



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA DE MINAS

PREDICCIÓN DE VIBRACIONES PRODUCIDAS POR TRONADURAS
MEDIANTE REDES NEURONALES ARTIFICIALES

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL DE MINAS

RODRIGO IGNACIO DÍAZ BUSTOS

PROFESOR GUÍA:
HANS GÖPFERT HIELBIG

MIEMBROS DE LA COMISIÓN:
XAVIER EMERY
GONZALO MONTES ATENAS

SANTIAGO DE CHILE
2024

RESUMEN DE LA MEMORIA PARA
OPTAR AL TÍTULO DE INGENIERO
CIVIL DE MINAS
POR: RODRIGO IGNACIO DIAZ BUSTOS
FECHA: 2024
PROF. GUÍA: HANS GÖPFERT HIELBIG

PREDICCIÓN DE VIBRACIONES PRODUCIDAS POR TRONADURAS MEDIANTE REDES NEURONALES ARTIFICIALES

Esta memoria investiga la posibilidad de utilizar redes neuronales artificiales como parte de una metodología operativa, integrando tanto la información procedente de la empresa minera como la información capturada a diario por las estaciones de monitoreo que la empresa contratista mantiene en terreno. Uno de los principales propósitos es mejorar la precisión en la predicción de la magnitud de las vibraciones producidas por tronaduras en la minería a cielo abierto, lo cual es fundamental para asegurar la estabilidad de los taludes y reducir los riesgos asociados a las posibles inestabilidades. Los modelos tradicionales, como el desarrollado en este proyecto (la Ley Escalar de Devine), siguen siendo ampliamente utilizados en la minería chilena. Estos modelos presentan ciertas limitaciones basadas en simplificaciones al asumir ciertos supuestos y en la poca capacidad de gestionar adecuadamente grandes volúmenes de datos.

El objetivo principal del trabajo es desarrollar una metodología que integre la predicción de vibraciones mediante redes neuronales artificiales (ANN) y emplear la mayor cantidad de datos disponibles. Al comparar los valores del coeficiente de determinación (R^2) y del error cuadrático medio (MSE) entre el método de modelado tradicional y el desarrollado con redes neuronales artificiales, se demuestra que es posible utilizar técnicas de aprendizaje avanzado, que tienen la capacidad de incluir un mayor número de datos de entrada, captar relaciones que las funciones matemáticas tradicionales no pueden identificar y ofrecer adaptabilidad a cambios en las condiciones iniciales, manteniendo e incluso aumentando la precisión.

El proceso de investigación contempló una exploración exhaustiva de los datos, la creación de modelos tanto con métodos tradicionales como con redes neuronales artificiales. La investigación también incluyó la justificación y selección del mejor estimador en función de los valores del coeficiente de determinación y el error cuadrático medio. Los resultados muestran una mejora significativa al utilizar la metodología con redes neuronales artificiales, que hace más robustas las predicciones y, al mismo tiempo, disminuye los riesgos de seguridad asociados.

ABSTRACT OF THE SUBMITTED THESIS
TO OBTAIN THE DEGREE OF: MINING
ENGINEER
BY: RODRIGO IGNACIO DIAZ BUSTOS
FECHA: 2024
THESIS ADV.: HANS GÖPFERT HIELBIG

PREDICTION OF GROUND VIBRATIONS CAUSED BY BLASTING USING ARTIFICIAL NEURAL NETWORKS

This report investigates the potential for utilising artificial neural networks as an integral component of an operational methodology, integrating both the data provided by the mining company and the data captured on a daily basis by the monitoring stations maintained by the contractor in the field. One of the primary objectives is to enhance the precision of forecasting the intensity of blasting vibrations in open-pit mining, which is crucial for maintaining slope stability and mitigating the risks associated with potential instabilities. Traditional models, such as the one developed in this project (Devine's Scalar Law), remain widely employed in Chilean mining. These models are constrained by certain limitations, namely the simplifications made in assuming certain assumptions and the limited capacity to adequately manage large volumes of data.

The principal aim of this study is to develop a methodology that integrates vibration prediction using artificial neural networks (ANN) and makes use of the largest possible amount of available data. A comparison of the values of the coefficient of determination (R^2) and mean square error (MSE) between the traditional modelling method and the one developed with artificial neural networks demonstrates that it is feasible to utilise advanced learning techniques, which possess the capacity to incorporate a greater number of input data, identify relationships that traditional mathematical functions are unable to discern, and offer adaptability to changes in initial conditions, thereby maintaining and potentially enhancing accuracy.

The research process entailed a comprehensive data exploration, the development of models using both traditional methods and artificial neural networks. The research also included the justification and selection of the best estimator based on the values of the coefficient of determination and the mean square error. The results demonstrate a significant improvement when using the methodology with artificial neural networks, which makes the predictions more robust while simultaneously reducing the associated safety risks.

“Dedicado a mi familia y pareja, con todo mi amor y gratitud”

AGRADECIMIENTOS

Quisiera agradecer a todos los profesores de la Universidad de Chile que en algún momento me hicieron clases. De todos he aprendido algo valioso, ya sea para mi vida personal o profesional. En especial, a quienes me apoyaron en este proceso. Son grandes profesionales, sin duda, pero quisiera resaltar su constante disposición a ayudar al alumnado, lo que los hace aún más sobresalientes. Muchas gracias, Profesor Hans, Profesor Xavier y Profesor Gonzalo.

Deseo también agradecer a todo el personal administrativo de la Facultad de Ciencias Físicas y Matemáticas, y de manera muy especial a Gloria Jiménez. Sin su invaluable ayuda, no podría haber concluido este documento. Muchas gracias Gloria.

A mi familia, que siempre han sido un pilar fundamental en todos mis proyectos e ideas, especialmente a mis padres, quienes han dado todo por mí y mis hermanos. Les estoy eternamente agradecido por haberme criado, por haberme educado, por haberme corregido, por todo.

Finalmente, como siempre lo hago, dejo lo mejor y más importante para el final. Quiero agradecer a quien ilumina todos mis días, a quien me comparte su amor incondicional, a quien me ha mostrado una paciencia infinita, a quien ha estado a mi lado tanto en los momentos difíciles como en los felices. A ti, con quien quiero compartir más viajes y aventuras. Gracias por creer en mí cuando ni siquiera yo lo hacía, por motivarme siempre; María José Bahamóndez, esta meta es tanto tuya como mía.

Con todo mi cariño y gratitud.

TABLA DE CONTENIDO

1.	INTRODUCCIÓN	1
1.1.	Motivación del trabajo	1
2.	OBJETIVOS	3
2.1.	Objetivo General.....	3
2.2.	Objetivos Específicos	3
2.3.	Alcances.....	3
3.	MARCO TEÓRICO.....	4
3.1.	Estaciones de monitoreo de vibraciones de campo lejano.....	4
3.1.1.	Geófono triaxial	5
3.1.2.	Instalación del geófono triaxial.....	5
3.2.	Reporte instantáneo de las estaciones de monitoreo.....	6
3.3.	Modelo de campo lejano de Devine.....	9
3.4.	Introducción a las redes neuronales	10
3.5.	Usos de redes neuronales en la predicción de parámetros vibratoriales.....	12
3.6.	Efectos de las vibraciones en la estabilidad de taludes.....	14
4.	METODOLOGÍA	18
4.1.	Estudio exploratorio de datos	18
4.2.	Creación de modelos de vibraciones de Devine	18
4.3.	Herramienta de análisis multivariante y selección del estimador	19
4.4.	Análisis de estabilidad	19
5.	RESULTADOS.....	20
5.1.	Estudio exploratorio de datos	20
5.1.1.	Representación espacial de las tronaduras y estaciones.....	20
5.1.2.	Análisis estadístico básico de datos brutos	21
5.1.3.	Análisis estadístico básico de datos por estaciones.....	23

5.2.	Creación de modelos de vibración (Devine).....	25
5.2.1.	Modelo de vibración de campo lejano para todos los datos.....	25
5.2.2.	Modelos de vibración de campo lejano por estaciones.....	26
5.3.	Herramientas de análisis multivariante para la predicción de vibraciones.....	28
5.3.1.	Selección y optimización de inputs.....	28
5.3.1.1.	Preparación de los datos.....	28
5.3.1.2.	Evaluación y configuración de entradas.....	29
5.3.1.3.	Implementación y evaluación de modelos con configuración óptima.....	32
5.4.	Selección de estimador.....	39
5.4.1.	Modelo conseguido de manera tradicional.....	39
5.4.2.	Modelo conseguido con redes neuronales.....	39
5.4.3.	Modelo seleccionado con mejores resultados.....	40
5.5.	Metodología operativa.....	40
6.	ANÁLISIS DE RESULTADOS.....	43
6.1.	Análisis de resultados del estudio exploratorio.....	43
6.1.1.	Descripción general de los datos.....	43
6.1.2.	Análisis estadísticos de los datos.....	43
6.1.3.	Análisis estadísticos de los datos por estaciones.....	44
6.2.	Análisis de resultados de la creación de modelos de vibración (Devine).....	44
6.2.1.	Análisis de resultados de la creación de modelos de vibración (Devine) para el set completo de datos.....	45
6.2.2.	Análisis de resultados de la creación de modelos de vibración (Devine) para los sets de datos de cada estación.....	45
6.3.	Análisis de resultados del análisis multivariante para la predicción de vibraciones.....	46
6.4.	Análisis de resultados de la selección del estimador.....	46
6.5.	Metodología operativa.....	47
7.	CONCLUSIONES.....	48
8.	SIGUIENTES PASOS.....	49

BIBLIOGRAFÍA.....	50
ANEXOS.....	51
Anexo A. Análisis estadístico básico de datos por estaciones.....	51
A.1. Estación de monitoreo EBM_01.....	51
A.2. Estación de monitoreo EBM_02.....	52
A.3. Estación de monitoreo EBM_03.....	53
A.4. Estación de monitoreo EBM_04.....	55
A.5. Estación de monitoreo EBM_05.....	56
A.6. Estación de monitoreo EBM_06.....	57
Anexo B. Modelo de vibración de campo lejano por estaciones.....	59
B.1. Modelo de vibración de campo lejano EBM_01.....	59
B.2. Modelo de vibración de campo lejano EBM_02.....	60
B.3. Modelo de vibración de campo lejano EBM_03.....	61
B.4. Modelo de vibración de campo lejano EBM_04.....	62
B.5. Modelo de vibración de campo lejano EBM_05.....	63
B.6. Modelo de vibración de campo lejano EBM_06.....	64

ÍNDICE DE FIGURAS

Figura 1. Estación de monitoreo inalámbrico, También llamada BM (BlastMonitor).....	4
Figura 2. Geófono triaxial estándar ISEE.....	5
Figura 3. Representación de formas de instalar los geófonos para una correcta captura de datos..	6
Figura 4. Ejemplo de reporte de eventos posterior a cada evento recibido por cada estación de monitoreo.....	8
Figura 5. Representación de un perceptrón según Minsky & Papert 1988.	10
Figura 6. Red neuronal artificial utilizada por Dehghani et al. (en rojo los inputs más influyentes en el PPV).....	12
Figura 7. Red neuronal artificial utilizada por Singh et al.....	13
Figura 8. Diagrama de cuerpo libre para falla planar.	15
Figura 9. a) Ábaco factor sísmico vs. factor de seguridad, b) análisis de onda sísmica y obtención de desplazamiento permanente.	16
Figura 10. a) Vista de perfil para diagrama de cuerpo libre para falla en cuña, b) vista frontal. ..	16
Figura 11. a) Ábaco para condición seca, b) Ábaco para condición en presencia de agua.	17
Figura 12. Metodología adoptada para llegar al objetivo del trabajo.	18
Figura 13. representación espacial del centroide de las 1.302 tronaduras analizadas y las posiciones de las estaciones de monitoreo.	21
Figura 14. Histogramas de los datos: (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.....	22
Figura 15. Modelo de campo lejano para la totalidad de datos: a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	25
Figura 16. Serie de R^2 para cada combinación evaluada en las redes neuronales.....	31
Figura 17. Representación gráfica de la infraestructura de la red neuronal que maximiza el coeficiente de determinación.	37
Figura 18. Gráfica de dispersión comparando valores observados (eje x) y los valores predichos por la red neuronal (eje y).....	38
Figura 19. Evolución del entrenamiento de la red neuronal seleccionada.	38
Figura 20. Metodología operativa con la inclusión del modelado mediante redes neuronales.	41
Figura 21. Histogramas de los datos para EBM_01 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	52
Figura 22. Histogramas de los datos para EBM_02 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	53

Figura 23. Histogramas de los datos para EBM_03 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	54
Figura 24. Histogramas de los datos para EBM_04 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	56
Figura 25. Histogramas de los datos para EBM_05 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	57
Figura 26. Histogramas de los datos para EBM_06 , (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.	58
Figura 27. Modelo de campo lejano para la estación EBM_01 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	59
Figura 28. Modelo de campo lejano para la estación EBM_02 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	60
Figura 29. Modelo de campo lejano para la estación EBM_03 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	61
Figura 30. Modelo de campo lejano para la estación EBM_04 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	62
Figura 31. Modelo de campo lejano para la estación EBM_05 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	63
Figura 32. Modelo de campo lejano para la estación EBM_06 , a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.	64

ÍNDICE DE ECUACIONES

Ecuación 1. Modelo de campo lejano de Devine.	9
Ecuación 2. Función Sigmoide.	11
Ecuación 3. Función Tangente hiperbólica.	11
Ecuación 4. Función Rectified Linear Unit.	11
Ecuación 5. Nueva fórmula encontrada con análisis dimensional.	13
Ecuación 6. Regresión multivariante de frecuencia dominante.	14
Ecuación 7. Factor de seguridad para falla planar.	15
Ecuación 8. Factor de seguridad para falla en cuña.	16
Ecuación 9. Coeficiente de determinación encontrado para la mejor combinación.	37

