

Redes Neuronales aplicadas al monitoreo de procesos de perforación en probetas de material geológico

Basgall A.^a, Ferrari, G.^a, Gómez, M. ^{a,b}

^a Grupo de Emisión Acústica, Facultad Regional Delta, Universidad Tecnológica Nacional, San Martín 1171, Campana, Buenos Aires, ARGENTINA.

^b Grupo de Ondas Elásticas – Proyecto ICES, Comisión Nacional de Energía Atómica, Av. Gral. Paz 1499, San Martín (1650), Buenos Aires, ARGENTINA.

e-mail: angelbasgall@hotmail.com

RESUMEN

Una Red Neuronal Artificial (RNA) es un modelo matemático computacional que intenta imitar, limitadamente, la estructura y funcionamiento de neuronas biológicas las cuales, a grandes rasgos, toman señales eléctricas de entrada y producen una señal de salida llamada respuesta. Mediante la combinación de una cantidad grande de neuronas artificiales, estas pueden tener la capacidad de “aprender” patrones específicos en el análisis de señales e inferir resultados. Estas redes pueden ser utilizadas en una amplia gama de aplicaciones como clasificación de objetos o señales, aproximación de funciones, conducción autónoma, reconocimiento de voz, análisis y tratamiento de imágenes o textos, etc. Las RNA tipo mapa auto-organizado (SOM Self Organized Map) o también llamadas Redes Kohonen realizan una suma ponderada de los datos multidimensionales de entrada, los cuales son afectados individualmente por un valor numérico denominado peso. Luego mediante una competencia entre neuronas se selecciona una ganadora y se procede a realizar un ajuste de vecindad para que la señal de salida sea más parecida a la señal de entrada. Esto genera un mapa en dos dimensiones donde la información se muestra organizada en zonas que tienen características similares. Los pesos de cada neurona se modifican continuamente y de diferente manera durante varias “épocas” (época se denomina a cada paso de ajuste de los pesos) hasta minimizar el error de la respuesta. Este proceso se denomina entrenamiento, donde específicamente para esta red, es un aprendizaje de tipo no supervisado. En este trabajo se utilizan RNA tipo SOM para el estudio de señales emisión acústica (EA) provenientes de un proceso perforación de materiales geológicos dispuestos en capas y asociados mediante un cementicio, con los cuales se construyeron probetas de tamaño de laboratorio (320x320x400 mm). El taladrado se realizó con brocas de 65 mm de diámetro, con insertos monofilos de carburo de tungsteno, haciendo cuatro agujeros por cada probeta multicapa, y se midió la EA durante cada perforación. Luego de un proceso de entrenamiento detallado y una selección rigurosa de la información, esta RNA mostró la capacidad de reconocer las diferentes capas de cada probeta a partir del procesamiento de las señales de EA obtenidas durante el proceso de perforación.

Palabras Clave: Redes Neuronales, Emisión Acústica, Taladrado, Rocas.

1. INTRODUCCIÓN

Una Red Neuronal Artificial (RNA) es un modesto modelo matemático computacional basado en sus homologas biológicas, las cuales reciben impulsos eléctricos en sus dendritas (entrada) que luego son procesados en el organismo (cuerpo de la neurona) y producen un impulso eléctrico que viaja por el axón (salida) y se conecta con dendritas

de neuronas próximas través de neurotransmisores químicos (peso) que modulan la señal. [Beale et al. 2020] [Zupan y Gasteiger, 1993].

Una vez planteado un modelo matemático que modeliza las funciones básicas de una neurona biológica individual, podemos combinar una gran cantidad de estas hasta adquirir la capacidad de “aprender” patrones específicos e inferir resultados. Estas redes pueden ser utilizadas en aplicaciones como conducción autónoma [Yáñez-Badillo H., 2017] [Faheem, 2013], análisis y tratamiento de imágenes (Su, 2019), y otras [Boldsaiikhana, 2011] [Fratini, 2009].

En el presente trabajo se utilizó una RNA tipo mapa auto-organizado o de Kohonen [Kohonen, 2001]. Esta red se caracteriza por tener un aprendizaje no supervisado, lo que significa que la red se ajusta automáticamente a los valores de entrada sin ningún tipo de estimulación positiva o negativa por parte del usuario. Este tipo de red brinda como resultado un mapa de dos dimensiones independiente de la cantidad de parámetros de entrada. Una red neuronal tipo Kohonen realiza un escalado multidimensional a bidimensional. Sobre el mapa resultante se muestran las neuronas que determinan zonas de similitud, de las que se puede analizar la topología, es decir, la distribución de la información con características semejantes. De esta forma, se llega a una forma de más fácil interpretación para un observador.

