

Rockburst Prediction in Great Depth Underground Mining based on Extreme Learning Machine

Sebastian Pastor-Villanueva, BSc¹, Humberto Pehovaz-Alvarez, MSc¹, and Carlos Raymundo, PhD¹

¹Universidad Peruana de Ciencias Aplicadas, Peru, u201420296@upc.edu.pe, pcpmhpeh@upc.edu.pe, carlos.raymundo@upc.edu.pe

Abstract— In great depth underground mining the stress accumulation in the rockmass leads to a condition known as Rockburst. Until now, no detection method has proven to be successful enough in detecting rockburst events. Because of that, a software has been developed in order to predict the probability of rockburst using as data entry the in-situ stress condition and geomechanics properties of the rockmass. This software is based on Extreme Learning Machine, a single perceptron feedforward Neuronal Network that uses random projection. The foreseen result is a detection of 90% of cases and an 85% of effectivity of rockburst quality prediction. The database has Acoustic Emission readings of different great depth mines around the globe.

Keywords— Rockburst, Extreme Learning Machine, Neural Network, Deep Underground Mining

Digital Object Identifier (DOI):
<http://dx.doi.org/10.18687/LACCEI2021.1.1.503>
ISBN: 978-958-52071-8-9 ISSN: 2414-6390

Método de Predicción de Estallido de Roca en Minería Subterránea de Gran Profundidad basado en Extreme Learning Machine

Sebastian Pastor-Villanueva, BSc¹, Humberto Pehovaz-Alvarez, MSc¹, and Carlos Raymundo, PhD¹

¹Universidad Peruana de Ciencias Aplicadas, Peru, u201420296@upc.edu.pe, pcgmhpeh@upc.edu.pe, carlos.raymundo@upc.edu.pe

Abstract– En la minería subterránea de gran profundidad la acumulación de esfuerzos en el macizo rocoso genera una condición conocida como Estallido de Roca. Hasta el momento no existen métodos de detección lo suficientemente avanzados como para prevenir exitosamente este evento. Por ello se ha desarrollado un programa que predice la probabilidad de que ocurra el Estallido de Roca utilizando una valoración de esfuerzos in-situ y las condiciones geomecánicas del macizo rocoso. El programa se basa en Extreme Learning Machine, una red neuronal prealimentada de un solo perceptrón que realiza una ponderación del valor de las variables de manera aleatoria. Los resultados previstos son un nivel de detección superior al 90% de casos y una eficiencia de al menos 85%. La base de datos utilizada recopila los esfuerzos de Emisión Acústica de distintas minas de gran profundidad en todo el mundo.

Keywords-- Estallido de Roca, Extreme Learning Machine, Redes Neuronales, Minería de Gran Profundidad

I. INTRODUCCIÓN

En la actualidad, la necesidad de elaborar vías de comunicación más cortas, encontrar métodos más eficientes en la producción de energía hidroeléctrica o extraer recursos minerales a mayores profundidades nos ha llevado a conocer niveles cada vez más profundos del subsuelo. Consecuencias propias de entrar a este nuevo contexto es la aparición de nuevos problemas que requieren soluciones ingenieriles. Entre estos problemas podemos identificar el estallido de roca, un proceso violento de liberación de energía en el cual las paredes y techo de túneles a gran profundidad y bajo una gran acumulación de esfuerzos son fragmentados y expedidos de manera aparentemente espontánea. Ante tal riesgo para industrias como la minería o la construcción diversos expertos han estudiado el fenómeno buscando la manera más efectiva de detener sus fatales consecuencias.

El estallido de roca es un problema muy serio de la minería subterránea de gran profundidad por el incremento de los accidentes relacionados a este fenómeno. Diversos investigadores han identificado que las principales causantes del estallido de roca se deben al incremento de los esfuerzos principales por encima de su capacidad y a un evento que inicia el proceso de estallido. Este evento suele ser un evento microsísmico que tiene origen en un evento externo al macizo rocoso y empieza un proceso de microfracturamiento en el interior del macizo rocoso. Después de un periodo de tiempo en el que la fracturación se propaga la energía tensional del macizo roco se libera de manera violenta mediante eyectar una porción en las cajas y techo de una labor subterránea. Muchos

investigadores han propuesto diversas técnicas para poder prevenir e identificar los efectos del estallido de roca. Entre los principales avances está el uso de sensores de microsismicidad para identificar eventos microsísmicos que puedan generar estallidos de roca. A su vez se posee diversos modelos empíricos basados en modelos numéricos como los que se utilizan en la mina El Teniente en Chile. Finalmente, algunos han optado por técnicas de big data utilizando redes neuronales para poder realizar predicciones respecto a la intensidad de los estallidos.