ÍNDICE DE TABLAS

Tabla 1. Especificaciones técnicas del geófono triaxial estándar ISEE.	5
Tabla 2. Modelos predictivos convencionales.....	10
Tabla 3. Cantidad de eventos por estación registrados.....	20
Tabla 4. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias.	22
Tabla 5. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de todas las estaciones de monitores (EBM).	24
Tabla 6. Modelos encontrados para las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	26
Tabla 7. Resumen de los modelos obtenidos por estación y componente, junto con el coeficiente de determinación correspondiente a cada modelo.	27
Tabla 8. Cálculo de combinaciones realizadas, (no se considera la ejecución de las 50 épocas por cada combinación).	30
Tabla 9. Mejores diez combinaciones de inputs encontradas.....	32
Tabla 10. Resultados con parámetro step=25 en búsqueda de las mejores combinaciones.	33
Tabla 11. Resultados con parámetro step=25 en búsqueda de las mejores combinaciones.	34
Tabla 12. Resultados con parámetro step=10 en búsqueda de las mejores combinaciones.	35
Tabla 13. Resultados con parámetro step=4 en búsqueda de las mejores combinaciones.	35
Tabla 14. Resultados con parámetro step=1 en búsqueda de las mejores combinaciones.	36
Tabla 15. Resumen de los coeficientes de determinación encontrados con los modelos tradicionales.....	39
Tabla 16. Mejor resultado con la red neuronal encontrada para los datos utilizados.	40
Tabla 17. Infraestructura de la red neuronal que maximiza el valor de coeficiente de determinación.	40
Tabla 18. Mejor resultado con la red neuronal encontrada para los datos utilizados.	40
Tabla 19. Infraestructura de la red neuronal que maximiza el valor de coeficiente de determinación.	40
Tabla 20. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_01	51
Tabla 21. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_02	52
Tabla 22. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_03	54
Tabla 23. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_04	55

Tabla 24. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_05	56
Tabla 25. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de EBM_06	58
Tabla 26. Modelos encontrados para la estación EBM_01 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	60
Tabla 27. Modelos encontrados para la estación EBM_02 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	61
Tabla 28. Modelos encontrados para la estación EBM_03 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	62
Tabla 29. Modelos encontrados para la estación EBM_04 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	63
Tabla 30. Modelos encontrados para la estación EBM_05 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	64
Tabla 31. Modelos encontrados para la estación EBM_06 en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d)), en la tercera columna se puede apreciar el coeficiente de determinación R^2	65

1. INTRODUCCIÓN

El tener la capacidad de predecir los niveles de vibraciones producidas por las tronaduras en la minería a cielo abierto ha sido siempre un gran desafío y una necesidad constante en la industria, principalmente para la planificación minera, la operación minera y, fundamentalmente, en términos de seguridad minera. Las vibraciones sísmicas, tanto de los sismos propiamente dichos como de las tronaduras, pueden afectar a las inestabilidades presentes. Las vibraciones producidas por sismos siguen siendo un campo difícil de predecir y escapan al control de la operación; sin embargo, las vibraciones producidas por las tronaduras, en cierta medida, sí pueden ser controladas, ya que, al contar con la capacidad de predecir sus magnitudes, es posible ajustar los inputs o parámetros operacionales para minimizar el impacto de la tronadura. Tradicionalmente, se han utilizado modelos relacionados con la Ley Escalar de Devine, pero la creciente disponibilidad de datos y el auge de la inteligencia artificial permiten explorar otras formas de predecir y evaluar las posibles mejoras en la precisión de estas predicciones.

Este trabajo tiene como objetivo principal encontrar o modificar una metodología operativa para integrar el uso del mejor estimador multivariable en la predicción de vibraciones producidas por tronaduras en la minería a cielo abierto. Específicamente, se busca evaluar un estimador tradicional junto con un estimador utilizando redes neuronales artificiales. Al hacerlo, se pretende incluir y usar toda la información disponible y capturada para la predicción, cosa que no se puede realizar con los modelos tradicionales.

1.1. Motivación del trabajo

Como se mencionó en la sección anterior, la industria minera ha tenido, desde siempre, la necesidad de realizar predicciones precisas de las vibraciones producidas por las vibraciones en la minería a cielo abierto (aunque esta necesidad también se presenta en la minería subterránea, no forma parte de este estudio). La predicción precisa de estas vibraciones no solo es esencial para la planificación y las operaciones mineras, sino que también es fundamental para la seguridad de los trabajadores y la integridad de la infraestructura que se pueda ver afectada por estos movimientos.

Los métodos actuales o tradicionales, generalmente basados en la Ley Escalar de Devine, aunque útiles y sencillos, presentan ciertas limitaciones a la hora de enfrentarse a grandes volúmenes de información y a la necesidad continua de interpretación especializada. A medida que la tecnología avanza, se tiene una mayor capacidad para capturar datos en terreno, y también se dispone de un mayor número de herramientas digitales para el manejo de datos. Así surge la necesidad de explorar enfoques más sofisticados, complejos y robustos que aprovechen estos avances en la industria.

La utilización de redes neuronales artificiales (RNA o ANN por sus siglas en inglés) proporciona una alternativa con gran potencial para la predicción de vibraciones producidas por

las tronaduras. Estas técnicas no solo permiten procesar una mayor cantidad de información, sino que también identifican relaciones no lineales y patrones complejos que los modelos tradicionales no son capaces de captar. Además, pueden adaptarse y ajustar sus parámetros internos en función de los cambios en las condiciones operativas.

La motivación principal de este trabajo es aprovechar el potencial de las redes neuronales para crear una metodología que permita aumentar la precisión en la predicción de las vibraciones generadas por las tronaduras, lo que contribuye a mantener la seguridad, la continuidad operativa y la sostenibilidad de las operaciones mineras. Al integrar este enfoque, se pretende modernizar la estimación que se realiza actualmente, proporcionando una metodología flexible y adaptable a futuros cambios operacionales.

2. OBJETIVOS

Los principales objetivos de esta memoria se exponen a continuación.

2.1. Objetivo General

- Establecer una metodología operativa para la predicción de las vibraciones producidas por tronaduras en minería a cielo abierto mediante redes neuronales.

2.2. Objetivos Específicos

- Elaborar estimadores multivariantes para predecir vibraciones producidas por tronaduras.
- Seleccionar el mejor estimador multivariante para su inclusión en el análisis de estabilidad.
- Estructurar la metodología con el mejor estimador encontrado.
- Proporcionar una lista de los pasos siguientes para la inclusión de nuevas metodologías.

2.3. Alcances

La presente memoria contemplará los siguientes alcances:

- Se realizará el análisis de outliers, considerado adecuado en la ejecución actual de limpieza de datos.
- Solo se considerarán en los estudios las mediciones de vibraciones de campo lejano provenientes de tronaduras de producción.
- Se asume que no se producen cambios en los estándares de mallas de perforación y de tronadura durante el periodo de recolección de datos.
- Se seleccionará el mejor estimador evaluando el coeficiente de determinación y el error cuadrático medio.
- El estudio se realizará a partir de datos capturados desde una mina de cobre explotada a cielo abierto en la Cordillera de los Andes.
- La litología está compuesta por pórfido de cobre y molibdeno, mientras que los minerales principales son sulfuros primarios como la calcopirita y la bornita. Por razones de confidencialidad, no se pueden aportar más detalles, por lo que cualquier variable litológica o mineralógica no será considerada para este proyecto

3. MARCO TEÓRICO

En el marco teórico se muestran las bases teóricas y conceptuales sobre las cuales se desarrolla este trabajo. En la actual sección se disponen de un conjunto de referencias, conceptos técnicos y teóricos, y equipos tecnológicos que permiten la captura de información, herramientas tecnológicas esenciales para el análisis de datos de vibraciones producidas por tronaduras en la minería a cielo abierto. Mediante una detallada revisión de los modelos existentes, así como también de los avances en el uso de redes neuronales en el ámbito de la predicción, se proporciona el soporte para la metodología predictiva que se quiere obtener.

3.1. Estaciones de monitoreo de vibraciones de campo lejano

Son estaciones integradas en su totalidad por la empresa contratista, cuyas principales características son la continuidad en el monitoreo y su capacidad inalámbrica; esto se debe a la implementación de alimentación eléctrica mediante paneles solares y capacidad de transmitir la información captada por redes disponibles como por ejemplo redes celulares.



Figura 1. Estación de monitoreo inalámbrico, También llamada BM (BlastMonitor).

Estas estaciones están compuestas de un mástil que sostiene los demás componentes como el panel solar y la antena de comunicación para extender la ganancia de ésta. El mástil también sostiene una caja de distribución, que contiene un regulador de voltaje, batería para almacenar energía y así alimentar tanto un modem para efectuar la comunicación como el equipo de medición. Cabe destacar que este equipo de medición se divide en dos partes principales, una parte que almacena los eventos y permite realizar configuraciones como por ejemplo la conexión y otra parte es el sensor que es quien percibe el evento con sus tres bobinas internas perpendiculares entre sí.

3.1.1. Geófono triaxial

Los geófonos triaxiales son el equipo principal para la captación de datos de vibraciones tridimensionales. A continuación, se detallan las especificaciones técnicas de los geófonos triaxiales estándar ISEE. La correcta calibración y su instalación son fundamentales para una captura de datos exactos y, posteriormente, unos análisis correctos.

Tabla 1. Especificaciones técnicas del geófono triaxial estándar ISEE.

Estándar de respuestas	Especificaciones ISEE edición 2011
Rango de frecuencia	2 a 250 Hz
Rango de velocidad	Hasta 10 in/s (254 mm/s)
Resolución	0,00031 in/s (0,00788 mm/s)
Densidad del sensor	1,33 lbs/ft ² (2,13 g/cc)
Largo de cable	6 ft (2 m)
Máximo largo de cable	250 ft (75 m)
Software requerido	Blastware compliance / Thor



Figura 2. Geófono triaxial estándar ISEE.

3.1.2. Instalación del geófono triaxial

El sensor, también llamado geófono, debe tener una instalación siguiendo los lineamientos recomendados por el fabricante o, como en estos casos de la Sociedad Internacional de Ingenieros Explosivistas (ISEE por sus siglas en inglés), estos lineamientos están enfocados a que el sensor quede lo más solidario posible al terreno o la estructura a cautelar y represente verdaderamente las

vibraciones del terreno o de la estructura, y no sea una vibración extra por balanceo propio del sensor (International Society of Explosives Engineers, 2020).

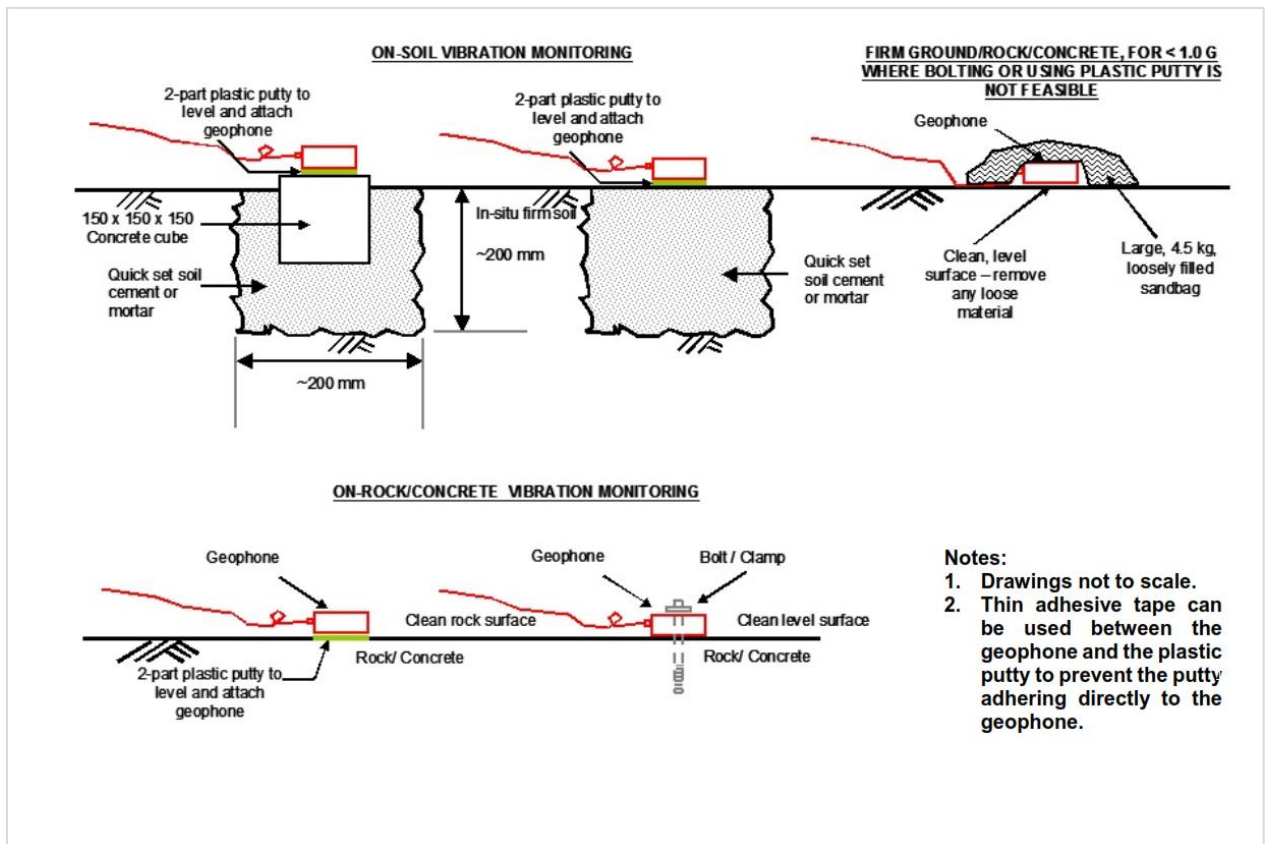


Figura 3. Representación de formas de instalar los geófonos para una correcta captura de datos.

3.2. Reporte instantáneo de las estaciones de monitoreo

Cada evento que active la medición produce un reporte que es personalizado dependiendo de los requerimientos del contrato o del cliente. En la Figura 4 se muestra un reporte de ejemplo. Este reporte tiene información de la fecha y hora de ocurrencia del evento y también identifica el equipo utilizado. Además, cuenta con información como la que se detalla a continuación:

- Especificaciones del equipo, como nombre, tasa de muestreo, valor de “trigger”, nivel de batería y última fecha de calibración.
- Ubicación de la estación y fecha en que se instaló.
- Valores de PPV (Peak¹ Particle Velocity) en las direcciones ortogonales transversal, longitudinal y vertical, en (mm/s).
- Frecuencias principales determinadas, en este caso por un cálculo utilizando transformada rápida de Fourier (FFT, Fast Fourier Transform).

