

REDES NEURONALES Y TELEDETECCIÓN APLICADAS A LA DISTRIBUCIÓN ESPACIAL DE MATERIAL EN SUSPENSIÓN EN CUERPOS DE AGUA.

Mariana Pagot¹, Oscar Dölling², Andrés Rodríguez¹, Felipe Niencheski³, Gerardo Hillman¹, Mariano Corral¹ y Claudia Oroná¹.

1 Laboratorio de Hidráulica. Universidad Nacional de Córdoba. Argentina

2 Dpto. de Hidráulica. Universidad Nacional de San Juan. Argentina

3 Dpto. Química Oceanográfica. FURG – Brasil.

Av. Vélez Sarsfield 1601, Ciudad Universitaria. CP: 5000. Córdoba, Argentina. Teléfono (Fax): 433-4446. E-mail: mpagot@com.uncor.edu

Key words: Redes neuronales, teledetección, material suspendido.

Resumen. *Este trabajo presenta la combinación de dos técnicas modernas: Redes Neuronales Artificiales y Teledetección. Se desarrolló un modelo de distribución espacial basado en Redes Neuronales Artificiales que determina la relación existente entre la concentración de material en suspensión (MES) en un cuerpo lagunar y un conjunto de valores de reflectividades medidos con sensores remotos de la serie LANDSAT (5 y 7) basado en la estrategia desarrollada por O. Dölling (2001) para selección de variables explicativas, diseño, entrenamiento y validación de modelos de redes. El lugar de estudio seleccionado es la laguna de Los Patos - Brasil. La metodología utilizada para entrenar las Redes Neuronales se basó en un aprendizaje de tipo supervisado. Los valores de entrada correspondieron a reflectividades de distintas bandas, mientras que los de salida correspondieron a valores de MES medidos en 4 campañas de monitoreo durante el año 1999 sobre 10 estaciones cada una, lo que hace un total de 40 ejemplos procesados. La Red Neuronal Artificial ajustada entrega valores correctos (error menor que 20%) de MES para datos de reflectividades que no se tuvieron en cuenta durante el proceso de entrenamiento, garantizando una buena capacidad de generalización y su validez de aplicación en un modelo de distribución espacial de parámetros sedimentológicos.*

1. INTRODUCCIÓN

Este trabajo presenta un modelo de distribución basado en la técnica de redes neuronales artificiales, que tiene por objetivo determinar una función que prediga espacialmente la concentración de material en suspensión (MES) en un cuerpo lagunar determinado, a partir de un conjunto de valores de reflectividad medidos con sensores remotos de la serie de satélites LANDSAT (5 y 7). El aprendizaje de la red neuronal es de tipo supervisado, entregándole a la red ejemplos constituidos por conjuntos de entradas y salidas como variables explicativas y explicadas respectivamente. El lugar de estudio es la Laguna de los Patos ubicada al sur de Brasil (Figura 1)




Figura 1: Ubicación esquemática de la región en estudio. Laguna de los Patos – Brasil.

1.1. Datos de campo

Se utilizaron datos de MES medidos en 10 estaciones distribuidas uniformemente sobre el eje longitudinal de la Laguna. Estas mediciones fueron realizadas en 4 campañas de monitoreo durante los meses de marzo a noviembre de 1999, por la Fundación Universitaria de Río Grande (FURG), Brasil.

1.2. Datos satelitales

Los datos utilizados corresponden a valores de reflectividades calculados en función de

parámetros propios de cada banda de los sensores LANDSAT; considerando además, las efemérides del satélite al momento de adquirir cada imagen.

Las imágenes disponibles fueron cedidas por la CONAE (Comisión Nacional de Actividades Espacial) a través del Instituto de Altos Estudios Espaciales “Mario Gulich”. Se contó con 8 imágenes de la región en coincidencia con las campañas realizadas. Cada imagen cubre un área de 180x180 km² por lo que se realizó un mosaico con 2 imágenes para analizar cada campaña.

La expresión utilizada en la transformación de variables se presenta en la ecuación 1.

$$\rho_p = \frac{\pi \cdot L_\lambda \cdot d^2}{E_{sun\lambda} \cdot \cos \Theta_s} \quad (\text{Ec. 1})$$

Donde: ρ_p es la reflectividad en la Banda p; L_λ : es la radiancia espectral ($L=a1*ND+a2$) con ND: número digital de la imagen; d: día juliano; $E_{sun\lambda}$: irradiancia solar (constante para cada satélite y cada banda); Θ_s : ángulo de elevación solar.

Se procesaron 4 mosaicos de imágenes satelitales y se midieron sobre cada estación monitoreada los correspondientes datos de intensidades de píxeles (ND) filtrados espacialmente para promediar el error en la ubicación de dicha estación. Los valores de reflectividades calculados con la Ec.1 se presentan en la Tabla 1.