Frente a esta situación ha surgido como objetivo de esta investigación experimentar con la eficiencia del Extreme Learning Machine que es una red neuronal de una sola capa oculta con gran capacidad de regresión y clasificación de datos, Ha sido utilizada por diversos autores para la identificación de la intensidad de los eventos de estallido, pero no para predecir la ubicación o la certidumbre de la ocurrencia de los eventos. Para utilizarla con este fin se utilizará su capacidad de clasificación mediante una capa de salida restringida que nos indicará la posibilidad de que ocurra estos eventos. Posteriormente se probarán los escenarios con alta incidencia y se determinará la capacidad de esta herramienta en predecir la distancia e intensidad que puede presentar el estallido.

El presente artículo explicará en el estado del arte cuáles han sido los autores referenciados para identificar los principales parámetros a utilizar que provocan el estallido de roca. Entre ellos estudiaremos la relación del estallido de roca con relación a la profundización, los esfuerzos realizados en la predicción del estallido de roca tanto mediante métodos numéricos como utilizando herramientas de redes neuronales, el uso de redes neuronales en la identificación de parámetros geomecánicos para otras aplicaciones y el uso del extreme learning machine en la geomecánica y en el estudio de esfuerzos.

II. ESTADO DEL ARTE

A. Estallido de Roca y Microsismicidad

Diversos autores ha expresado la significancia de la profundización respecto a la presencia de estallido de rocas [1][2][3]. Ello se explica cómo a gran acumulación de la carga litostática se ve afectada por la incorporación de un espacio libre durante la construcción de una labor minera o un túnel. Debido a ese evento la capacidad de confinamiento del macizo rocoso se ve afecta e incrementa la energía del esfuerzo

elástico que sufre el macizo rocoso [4]. Por ello la generación de eventos microsísmicos generan un cambio en la nueva distribución de esfuerzos que puede dar como resultado la iniciación de un microfisuramiento del macizo rocoso que finalmente iniciará el proceso de estallido de roca.[5][4][6].

B. Predicción del Estallido de Roca

Dado la base sobre el conocimiento de la incidencia de los eventos microsísmicos sobre el estado de distribución de esfuerzos en el macizo rocoso se derivó parámetros sobre el estado tensional de la roca y del comportamiento de las ondas microsísmicas asociadas al evento microsísmico. Para poder iniciar el proceso de clasificación y predicción se empezó utilizando los modelos numéricos basados en la discretización de los parámetros geomecánicos del macizo rocoso [7][8][9]. Para poder validar las investigaciones se utilizó la experimentación tanto en minería subterránea [4][10], experimentación en túneles de uso civil [11][12][8] y en experimentación en laboratorio [13].

En los años recientes el uso de herramientas basadas en redes neuronales ha tomado protagonismo por su gran capacidad de clasificación y regresión lineal y no lineal para identificar el origen de los eventos microsísmicos[14][15][16]. Ante tal escenario se concluyó que el comportamiento de redes que utilicen propagación inversa y conglomeramiento de datos presentaban una mayor capacidad de predicción respecto a otros métodos numéricos.[17][5].

C. Redes Neuronales y Geomecánica

Para demostrar la capacidad de las redes neuronales en el ámbito de la clasificación y valoración de parámetros geomecánicos [8][18]. A su vez, se utilizó en la clasificación geomecánica demostrando la capacidad de clasificación de las redes neuronales. Por ello sería utilizado mediante al definición de los valores discretos de los esfuerzos principales que se encuentran en los estallidos de roca.[19]. De tal manera que las únicas consideraciones a valorar estuviesen ligadas a la clasificación y homogenización de las variables para facilitar el entrenamiento.

D. Extreme Learning Machine y Estallido de Roca

El extreme learning machine ha sido diseñado como una red neuronal de una sola capa oculta que no requiere un acompañamiento en la iteración de los entrenamientos, de tal manera que sólo hace falta limitar el tamaño de la capa oculta durante el diseño del ELM. Diversos autores han demostrado la efectividad del método por encima del redes neuronales de propagación inversa por el uso de la aleatoriedad en la ponderación de los parámetros [20]. Para utilizarlo dentro de la detección de estallidos de roca se le acompaña con técnicas complementarias como el uso de algoritmos genéticos [3] o las redes difusas [17] que tienen un gran potencial de incrementar la capacidad de regresión del análisis de la data. Sin embargo, las investigaciones no han desarrollado sistemas de detección sino de clasificación de los eventos de estallido de roca [5]. Por ello algunos investigadores utilizan métodos combinados

con una clasificación previa de la base de datos utilizando el modelamiento numérico como base de estudio [21].