¹ En este documento no habrá distinciones entre peak, pico o máximo.

- Tiempo relativo al comienzo del registro en el que se alcanzan los valores peak en cada componente, en (s).
- Peak de aceleración en cada componente, en (g).
- Peak de desplazamiento en cada componente, en (mm).
- Suma vectorial de la aceleración (g) y su tiempo relativo de ocurrencia (s).
- Suma vectorial de la velocidad (mm/s) (también llamada PVS, Peak Vector Sum) y su tiempo relativo de ocurrencia (s).

Además, también se entrega una representación gráfica de los datos capturados:

- Gráfica de velocidad separada en cada componente versus el tiempo relativo al inicio de la captura de datos.
- Posición de los picos (peak) de velocidad de cada componente en una gráfica de velocidad en (mm/s) versus frecuencia (Hz); en esta gráfica también se incluye, en este caso, información de la norma alemana DIN4150.
- Por último, también se muestra una evolución temporal de la suma vectorial de velocidad, en (mm/s).



Monitoreo Remoto de Vibraciones

Reporte Emitido por BlastReport®

Date/Time	Long at abr. 25, 2024 15:48:00	Serial Number	UM12403 V 10-90GC Micromate ISEE
Trigger Source	Geo: 0,600 mm/s	Battery level	3,8 Volts
Range	Geo: 254,0 mm/s	Unit Calibration	July 14, 2024 by InstanTEL
Sample Rate	5,306 sec. at 2048 sps	File Name	UM12403_20240425154800.IDFW
Location:	Mina NN 09		
Client:	Mina NN		
Implement	Rockblast Design SPA.		

Station: BM_Mina_NN_09
 S/N: UM12403
 Implementation date: 10-11-2018

	Tran	Vert	Long	
PPV	1,048	0,599	1,356	mm/s
FFT freq	6,5	6,3	6,7	Hz
Time (Rel. to Trig)	0,246	0,495	0,556	sec
Peak Acceleration	0,013	0,01	0,015	g
Peak Displacement	0,02	0,011	0,024	mm
Sensor Check	Passed	Passed	Passed	
Peak Vector Acc	0,016 g at 0,589 s			
Peak Vector Sum	1,587 mm/s at 0,554 s			



ROCKBLAST

TROHADURA • GEOMECÁNICA • TECNOLOGÍA

Lo Fontecilla 201, Oficina 434, Las Condes, Santiago.

Figura 4. Ejemplo de reporte de eventos posterior a cada evento recibido por cada estación de monitoreo.

3.3. Modelo de campo lejano de Devine

Modelo creado a partir de una investigación realizada por el United States Bureau of Mines (USBM) en el año 1966 (Devine, Beck, Meyer, & Duvall, 1966), la cual consiste en la medición de la velocidad de partícula de 39 tronaduras en canteras a distinta distancia, de estas 39 tronaduras 12 fueron instantáneas, 5 con retardo tiro a tiro usando detonadores de milisegundos y 22 con retardo múltiples tiros, la cantidad de explosivo utilizado varía desde 3.6 a 680 kg y la carga por retardo varió desde 11 a 2.095 kg (incluyendo las tronaduras instantáneas). El modelo se basa en el análisis estadístico de los datos recogidos por cada componente de velocidad de partícula (vertical, longitudinal y transversal)

El análisis estadístico de la velocidad de partícula máxima (en sus tres componentes) con respecto a la distancia, muestra que la carga explosiva o la carga explosiva por retardo puede ser usada como un factor escalar en una ecuación de la siguiente forma.

$$PPV = k \left(\frac{d}{\sqrt{W}} \right)^{-\alpha}$$

Ecuación 1. Modelo de campo lejano de Devine.

Donde:

- α y k : Constantes que caracterizan la atenuación de las ondas de vibración a través del terreno
- W : Carga explosiva total o carga explosiva máxima por intervalo de retardo (kg)
- d : Distancia desde la carga detonada al punto de medición (m)

Este modelo cuenta con ciertas restricciones, como que tiene validez solo en campo medio-lejano, recomendable para distancias mayores a dos o tres veces la longitud de la carga. No es recomendable para macizos rocosos altamente fracturados, además no considera la secuencia de salida de los tiros. Adicionalmente, asume cargas explosivas de geometría cilíndrica y 100% acopladas.

A su vez, este modelo es uno de los más famosos y representa la base de muchos otros modelos que han ido mejorando o ajustando distintos parámetros de la fórmula para lograr una mejor estimación o representación de las vibraciones, tales como los que se muestran en la Tabla 2.

Tabla 2. Modelos predictivos convencionales.

Modelo	Ecuación
(Langefor & Kihlström, 1963)	$v = k \left[d^{2/3} / \sqrt{W} \right]^{-\alpha}$
(Devine, Beck, Meyer, & Duvall, 1966)	$v = k \left[d / \sqrt{W} \right]^{-\alpha}$
(Bureau of Indian Standards, 1973)	$v = k \left[d^{2/3} / W \right]^{-\alpha}$
(Ambraseys & Hendron, 1968)	$v = k \left[d / \sqrt[3]{W} \right]^{-\alpha}$

3.4. Introducción a las redes neuronales

Las redes neuronales artificiales, o ANN por sus siglas en inglés, son un modelo computacional que está inspirado en el funcionamiento del cerebro humano, específicamente en las interacciones neuronales de este. Al igual que los humanos, las ANN están diseñadas para realizar tareas de aprendizaje automático, clasificación y predicciones (Goodfellow, Bengio, & Courville, 2016).

Las ANN están compuestas por tres capas: una capa de entrada, una de salida y una capa oculta; esta capa oculta está compuesta de nodos conectados llamados neuronas artificiales. Las redes neuronales artificiales aprenden patrones a través de un ajuste inicial, llamado entrenamiento, en donde se realiza un proceso de calibración de los distintos pesos de las conexiones entre neuronas.




Figura 5. Representación de un perceptrón según Minsky & Papert 1988.

Dependiendo del problema a resolver, las redes neuronales pueden adoptar distintas estructuras o arquitecturas. Algunas de las arquitecturas comunes son las siguientes:

- Redes Convolucionales (CNN)
- Redes Recurrentes (RNN)
- Perceptrón multicapa (MLP)

Para el caso de este proyecto, se utilizarán las redes neuronales profundas (Deep Feedforward Networks), que son una categoría de las redes neuronales que se caracterizan por tener múltiples capas ocultas entre las dos capas de entrada y salida; por esto, también son llamadas perceptrón de multicapa (MLP por sus siglas en inglés). Esta categoría de redes neuronales puede ser utilizada para encontrar relaciones más complejas y abstractas de los datos.

Un componente crucial de las redes neuronales son las funciones de activación, funciones que determinan la salida de una neurona dada una entrada. La principal finalidad es la introducción de la no linealidad a los modelos, lo que los hace diferentes de una combinación lineal. Algunas de las funciones más típicas pueden ser:

- Función Sigmoide

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Ecuación 2. Función Sigmoide.

- Función Tanh

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Ecuación 3. Función Tangente hiperbólica.

- Función ReLU

$$\text{ReLU}(x) = \max(0, x)$$

Ecuación 4. Función Rectified Linear Unit.

Como se mencionó, la principal finalidad es aplicar la no linealidad a los modelos, lo que lo diferencia de los modelos comunes y permite resolver problemas complejos; además, permiten controlar el flujo de información regulando la propagación de esta a través de la red, lo que puede afectar el aprendizaje y la convergencia. Por último, algunas funciones permiten entrenamientos más rápidos y eficientes.

Un aspecto importante de la utilización de redes neuronales artificiales es la correcta designación del conjunto de datos de entrenamiento y de validación, para este caso se destina un 85% de la totalidad de datos para el entrenamiento y un 15% para la validación.

3.5. Usos de redes neuronales en la predicción de parámetros vibracionales

El uso de las redes neuronales (RNA, redes neuronales artificiales) en la predicción de distintos parámetros de las vibraciones ha demostrado en varios estudios mejorar la precisión de predicción, además de poder utilizar una mayor cantidad de datos que se pueden tener disponibles. A continuación, se muestran dos estudios realizados por investigadores en los que se utiliza redes neuronales en la predicción de PPV y también para la predicción de la frecuencia dominante de las vibraciones.

En primer lugar, se puede destacar a Dehghani y Ataee-pour (2011), que desarrollan de forma paralela un modelo predictivo inteligente en base a redes neuronales y una nueva fórmula para el PPV con un análisis dimensional. Para el modelo con redes neuronales, optan por una red de tres capas: en la primera capa de nueve inputs, en la capa oculta con veinticinco neuronas y un output en la capa de salida que representa el PPV (mm/s), encuentran que la mejor arquitectura resulta en un $RMSE^2$ de 0,0245, además realizan un análisis de sensibilidad (realizando iteraciones activando y desactivando inputs) encontrando que cinco de los nueve inputs son los que más influyen en el parámetro de salida (ver Figura 6). En el caso de la nueva fórmula hecha por medio de un análisis dimensional, se encuentra la Ecuación 5 que tiene un coeficiente de determinación del 74,5% siendo mayor que otros predictores ocupando los datos estudiados según los investigadores.

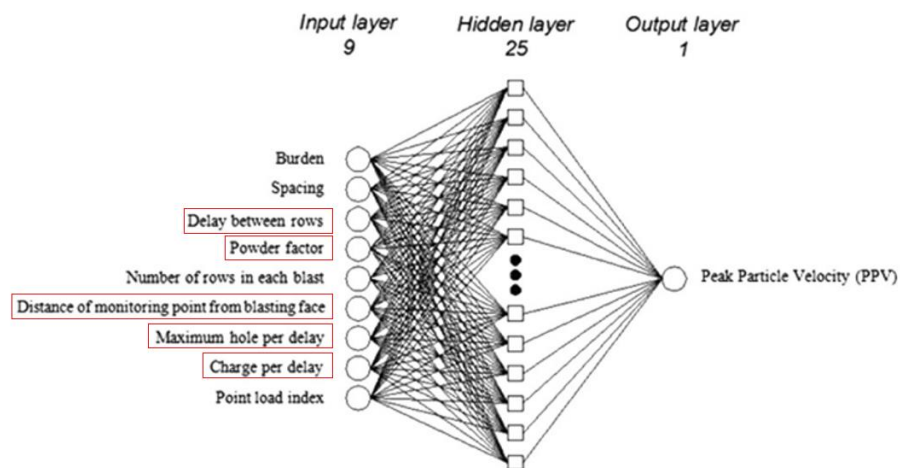


Figura 6. Red neuronal artificial utilizada por Dehghani et al. (en rojo los inputs más influyentes en el PPV).

² Root Mean Square Error

$$PPV = \frac{168.85}{D_e} \left(\frac{q}{ch} \right)^{-1.48} B^{-5.64} S^{3.43} \mu^{-1.22} \theta^{-1.18}$$

Ecuación 5. Nueva fórmula encontrada con análisis dimensional.

Donde:

- D_e : Tiempo entre filas (ms).
- q : Factor de forma (kg/m^3).
- ch : Carga por retardo (kg).
- B : Burden (m).
- S : Espaciamiento (m).
- μ : Distanciamiento entre punto de monitoreo y tronadura (m).
- θ : Máximos pozos por retardo (unidades).

Por otro lado, Singh y Singh (2005) desarrollan en su estudio, también de forma paralela un modelo predictivo en base a redes neuronales artificiales y una regresión multivariante para la predicción de la frecuencia de una tronadura, para luego realizar una comparación entre ambas predicciones. Para el modelo con red neuronal, utilizan una red de tres capas con la primera capa de nueve inputs, la capa oculta con seis neuronas y por último en la capa de salida un output que refleja la frecuencia dominante (Hz). En el caso de la regresión multivariante se encuentra la Ecuación 6

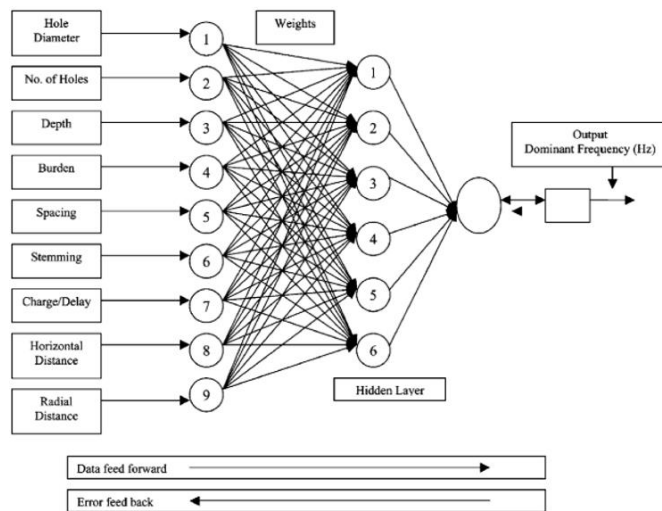


Figura 7. Red neuronal artificial utilizada por Singh et al.

$$\begin{aligned}
 \text{Frecuencia Dominante (Hz)} = & 30.8525 + 0.0583 \cdot D_h - 0.0478 \cdot N_h \\
 & - 1.0894 \cdot H_d + 5.1792 \cdot B - 6.3142 \cdot S \\
 & + 1.2925 \cdot H_s - 0.0051 \cdot ch - 0.4388 \cdot \mu_h \\
 & + 0.4757 \cdot \mu
 \end{aligned}$$

Ecuación 6. Regresión multivariante de frecuencia dominante.

Donde:

- D_h : Diámetro del pozo (m).
- N_h : Números de pozos (un).
- H_d : Profundidad del pozo (m).
- B : Burden (m).
- S : Espaciamiento (m).
- H_s : Altura de la columna del taco (m).
- ch : Carga por retardo (kg).
- μ_h : Distanciamiento horizontal entre punto de monitoreo y tronadura (m).
- μ : Distanciamiento entre punto de monitoreo y tronadura (m).

Algunas mejoras y ventajas que se pueden desprender de estos estudios en el uso de redes neuronales en la predicción de parámetros vibratoriales en comparación con los métodos tradicionales son la capacidad de realizar modelado complejo y no lineal de los datos de entrada y salida, pudiendo captar patrones que no son identificables en los métodos analíticos comunes. La capacidad de poder adaptarse a distintas situaciones y cambios de los inputs sin tener que redefinir los fundamentos del modelo es una de las principales ventajas que se tiene con el uso de las RNA. Esto pasa a menudo en la operación minera, donde, por ejemplo, en este caso, las detonaciones realizadas pueden variar de un sector a otro. Sumado a las ventajas mencionadas, se obtienen predicciones de mayor precisión según varios estudios, incluidos los mostrados en esta sección.