Tabla 1: Datos satelitales y de campo disponibles para desarrollar la red.

Número	Código	Fecha	Reflectividad (R)				Variables de campo
	Estación	Imagen	Banda1 (R1)	Banda2 (R2)	Banda 3 (R3)	Banda 4 (R4)	In (MES) (y)
1	R1	17-Sep-99	0,00000	0,03972	0,022	0,021	4,292
2	P1		0,00925	0,00000	0,000	0,000	4,090
3	P2		0,01658	0,05390	0,003	0,002	3,413
4	P3		0,01785	0,05390	0,000	0,010	3,360
5	P4		0,01020	0,05248	0,020	0,019	3,658
6	P5		0,00383	0,04681	0,037	0,029	4,084
7	P6		0,00638	0,04965	0,041	0,031	3,932
8	P7		0,01913	0,05674	0,045	0,031	2,982
9	P8		0,02168	0,05958	0,032	0,027	2,681
10	O1		0,01020	0,04965	0,008	0,035	3,681
11	R1	17-Mar-99	0,014947	0,015542	0,015	0,011	2,608
12	P1		0,010463	0,012433	0,003	0,008	2,964
13	P2		0,000000	0,000000	0,000	0,000	3,555

Número	Código	Fecha	Reflectividad (R)				Variables de campo
	Estación	Imagen	Banda1 (R1)	Banda2 (R2)	Banda 3 (R3)	Banda 4 (R4)	In (MES) (y)
14	P3		0,014947	0,015542	0,000	0,008	2,097
15	P4		0,023916	0,024867	0,023	0,019	0,262
16	P5		0,017937	0,021758	0,030	0,019	1,224
17	P6		0,017937	0,021758	0,018	0,015	1,155
18	P7		0,017937	0,021758	0,003	0,004	1,163
19	P8		0,014947	0,018650	0,025	0,019	2,063
20	O1		0,014947	0,018650	0,030	0,026	1,864
21	R1		08-Ago-99	0,000000	0,000000	0,007	0,018
22	P1	0,000000		0,005989	0,002	0,000	5,184
23	P2	0,015839		0,047910	0,005	0,004	4,537
24	P3	0,031678		0,074859	0,000	0,007	3,934
25	P4	0,000000		0,029944	0,010	0,004	5,175
26	P5	0,023039		0,050904	0,015	0,011	4,492
27	P6	0,025919		0,065876	0,032	0,029	4,257
28	P7	0,050397		0,098814	0,019	0,018	2,655
29	P8	0,047517		0,089831	0,022	0,033	3,345
30	O1	0,014399		0,044915	0,019	0,022	4,616
31	R1	12-Nov-99	0,022296	0,053321	0,019	0,028	4,159
32	P1		0,004459	0,030138	0,002	0,008	4,921
33	P2		0,008918	0,032456	0,004	0,006	4,877
34	P3		0,000000	0,000000	0,000	0,010	5,565
35	P4		0,040133	0,076504	0,000	0,000	2,850
36	P5		0,027870	0,060276	0,021	0,034	3,829
37	P6		0,027870	0,060276	0,036	0,048	3,875
38	P7		0,015607	0,039411	0,047	0,045	4,502
39	P8		0,032330	0,067230	0,058	0,054	3,444
40	O1		0,030100	0,064912	0,053	0,048	3,509

En la Tabla 2 se presentan los valores resultantes del coeficiente de asimetría de cada serie, los cuales permanecen dentro de un intervalo entre [-0,75 y 0,75] correspondiente a una probabilidad (α) igual a 0,05 y 40 valores datos.

Tabla 2: Parámetros de normalidad

R1	R2	R3	R4	Y
0,73463	0,12259	0,69239	0,60495	-0,67231
Verifica	Verifica	Verifica	Verifica	Verifica

Se analizó la periodicidad de las variables a través de los gráficos de autocorrelogramas

(Figura 2) método que permite definir la estructura de dependencia de cada serie. En las series correspondientes a las reflectividades de las Bandas 2, 3 y 4 respecto a la del logaritmo de la variable MES se identificó una dependencia espacial igual a un intervalo (o sea, una estación), lo cual se consideró al momento de generar el conjunto de ejemplos de la red a proponer.

En este caso, la dependencia que se verifica entre los datos es de tipo espacial y no temporal, debido a las características de los ejemplos utilizados.