Este tipo de RNA contiene gran cantidad de parámetros a ser definidos, con el objetivo de lograr un correcto aprendizaje de los patrones existentes en el conjunto de datos. Aspectos importantes para considerar mínimamente a la hora de “diseñar” y optimizar una RNA del tipo Kohonen comprenden el tipo de aprendizaje, la cantidad de neuronas (que al ser de una sola capa se expresa como una matriz de $M \times N$), la forma en la corrección de pesos, la topología, la geometría de la red y las épocas de entrenamiento. Una de las formas de definir una regla de aprendizaje de la información se logra comparando las salidas de todas las neuronas con el dato de entrada y definiendo como “neurona ganadora” la que tenga el peso más parecido al dato ingresado. Una vez seleccionada la neurona ganadora se procede a ajustar los pesos de esa neurona y de sus vecinas para que se asemejen más a esa clase de datos. La función de corrección de los pesos de la neurona y su vecindad es la forma en la que se distribuye un factor de ajuste en cada neurona, generalmente este valor tiene una corrección alta en la ganadora y decrece al alejarse de esta. Las funciones más comunes de ajuste pueden ser constantes, gaussianas, lineales, etc.

La topología se define como la forma en la que cada neurona interactúa con sus vecinas, definiendo la cantidad de comunicaciones individuales. Esto se puede observar en la Fig. 1 donde se representan diferentes arreglos que varían la cantidad de vecinos de una neurona.




Fig. 1. a. Distribución ortogonal, b. Distribución Panal de abeja, c. Distribución Triangular.

La geometría de una red establece el comportamiento de la vecindad cuando está dentro de los límites. Esta puede modelizarse en forma plana, tubular o toroidal (Fig. 2 a, b, c) que luego es representada en un mapa de dos dimensiones como se puede observar en la vista planar de la Figura 3 para una geometría tubular y otra toroidal.




Fig. 2. a. Geometría Plana, b. Geometría Tubular, c. Geometría Toroidal.




Fig. 3. Vista planar de a. Geom. Tubular, b. Geom. Toroidal.

Por último, una época se define cuando todo el lote de datos ha ingresado en la red. Habitualmente se deben realizar muchas épocas de entrenamiento para que los pesos se ajusten teniendo cuidado de no sobre-entrenar la red. En cada época se mide el error como distancias vectoriales, ya sean euclideas, Minkowski, Tanimoto, Mahalanobis, etc; que expresan la diferencia entre los valores de entrada y salida de la red. Adicionalmente se puede calcular el error de mezclado, que se produce cuando un dato de una clase es clasificado por una neurona que anteriormente reconoció un dato de otra clase. Esto último, solo se puede hacer si previamente se etiquetaron los datos de las diferentes clases.

La técnica de Emisión Acústica (EA) está basada en el monitoreo de ondas elásticas que se producen en un material y se propagan por ese medio físico. En general es producida por una sollicitación del material. Esta onda puede ser detectada y adquirida mediante un transductor piezoeléctrico que transforma el movimiento de la superficie del material en una señal de voltaje proporcional a la energía de la onda. En este proceso, la señal de EA es digitalizada, parametrizada y finalmente analizada. Con el fin de economizar cálculos y recursos de cómputo se extrae la información más relevante de las ondas, mediante parámetros característicos que permiten describirla. Estos, en general, se definen a partir del cruce por primera y última vez de un umbral definido por el operador con el fin de separar la señal del ruido. Esta porción de señal se denomina hit o golpe de EA. Algunos de los parámetros característicos de la EA son la amplitud (expresada en dB), el número de cuentas, la duración, el valor cuadrático medio (“rms”), el tiempo de subida (“rise time”) y otros. El valor cuadrático medio (“RMS”) es una medida de la energía que contiene la señal, además tiene la ventaja de suavizar pequeños cambios en la ganancia del sistema electrónico o en el acoplamiento del transductor. Se calcula mediante la ecuación:

$$V_{ef} = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} v^2(t) dt} \quad (1)$$

La energía absoluta es la integral en el tiempo del cuadrado de la señal de EA, dividida por la resistencia de entrada del preamplificador. Este parámetro calcula la energía eléctrica a la salida del sensor la cual se relacionará a la energía elástica generada por el fenómeno escuchado.

$$E_e = \frac{1}{R} \int [V(t)^2] dt \quad (2)$$

El número de cuentas es la cantidad de veces que la señal cruza el umbral durante el tiempo de duración del hit. El tiempo de subida (“rise time”) es el lapso desde que la señal cruza el umbral hasta que el hit alcanza su amplitud máxima. La amplitud es el valor máximo en módulo de la tensión de la señal de EA. Este valor está relacionado con la magnitud de la fuente y propiedades del material. En general se expresa en decibeles (dB_{EA}) dado que la variación en mV es de varios órdenes.