3.6. Efectos de las vibraciones en la estabilidad de taludes

La influencia o los efectos de las vibraciones ya sean de sismos naturales o artificiales inducidas por tronaduras sobre la estabilidad de taludes son fundamentales para la planificación, seguridad y continuidad operacional en una mina. Los estudios detallados a continuación muestran cómo estas vibraciones influyen en distintitos tipos de fallas.

El primer estudio es el de Ling & Cheng (1997), que determinaron una serie de ábacos con el objetivo de estudiar, primeramente, el efecto del movimiento sísmico en el factor de seguridad a lo largo de una falla planar (ver Figura 8 y Ecuación 7), luego observar el funcionamiento

(performance) de la aceleración y el desplazamiento permanente del macizo rocoso sujeto a movimiento sísmico (ver Figura 9), y para finalizar, realizan una extensión del proceso a una falla tipo cuña.




Figura 8. Diagrama de cuerpo libre para falla planar.

$$F_s = \frac{\tan \phi}{\tan(\psi_p + \theta)}$$

Ecuación 7. Factor de seguridad para falla planar.

Donde:

- F_s : Factor de seguridad sísmico.
- ϕ : Ángulo de fricción (°).
- θ : Función que relaciona los coeficientes sísmicos horizontal y vertical.
- ψ_p : Ángulo del plano de falla con respecto a la horizontal (°).

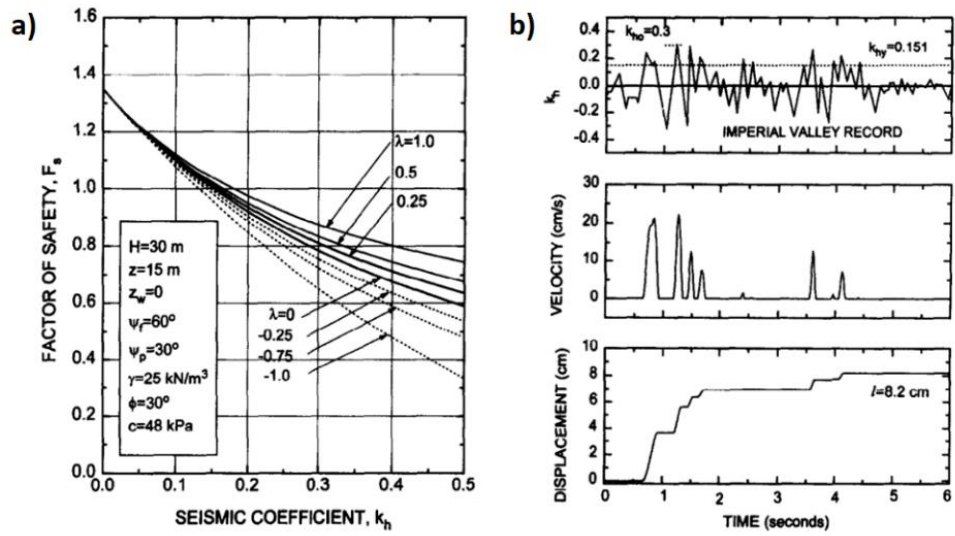


Figura 9. a) Ábaco factor sísmico vs. factor de seguridad, b) análisis de onda sísmica y obtención de desplazamiento permanente.




Figura 10. a) Vista de perfil para diagrama de cuerpo libre para falla en cuña, b) vista frontal.

$$F_{sd} = \frac{\tan \hat{\phi}}{\tan(\psi_i + \theta)} \quad \text{donde} \quad \tan \hat{\phi} = K \tan \phi \quad \text{y} \quad K = \frac{\sin \beta}{\sin \frac{\xi}{2}}$$

Ecuación 8. Factor de seguridad para falla en cuña.

Donde:

- F_{sd} : Factor de seguridad sísmico.
- θ : Función que relaciona los coeficientes sísmicos horizontal y vertical.
- ψ_i : Ángulo de la línea de intersección de las fallas planares que forman la cuña ($^{\circ}$).

También Kesimal, Ercikdi & Cihangir (2008) realizan un estudio de la aceleración sísmica producidas por tronaduras en la estabilidad de talud en una cantera de caliza, donde se contaba con eventos de desplazamientos planares producto de las vibraciones producidas por tronaduras no controladas. Se realiza un análisis de equilibrio límite similar al realizado anteriormente para luego elaborar graficas con distintas propiedades de la roca y en condiciones tanto secas como en presencia de agua. El estudio destaca cómo las vibraciones descontroladas tienen un efecto reductor en el factor de seguridad de los taludes especialmente en presencia de agua.

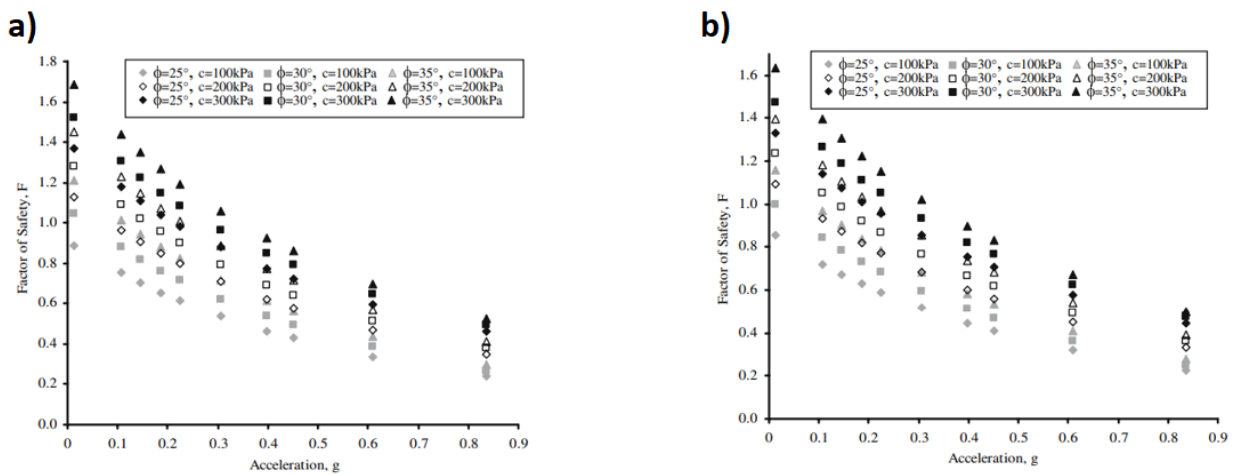


Figura 11. a) Ábaco para condición seca, b) Ábaco para condición en presencia de agua.

Estos estudios muestran la importancia de controlar las tronaduras y las vibraciones para evitar consecuencias negativas en la estabilidad de los taludes. Al contar con un método predictivo de las vibraciones, es posible anticipar sus implicaciones y gestionar las medidas para la mitigación de éstas. Así, se pueden realizar operaciones mineras más continuas y seguras, al tiempo que se minimizan eventos no deseados.

4. METODOLOGÍA

En esta sección se muestra la metodología adoptada para desarrollar el trabajo de memoria, con el foco de realizar múltiples modelados y comparaciones para poder determinar la mejor opción y definir la metodología para integrar el registro de vibraciones, el modelado de vibraciones y los levantamientos geológicos estructural mediante tecnología de drones.



Figura 12. Metodología adoptada para llegar al objetivo del trabajo.

4.1. Estudio exploratorio de datos

En esta etapa inicial se adquieren y verifican los datos provenientes tanto de la información entregada por la empresa minera como de las registradas por las estaciones de monitoreo. Luego se realiza una asociación y cotejo de los datos provenientes de estas dos fuentes. Posteriormente, se lleva a cabo un análisis estadístico para entender sus distribuciones, correlaciones y poder discernir distintas familias de datos.

4.2. Creación de modelos de vibraciones de Devine

Tomando los datos anteriores trabajados, se encuentran los modelos de vibraciones de la forma tradicional. Para este caso, se buscan los parámetros del Modelo de Devine. Este modelo estándar será el punto de comparación para la predicción mediante redes neuronales artificiales.

4.3. Herramienta de análisis multivariante y selección del estimador

Al igual que en la etapa anterior, se utilizan los datos para elaborar un estimador multivariante. Para determinar una estructura de red neuronal artificial, con el objetivo de analizar la eficacia de los predictores, se tomará un 85% de los datos para el entrenamiento de los predictores y el 15% restante para la evaluación. Esto permitirá seleccionar el mejor estimador para ser utilizado en la siguiente etapa.

4.4. Análisis de estabilidad

El análisis de estabilidad se escapa de los alcances de este proyecto en particular, pero se incluye en la Figura 12 debido a que es el foco de unir el área de predicción de vibraciones con el de análisis de estabilidad, el cual es responsabilidad de otra área de la empresa, utilizando información proveniente de la empresa minera y los levantamientos con drones que se realizan en la empresa.

5. RESULTADOS

En esta sección se muestran todos los resultados obtenidos siguiendo la metodología presentada. Todo comienza con la obtención de datos, tanto provenientes de la empresa minera con las órdenes de trabajo como por los registros captados por las estaciones de monitoreo.

5.1. Estudio exploratorio de datos

El conjunto de datos tomado para este trabajo fue cuidadosamente seleccionado; los datos deben cumplir con las siguientes características:

- Asociar los registros de las estaciones de monitoreo con la información de tronadura informada por la minera.
- Ser tronaduras de producción; se obvian las tronaduras de contorno, rampas, entre otras.
- Datos registrados entre 2018 y 2020 (3 años).
- Los datos deben pasar el análisis de outliers.

Considerando estos factores, se cuenta con 1.302 registros en total, los cuales se distribuyen de la siguiente manera.

Tabla 3. Cantidad de eventos por estación registrados.

Estación	Registros
EBM_01	312
EBM_02	103
EBM_03	346
EBM_04	139
EBM_05	319
EBM_06	83
Total	1.302

5.1.1. Representación espacial de las tronaduras y estaciones

En la siguiente figura se muestra una disposición espacial de las tronaduras, representadas por el centroide de éstas (puntos azules). También se pueden ver las estaciones de monitoreo instaladas en la mina (puntos rojos). Cabe destacar que las coordenadas son una traslación de las originales.




Figura 13. representación espacial del centroide de las 1.302 tronaduras analizadas y las posiciones de las estaciones de monitoreo.

5.1.2. Análisis estadístico básico de datos brutos

Este análisis estadístico básico, mostrado en la Tabla 4, proporciona una visión cuantitativa y descriptiva de las variables de velocidad y frecuencia; específicamente se proporciona el promedio, la desviación estándar y el valor máximo de cada variable. Estas estadísticas reflejan la distribución y tendencia general de los datos brutos.

Tabla 4. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	4,203	5,998	64,350
Nivel de vibración Vertical (mm/s)	3,763	6,840	95,980
Nivel de vibración Longitudinal (mm/s)	4,272	6,061	76,340
Nivel de vibración VS (mm/s)	5,839	8,893	99,300
Niveles de Frecuencias FFT Transversal (Hz)	7,555	3,064	35,500
Niveles de Frecuencias FFT Vertical (Hz)	8,168	3,754	31,000
Niveles de Frecuencias FFT Longitudinal (Hz)	7,400	3,242	30,750

Para tener una visualización del comportamiento de los datos brutos (datos sin procesar aún), se puede observar la Figura 14, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones log-normales cuyos parámetros están indicados en la figura (Loc, Scale y Thresh).

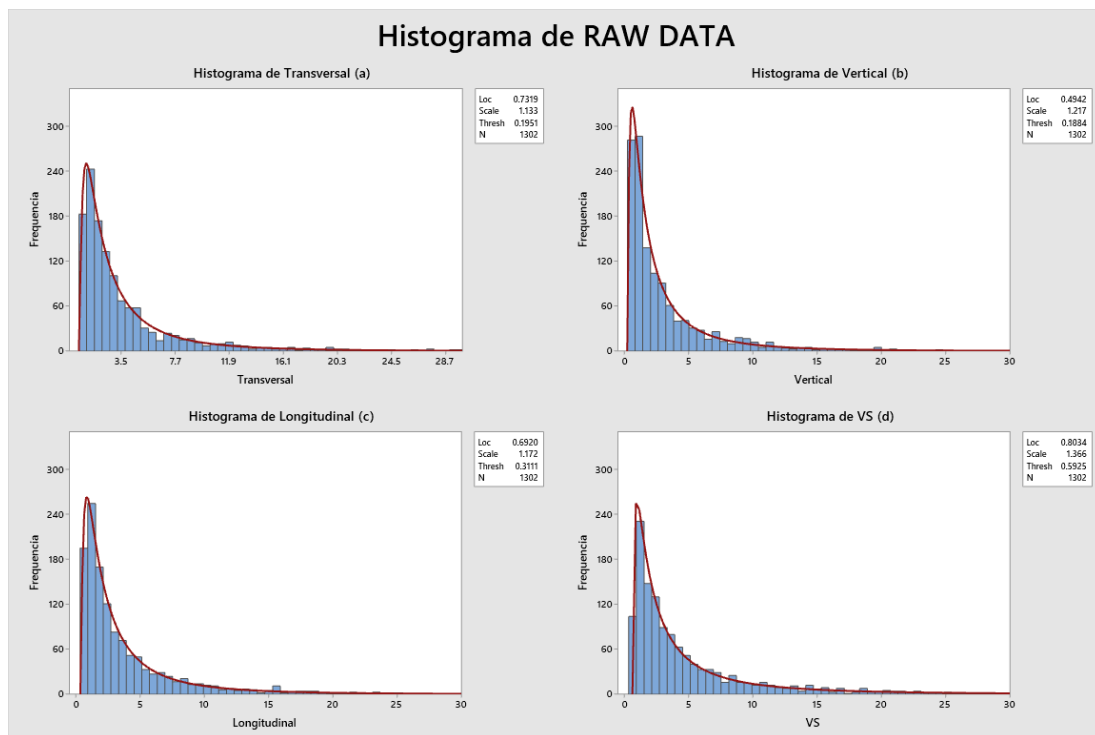


Figura 14. Histogramas de los datos: (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

5.1.3. Análisis estadístico básico de datos por estaciones

Esta sección se centra en mostrar el análisis estadístico básico de los datos separados por las diferentes estaciones de monitoreo. En la Tabla 5, se pueden observar los datos de desviación estándar, promedios y máximos de las capturas de datos, así como la cantidad de datos capturados por cada estación.