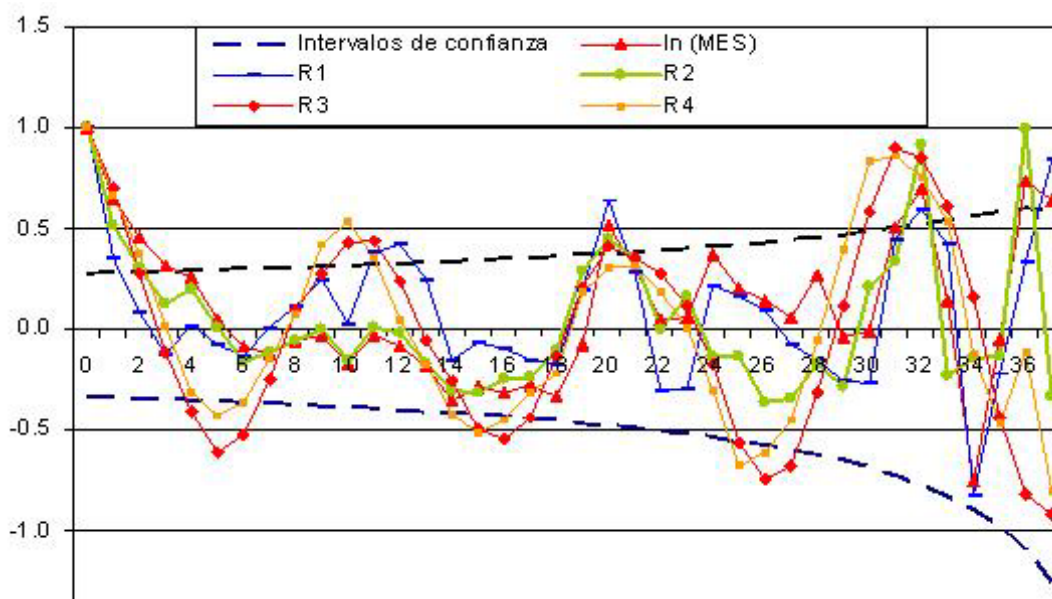


Figura 2: Coeficientes de autocorrelación de las series de reflectividades y Ln(MES).

En la mayoría de las series la dependencia comprobada correspondió a 1 desfase ($k = 1$). Esto es debido a que las estaciones (ubicadas en dirección NE-SO) reciben desde el NE los mayores aportes por tributarios de la Laguna, del Río Guaiba, cuya concentración de sedimentos medida en la desembocadura de este río influye en la próxima estación ubicada hacia aguas abajo.

Por otro lado, se realizaron análisis estadísticos básicos como valores extremos (máximos y mínimos), promedios, desviación típica y asimetría de cada serie. (Tabla 3)

Tabla 3: Parámetros estadísticos típicos

	R1	R2	R3	R4	Ln(MES)
Mínimo:	0,00	0,00	0,00	0,00	0,26
Máximo:	0,050	0,099	0,058	0,054	5,57
Promedio:	0,017	0,041	0,018	0,019	3,50
Desviación típica:	0,01386	0,02535	0,01641	0,01465	1,25002
Nro. de observaciones:	40				

A partir de un análisis de autocorrelación cruzada entre variables de entrada y salida, se evaluó la existencia de problemas estructurales, ya que todas las variables explicativas presentaron algún punto fuera del intervalo de confianza. (Figura 3)

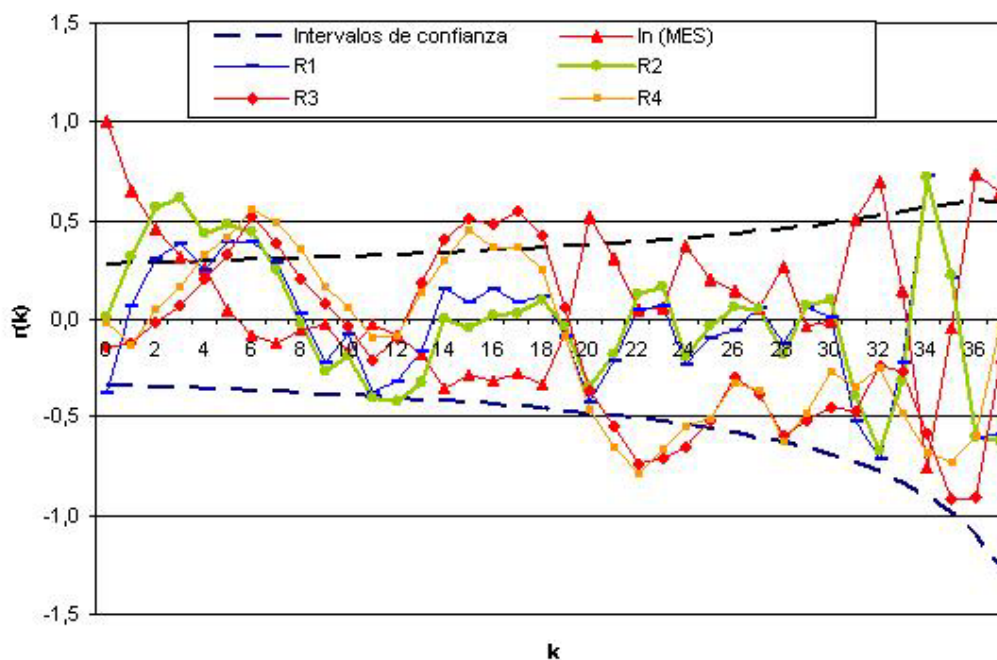


Figura 3: Coeficientes de autocorrelación cruzada entre las series de reflectividades y Ln (MES).