En términos generales, los autores han demostrado el gran potencial de predecir eventos de estallido de roca debido a la gran capacidad de regresión y clasificación del extreme learning machine, sin embargo, es necesaria una previa clasificación de datos o integrar la clasificación al entrenamiento para poder obtener los mejores resultados. A su vez no se han realizado estudios de detección utilizando solamente las condiciones iniciales, sino que siempre se han apoyado en las condiciones finales para lograr la predicción lo que disminuye el potencial para aplicar estos métodos en la práctica por no poder ser evaluados sólo con las condiciones iniciales del evento microsísmico

III. APORTE

A. Identificación de Parametros Principales

Como parte del proceso de identificación de parámetros principales es necesario establecer un filtro respecto al nivel de significancia de cada uno de los parámetros y las variables dentro de la ejecución del método. Para conseguirlo es necesario identificar la relación de cada uno de los parámetros con su parámetro de salida dentro de la red. Para poder identificarlo se utilizó los Algoritmos Genéticos que nos permitirán identificar el origen de las variables respecto a sus acompañantes y nos darán el nivel de significancia. Para mejorar la finesa de los resultados solamente se utilizará los que posean una ponderación mayor al 50% de los casos, dado que si es menor revela que no poseen una relación directa con el parámetro de salida que se está estudiando.

En Fig. 1 se puede apreciar el diseño del entrenamiento utilizado para el cálculo de la relación de los parámetros de entrada con los de salida.

Producto de este entrenamiento se consiguió determinar los parámetros principales y su participación en el entrenamiento. De tal manera que podemos separar los parámetros secundarios para entrenamientos posteriores.

B. Método de Predicción basado en Extreme Learning Machine

1) Clasificación de datos

La Metodología utilizada para esta investigación será el uso de redes neuronales retroalimentadas de una sola capa, en nuestro Extreme Learning Machine desarrollado por Huang, para identificar los componentes causantes del estallido de Roca mediante el uso de las capacidades de regresión de esta red Neuronal.

Todas las redes neuronales constan de 3 elementos indispensables: un parámetro de entrada, en el cual se ingresan los datos de las condiciones iniciales a analizar; un conjunto de neuronas, que se encargaran de realizar la ponderación, el cálculo y regresión de los datos ingresados en el parámetro de entrada; y un parámetro de salida, que es el resultado del procesamiento de datos de entrada por las neuronas.

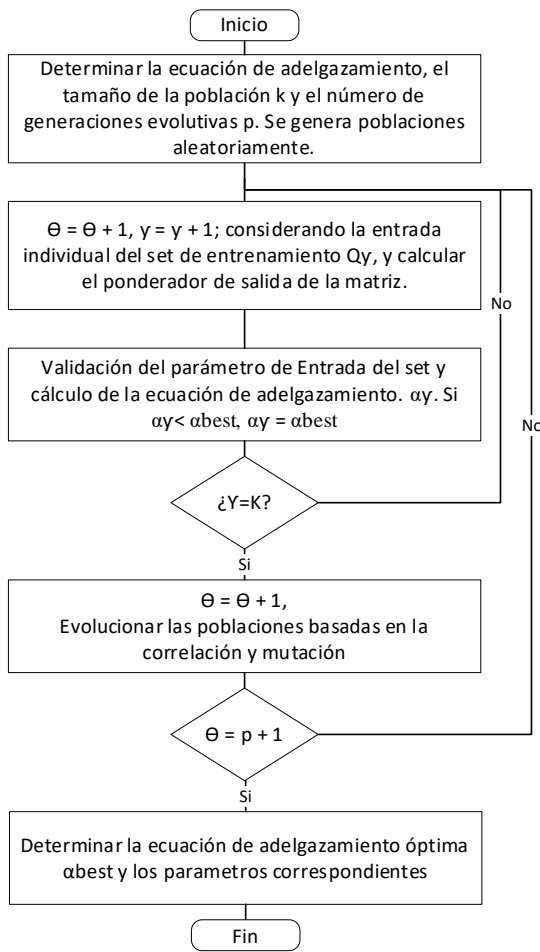


Fig.1 Diseño de entrenamiento

Para el caso del Extreme learning Machine las neuronas poseen un comportamiento variable aleatorio, por lo cual no es necesario programarlas más que en parámetros de máximos y mínimos.