En la sección **Error! Reference source not found.** de Anexos, se pueden ver en detalle por estaciones las estadísticas básicas, así como una visualización del comportamiento de los datos en forma de histogramas y las curvas de tendencias de cada componente de velocidad y del Vector Suma (VS). Las curvas de tendencias se ajustan a distribuciones log-normales, cuyos parámetros se encuentran en cada figura (Loc, Scale y Thresh).

Tabla 5. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de todas las estaciones de monitores (EBM).

Estación / Variable		Total, cuentas (un)	Nivel de Vibración (mm/s)				Niveles de Frecuencias FFT (Hz)		
			Tran	Vert	Long	VS	Tran	Vert	Long
EBM_01	Promedio	312	2,549	2,062	2,210	3,103	4,945	5,806	5,007
	Desv. Est.		2,806	2,613	2,434	3,485	1,620	2,652	1,909
	Máximo		18,680	17,320	15,530	22,920	11,750	30,120	11,500
EBM_02	Promedio	103	2,455	2,806	3,283	4,370	7,120	11,212	9,884
	Desv. Est.		4,031	5,692	8,076	9,700	2,043	7,030	6,761
	Máximo		39,280	43,900	72,610	87,260	13,900	31,000	30,750
EBM_03	Promedio	346	7,096	6,748	6,565	9,870	7,519	8,480	7,122
	Desv. Est.		9,267	11,132	8,235	13,528	2,231	2,537	2,278
	Máximo		64,350	95,980	76,340	99,300	14,250	17,000	22,000
EBM_04	Promedio	139	5,872	4,991	6,575	8,102	8,049	8,276	7,772
	Desv. Est.		5,201	5,502	6,291	7,338	3,074	3,469	2,166
	Máximo		38,830	43,940	42,050	49,980	29,000	29,000	12,250
EBM_05	Promedio	319	2,910	2,264	3,564	4,200	9,707	8,920	8,993
	Desv. Est.		2,841	2,228	3,934	4,410	2,672	3,351	2,410
	Máximo		17,810	11,970	27,850	29,430	15,800	26,500	18,200
EBM_06	Promedio	83	2,698	2,606	2,564	3,652	8,971	8,900	7,727
	Desv. Est.		4,418	4,692	3,723	5,641	4,768	2,913	1,957
	Máximo		37,080	41,730	31,640	48,420	35,500	20,500	13,000

5.2. Creación de modelos de vibración (Devine)

En esta subsección se muestran los modelos de vibración de campo lejano, de acuerdo con la Ley Escalar de Devine, obtenidos a partir de los datos de las tronaduras de tres años, de 2018 a 2020. Este modelo utiliza los datos históricos y el análisis estadístico permite la estimación de la velocidad de partícula (PPV o PVS) en función de la carga explosiva y la distancia desde el origen de la tronadura hasta el punto de medición. Para la elaboración del modelo, se utiliza información proporcionada por la empresa minera, incluyendo las coordenadas de la ubicación central de la malla de perforación, la carga explosiva por retardo de cada tronadura utilizada y las mediciones asociadas a cada tronadura registradas por las estaciones de monitoreo.

5.2.1. Modelo de vibración de campo lejano para todos los datos

En la siguiente figura se muestran los distintos modelos tanto para las diferentes direcciones ortogonales como para el vector suma del conjunto completo de 1.302 datos.

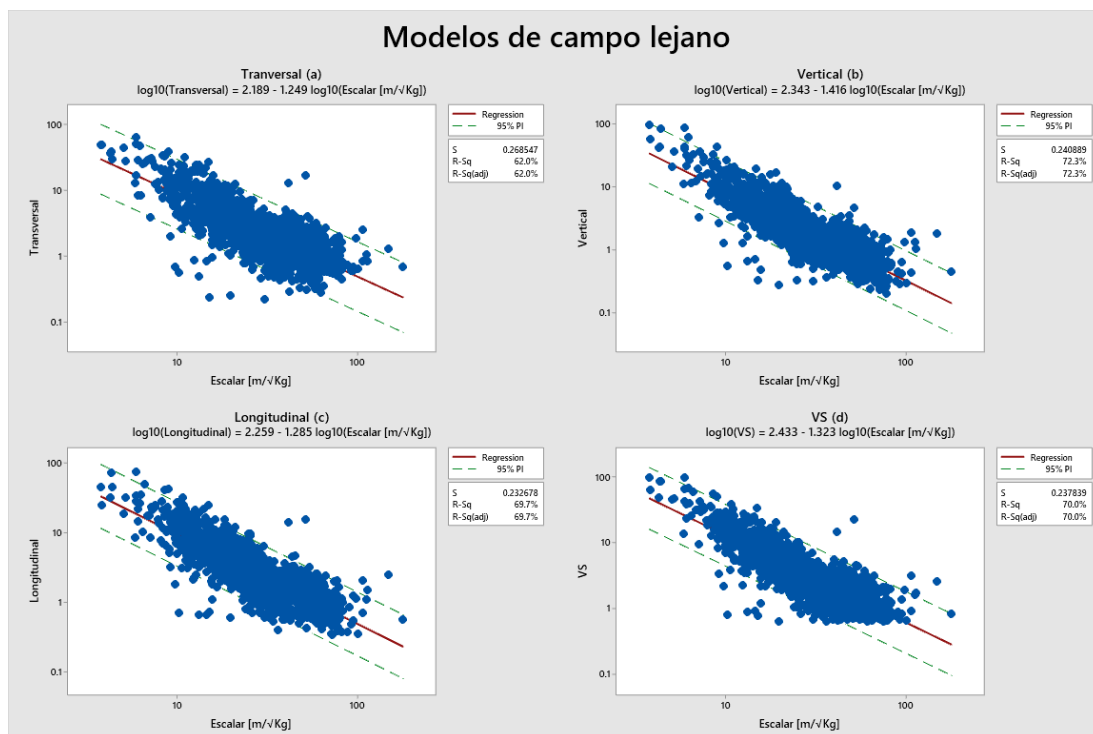


Figura 15. Modelo de campo lejano para la totalidad de datos: a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

En la Tabla 6 se muestran los modelos resultantes de las regresiones para la predicción de velocidades peak de partículas para las distintas direcciones ortogonales, así como el vector suma, cada modelo etiquetado desde la “a” a la “d”, indicando distintas direcciones: transversal (a), vertical (b), longitudinal (c) y vector suma o PVS (d) para el conjunto completo de datos. Los modelos se encuentran en su versión lineal transformada y también en su versión original, como se

muestra en la Ecuación 1. En la tercera columna de la tabla se muestra el coeficiente de determinación que en este caso varía del 62,0% al 72,3%, indicando la calidad de ajuste para cada modelo.

Tabla 6. Modelos encontrados para las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 2,189 - 1,249 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 154,525 \cdot (D_e)^{-1,249}$	62,0%
b)	$\log_{10}(PPV_V) = 2,343 - 1,416 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 220,292 \cdot (D_e)^{-1,416}$	72,3%
c)	$\log_{10}(PPV_L) = 2,259 - 1,285 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 181,551 \cdot (D_e)^{-1,285}$	69,7%
d)	$\log_{10}(PVS) = 2,433 - 1,323 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 271,019 \cdot (D_e)^{-1,323}$	70,0%

5.2.2. Modelos de vibración de campo lejano por estaciones

En la siguiente sección se presentan los distintos modelos, tanto para las diferentes direcciones ortogonales como para el vector suma, así como para las distintas estaciones de monitoreo. En la Tabla 7 se muestra un resumen de los modelos obtenidos, junto con el coeficiente de determinación de cada uno.

En el apartado Anexo B de Anexos, se pueden ver con más detalle los modelos obtenidos, con una representación gráfica para cada estación.

Tabla 7. Resumen de los modelos obtenidos por estación y componente, junto con el coeficiente de determinación correspondiente a cada modelo.

Estación / Variable		Transversal	Vertical	Longitudinal	Vector Suma
EBM_01	R ²	79,1%	83,2%	79,5%	82,5%
	Modelo	$PPV_T = 251,188 \cdot (D_e)^{-1,322}$	$PPV_V = 511,681 \cdot (D_e)^{-1,588}$	$PPV_L = 222,331 \cdot (D_e)^{-1,327}$	$PVS = 372,250 \cdot (D_e)^{-1,378}$
EBM_02	R ²	67,2%	82,5%	85,4%	82,2%
	Modelo	$PPV_T = 51,360 \cdot (D_e)^{-0,941}$	$PPV_V = 563,637 \cdot (D_e)^{-1,673}$	$PPV_L = 204,644 \cdot (D_e)^{-1,335}$	$PVS = 256,448 \cdot (D_e)^{-1,302}$
EBM_03	R ²	77,2%	69,5%	72,1%	74,7%
	Modelo	$PPV_T = 668,344 \cdot (D_e)^{-1,787}$	$PPV_V = 605,341 \cdot (D_e)^{-1,770}$	$PPV_L = 415,911 \cdot (D_e)^{-1,595}$	$PVS = 807,235 \cdot (D_e)^{-1,727}$
EBM_04	R ²	63,9%	71,2%	68,1%	68,1%
	Modelo	$PPV_T = 196,336 \cdot (D_e)^{-1,324}$	$PPV_V = 194,089 \cdot (D_e)^{-1,416}$	$PPV_L = 194,089 \cdot (D_e)^{-1,318}$	$PVS = 225,424 \cdot (D_e)^{-1,282}$
EBM_05	R ²	70,2%	72,8%	69,1%	73,7%
	Modelo	$PPV_T = 397,192 \cdot (D_e)^{-1,551}$	$PPV_V = 266,073 \cdot (D_e)^{-1,509}$	$PPV_L = 256,448 \cdot (D_e)^{-1,373}$	$PVS = 449,780 \cdot (D_e)^{-1,488}$
EBM_06	R ²	70,7%	68,9%	71,9%	74,7%
	Modelo	$PPV_T = 1671,091 \cdot (D_e)^{-2,102}$	$PPV_V = 651,628 \cdot (D_e)^{-1,819}$	$PPV_L = 774,462 \cdot (D_e)^{-1,855}$	$PVS = 1778,279 \cdot (D_e)^{-2,012}$

5.3. Herramientas de análisis multivariante para la predicción de vibraciones

En esta sección se detalla el uso de herramientas de análisis multivariante, con un enfoque en la implementación de redes neuronales para la predicción de vibraciones producto de tronaduras en la minería a cielo abierto. Primero que todo, se exploran métodos para buscar la mejor configuración de los inputs que maximizan la precisión de la predicción, seguido de la configuración final de la red neuronal y la posterior validación del modelo con un porcentaje de datos reservados para este propósito.

5.3.1. Selección y optimización de inputs

Gran parte del éxito de todo modelo es la selección de los inputs correctos para ingresar al modelo, que primero debe ser entrenado. Para tener éxito en este proyecto, se realiza una selección de inputs y posterior optimización de estos.

5.3.1.1. Preparación de los datos

Se comienza con la carga de los siguientes inputs disponibles, que van desde coordenadas geográficas, nombres de estaciones, horas y días de detonación, hasta las mediciones específicas de cada tronadura. A continuación, se observa una lista de los inputs.

- **EBM_name:** Nombre de la estación de monitoreo.
- **Fecha:** Fecha de la tronadura.
- **Hora:** Hora de la tronadura.
- **EBM_Este:** Coordenada Este de la ubicación de la estación de monitoreo.
- **EBM_Norte:** Coordenada Norte de la ubicación de la estación de monitoreo.
- **EBM_Cota:** Coordenada Cota de la ubicación de la estación de monitoreo.
- **Tron_Este:** Coordenada Este de la ubicación del centro geométrico de la malla de perforación del polígono tronado.
- **Tron_Norte:** Coordenada Norte de la ubicación del centro geométrico de la malla de perforación del polígono tronado.
- **Tron_Cota:** Coordenada Cota de la ubicación del centro geométrico de la malla de perforación del polígono tronado.
- **kg_ret:** Máximos kilogramos por retardo de la tronadura.
- **Fase:** Nombre de la fase donde se realiza la tronadura.
- **Banco:** Generalmente es un número asociado a la elevación geográfica³.
- **Horizontal [m]:** Distancia horizontal de la tronadura con la estación de monitoreo (no incluye coordenada “z”)

³ Aunque pueda ser redundante se decide considerar la variable igualmente para los inputs.

- **Total [m]:** Distancia total de la tronadura con la estación de monitoreo.
- **Escalar:** Distancia escalar que corresponde a la distancia total dividida por la raíz cuadrada del máximo kilogramos por retardo de la tronadura.

Como se observa en la lista anterior, existen variables que son categóricas, es decir, que no son número como los datos de cotas y distancias, sino que son nombres, como los nombres de estaciones y fases. Por ello se realiza una codificación de estas variables para transformarlas en variables que puedan ser utilizadas por la red neuronal.

Otra observación importante es el escalado de valores, para evitar ponderar de manera diferente las variables solo por ser un valor mayor o menor. Por ejemplo, las coordenadas suelen ser valores de miles de metros como 99.100 [m] (en otros casos puede ser incluso valores que superan el millón). Este valor no debería ponderar más solo por ser mayor que la distancia escalar que rara vez es mayor que 100 [m kg^{1/2}]. Cada valor debe demostrar la mayor o menor ponderación en el modelo; por esto, se realiza un escalado de variables para solucionar este problema.

5.3.1.2. Evaluación y configuración de entradas

Utilizando las bibliotecas de Python Keras⁴ y Keras Tuner⁵, específicamente para la búsqueda de la mejor configuración de hiperparámetros para modelos de TensorFlow⁶ y Keras, la librería Keras Tuner permite una búsqueda optimizada y con importante reducción de costos computacionales de la mejor arquitectura de la red.

Primero que todo, se realiza una función para hacer todas las posibles combinaciones con los parámetros de entrada; esto quiere decir que se evaluará 32.767 combinaciones ($2^n - 1$ donde $n = 15$).

