 1: Evolution. Proceeding of an International Workshop, 19-20 October, 1987, Jülich, Germany, Springer Verlag, Berlin, 2-30p.
- Balch, W.M.; R. W. Eppley & M. R. Abbott.** 1989. Remote sensing of primary production-II. A semi-analytical algorithm based on pigments, temperature and light. *Deep-Sea Res.* 36(8): 1201-1217.
- Cole B.E. & J. E. Cloern.** 1987. An empirical model for estimating phytoplankton productivity in estuaries. *Mar. Ecol. Prog. Ser.* 36: 299-305.
- Eppley R.W.; E. Stewart; M. R. Abbott & U. Heyman.** 1985. Estimating ocean primary production from satellite chlorophyll. Introduction to regional differences and statistics for the Southern California bight. *J. Plank. Res.* 7: 57-70.
- Dukatz F.; R. Ferrari & G. Canziani.** 2005. Evaluación de Sistemas Lacunares Bonaerenses mediante Imágenes LANDSAT TM. En: Res. III Congreso de Ecología y Manejo de Ecosistemas Acuáticos Pampeanos.
- Fausett, L.** 1994. *Fundamentals of Neural Networks, Architectures, Algorithms, and Applications*. Ed. Prentice Hall.
- Jorgensen S.E.** 1995. The growth rate of zooplankton at the edge of chaos. *L. Theor. Biol.* 175:13-21.
- Jorgensen S.E.** 1998. An improved parameter estimation procedure in lake modelling. *Lakes and Reservoirs Res. Manag.* 3: 139-142.
- Jorgensen S.E.** 1999. State-of-the-art of ecological modelling with emphasis on development of structural dynamic models. *Ecological Modeling* 120:75-96.
- Jorgensen S.E. & R. de Bernardi.** 1997. The application of a model with dynamic structure to simulate the affect of mass fish mortality on zooplankton structure in Lago de Annone. *Hydrobiologia* 356: 87-96.
- Kompare, B.** 1995. The use of Artificial Intelligence in Ecological Modeling, Ph. D Thesis at DFH, University Park 2, Copenhagen, 360p.
- Quiros, R.; A. Rennella; M. Boveri; J. Rosso & A. Sosnovsky.** 2002. Factores que afectan la estructura y el funcionamiento de las lagunas pampeanas. 2da. Reunión Internacional de Eutrofización de Lagos y Embalses, Montevideo Uruguay <http://limno.fcien.edu.uy/taller/Quiros.html>
- McClelland, J. L. & D. E. Rumelhart.** 1988. *Explorations in Parallel Distributed Processing*. Cambridge, MA, MIT Press.
- Minsky, M.L. & S. A. Papert.** 1969. *Perceptrons*, Expanded Edition. Cambridge, MA, MIT Press.
- Rosenblatt, F.** 1962. *Principles of Neurodynamics*. Spartan, New York.
- Rumelhart, D. E.; G. E. Hinton & R. J. Willams.** 1986a. Learning Internal representations by Error Propagation. En: D. E. Rumelhart & J. L. McClelland (eds.) *Parallel Distributed Processing, Explorations in the Microstructure of Cognition; Vol. 1: Foundations*. Cambridge, MA, MIT Press.
- Rumelhart, D. E.; G. E. Hinton & R. J. Willams.** 1986b. Learning Representations by Back-Propagation Error. *Nature* 323: 533-536.
- Scardi, M. & L. Harding.** 1999. Developing an empirical model of phytoplankton primary production: a neural network case study. *Ecological Modeling* 120: 213-224.