El proceso inicia acorde al desarrollo de otras redes neuronales haciendo un detallado proceso de selección de los datos a utilizar. Se evaluará la relevancia de los que serán los parámetros de entrada mediante filtros lógicos y el uso de un algoritmo de apoyo, como es el caso de los algoritmos genéticos que nos demostraran los rastros de dependencia en una misma base de datos para distintas variables.

Para empezar el entrenamiento, dividiremos nuestros casos en dos grupos uno de 30% y el otro de 70%. En ambos se encontrará la misma relación de casos con estallido de rocas, como el uso de blancos que no lo presenten para que la red neuronal pueda ser entrenada en la detección de escenarios positivos para el estallido de roca y de escenarios negativos de estallido de Roca. El 70% tendrá como fin el entrenamiento de la Red Neuronal para el Objetivo Específico 2 y 3, mientras el 30% restante servirá como muestra para validar la efectividad del modelo en la detección de Estallido de Roca.

2) Definición de parámetros

Tras haber seleccionado los parámetros más relevantes, se procederá al entrenamiento para nuestro primer objetivo específico la detección y predicción de estallido de Roca. Para ello se programarán las neuronas para seguir límites lógicos que delimiten el desarrollo del entrenamiento y se generaran parámetros de salida que nos permitirán determinar la efectividad del procedimiento a partir de un procesamiento de datos que no hayan sido utilizados para el primer entrenamiento.

Una vez se hayan obtenido los modelos de entrenamiento con los resultados más altos en la detección de estallidos de roca, se implementará un segundo entrenamiento que prediga la posición del Estallido. Previamente, se realizará una zonificación de cada nivel a estudiar para facilitar el desarrollo de los parámetros de detección, pues al basarse en un sistema finito de datos, no se puede realizar un modelamiento punto por punto de cada nivel de desarrollo de la mina. Cada zonificación será evaluada y diferenciada por las características Geomecánicas que posea y las condiciones de esfuerzos a las que está siendo sometida. El zoneamiento será realizado de manera operativa hasta que se elabore una clasificación automatizada de este proceso.

Posteriormente se realizará un entrenamiento de medición de efectividad en la detección de eventos de estallido de Roca en base a un conjunto de eventos que han sido documentados y medidos. El objetivo de este segundo entrenamiento es determinar las condiciones finales del estallido en caso de determinarlo como un escenario feasible. De esta manera se podrá tener dos índices: uno de efectividad que determinará el número de casos detectados con éxito y uno de eficiencia que determinará con que presión está prediciendo la intensidad y ubicación de los eventos de Estallido de Roca.

Para empezar, debemos definir a X como el conjunto de datos en los parámetros de entrada, pertenecientes a una dimensión n. La dimensión n está determinada por el número de parámetros de entrada que se está considerando. También definiremos la dimensión m como el número total de casos dentro de entrenamiento Para fines de procesamiento, X deberá estar definido como un vector de la forma $X = \{x_{j1}; x_{j2}; x_{j3}; \dots x_{jm}\}$. Sin embargo, de esa manera sólo se interpreta un parámetro para todo n por ello se vectorizará en n dimensiones de manera que integre a todos los factores como se observa a continuación:

$$X = \begin{Bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nm} \end{Bmatrix} \quad (1)$$

A su vez se deberá determinar a Y como el conjunto de parámetros de salida para esta etapa inicial de entrenamiento. Y estará definido por el vector $Y = \{y_1; y_2; y_3; y_4 \dots y_m\}$

Siendo todos los resultados del entrenamiento. Cabe destacar que para esta primera etapa y sólo definirá si nos

encontramos frente a un escenario de estallido de roca o no. Por ello $y = 1$ (Estallido de Roca), $y = 0$ (No existe estallido de Roca). Para ello se utilizarán las zonas adyacentes al estallido de roca durante el mismo evento microsismo que no presentaron estallido, aunque pueden de haber presentado daños estructurales como la presencia de nuevas fracturas. En este punto podemos definir que la red neuronal tendrá el siguiente aspecto:

Luego definiremos a \hat{y} cómo la probabilidad de que $y = 1$ dado por la siguiente función: $\hat{y} = P(y = 1|x)$ por lo cual el valor de \hat{y} se comprenderá entre $0 \leq \hat{y} \leq 1$. Su fórmula está determinada por $\hat{y} = \sigma(wx + b)$. Siendo σ el sigmoide de la función $wx + b$. w es el peso determinado por la capa oculta sobre el valor x y b es un valor aleatorio. Este factor se nos hará importante para poder hallar la función de Costo J que es la sumatoria de todas las funciones de error $L(\hat{y}, y) = \frac{(\hat{y}-y)^2}{2}$. Por lo tanto, la función de costo estará definida por $J(w, b) = \frac{1}{m} \sum_{i=1}^m [y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i)]$. Esta función nos permitirá conocer el error que se maneja en toda nuestra red neuronal.

Ahora todas las funciones \hat{y} se encontrarán dentro de la Matriz H que representa la Moore-Penrose Generalizada Inversa de las capas ocultas de la matriz. Entonces H estaría definida por:

$$H = \begin{bmatrix} \sigma(w_1x_1 + b_1) & \dots & \sigma(w_mx_1 + b_m) \\ \vdots & \ddots & \vdots \\ \sigma(w_1x_n + b_1) & \dots & \sigma(w_mx_n + b_m) \end{bmatrix} \quad (2)$$

A su vez para definir el peso de la capa oculta hasta nuestro resultado se utilizará β . Siendo β definida como $\beta = \{\beta_1; \beta_2; \beta_3; \dots; \beta_m\}$. También habrá que definir la dimensión del producto del peso de entrada H con el peso hacia la salida β , es este caso lo definiremos por T cómo una matriz de dimensión $1 \times m$ dado por $T = (y_1^T \dots y_m^T)$ y $H\beta = T$.

3) Evaluación de Entrenamiento

Por lo tanto, llegamos a la declaración formal de la red:

Para m diferentes muestras $\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}; y$, dónde $x = \begin{bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nm} \end{bmatrix} \in \mathbf{R}, y = [y_1; y_2; \dots; y_m] \in \mathbf{R}$. Dónde la fórmula de la función de Excitación $G(x)$ y los nodos de las capas ocultas L se pueden representar por la siguiente ecuación.

$$f_L(x) = \sum_{i=1}^L G(w_i \cdot x_j + b_i) \beta_i \quad (3)$$

Dado que:

$$\sum_{i=1}^n \|f_L(x_j) - y_j\| = 0 \quad (4)$$

Entonces:

$$y_j = \sum_{i=1}^L G(w_i \cdot x_j + b_i) \beta_i \quad (5)$$

Tras haber realizado el entrenamiento en Python graficamos los resultados de la función de costo para identificar el error de nuestra red Neuronal sobre el total de datos entrenados

4) Análisis de Resultados y Entrenamiento 2

Una vez realizada el entrenamiento para la fase uno se pasa a seleccionar los datos basados en los parámetros que se definieron para el objetivo específico 2 y se utilizará la misma estructura de la red neuronal cambiando los valores de Y que ahora determinarán la distancia al origen del evento microsísmico y la intensidad según la escala SB que han utilizado otros autores cómo Li.

Para empezar, debemos definir a X como el conjunto de datos en los parámetros de entrada al igual que en el objetivo específico 2, pertenecientes a una dimensión n . La dimensión n está determinada por el número de parámetros de entrada que se está considerando. También definiremos la dimensión m como el número total de casos dentro de entrenamiento Para fines de procesamiento, X deberá estar definido cómo un vector de la forma $X = \{x_{j1}; x_{j2}; x_{j3}; \dots; x_{jm}\}$. Sin embargo, de esa manera sólo se interpreta un parámetro para todo n por ello se vectorizará en n dimensiones de manera que integre a todos los factores cómo se observa a continuación:

$$X = \left\{ \begin{bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nm} \end{bmatrix} \right\} \quad (6)$$

A su vez se deberá determinar a Y cómo el conjunto de parámetros de salida para esta etapa inicial de entrenamiento.

Y estará definido por el vector $Y = \begin{bmatrix} y_{11} & \dots & y_{m1} \\ y_{12} & \dots & y_{m2} \end{bmatrix}$

Siendo todos los resultados del entrenamiento.