1.3. Selección del conjunto de ejemplos

El tratamiento de los datos incluyó la división del conjunto de datos en clases de entrenamiento, de calibración y de verificación; además de la selección de la función sigmoide como función de activación de neurona para lo que se escalan los datos de salida entre $[-0,7$ y $0,7]$. Los datos de entrada se encontraban originalmente dentro de este rango. Luego se evaluaron tres estructuras principales de ejemplos:

a) Los datos de entrada corresponden a las series analizadas de reflectividades (R1, R2, R3 y R4) mientras que los de salida corresponden a los valores escalados del Ln (MES).

b) Los datos de entrada corresponden a las series analizadas (R1, R2, R3 y R4) junto con las series desplazadas un intervalo igual a una estación de monitoreo hacia el Sur de la Laguna para R2, R3 y R4, mientras que los de salida, corresponden a los valores escalados a Ln (MES).

c) Igual que (b) pero considerando una variable explicativa adicional relacionada con el índice (R1i/R2i) con i desde 1 a 40.

La alternativa (c) surgió del análisis de las regresiones múltiples lineales entre las variables explicativas y explicadas, con un coeficiente de determinación (r^2) igual a 0,71; el cual resulta mayor al obtenido con el resto de las alternativas propuestas. El criterio de selección de las alternativas se basó en la evaluación de pruebas de significancia y análisis estadístico (pruebas t, determinación de intervalos de confianza) sobre valores calculados y residuos. Además, se verificó que cada conjunto de entrenamiento cubriera el espectro de los posibles rangos de valores de entrada.

1.4. Selección de la topología de red

Se evaluaron distintas arquitecturas de redes neuronales, presentadas a continuación con el siguiente criterio (RED [cantidad de neuronas de entrada, cantidad de neuronas ocultas, cantidad de neuronas de salida]):

- a) RED [4,4,1]
- b) RED [4,3,1]
- c) RED [4,10,1]
- d) RED [7,4,1]
- e) RED [7,3,1]
- f) RED [8,4,1]

1.5. Estrategia de entrenamiento

La estrategia de entrenamiento seleccionada se aplicó a las distintas topologías mencionadas y está definida a través de los siguientes aspectos: - algoritmo de aprendizaje: Backpropagation mom., actualización de pesos: On-line, modo aleatorio de inicialización de pesos y presentación aleatoria de las tuplas de entrenamiento.

1.6. Problemas observados en el aprendizaje de los modelos candidatos

Las distintas redes presentaron diversos problemas durante su entrenamiento derivados de la estructura y la estrategia de entrenamiento seleccionada.

Se destaca el caso de la red (c) la cual posee demasiadas neuronas ocultas generando una superficie de pesos asociados a los enlaces demasiado compleja (sobreparametrización del modelo), otro ejemplo de red presentó problemas de overfitting (sobrentrenamiento) derivado de una mala estrategia de entrenamiento inicial. Esto se puede ver en la Figura 4, donde se observa que no se logra entrenar la red, debido a insuficientes nodos lo que está relacionado con una falta de expresividad de la red. Se observa, además, que la curva del conjunto de validación no logra convergencia a un mínimo y corta a la curva de entrenamiento (suma de residuos elevados al cuadrado (SSE) vs ciclos de entrenamiento) aproximadamente a los 60.000 ciclos.




Figura 4: Gráfico de SSE vs tiempo. Sobrentrenamiento de la red [7, 3, 1].

Entre los esquemas analizados, los resultados presentaron los siguientes errores medios de predicción entre los valores calculados por el programa SNNS y los valores objetivos correspondientes a cada ejemplo de entrenamiento:

Para la RED [4,4,1]: - 5,46%

Para la RED [4,3,1]: 4,52 %

Para la RED [4,10,1]: -8,9%
 Para la RED [7,4,1]: - 0,45 %
 Para la RED [7,3,1]: -3,55 %
 Para la RED [8,4,1]: -0,5 %

De lo anterior surge que las redes (d) y (f) son las que menores errores de predicción presentaron. En la Figura 5, se presenta la estructura de la red (d) [7, 4, 1], en la cual se observan los pesos calculados para cada enlace de neuronas en un ciclo determinado.




Figura 5: Estructura de la red [7, 4, 1] y pesos calculados.

Bajo esta estructura es posible evaluar que los pesos mayores corresponden a la variable explicativa R1, lo cual coincide con lo estimado a partir de las regresiones lineales realizadas entre las distintas variables explicativas y explicadas.