Se calcula mediante la ecuación:

$$A(dB_{EA}) = 20 \log \frac{V_p}{V_{ref}} \quad (3)$$

Estos parámetros o descriptores de la EA se pueden definir como vectores de información que eventualmente pueden ser utilizados como información de entrada para entrenar y simular una RNA con la capacidad de reconocer las diferentes señales de EA durante el monitoreo de un proceso.

Existe bibliografía que relaciona la utilización de RNA y señales de EA, en diferentes campos de aplicación como la clasificación de estado de herramientas, así como la rugosidad final obtenida en procesos de desbaste [Kwak, 2004], Caracterización de procesos de soldadura por fricción [Jiménez Macías, 2013], monitoreo en procesos de manufactura aditiva [Shevchik, 2018], monitoreo en línea del desgaste de herramientas [Sick, 2002], predicción de características mecánicas en procesos de taladrado de rocas [Kumar, 2013], predicción de tensión de producción de falla en material compuesto [Kumar, 2017], inferir índice de abrasión se rocas [Pérez, 2015], monitoreo en procesos de desbaste, entre muchos otros.

En el presente, se utilizó una RNA tipo Kohonen para clasificar los patrones característicos de EA correspondientes a un proceso de taladrado sobre materiales rocosos. Luego de seleccionar parámetros de EA y diseñar la arquitectura de la RNA se obtuvieron mapas de clasificación que permiten distinguir las diferentes capas de los diferentes materiales geológicos.

2- DESARROLLO EXPERIMENTAL

2.1 Construcción de probetas

Las probetas se realizaron depositando capas de diferentes rocas unidas con cemento. Todas las probetas tienen las mismas dimensiones, varía el grosor y tipo de roca de cada

capa intermedia. Están diseñadas para permitir 4 perforaciones en una misma probeta (ver Fig. 4)

Las rocas utilizadas para este trabajo son arenisca y lutita (Caliza). El elemento cementicio está conformado por 3 partes de arena, 0.8 de cemento y 0.2 de cal.




Fig. 4. Montaje experimental (Probeta A2AC2 ver Tabla 1).

Para la realización de este ensayo se utilizaron probetas con las composiciones detalladas en la Tabla 1.

Tabla 1 – Resumen de la conformación de las probetas.

Nombre de ensayo	AC1C				A2AC2				A2CP1				A3A1							
	Cem.	Roca 1	Cem.	Roca 2	Cem.	Cem.	Roca 1	Cem.	Roca 2	Cem.	Cem.	Roca 1	Cem.	Roca 2	Cem.	Cem.	Roca 1	Cem.	Roca 2	Cem.
Arenisca							X					X					X		X	
Caliza		X		X					X											
No utilizado														X						

2.2 Equipo

Para la adquisición de los datos de EA se utilizó una placa adquisidora marca PAC modelo DISP-4 de cuatro canales y un sensor de la misma marca, de banda ancha, modelo WD con un preamplificador modelo 2/4/6 con 20 dB de ganancia. El equipo fue operado con el software PAC AEWIN Versión E4.6.

Para realizar la penetración de las probetas se utilizó una herramienta rotante de 62 mm montada sobre un carro de traslación vertical, accionado por un cilindro hidráulico, el cual es manejado por un sistema que permite regular el avance de la herramienta rotante (Fig. 5).




Fig. 5. Diagrama en bloques del experimento.