Basándonos en los mismos parámetros que se utilizaron para la determinación de nuestra función inicial la nueva configuración formal de la red sería la siguiente:

Para m diferentes muestras $\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}; y$, dónde $x = \begin{bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nm} \end{bmatrix} \in \mathbf{R}, y = \begin{bmatrix} y_{11} & \dots & y_{m1} \\ y_{12} & \dots & y_{m2} \end{bmatrix} \in \mathbf{R}$

Dónde la fórmula de la función de Excitación $G(x)$ y los nodos de las capas ocultas L se pueden representar por la siguiente ecuación.

$$f_L(x) = \sum_{i=1}^L G(w_i \cdot x_j + b_i) \beta_i$$

Dado que:

$$\sum_{i=1}^n \|f_L(x_j) - y_j\| = 0$$

Entonces:

$$y_j = \sum_{i=1}^L G(w_i \cdot x_j + b_i) \beta_i$$

Tras haber realizado el entrenamiento en Python graficamos los resultados de la función de costo para identificar el error de nuestra red Neuronal sobre el total de datos entrenados.

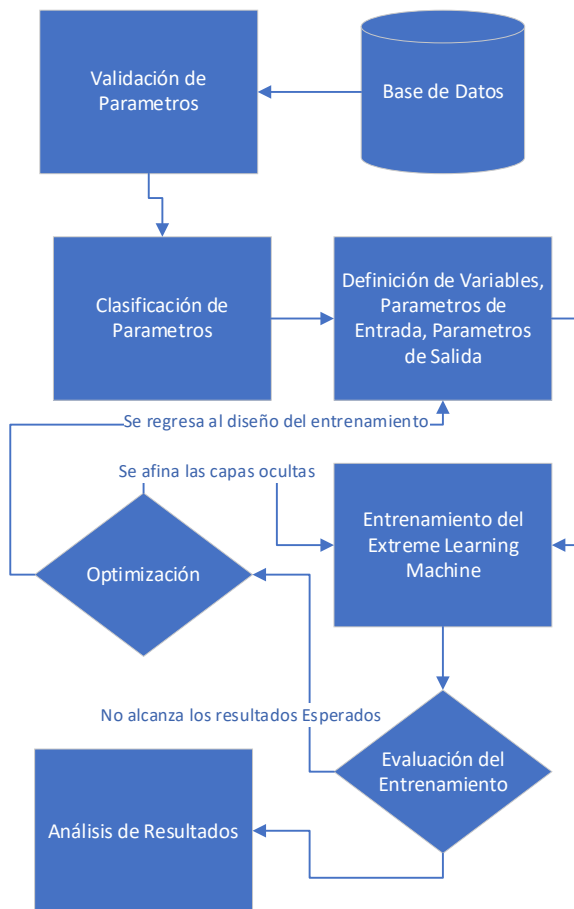


Fig. 2 Entrenamiento

IV. VALIDACIÓN

Para nuestra validar nuestro método es necesario el uso de un escenario donde se presente el estallido de roca, por ello se utilizó una mina de gran profundidad con presencia de estallido de Roca. A esta se le realizó en análisis y la

clasificación de datos para encontrar y validar los parámetros de ingreso utilizados por el método del extreme learning machine. A partir del entrenamiento se hallaron los siguientes resultados tanto para la primera parte como para el segundo entrenamiento del modelo.

Cómo se puede observar, sólo se consiguió una identificación en el 78.36% de los casos con el entrenamiento utilizando las 132 muestras en usando 94 para entrenar, 26 para validar y 10 para predecir el estallido.

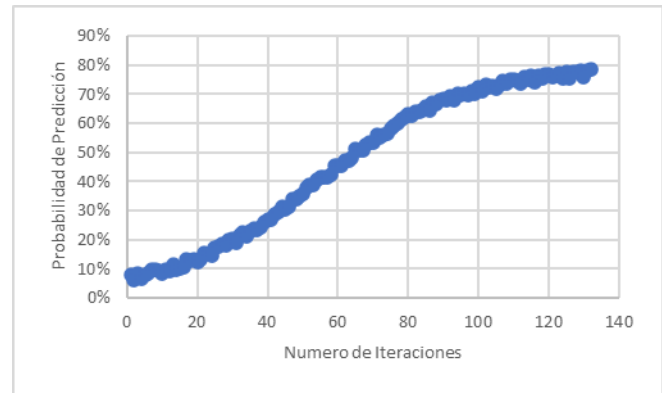


Fig. 3 Predicción

Tras haber realizado el entrenamiento en Python graficamos los resultados de la función de costo para identificar el error de nuestra red Neuronal sobre el total de datos entrenados.