El test de los desvíos correspondiente se presenta en la Figura 6, para el conjunto de datos de entrenamiento considerado.

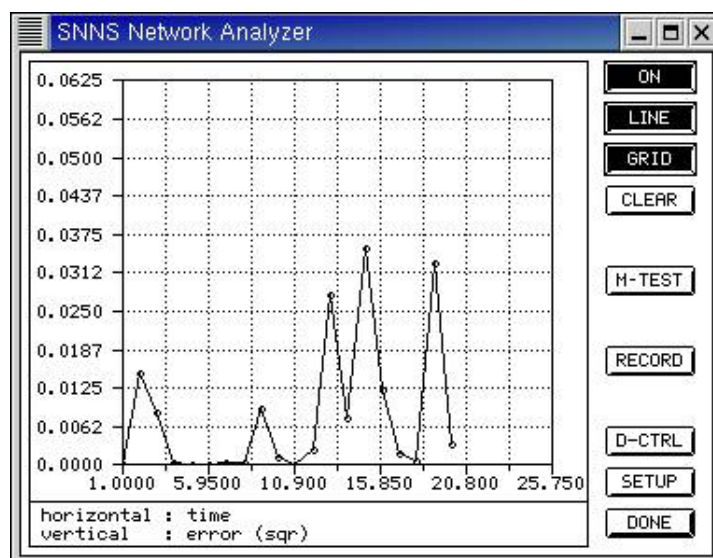


Figura 6: Test para el conjunto de ejemplos de entrenamiento de la red [7, 4, 1]

En la Figura 7, se presenta el resultado del test de desvíos para el conjunto de ejemplos designado para la calibración, donde es posible visualizar el buen ajuste de la simulación, ya que los errores de predicción son menores al 1%.

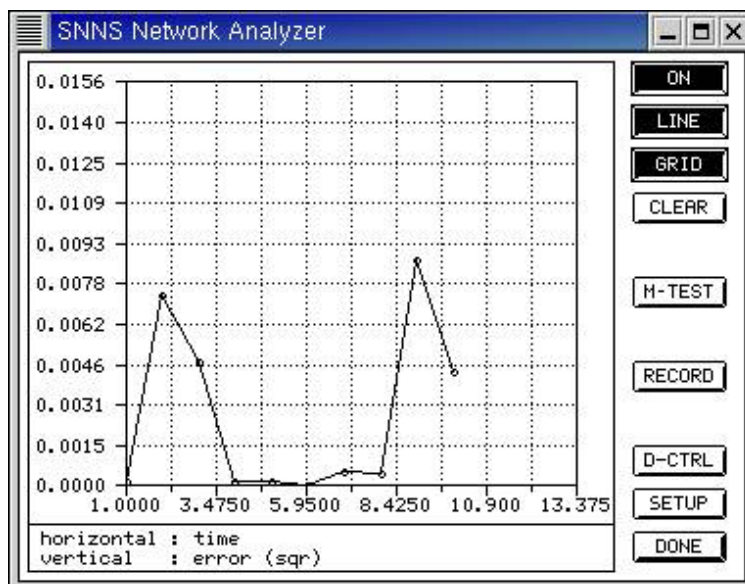


Figura 7: Test para el conjunto de ejemplos de calibración de la red [7,4,1]

La Figura 8 muestra la estructura de la red [8, 4, 1] y el conjunto de pesos calculados.




Figura 8: Estructura de la red [8, 4, 1]

En cada uno de los casos presentados se entrenó la red hasta que se alcanzó el punto mínimo de SSE.

El análisis anterior permitió orientar en la selección de los modelos con mejor comportamiento en la predicción de los ejemplos de entrenamiento. Para evaluar la capacidad de generalización de cada red, para conjuntos de ejemplos distintos a los de entrenamiento, se verificó la Hipótesis Nula de que la serie de residuos obtenida posee un comportamiento estadístico equivalente a un “ruido blanco”. Para ello, en cada red (d) y (f) se verificó el test de Normalidad de Fischer con valores $-0,1551$ y $-0,0776$, respectivamente, para un intervalo de confianza comprendido entre $0,7893$ y $-0,7893$. El análisis del autocorrelograma simple indicó una dependencia espacial de los dos primeros intervalos (Figura 9) para la red (f). Mientras que para la estructura [7, 4, 1] no se presentaron valores fuera del intervalo de confianza, definido en ambos casos para una probabilidad del 5% (Figura 10).