Luego, por cada combinación, se evaluarán distintas redes neuronales buscando la mejor arquitectura para la combinación de inputs inicial, las ventanas de libertad de la arquitectura son las siguientes:

- Cantidad de funciones de activación probadas: 3
- Número de capas internas, desde 1 capa hasta 3 capas
- Número de neuronas por cada capa interna, desde 1 hasta 100 neuronas
- Cantidad de épocas que se evaluará cada arquitectura: 50 épocas

Las combinaciones totales calculadas se pueden observar en la Tabla 8. Es importante mencionar que se enfocan los esfuerzos en la obtención de redes neuronales para determinar datos

⁴ (Chollet & Others, n.d.)

⁵ (Chollet & Others, Hyperparameter Tuning, n.d)

⁶ (TensorFlow, n.d.)

de todas las componentes del pico de la velocidad de partícula (PPV), pero la evaluación del coeficiente de determinación se realiza solo con la del vector suma.

Tabla 8. Cálculo de combinaciones realizadas, (no se considera la ejecución de las 50 épocas por cada combinación).

Combinaciones totales de inputs	$2^n - 1 = 2^{15} - 1 = 32.767$
Combinaciones para la primera capa	$100 \times 3 = 300$
Combinaciones para la segunda capa	$(100 \times 3)^2 = 300^2 = 90.000$
Combinaciones para la tercera capa	$(100 \times 3)^3 = 300^3 = 27.000.000$
Total de combinaciones	$(2^{15} - 1)(300 + 90.000 + 27.000.000) =$ $32.767 \times 27.090.300 =$ $887.667.860.100$

Se implementan funciones de evaluación que analiza todas las combinaciones para determinar cuál genera el mejor resultado de predicción, medido mediante el coeficiente de determinación R^2 . Cabe destacar que se realiza una división de datos para el cálculo de este coeficiente, que divide los datos en un conjunto de entrenamiento y otro conjunto de validación.

Es importante destacar que, en este caso, se contaba con buenos recursos computacionales; por esto se realiza la evaluación de todas las combinaciones posibles. En situaciones de contar con recursos más limitados se debe hacer una preparación más extensa de los datos, lo que es básicamente determinar o seleccionar los inputs que, debido a la bibliografía o experiencia tendrán mayores efectos en la estimación.

Los resultados se pueden visualizar en el Figura 16 donde se muestra que cada punto corresponde a una combinación evaluada obteniendo el mejor R^2 que arroja la mejor configuración encontrada para la combinación.




Figura 16. Serie de R^2 para cada combinación evaluada en las redes neuronales.

Con la inspección de todas las combinaciones posibles se puede determinar que la mejor diez selecciones de los inputs son las siguientes:

Tabla 9. Mejores diez combinaciones de inputs encontradas.

ID	Combinación de inputs	R ²
1	EBM, Fecha, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Total [m], Escalar	0,926
2	EBM, Fecha1, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Banco, Total [m], Escalar	0,919
3	EBM, Fecha1, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,917
4	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,916
5	EBM, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,915
6	Fecha1, EBM_Norte, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m]	0,914
7	EBM, Fecha, Tron_Este, Tron_Norte, Fase, Escalar	0,914
8	EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Total [m], Escalar	0,912
9	Fecha1, EBM_Este, EBM_Norte, Tron_Norte, Tron_Cota, kg_ret, Banco, Escalar	0,912
10	EBM, Fecha, EBM_Este, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,912

5.3.1.3. Implementación y evaluación de modelos con configuración óptima

Analizando exhaustivamente sobre las diez combinaciones se obtiene que las mejores infraestructuras de las redes con cada combinación, se realiza una búsqueda saltando de 25 neuronas a la vez son las siguientes:

Tabla 10. Resultados con parámetro $step=25$ en búsqueda de las mejores combinaciones.

ID	Combinación de inputs	R ²	Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
1	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,928	25	ReLU	75	ReLU	75	ReLU
2	EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Total [m], Escalar	0,923	25	ReLU	25	ReLU	75	ReLU
3	EBM, Fecha1, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,923	25	ReLU	75	ReLU	75	ReLU
4	EBM, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,92	75	tanh	75	ReLU	75	ReLU
5	EBM, Fecha1, Tron_Este, Tron_Norte, Fase, Escalar	0,919	75	ReLU	25	ReLU	75	ReLU
6	EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Total [m], Escalar	0,919	75	ReLU	25	ReLU	75	ReLU

Tabla 11. Resultados con parámetro *step=25* en búsqueda de las mejores combinaciones.

ID	Combinación de inputs	R ²	Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
7	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,919	75	ReLU	75	tanh	75	ReLU
8	EBM, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Banco, Total [m], Escalar	0,919	75	ReLU	75	ReLU	75	tanh
9	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,917	75	ReLU	25	ReLU	75	ReLU
10	EBM, Fecha1, EBM_Este, EBM_Norte, EBM_Cota, Tron_Este, Tron_Norte, Tron_Cota, kg_ret, Fase, Total [m], Escalar	0,917	75	ReLU	75	tanh	25	ReLU

En función de hacer una búsqueda más rápida, se desarrollan tres iteraciones buscando la infraestructura que maximiza cada coeficiente de determinación, aumentando el detalle de inspección (disminuyendo el parámetro “step”) y fijando la combinación que maximiza el coeficiente de determinación (EBM, Tron_Este, Tron_Norte, Banco, Escalar).

En la primera iteración, se realiza una búsqueda en la que se desarrollan infraestructuras de entre una a tres capas internas y de entre una a cien neuronas por capa, variando las funciones de activación entre ReLU, Tanh y Sigmoid. En esta iteración, se realiza una búsqueda saltando de diez en diez la ejecución.

Tabla 12. Resultados con parámetro $step=10$ en búsqueda de las mejores combinaciones.

ID	R ²	Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
1	0,935	51	ReLU	101	ReLU	41	ReLU
2	0,932	91	ReLU	91	ReLU	61	ReLU
3	0,932	61	ReLU	61	ReLU	101	ReLU
4	0,931	51	ReLU	101	ReLU	61	ReLU
5	0,93	91	ReLU	71	ReLU	41	ReLU
6	0,929	51	ReLU	61	ReLU	91	ReLU
7	0,929	101	ReLU	81	ReLU	71	ReLU
8	0,929	71	ReLU	91	ReLU	21	ReLU
9	0,929	71	ReLU	91	ReLU	101	ReLU
10	0,929	91	ReLU	81	ReLU	61	ReLU

En la segunda iteración, se realiza una búsqueda en la que se desarrollan infraestructuras en una ventana más reducida. Esta vez, se desarrolla fijando las funciones de activación a la función “ReLU”. En esta iteración, se realiza una búsqueda saltando de cuatro neuronas en cuatro durante la ejecución.

Tabla 13. Resultados con parámetro $step=4$ en búsqueda de las mejores combinaciones.

ID	R ²	Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
1	0,936	63	ReLU	81	ReLU	67	ReLU
2	0,936	79	ReLU	89	ReLU	63	ReLU
3	0,934	79	ReLU	85	ReLU	67	ReLU
4	0,932	79	ReLU	81	ReLU	71	ReLU
5	0,93	71	ReLU	77	ReLU	63	ReLU
6	0,929	67	ReLU	73	ReLU	71	ReLU
7	0,927	79	ReLU	77	ReLU	67	ReLU
8	0,927	71	ReLU	81	ReLU	63	ReLU
9	0,927	71	ReLU	89	ReLU	59	ReLU
10	0,927	75	ReLU	85	ReLU	59	ReLU

En la tercera iteración, se realiza una búsqueda, reduciendo aún más la ventana y convirtiendo la búsqueda en saltos unitarios.

Tabla 14. Resultados con parámetro $step=1$ en búsqueda de las mejores combinaciones.

ID	R ²	Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
1	0,938	73	ReLU	77	ReLU	66	ReLU
2	0,938	72	ReLU	79	ReLU	71	ReLU
3	0,937	76	ReLU	80	ReLU	60	ReLU
4	0,937	71	ReLU	83	ReLU	60	ReLU
5	0,936	71	ReLU	84	ReLU	71	ReLU
6	0,935	76	ReLU	81	ReLU	72	ReLU
7	0,935	71	ReLU	85	ReLU	67	ReLU
8	0,934	76	ReLU	84	ReLU	73	ReLU
9	0,934	76	ReLU	77	ReLU	71	ReLU
10	0,934	71	ReLU	86	ReLU	65	ReLU

Finalizando la búsqueda, se obtiene que la mejor combinación de parámetros de entrada es la que utiliza lo siguiente:

- EBM
- Tron_Este
- Tron_Norte
- Banco
- Escalar

También, la mejor estructura encontrada es la que se muestra a continuación:

- Función de activación de la primera capa: ReLU
- Cantidad de neuronas de la primera capa: 73 neuronas
- Función de activación de la segunda capa: ReLU
- Cantidad de neuronas de la segunda capa: 77 neuronas
- Función de activación de la tercera capa: ReLU
- Cantidad de neuronas de la tercera capa: 66 neuronas

De manera gráfica se puede ver la infraestructura de la red encontrada en la Figura 17.

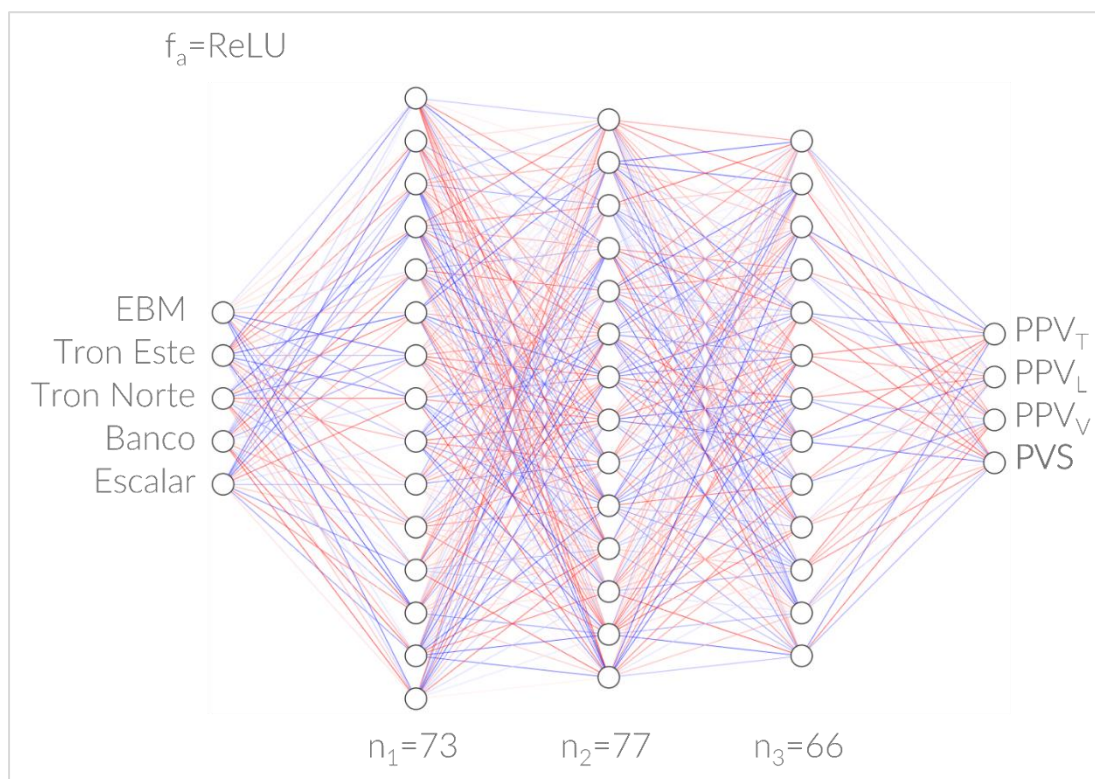


Figura 17. Representación gráfica de la infraestructura de la red neuronal que maximiza el coeficiente de determinación.

Además, el coeficiente de determinación para la mejor combinación e infraestructura encontrada es de 0,938.

Ecuación 9. Coeficiente de determinación encontrado para la mejor combinación.

$$R^2 = 0,938$$

De manera gráfica se puede ver la comparación de la predicción obtenida por la red neuronal con los datos observados⁷. Cabe destacar que estos datos no intervienen en la búsqueda y construcción de la red neuronal; están solamente destinados para la evaluación, por lo tanto, pertenecen al set de testeo.

⁷ Datos observados en este caso son los datos capturados por las estaciones, pero pertenecen al set de datos destinados al testeo (no al entrenamiento)




Figura 18. Gráfica de dispersión comparando valores observados (eje x) y los valores predichos por la red neuronal (eje y).

También, en la Figura 19 se puede ver la evolución del entrenamiento de la red neuronal en la que se observa la clara reducción de las pérdidas y por ende el aprendizaje efectivo de la red.




Figura 19. Evolución del entrenamiento de la red neuronal seleccionada.

5.4. Selección de estimador

Para seleccionar el mejor estimado, se debe comparar los coeficientes de determinación de los modelos conseguidos entre los modelos tradicionales y los encontrados buscando la mejor infraestructura posible de las redes neuronales.

5.4.1. Modelo conseguido de manera tradicional

En la Tabla 15 se observa, a modo de resumen los coeficientes de determinación encontrados al realizar los modelos tradicionales. Como se observa, se puede ver que el mejor coeficiente de determinación es de 85,4%, correspondiente a la componente Longitudinal de los datos captados por la estación de monitoreo EBM_2 (destacada en gris). Es importante mencionar que el mejor coeficiente de determinación del vector suma corresponde a la estación EBM_1 con un valor de 82,5%.

Tabla 15. Resumen de los coeficientes de determinación encontrados con los modelos tradicionales.