Cómo se puede observar, sólo se consiguió una identificación en el 70.89% de los casos con el entrenamiento utilizando las 132 muestras en usando 94 para entrenar, 26 para validar y 10 para predecir el estallido.

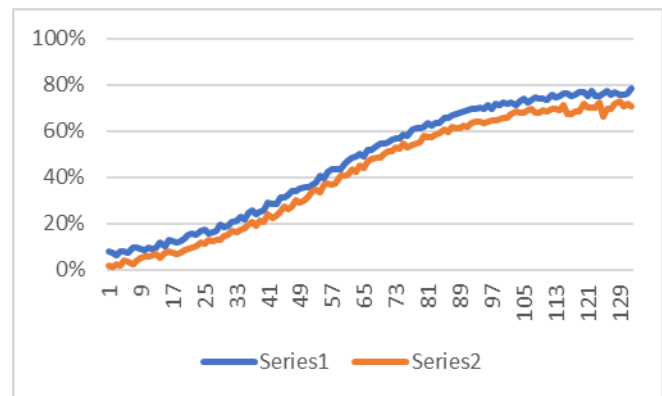


Fig. 4 Resultados

En este escenario se identificó la distancia del estallido con un margen de 29.11% respecto a la distancia del punto de origen del estallido de roca.

V. CONCLUSIONES

El extreme learning machine demostró su capacidad de detección para los escenarios de estallido de roca mediante el análisis de eventos microsísmicos, sin embargo, no alcanzó el

margen de error esperado en comparación a otros métodos. Se ha alcanzado a validar los parámetros de entrada, específicamente el uso de los esfuerzos principales y el sobreesfuerzo en el que se encuentra el macizo rocoso. A su vez, se determina que la incorporación de nuevos parámetros geológicos puede incrementar la eficiencia de la predicción.

La incorporación de otros métodos durante el análisis de eventos de estallido de roca, cómo el uso de algoritmos genéticos o la simulación numérica incrementan la eficacia de la detección por ello deberían ser incorporados en futuras investigaciones.

Se recomienda realizar una construcción de no sólo los escenarios de estallido sino de las otras zonas que no generaron un estallido para poder tener un parámetro de referencia.

El uso de técnicas complementarias el extreme learning machine disminuye el margen de error sobre el escenario base utilizando sólo extreme learning machine, por lo tanto, se recomienda la integración de otras técnicas con propagación inversa para contrastar los métodos de generación aleatoria de neuronas ocultas.

Se recomienda poder hacer una evaluación del posicionamiento de los sensores, así como de la sensibilidad de las lecturas para poder hacer futuras recomendaciones en la detección de estallidos de roca.