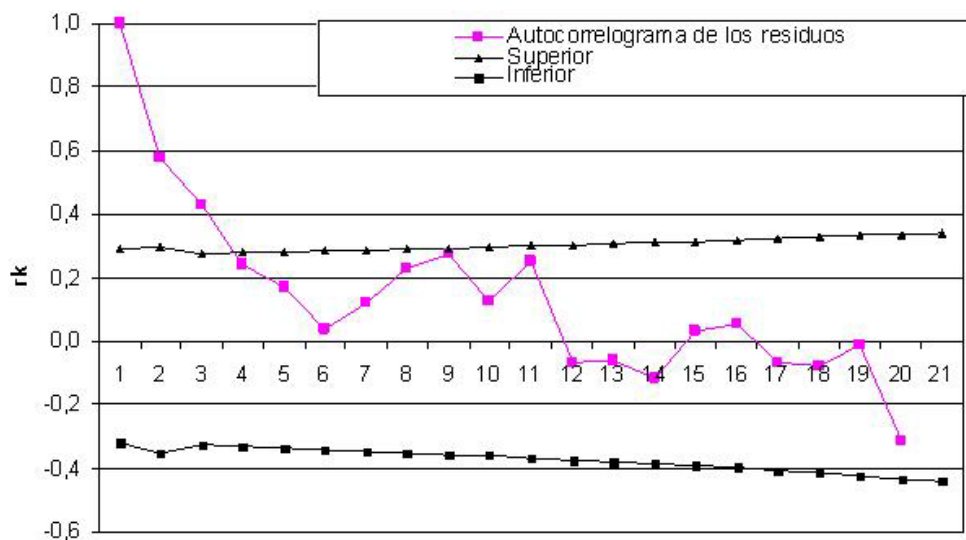


Figura 9: Autocorrelograma de los residuos correspondientes a la red [8, 4, 1]

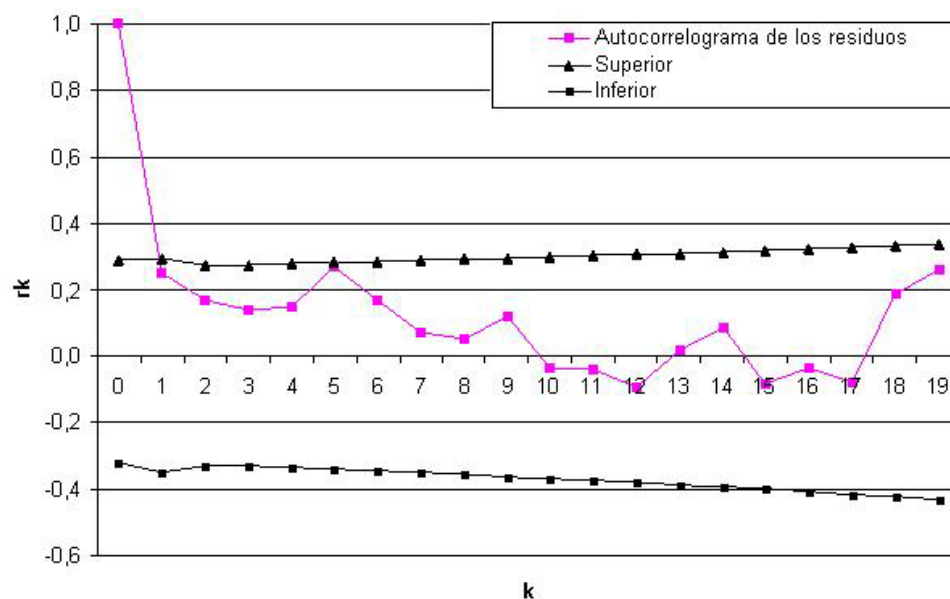


Figura 10: Autocorrelograma de los residuos correspondientes a la red [7, 4, 1]

Los resultados del autocorrelograma parcial de cada red verificó la independencia de los residuos, presentándose en las Figuras 11 y 12 los correspondientes a las redes d y f respectivamente.




Figura 11: Autocorrelograma parcial de residuos correspondiente a la red [7, 4, 1]




Figura 12: Autocorrelograma parcial de residuos correspondiente a la red [8, 4, 1]

1.7. Análisis de los resultados

El análisis y la validación de los modelos candidatos se realizaron evaluando la capacidad de predicción de dichos modelos. Esta etapa se enfocó sólo sobre los resultados de las redes previamente seleccionadas (d y f).

Los resultados alcanzados con la red [7, 4, 1] presentaron sobre los ejemplos de validación un coeficiente de determinación (r^2) igual a 0,95. Este coeficiente en la red [8, 4, 1] aumenta

hasta 0,99. Los resultados se presentan en las Figuras 13 y 14, respectivamente. En ambas simulaciones se realizó, nuevamente, un análisis de los residuos, verificándose el test de Normalidad de Fisher, el cual se encuentra dentro de un intervalo de confianza comprendido entre [-0,89 y 0,89].




Figura 13: Curva de regresión lineal entre los valores medidos de (MES) y los generados con la red neuronal y el programa SNNS. Red [7, 4, 1].




Figura 14: Curva de regresión lineal entre los valores medidos de (MES) y los generados con la red neuronal y el programa SNNS. Red [8, 4, 1].