Datos	Comp.	R ²	Datos	Comp.	R ²	Datos	Comp.	R ²
Todos	PPV_T	62,0	EBM_3	PPV_T	77,2	EBM_5	PPV_T	70,2
Todos	PPV_V	72,3	EBM_3	PPV_V	69,5	EBM_5	PPV_V	72,8
Todos	PPV_L	69,7	EBM_3	PPV_L	72,1	EBM_5	PPV_L	69,1
Todos	PVS	70,0	EBM_3	PVS	74,7	EBM_5	PVS	73,7
EBM_1	PPV_T	79,1	EBM_4	PPV_T	63,9	EBM_6	PPV_T	70,7
EBM_1	PPV_V	83,2	EBM_4	PPV_V	71,2	EBM_6	PPV_V	68,9
EBM_1	PPV_L	79,5	EBM_4	PPV_L	68,1	EBM_6	PPV_L	71,9
EBM_1	PVS	82,5	EBM_4	PVS	68,1	EBM_6	PVS	74,7
EBM_2	PPV_T	67,2						
EBM_2	PPV_V	82,5						
EBM_2	PPV_L	85,4						
EBM_2	PVS	82,2						

5.4.2. Modelo conseguido con redes neuronales

En el caso de los resultados obtenidos con las redes neuronales, se puede resumir con lo mostrado en la Tabla 16, donde se muestra que la mejor combinación de inputs que maximizó el valor del coeficiente de corrección fue al utilizar los datos de EBM, Tron_Este, Tron_Norte, Banco y Escalar, obteniendo un 93,8%. En la Tabla 17 se muestra la infraestructura de la red que se selecciona.

Tabla 16. Mejor resultado con la red neuronal encontrada para los datos utilizados.

ID	Inputs ingresados	R ²
1	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,938

Tabla 17. Infraestructura de la red neuronal que maximiza el valor de coeficiente de determinación.

Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
73	ReLU	77	ReLU	66	ReLU

5.4.3. Modelo seleccionado con mejores resultados

Observando los resultados tanto del modelo tradicional obtenido con desarrollando el modelo de Devine, que se resume en la Tabla 15, y los resultados obtenidos con las redes neuronales, resumidos en la Tabla 16, se puede determinar que el mejor modelo encontrado para los datos utilizados es el determinado con las redes neuronales y la infraestructura mostrada en la Tabla 17.

Tabla 18. Mejor resultado con la red neuronal encontrada para los datos utilizados.

ID	Inputs ingresados	R ²
1	EBM, Tron_Este, Tron_Norte, Banco, Escalar	0,938

Tabla 19. Infraestructura de la red neuronal que maximiza el valor de coeficiente de determinación.

Units Layer 1	Activ. Funct 1	Units Layer 2	Activ. Funct 2	Units Layer 3	Activ. Funct 3
73	ReLU	77	ReLU	66	ReLU

5.5. Metodología operativa

Con los resultados obtenidos, se puede definir la metodología operativa para el uso y predicción de vibraciones, que en este caso se realiza mediante el uso de redes neuronales con la infraestructura anteriormente mencionada.

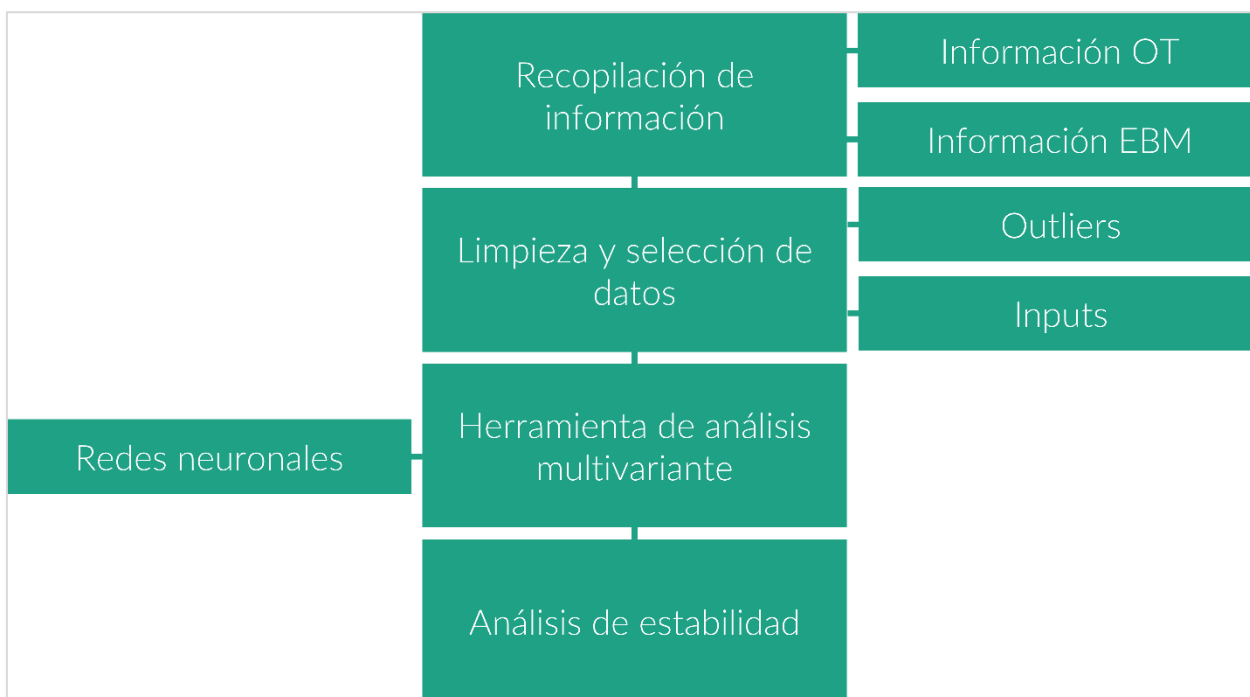


Figura 20. Metodología operativa con la inclusión del modelado mediante redes neuronales.

La metodología inicia con la recopilación de información, dividida en dos fuentes: la primera es la proveniente de las órdenes de trabajo (OT), que contiene información como ubicaciones de los pozos, kilogramos de explosivo por retardo, entre otros parámetros del trabajo propiamente tal. La segunda fuente es la captura de información mediante las estaciones de monitoreo, las cuales, como se ha mencionado, registran las vibraciones sísmicas producto de las tronaduras (velocidad de propagación y frecuencia).

Posterior a la obtención de la información, se realiza un preprocesamiento de estos, en el cual se lleva a cabo una fase de detección de valores atípicos (outliers) que podrían distorsionar los resultados obtenidos. Pasando a la selección de los inputs que se utilizarán en el trabajo de la red neuronal, en este caso, una 5-tupla compuesta por el nombre de la estación que registra el dato, la coordenada Este y Norte del centro de la tronadura, el banco en el cual se ejecuta la tronadura y, por último, la distancia escalar que, recordemos, es la distancia desde el punto de medición al centro de la tronadura dividida por la raíz cuadrada de la carga máxima por intervalo de retardo (EBM, Tron_Este, Tron_Norte, Banco y Escalar).

Siguiendo el flujo de la metodología propuesta, ya se cuenta con los inputs definidos y representativos; con esto, se ejecuta el aprendizaje de la red neuronal con la configuración mencionada, con cinco neuronas de entrada, tres capas internas (con 73 neuronas en la primera capa, 77 en la segunda y 66 en la tercera, todas con función de activación ReLU), generando cuatro neuronas de salida (PPV_T, PPV_L, PPV_V y PVS).

Ahora, con el entrenamiento ya realizado, se deben ingresar los parámetros deseados o planificados para la siguiente tronadura, y la red neuronal generará su predicción en base a los

pesos y configuraciones internas que generó el entrenamiento. Es importante mencionar que se recomienda, siempre posterior a la ejecución de la tronadura, realizar la inclusión de esta al entrenamiento para que el aprendizaje de la red sea recurrente y no quede obsoleto.

Con esta estimación se puede hacer la evaluación de las estructuras identificadas que puedan verse influenciadas con el movimiento sísmico de tronadura. No se desarrolla en profundidad este tema por escaparse de los alcances del presente trabajo.

6. ANÁLISIS DE RESULTADOS

En esta sección se realizará el análisis de los resultados obtenidos para completar la metodología operativa para una predicción de vibraciones producidas por tronaduras, específicamente en la minería de cielo abierto, destacando las principales características y tendencias encontradas que sirven como guía para el desarrollo de los modelos predictivos.

6.1. Análisis de resultados del estudio exploratorio

Como en la mayoría de los proyectos, el análisis exploratorio es importante para ver la naturaleza de los datos y las posibles tendencias que se tienen con cada dato, especialmente los datos que iban a ser utilizados para hacer las distintas combinaciones de los inputs para la búsqueda de la mejor red neuronal.

6.1.1. Descripción general de los datos

Se analizan 1.302 datos correspondientes a la recolección de datos entre 2018 y 2020 de tronaduras, las cuales son cuidadosamente seleccionadas, cumpliendo con que sean solo datos de producción para homogenizar el set de datos y el origen de estos. Además, se realiza un tratamiento de outliers para eliminar datos atípicos que se producen en cualquier captura de datos como es este caso.

Revisando la descripción general de todos los datos, se observa una gran distribución, pero siguiendo un comportamiento log-normal, como es común en las mediciones sísmicas y en la teoría de propagación de las ondas.

6.1.2. Análisis estadísticos de los datos

Claramente, los máximos valores están sujetos a la cercanía de las estaciones de monitoreo y el origen de la tronadura; por esto, es de suma importancia una buena selección de la ubicación de las estaciones de monitoreo, las cuales deben contemplar las futuras expansiones de las fases aledañas a la ubicación.

Mientras que los valores mínimos son los datos más alejados que las estaciones registran y han superado el umbral mínimo establecido en la estación. Estos pueden ser truncados tanto aumentando el umbral mínimo en el equipo como en el análisis de datos outliers.

De los valores promedios, se puede decir que la componente vertical tiende a ser ligeramente menor a las otras componentes; a menudo, esta componente se considera la más influyente en los daños estructurales.

Las medidas del Vector Suma (VS), que recordemos combina las tres componentes de las mediciones, es una suma vectorial entre las componentes longitudinal, transversal y vertical,

presenta una medición promedio de 5,839 mm/s, medición mayor a cada componente, por lo que sustenta el uso de esta estimación como principal variable para evaluar mediante el coeficiente de determinación y también sustenta el uso de esta variable por parte del área geotécnica y de tronadura de distintas mineras.

6.1.3. Análisis estadísticos de los datos por estaciones

Primero que todo, he de mencionar que la diferencia en la cantidad de eventos recibidos por cada estación se debe a posibles instalaciones posteriores de alguna estación de monitoreo o a la mayor actividad propia de alguna fase con mayor interés para la operación y producción de la mina. Esto se puede ver de manera gráfica en la Figura 13 y la Tabla 3.

Analizando las medias de las mediciones de velocidad, se puede notar que las estaciones EBM_3 y EBM_4 presentan en general medias mayores, por lo que las tronaduras están más cerca de estas ubicaciones. Por otro lado, en general, la componente vertical analizada por estación, en algunos casos, es menor que las otras componentes.

Los valores medios del Vector Suma (VS) varían significativamente entre todas las estaciones. En la estación EBM_3 se pueden ver los valores más altos (9.870 mm/s), seguido luego por la estación EBM_4 (8,102 mm/s), lo que se condice con el párrafo anterior, y esta zona es la que se ve más afectada por las vibraciones sísmicas.

Por otro lado, las estaciones EBM_1 y EBM_6 son las estaciones que tienen los valores más bajos en términos de vibración, debido a que ese sector está más resguardado por estar cerca de infraestructura industrial y oficinas.

El análisis de los datos máximos se obvia debido a que esto está fuertemente influenciado por la distancia del punto de origen de la vibración (polígono tronado) al punto de medición (posición de la estación).

Analizando la otra medición importante que realizan las estaciones de monitoreo, la frecuencia, se puede apreciar que las frecuencias se mantienen en los rangos comunes de las frecuencias para tronaduras de cielo abierto, que varían entre 4 Hz y 12 Hz, siendo común una media de 7 u 8 Hz.

6.2. Análisis de resultados de la creación de modelos de vibración (Devine)

Se ha realizado el modelamiento basado en la Ley Escalar de Devine para el conjunto completo de los datos; también se realizan modelos individuales para cada estación con los datos que recibe cada estación.

Los modelos de vibraciones de campo lejano de Devine se realizan para todas las direcciones ortogonales (Transversal, Vertical y Longitudinal) y también para el vector suma.

6.2.1. Análisis de resultados de la creación de modelos de vibración (Devine) para el set completo de datos

Los modelos de vibraciones de campo lejano, basado en la Ley Escalar de Devine, se puede ver de manera gráfica en la Figura 15 y en la Tabla 6 se observa los modelos específicos encontrados en las distintas direcciones y el vector suma.

Modelos que, para este set de datos, se obtienen R^2 que van desde 62% a 72,3%, lo que indica un ajuste moderado con buena capacidad de predecir el comportamiento de las vibraciones.

6.2.2. Análisis de resultados de la creación de modelos de vibración (Devine) para los sets de datos de cada estación

La creación de los modelos de predicción de velocidad de vibraciones para cada estación presenta algunas mejoras en sus resultados.

El modelo de vibración para la estación EBM_1 muestra un ajuste entre 79,1% y 83,2%, indicando una buena precisión de los modelos y señalando correctamente la variabilidad del fenómeno. Cabe señalar que esta estación es la que tiene mejores resultados debido a la poca diferencia de coeficientes de determinación.

El modelo de vibración para la estación EBM_2 muestra un ajuste entre 67,2% y 85,4%, indicando ajustes entre moderado y bueno, y señalando que en algunas direcciones se ve muy explicadas con el modelo, mientras que en otras direcciones aún hay oportunidades de mejora.

El modelo de vibración para la estación EBM_3 muestra un ajuste entre 69,5% y 77,2%, indicando un ajuste moderado a bueno, aunque ligeramente menor que los modelos obtenidos anteriormente.

El modelo de vibración para la estación EBM_4 muestra un ajuste entre 63,9% y 71,2%, indicando un ajuste moderado que mayoritariamente puede representar o predecir de buena manera, pero con alta variabilidad; los resultados para esta estación son similares al modelo global.

El modelo de vibración para la estación EBM_5 muestra un ajuste entre 69,1% y 73,7%, indicando un buen ajuste y bastante equilibrado para todas las componentes y el vector suma, aunque con un gran porcentaje de mejora.

El modelo de vibración para la estación EBM_6 muestra un ajuste entre 68,9% y 74,7%, indicando un ajuste similar al de la estación anterior.

6.3. Análisis de resultados del análisis multivariante para la predicción de vibraciones

En la búsqueda del mejor modelo predictivo utilizando redes neuronales, en esta oportunidad se ha examinado un gran número de variables, incluyendo variables categóricas y numéricas, las cuales fueron cuidadosamente tratadas, codificadas y escaladas para la correcta inclusión en los inputs disponibles para su uso.