REFERENCIAS

- [1] 1970- Nussbaumer, Martin M. (Martin Manfred), "A comprehensive review on rock burst," Massachusetts Institute of Technology, 2000.
- [2] H. M. Tian, W. Z. Chen, C. S. Ma, D. S. Yang, and X. J. Tan, "Energy Release Analysis of a Severe Rockburst in a Headrace Tunnel Crossing a Tectonic Stress Zone," *Shock Vib.*, vol. 2019, pp. 1–9, Sep. 2019, doi: 10.1155/2019/8959845.
- [3] T. zheng Li, Y. xin Li, and X. li Yang, "Rock burst prediction based on genetic algorithms and extreme learning machine," *J. Cent. South Univ.*, vol. 24, no. 9, pp. 2105–2113, Sep. 2017, doi: 10.1007/s11771-017-3619-1.
- [4] G. Wang, X. Yuan, S. Gong, L. Dou, W. Cai, and C. Fan, "Understanding Rockburst-Generating Behaviors and Associated Seismicity by Using a Spatial Calculation Methodology with an Energy Density Index," *Math. Probl. Eng.*, vol. 2018, pp. 1–10, Nov. 2018, doi: 10.1155/2018/6128368.
- [5] Y. Geng, L. Su, Y. Jia, and C. Han, "Seismic Events Prediction Using Deep Temporal Convolution Networks," *J. Electr. Comput. Eng.*, vol. 2019, pp. 1–14, Apr. 2019, doi: 10.1155/2019/7343784.
- [6] J. Šílený and A. Milev, "Seismic Moment Tensor Resolution on a Local Scale: Simulated Rockburst and Mine-induced Seismic Events in the Kopanang Gold Mine, South Africa," *Pure Appl. Geophys.*, vol. 163, no. 8, pp. 1495–1513, Aug. 2006, doi: 10.1007/s00024-006-0089-z.
- [7] J. A. Jarufe and P. Vasquez, "Numerical modelling of rock-burst loading for use in rock support design at Codelco's New Mine Level Project," *Min. Technol.*, vol. 123, no. 3, pp. 120–127, Sep. 2014, doi: 10.1179/1743286313y.0000000050.
- [8] X. Guo, Z. Zhao, X. Gao, Z. Ma, and N. Ma, "The Criteria of Underground Rock Structure Failure and Its Implication on Rockburst in Roadway: A Numerical Method," *Shock Vib.*, vol. 2019, pp. 1–12, Feb. 2019, doi: 10.1155/2019/7509690.
- [9] Z. Wang, L. Li, B. Liu, C. Han, and T. Lan, "Study of Simulation Test in Inclusion Rockburst," *Adv. Civ. Eng.*, vol. 2019, pp. 1–20, Jan. 2019, doi: 10.1155/2019/6192546.
- [10] X. Sun et al., "Numerical Investigation of Gob-Side Entry Retaining through Precut Overhanging Hard Roof to Control Rockburst," *Adv. Civ. Eng.*, vol. 2018, pp. 1–10, Dec. 2018, doi: 10.1155/2018/8685427.
- [11] H. Zhang, L. Chen, S. Chen, J. Sun, and J. Yang, "The spatiotemporal distribution law of microseismic events and rockburst characteristics of the deeply buried tunnel group," *Energies*, vol. 11, no. 12, p. 3257, Nov. 2018, doi: 10.3390/en11123257.
- [12] Y. Xue et al., "Prediction of rock burst in underground caverns based on rough set and extensible comprehensive evaluation," *Bull. Eng. Geol. Environ.*, vol. 78, no. 1, pp. 417–429, Feb. 2019, doi: 10.1007/s10064-017-1117-1.
- [13] Y. Wang, M. He, D. Liu, and Y. Gao, "Rockburst in Sandstone Containing Elliptic Holes with Varying Axial Ratios," *Adv. Mater. Sci. Eng.*, vol. 2019, pp. 1–17, Apr. 2019, doi: 10.1155/2019/5169618.
- [14] Y. Zheng et al., "Rockburst Prediction Model Based on Entropy Weight Integrated with Grey Relational BP Neural Network," *Adv. Civ. Eng.*, vol. 2019, pp. 1–8, May 2019, doi: 10.1155/2019/3453614.
- [15] Y. Geng, L. Su, Y. Jia, and C. Han, "Seismic Events Prediction Using Deep Temporal Convolution Networks," *J. Electr. Comput. Eng.*, vol. 2019, pp. 1–14, Apr. 2019, doi: 10.1155/2019/7343784.
- [16] H. Zhang, L. Chen, S. Chen, J. Sun, and J. Yang, "The spatiotemporal distribution law of microseismic events and rockburst characteristics of the deeply buried tunnel group," *Energies*, vol. 11, no. 12, Dec. 2018, doi: 10.3390/en11123257.
- [17] Y. Xue, C. Bai, D. Qiu, F. Kong, and Z. Li, "Predicting rockburst with database using particle swarm optimization and extreme learning machine," *Tunn. Undergr. Sp. Technol.*, vol. 98, Apr. 2020, doi: 10.1016/j.tust.2020.103287.
- [18] R. Chen, P. Zhang, H. Wu, Z. Wang, and Z. Zhong, "Prediction of shield tunneling-induced ground settlement using machine learning techniques," *Front. Struct. Civ. Eng.*, vol. 13, no. 6, pp. 1363–1378, Dec. 2019, doi: 10.1007/s11709-019-0561-3.
- [19] Z. Wen, X. Wang, Y. Tan, H. Zhang, W. Huang, and Q. Li, "A Study of Rockburst Hazard Evaluation Method in Coal Mine," *Shock Vib.*, vol. 2016, pp. 1–9, 2016, doi: 10.1155/2016/8740868.
- [20] L. fen Yang, C. Liu, H. Long, R. A. R. Ashfaq, and Y. lin He, "Further improvements on extreme learning machine for interval neural network," *Neural Comput. Appl.*, vol. 29, no. 8, pp. 311–318, Apr. 2018, doi: 10.1007/s00521-016-2727-4.
- [21] M. He, J. Miao, L. Dejian, and C. Wang, Experimental study on rockburst processes of granite specimen at great depth. 2007.