2.3 Parámetros de emisión acústica utilizados

En la adquisición se tomaron 20 parámetros de emisión acústica: Tiempo de subida (RISE), Cuentas (COUNTS), Energía (ENER), Duración (DUR), Amplitud (AMP), Frecuencia Media (AFRQ), RMS, Nivel Promedio de la Señal (ASL), PCNTS, Frecuencia de Reverberación (RFRQ), frecuencia inicial (IFRQ), Signal Strenght (SIG STRENGHT), Energía Absoluta (ABS ENE), Primer Cuartil de frecuencias (FREQ PP1), Segundo Cuartil de frecuencias (FREQ PP2), Tercer Cuartil de frecuencias (FREQ PP3), Cuarto Cuartil de frecuencias (FREQ PP4), Centroide de frecuencias (CFRQ), Frecuencia Pico (PFRQ).

Se decidió utilizar RMS, ABS ENERGY, COUNTS, RISE y AMP como parámetros de entrada para la red neuronal:

La selección de los parámetros de EA se basa en la correlación de Pearson ver Ec. (4), que es un valor estadístico que nos indica la dependencia lineal entre dos variables, similar a la covarianza, pero con escalas de valores normalizados entre 0 y 1.

$$\rho_{a,b} = \frac{\sigma_{ab}}{\sigma_a \cdot \sigma_b} \quad (4)$$

Dónde: σ_{ab} es la covarianza de a y b.
 σ_a es la desviación estándar de a.
 σ_b es la desviación estándar de b.

A modo de ejemplo, en la Tabla 2 se ponen los resultados obtenidos de la correlación de Pearson para el ensayo A2C1.

Tabla 2 – Coeficientes de correlación de Pearson.

A2C1	ABSENERGY	AFRQ	AMP	ASL	CFRQ	COUN	CYCLES	DURATION	ENER	FREQPP1	FREQPP2	FREQPP3	FREQPP4	IFRQ	PARA1	PARA2	PCNTS	PFRQ	RFRQ	RISE	RMS	SIGSTRENGHT
ABSENERGY	1.00	-0.03	0.24	0.13	-0.01	0.69	NaN	0.36	0.80	-0.01	-0.01	0.04	0.05	-0.05	0.01	-0.01	0.29	-0.01	0.05	0.09	0.32	0.88
AFRQ	-0.03	1.00	-0.26	-0.15	0.10	-0.11	NaN	-0.20	-0.11	0.04	0.16	0.03	0.01	0.67	0.05	0.06	-0.16	0.06	-0.19	-0.22	-0.10	-0.10
AMP	0.24	-0.26	1.00	0.63	0.06	0.37	NaN	0.22	0.43	0.18	-0.21	0.03	0.09	-0.38	0.04	-0.14	0.43	0.14	0.26	0.19	0.51	0.38
ASL	0.13	-0.15	0.63	1.00	-0.15	0.21	NaN	0.14	0.27	-0.06	-0.37	-0.09	-0.03	-0.22	-0.09	0.01	0.25	-0.08	0.16	0.13	0.80	0.24
CFRQ	-0.01	0.10	0.06	-0.15	1.00	-0.06	NaN	-0.13	-0.04	0.92	0.56	0.22	0.13	0.10	0.12	0.01	-0.06	0.89	-0.02	-0.11	-0.12	-0.04
COUN	0.69	-0.11	0.37	0.21	-0.06	1.00	NaN	0.74	0.90	-0.06	-0.04	0.05	0.05	-0.16	-0.03	0.00	0.54	-0.05	0.10	0.28	0.33	0.91
CYCLES	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
DURATION	0.36	-0.20	0.22	0.14	-0.13	0.74	NaN	1.00	0.67	-0.14	-0.08	0.01	0.02	-0.21	-0.07	0.03	0.40	-0.13	0.00	0.42	0.19	0.63
ENER	0.80	-0.11	0.43	0.27	-0.04	0.90	NaN	0.67	1.00	-0.03	-0.06	0.02	0.04	-0.15	-0.02	-0.02	0.51	-0.03	0.08	0.27	0.41	0.97
FREQPP1	-0.01	0.04	0.18	-0.06	0.92	-0.06	NaN	-0.14	-0.03	1.00	0.26	0.06	0.03	0.01	0.11	-0.09	-0.05	0.85	0.02	-0.10	-0.07	-0.03
FREQPP2	-0.01	0.16	-0.21	-0.37	0.56	-0.04	NaN	-0.08	-0.06	0.26	1.00	0.27	0.14	0.20	0.12	0.14	-0.07	0.52	-0.07	-0.09	-0.23	-0.05
FREQPP3	0.04	0.03	0.03	-0.09	0.22	0.05	NaN	0.01	0.02	0.06	0.27	1.00	0.68	0.04	0.00	-0.01	0.04	0.13	0.00	0.00	-0.03	0.02
FREQPP4	0.05	0.01	0.09	-0.03	0.13	0.05	NaN	0.02	0.04	0.03	0.14	0.68	1.00	0.00	0.00	-0.02	0.05	0.08	0.01	0.00	0.00	0.03
IFRQ	-0.05	0.67	-0.38	-0.22	0.10	-0.16	NaN	-0.21	-0.15	0.01	0.20	0.04	0.00	1.00	0.05	0.08	-0.26	0.05	-0.30	-0.35	-0.16	-0.13
PARA1	0.01	0.05	0.04	-0.09	0.12	-0.03	NaN	-0.07	-0.02	0.11	0.12	0.00	0.00	0.05	1.00	-0.03	-0.04	0.12	-0.01	-0.07	-0.06	-0.01
PARA2	-0.01	0.06	-0.14	0.01	0.01	0.00	NaN	0.03	-0.02	-0.09	0.14	-0.01	-0.02	0.08	-0.03	1.00	-0.01	-0.01	-0.03	0.01	0.01	-0.02
PCNTS	0.29	-0.16	0.43	0.25	-0.06	0.54	NaN	0.40	0.51	-0.05	-0.07	0.04	0.05	-0.26	-0.04	-0.01	1.00	-0.04	0.16	0.63	0.30	0.45
PFRQ	-0.01	0.06	0.14	-0.08	0.89	-0.05	NaN	-0.13	-0.03	0.85	0.52	0.13	0.08	0.05	0.12	-0.01	-0.04	1.00	0.02	-0.10	-0.08	-0.03
RFRQ	0.05	-0.19	0.26	0.16	-0.02	0.10	NaN	0.00	0.08	0.02	-0.07	0.00	0.01	-0.30	-0.01	-0.03	0.16	0.02	1.00	0.12	0.12	0.07
RISE	0.09	-0.22	0.19	0.13	-0.11	0.28	NaN	0.42	0.27	-0.10	-0.09	0.00	0.00	-0.35	-0.07	0.01	0.63	-0.10	0.12	1.00	0.12	0.23
RMS	0.32	-0.10	0.51	0.80	-0.12	0.33	NaN	0.19	0.41	-0.07	-0.23	-0.03	0.00	-0.16	-0.06	0.01	0.30	-0.08	0.12	0.12	1.00	0.38
SIGSTRENGHT	0.88	-0.10	0.38	0.24	-0.04	0.91	NaN	0.63	0.97	-0.03	-0.05	0.02	0.03	-0.13	-0.01	-0.02	0.45	-0.03	0.07	0.23	0.38	1.00