Los valores generados con el programa SNNS transformados a parámetros comparables con los respectivos valores medidos se presentan en las Figuras 15 y 16, para las redes (d) y (f) y el conjunto de ejemplos correspondientes a la validación. Se observó el buen ajuste alcanzado tanto en el conjunto de entrenamiento como en el conjunto de validación de cada red.

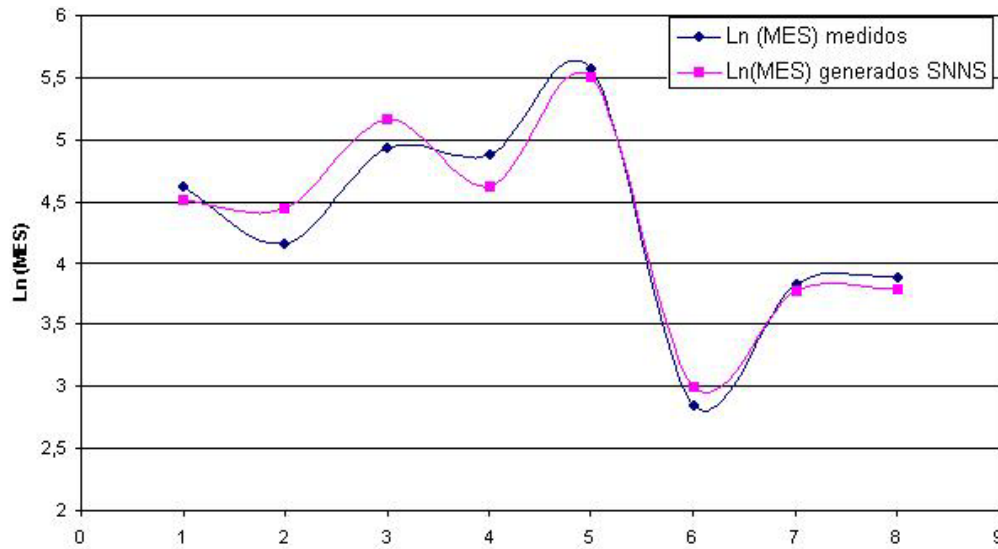


Figura 15: Comparación entre resultados medidos y generados para la red [7, 4, 1] de los ejemplos de calibración.

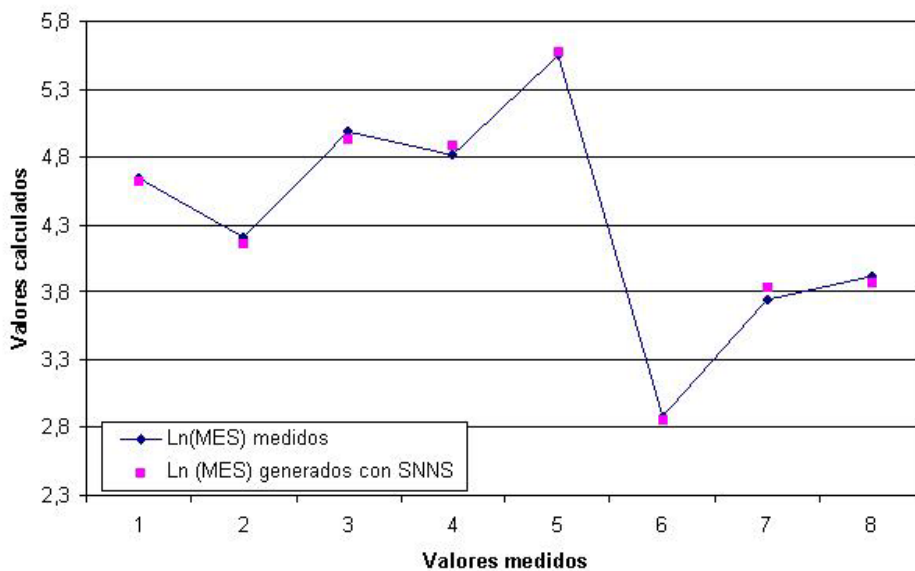


Figura 16: Comparación entre resultados medidos y generados para la red [8, 4, 1] de los ejemplos de calibración.

En ambos gráficos se observa el buen ajuste de los valores generados respecto de los datos,

siendo la red con mayor cantidad de variables explicativas la que presenta mejor ajuste. Sin embargo al combinar estos resultados con los de entrenamiento se encontró una condición inversa a la descrita anteriormente, la cual se presenta en las Figuras 17 y 18. En estas figuras se observa la recta de regresión vinculando ambas variables y el coeficiente de determinación asociada a la misma: mayor correlación arrojaron los resultados de la red [7, 4, 1] respecto de la red [8, 4, 1]. A partir de esta situación es posible interpretar que los datos de entrenamiento fueron mejor entendidos con la primer red que con la segunda.