Una vez seleccionados los parámetros a utilizar se procedió a fraccionar los ensayos para obtener todos los tramos de señal pertenecientes a la condición de corte de cada roca particular, luego se realizó una reducción de los datos para reducir el tiempo de entrenamiento de la red.

Cada tramo se redujo a 500 datos por variable.

En la Tabla 3, se muestra el resumen para el fraccionamiento de los tramos de la señal, mostrando los tiempos de inicio y finalización de cada capa de roca, indicador (etiqueta) y cantidad de datos perteneciente a cada tramo.

Tabla 3 - Resumen de tiempos y cantidades de datos

Tabla Resumen Tiempos y Cantidad de Datos							
Ensayo	Roca	Indicador	T. Inicio	T. Final	Cant. Datos Original	Cant. Datos Reducidos	Total Reducidos
A1C1	Caliza	C	161.31	273.61	4807	480	3779
	Caliza	C	508.81	623.21	2554	510	
A2AC2	Arenisca	A	338.5	734	18681	518	
	Caliza	C	787.78	977.1	1548	516	
A2CP1	Caliza	C	378.01	430.372	675	675	
	No utilizo						
A3A1	Arenisca	A	280.55	437.44	5798	579	
	Arenisca	A	629.034	844.1	24075	501	

En las Fig. 6, 7, 8 y 9 se puede observar la fragmentación de los distintos ensayos utilizando el parámetro RMS donde se aprecia la diferencia entre cada capa de roca y de cemento.




Fig. 6. RMS vs. Tiempo para ensayo A1C1.

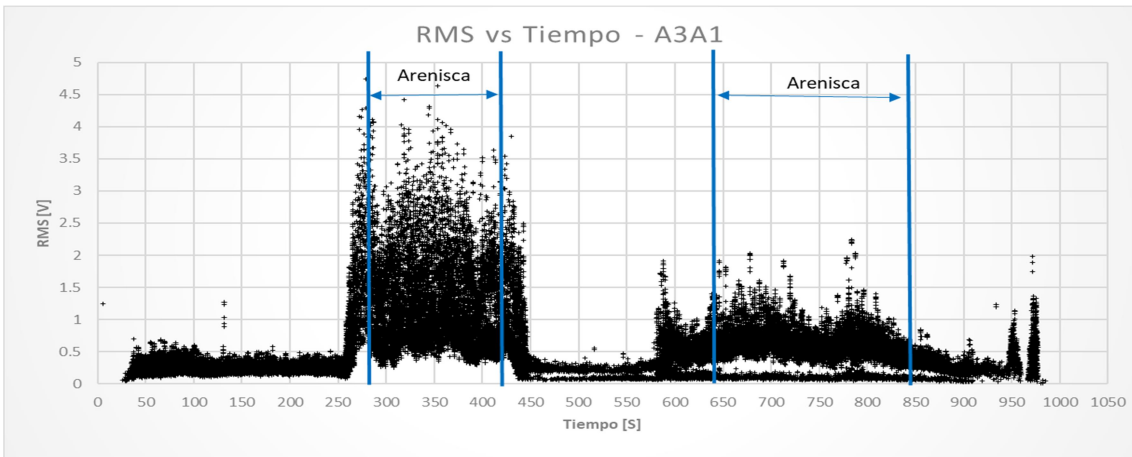


Fig. 7. RMS vs. Tiempo para ensayo A3C1.

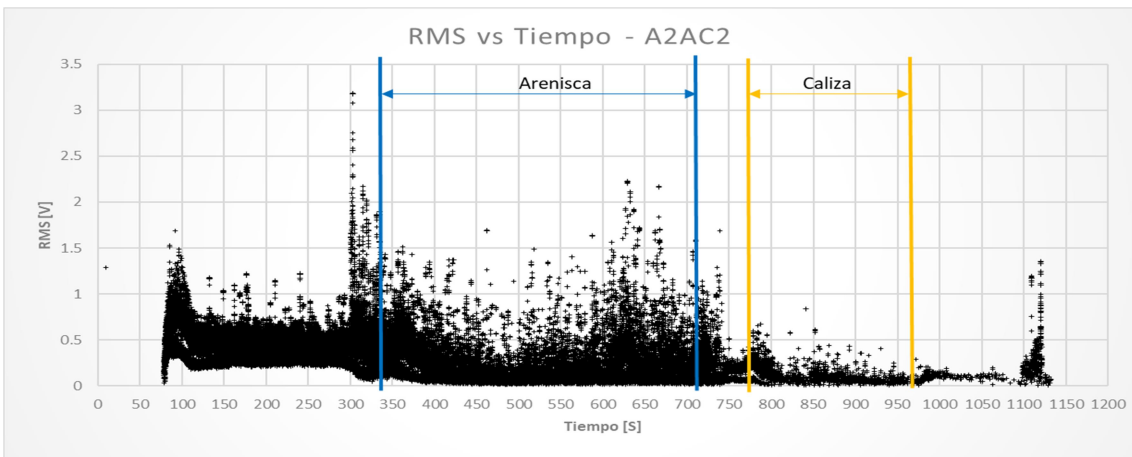


Fig. 8. RMS vs. Tiempo para ensayo A2C2.