Figura 17: Valores medidos vs valores generados con la red [7, 4, 1]




Figura 18: Valores medidos vs valores generados con la red [8, 4, 1]

1.8. Selección del modelo óptimo

En base a diferentes análisis comparativos entre los indicadores del poder de predicción de cada topología evaluada (dispersión, independencia, normalidad, etc.) se ha seleccionado la red [7, 4, 1] como la que mejor entrena y generaliza los datos medidos. La visualización de los resultados medidos y generados se presenta en la Figura 19.

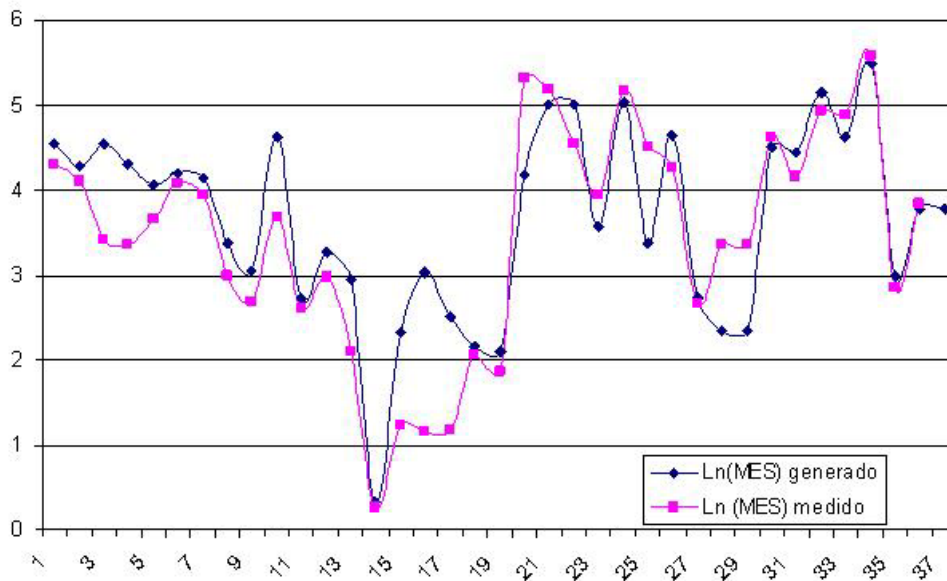


Figura 19: Visualización de resultados medidos y generados con SNNS.

2. CONCLUSIÓN

Los resultados del trabajo presentado muestran que en términos particulares la red [7, 4, 1] tiende a subestimar el primer conjunto de ejemplos de entrenamiento (puntos 3-5 y 17-20) y sobrestimar algunos puntos en el resto (que incluye los datos de calibración: principalmente puntos 28-29). Mientras que en términos generales, la modelación con redes neuronales explicó en un 75 % el conjunto de ejemplos (escasos) disponibles. La arquitectura de red resultante puede, aún, mejorarse, ya que el coeficiente de determinación fue menor a 0,90.

El modelo propuesto permite sumar datos de reflectividades de otros sensores con el objetivo de aumentar el número de ejemplo.

3. REFERENCIAS

- [1] O. Dölling y E. Varas. *Artificial neural networks for streamflow prediction*. Journal of IARH –International Asociation of Hydraulic Engeneering and Research – 2629 HD Delft The Netherlands, (2002).
- [2] B. Fernández, D. Tripodi, O. Dölling. *Meltwater streamflow forecasting using ENSO and snow cover data*. Hydrological Sciences Journal IAHS, Inglaterra, (2000).
- [3] L. F. Niencheski y Baumgarten. *Distribution of particulate trace metal in surrounding waters of Rio Grande City (Brazil)*. Aquatic Ecosystem Health & Management. Brasil, 3(4), 515-520, (2001).
- [4] L. F. Niencheski y R. Smith. *Distribution of Particulate Trace Metal in Patos Lagoon Estuary (Brazil)*. Marine Pollution Bulletin, Brasil, 28 (2), 96-102, (1994).
- [5] M. Pagot, L.F. Niencheski, M. Corral, G. Hillman, A. Rodríguez, C. Oroná, A. Friedrich, M. Scavuzzo, M. Baumgarten. *Modelado de distribución de Material en Suspensión en la Laguna de Los Patos (Brasil) utilizando técnicas de teledetección*. V Jornadas de Ciencias del Mar. Mar del Plata, Argentina. (2003).

4. AGRADECIMIENTOS

Este proyecto de investigación se realiza en conjunto, desde el Laboratorio de Hidráulica de la FCEFyN de la UNC como parte de un programa más amplio de investigación fundado por la Comunidad Europea denominado ECOSUD (Estuaries and Coastal Areas, Basis and Tools for a more Sustainable Development) (ICA-CT-2001-10027).