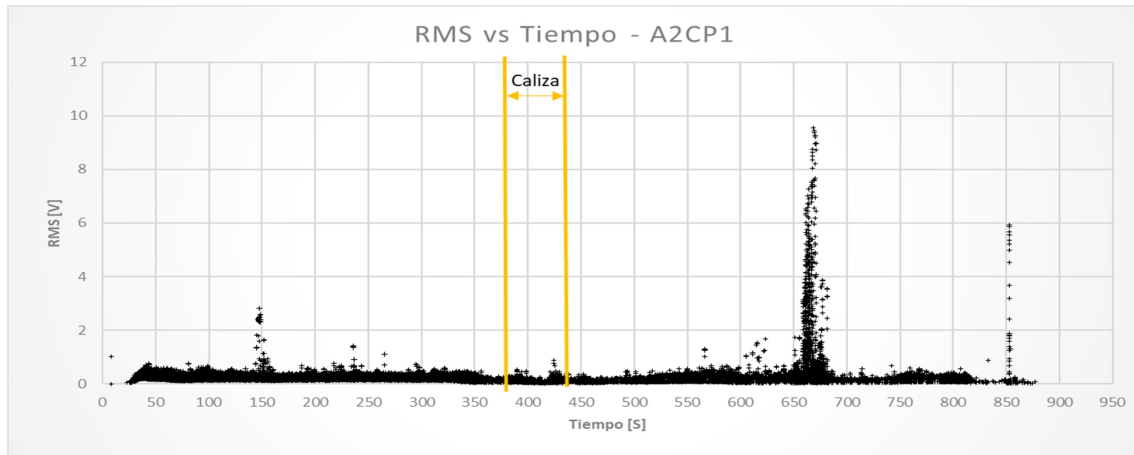


Fig. 9. RMS vs. Tiempo para ensayo A2CP1.

2.4 Arquitectura final de red neuronal Kohonen

Los parámetros determinados para la arquitectura final de la red luego de realizar varias iteraciones hasta obtener resultados aceptables se resumen en la Tabla 4.

Tabla 4. Resumen de Parámetros de red utilizados.

Tamaño de Red	25x25
Geometria	Toroidal
Top. Funcion de correccion	Gausiana
Nº de vecinos	5
Factor de Correccion	Max : 0.6 ~ Min: 0.01
Epocas de Entrenamiento	500

Proceso de entrenamiento y predicción

Los datos anteriormente seleccionados son previamente escalados entre 0 y 1, luego unidos formando matriz de 3779 x 5 (donde las filas son las mediciones y las columnas los 5 parámetros previamente seleccionados). Se realiza un escalado que tiene por objetivo que todos los parámetros queden en el mismo orden de magnitud, esto permite que el error pueda ser medido de forma efectiva y el proceso de ajustado de los pesos se realice de una forma óptima.

Los datos son etiquetados para identificar con facilidad la red resultante. Se utilizó una “A” para identificar la piedra arenisca y una “C” para identificar la piedra caliza.

Luego, los datos se ordenan aleatoriamente para que el orden de entrenamiento no sea inicialmente preferencial a una clase en particular.

Finalmente se separa el 70% de los datos para realizar el entrenamiento y un 30% para realizar la predicción, los datos introducidos en esta etapa de predicción nunca participaron en el proceso de entrenamiento y nunca se tuvieron en cuenta para el ajuste de sus pesos; sino que se ubican en la zona donde su distancia vectorial es similar a ese dato en concreto.

2. RESULTADOS

A continuación, se mostrarán los resultados obtenidos del entrenamiento (Fig. 10.a) y en la predicción (Fig. 10.b).

En el entrenamiento se observa como existe una zona donde preferencialmente se ubican los datos de arena (letras "A" de color verde) y otra gran zona donde se ubican los datos de caliza (letras "C" de color amarillo), tener en cuenta que se trata de una red de geometría toroidal con lo cual las zonas del borde son de distancias similares. También se observa la existencia de una dispersión donde algunos de los datos de "A" se encuentran dentro de la zona de "C".

En la predicción, se puede observar un patrón similar, con lo cual la clasificación se realiza de forma aceptable, se recuerda que estos datos no participaron en el ajuste de los pesos de las neuronas, con lo cual se ubican en las zonas donde los datos son los más parecidos.

El control de errores en función de la cantidad de épocas se encuentra en la Fig. 11, los resultados finales son 0.05 en error de norma y 11.45% en el error de mezclado.


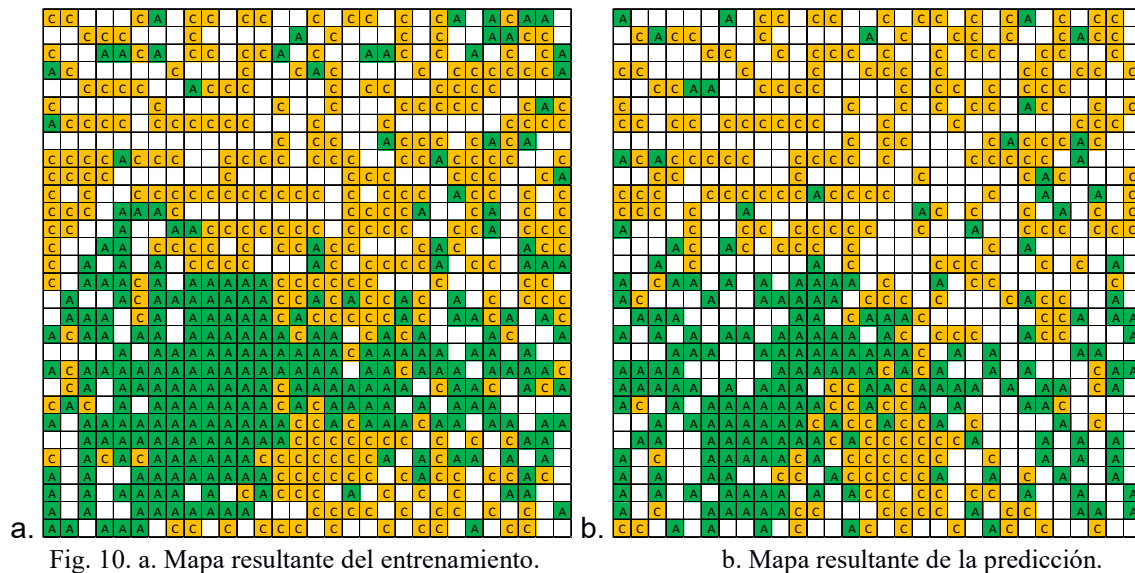


Fig. 11. Control de errores.

3. CONCLUSIONES

Se pudo observar la capacidad de las redes neuronales tipo Kohonen para clasificar información, a partir de una gran cantidad de datos, mediante patrones fácilmente reconocibles expresados de manera amigable para el usuario. Esto se podría mejorar utilizando redes multicapas con una arquitectura más compleja, optimizando aún más los parámetros de red y utilizando una mayor cantidad de datos. Este último punto conlleva a optimizar la programación del código fuente de la red para aprovechar los recursos de un ordenador moderno.

Cabe aclarar que los parámetros seleccionados son efectivos para este caso particular, para el error alcanzado expresado en los resultados, por lo cual si se utilizaran redes similares para otro propósito podrían no producirse resultados satisfactorios.

REFERENCIAS

- Beale M., Hagan M., Demuth H., *Neural Network Toolbox User's Guide*. MathWorks, 2010
- Zupan J., Gasteiger J., *Neural Networks for Chemists*. VHC, 1993.
- Yañez-Badillo H., Control Neuronal en Línea para Regulación y Seguimiento de Trayectorias de Posición para un Quadrotor - *Revista Iberoamericana de Automática e Informática industrial* 14 (2017) 141–151.
- Faheem., A Survey Of Intelligent Car Parking System- *Journal of Applied Research and Technology* 2013;11:714-26
- Hang Su., Pixel-Adaptive Convolutional Neural Networks - *Computer Vision and Pattern Recognition (CVPR)*, 2019:05:16
- Boldsaiikhana E., The use of neural network and discrete Fourier transform for real-time evaluation of friction stir welding - *Applied Soft Computing* 11 (2011) 4839–4846.
- Fratini L., Using a neural network for predicting the average grain size in friction stir welding processes - *Computers and Structures* 87 (2009) 1166–1174.
- Kohonen T., *Self-Organizing Maps*. Springer 2001.
- Kwak J., Neural network approach for diagnosis of grinding operation by acoustic emission and power signals - *Journal of Materials Processing Technology* 147 (2004) 65–71.
- Jiménez Macías E., Emisión Acústica y Redes Neuronales para Modelado y Caracterización del Proceso de Soldadura por Fricción Agitación - *Revista Iberoamericana de Automática e Informática industrial* 10 (2013) 434–440.
- Shevchik S.A., Acoustic emission for in situ quality monitoring in additive manufacturing using spectral convolutional neural networks - *Additive Manufacturing* Volume 21, May 2018, Pages 598-604.
- Sick B., On-line and indirect toolwear monitoring in turning with artificial neural networks: a review of more than a decade of research - *Mechanical Systems and Signal Processing* (2002) 16(4), 487–546.
- Rajesh Kumar B., Regression analysis and ANN models to predict rock properties from sound levels produced during drilling - *International Journal of Rock Mechanics & Mining Sciences* 58 (2013) 61–72
- Suresh Kumar C., Failure strength prediction of glass/epoxy composite laminates from acoustic emission parameters using artificial neural network - *Applied Acoustics* 115 (2017) 32–41.
- Perez S., A preliminary study on the role of acoustic emission on inferring Cerchar abrasivity index of rocks using artificial neural network – *Wear* 344-345 (2015) 1–8.