De las quince variables que pueden ser consideradas en los inputs, se examinan inicialmente todas las combinaciones posibles: 32.767 combinaciones, las cuales mostraban notables mejoras a medida que se iban incluyendo más variables. En la Figura 16 se observa principalmente que las variaciones de la tendencia superior y la tendencia inferior se van reduciendo. De esta inspección se determina que las mejores combinaciones se analizan más exhaustivamente para encontrar la configuración exacta de la estructura de la red neuronal y los inputs que maximizan el coeficiente de determinación.

La configuración final encontrada que maximiza el coeficiente de determinación (R^2) considera EBM, Tron_Este, Tron_Norte, Banco y Escalar como combinación de inputs y la configuración con tres capas internas de 73, 77 y 66 neuronas cada una, todas con la función de activación ReLU. Esta configuración logra un coeficiente de determinación de 93,8%, lo que significa que el modelo logra una excelente capacidad predictiva.

La Figura 18 muestra un gráfico de dispersión que presenta la comparación de los datos destinados para la validación de la red neuronal; se puede apreciar que los datos observados y predichos se agrupan cercanos a la línea diagonal, indicando la buena predicción conseguida por la red neuronal.

6.4. Análisis de resultados de la selección del estimador

Tal y como se puede ver en la Tabla 15, los modelos tradicionales muestran una alta variabilidad del coeficiente de determinación en distintas componentes y distintas estaciones. El mejor resultado obtenido en los modelos fue el de la componente Longitudinal de la estación EBM_2, con un R^2 de 85,4%; no obstante, otras componentes, como por ejemplo las de la estación EBM_4, tienen una correlación baja (63,9%), indicando una predicción variable e inconsistente.

Por otro lado, en la Tabla 16 se puede ver la capacidad de predicción que obtuvo la red neuronal, con un 93,8% de predicción y la ventaja de no necesitar hacer una separación de datos o modelar por separado cada posición.

Comparando los resultados de ambos modelos, queda claro que la configuración compleja de la red neuronal genera una mayor precisión en la predicción, además de buena robustez y exactitud, mientras que el modelado tradicional se ve limitado para algunas ubicaciones y componentes.

Por lo tanto, el modelo basado en redes neuronales con la configuración mostrada en la Tabla 17 es el seleccionado como el modelo que maximiza el coeficiente de determinación para este proyecto.

Es importante analizar la Tabla 17, donde EBM, Tron_Este, Tron_Norte, Banco y Escalar son los inputs que maximizan el coeficiente de determinación. Se puede pensar que el input EBM puede generar alguna información sobre la posición de la ubicación de la estación y, por ende, la influencia de la litología circundante al sensor, mientras que Tron_Este, Tron_Norte y Banco proporcionan información sobre la ubicación de la tronadura y también recopilan información intrínsecamente de la litología o el comportamiento de las vibraciones en ese sector. Por último, Escalar proporciona información sobre los kilogramos por retardo de la tronadura y la distancia entre la estación de monitoreo y el centroide de la tronadura.

6.5. Metodología operativa

Con los resultados obtenidos, se puede determinar que la metodología de trabajo se puede realizar con el modelado de redes neuronales y la infraestructura obtenida. Por esto, se debe considerar comenzar con una colección de datos tanto de las órdenes de trabajo provenientes de la empresa minera como de los registros obtenidos por las estaciones de monitoreo. Posteriormente, se debe comenzar con la limpieza de datos atípicos bajo metodologías tradicionales y la selección de los inputs necesarios para el modelado mediante redes neuronales.

En el modelado mediante redes neuronales, se debe utilizar la siguiente configuración: una red neuronal con cinco neuronas de entrada (EBM, Tron_Este, Tron_Norte, Banco y Escalar), tres capas internas (con 73 neuronas en la primera capa, 77 en la segunda y 66 en la tercera capa, todas con función de activación ReLU) y generando cuatro neuronas de salida (PPV_T, PPV_L, PPV_V y PVS).

7. CONCLUSIONES

El desarrollo del trabajo presentado muestra la viabilidad del uso de redes neuronales en la predicción de vibraciones producidas por tronaduras en la minería de cielo abierto, cumpliendo con el objetivo principal de la obtención de una metodología operativa para un trabajo rutinario y preciso.

- *Desarrollo de estimadores multivariantes:* en el presente trabajo se realiza la elaboración y optimización de dos técnicas de estimadores multivariantes, utilizando el método tradicional, que es la Ley Escalar de Devine, y el uso de redes neuronales para la estimación. Se logra determinar la capacidad y potencial de las redes neuronales para procesar los datos de entrada e interpretar de mejor manera que los métodos tradicionales.
- *Selección del mejor estimados:* tras una exhaustiva búsqueda y evaluación, se determinó que el mejor estimador, dentro de los evaluados, es el desarrollado con redes neuronales, el cual no solo proporciona los mejores resultados en términos del coeficiente de determinación (R^2), sino que también reduce significativamente el error cuadrático medio.
- *Metodología operativa:* se estableció una metodología operativa en la cual se integra el uso de redes neuronales en la predicción de vibraciones producidas por tronaduras en minería de cielo abierto, la cual genera un resultado apto para el análisis de estabilidad de taludes. La inclusión y uso de redes neuronales permite un avance en la precisión de la predicción en las operaciones mineras.
- *Aplicación en la industria minera:* la metodología con la inclusión de redes neuronales tiene un gran potencial por la facilidad y mayor precisión que presenta, especialmente en términos de seguridad y eficiencia necesarias para las operaciones mineras. Sin embargo, es importante mencionar que romper barreras en la industria minera es siempre un desafío, debido a su naturaleza cautelosa y a la rapidez de la operación.
- *Limitaciones:* aunque los resultados obtenidos son muy buenos y prometedores, la principal limitación para una expansión general de esta metodología a la industria minera es la gran cantidad de datos que se debe contar, situación que, en este caso, no genera limitaciones por contar con estaciones de monitoreo que registran todas las tronaduras de la mina de manera diaria.
- *Recomendaciones:*
 1. La primera recomendación va por el lado de hacer más robusto el uso de redes neuronales para la inclusión de datos no preprocesados, que no requiera el análisis y búsqueda de datos atípicos o selección de solo un tipo de datos, como las tronaduras de borde/contorno, precorte, entre otros; que la red neuronal pueda hacer predicciones al nivel de las encontradas en este proyecto con toda la data disponible.
 2. Se recomienda la inclusión o expansión del uso de redes neuronales para el análisis de estabilidad de taludes, lo cual puede ser la siguiente etapa de este proyecto, realizando la expansión de la metodología.

8. SIGUIENTES PASOS

Completando el objetivo principal de este trabajo, se pueden mencionar las siguientes etapas posibles para una ejecución, inclusión o expansión del actual proyecto a la industria minera.

- Realizar una evaluación similar a la realizada con el VS para los demás componentes de PPV (Longitudinal, Transversal y Vertical).
- Es fundamental continuar con la inclusión de datos para tener un continuo aprendizaje y una actualización de los parámetros internos de la red neuronal utilizada.
- Evaluar la inclusión de información litológica o condiciones geológicas, principalmente realizar la evaluación de mantener un constante flujo de información actualizada proveniente de la mina, lo cual siempre es dificultoso debido a la poca interacción entre áreas dentro de la mina.
- Realizar una implementación piloto en paralelo con los métodos tradicionales que aún se consideran en la industria para mostrar las mejoras y el potencial de la herramienta.
- Realizar difusiones y capacitaciones en la mina para combatir la resistencia al cambio y facilitar la integración de esta nueva metodología.
- Explorar técnicas más avanzadas para la predicción de vibraciones, evaluando los costos y mejoras posibles, como la inclusión de nuevos y actualizados métodos y herramientas de aprendizaje.

BIBLIOGRAFÍA

- [1] Ambraseys, N. R., & Hendron, A. J. (1968). Dynamic behavior of rock masses. In K. Stagg, & J. Wiley, *Rock Mechanics in Engineering Practices* (pp. 203-207). London, UK.
- [2] Bureau of Indian Standards. (1973). IS 6922 Criteria for Safety and Design of Structures Subjected to Underground Blast.
- [3] Chollet, F., & Others. (n.d). *Hyperparameter Tuning*. Retrieved from Keras Tuner Guide: https://keras.io/guides/keras_tuner/
- [4] Chollet, F., & Others. (n.d.). *Keras Guides*. Retrieved from Keras: <https://keras.io/guides/>
- [5] Dehghani, H., & Ataee-pour, M. (2011). Development of a model to predict peak particle velocity in a blasting operation. *International Journal of Rock Mechanics and Mining Sciences*, 51-58.
- [6] Devine, J. F., Beck, R. H., Meyer, A. V., & Duvall, W. I. (1966). Effect of charge weight on vibration levels from quarry blasting. *Report of investigations 6774*, 42.
- [7] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Cambridge, Massachusetts: MIT Press.
- [8] International Society of Explosives Engineers. (2020). ISEE Field Practice Guidelines for Blasting Seismographs. 11. Retrieved from <https://www.isee.org>
- [9] Kesimal, A., Ercikdi, B., & Cihangir, F. (2008). Environmental impacts of blast-induced acceleration on slope instability at a limestone quarry. *Environmental Geology*, 381-389.
- [10] Langefor, U., & Kihlström, B. (1963). *The modern technique of rock blasting*. New York.
- [11] Ling, H. I., & Cheng, A. H.-D. (1997). Rock sliding induced by seismic force. *International Journal of Rock Mechanics and Mining Sciences*, 1021-1029.
- [12] Minsky, M. L., & Papert, S. A. (1988 (Expanded Edition)). *Perceptrons: An Introduction to Computational Geometry*. Cambridge, Massachusetts: The MIT Press.
- [13] Singh, T. N., & Singh, V. (2005). An intelligent approach to prediction and control ground vibration in mines. *Geotechnical & Geological Engineering*, 249-262.
- [14] TensorFlow. (n.d.). *Learn TensorFlow*. Retrieved from TensorFlow: <https://www.tensorflow.org/learn>

ANEXOS

Anexo A. Análisis estadístico básico de datos por estaciones

A.1. Estación de monitoreo EBM_01

En la estación EBM_01 se tiene la Tabla 20 con sus estadísticas básicas compuestas por el promedio, la desviación estándar y los máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 20. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_01**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	2,549	2,806	18,680
Nivel de vibración Vertical (mm/s)	2,062	2,613	17,320
Nivel de vibración Longitudinal (mm/s)	2,210	2,434	15,530
Nivel de vibración VS (mm/s)	3,103	3,485	22,920
Niveles de Frecuencias FFT Transversal (Hz)	4,945	1,620	11,750
Niveles de Frecuencias FFT Vertical (Hz)	5,806	2,652	30,120
Niveles de Frecuencias FFT Longitudinal (Hz)	5,007	1,909	11,500

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_01 se puede observar la Figura 21, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

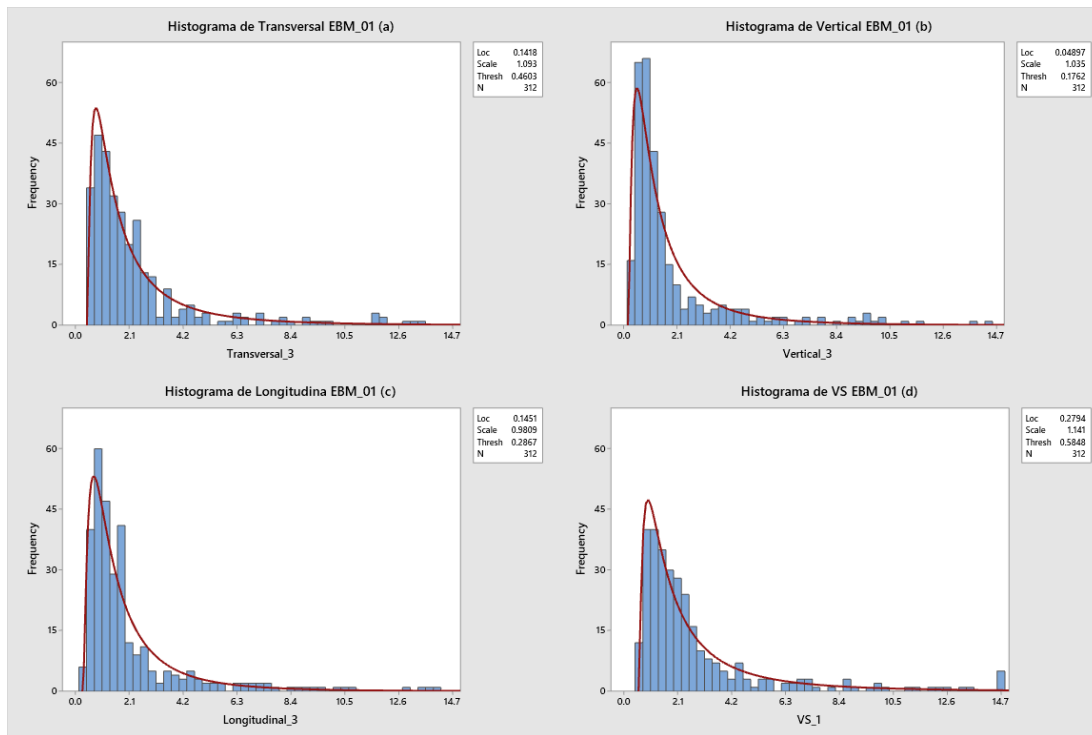


Figura 21. Histogramas de los datos para **EBM_01**, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

A.2. Estación de monitoreo EBM_02

En la estación EBM_02 se tiene la Tabla 21 con sus estadísticas básicas compuestas por el promedio, la desviación estándar y los máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 21. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_02**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	2,455	4,031	39,280
Nivel de vibración Vertical (mm/s)	2,806	5,692	43,900
Nivel de vibración Longitudinal (mm/s)	3,283	8,076	72,610
Nivel de vibración VS (mm/s)	4,370	9,700	87,260
Niveles de Frecuencias FFT Transversal (Hz)	7,120	2,043	13,900
Niveles de Frecuencias FFT Vertical (Hz)	11,212	7,030	31,000
Niveles de Frecuencias FFT Longitudinal (Hz)	9,884	6,761	30,750

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_02 se puede observar la Figura 22, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

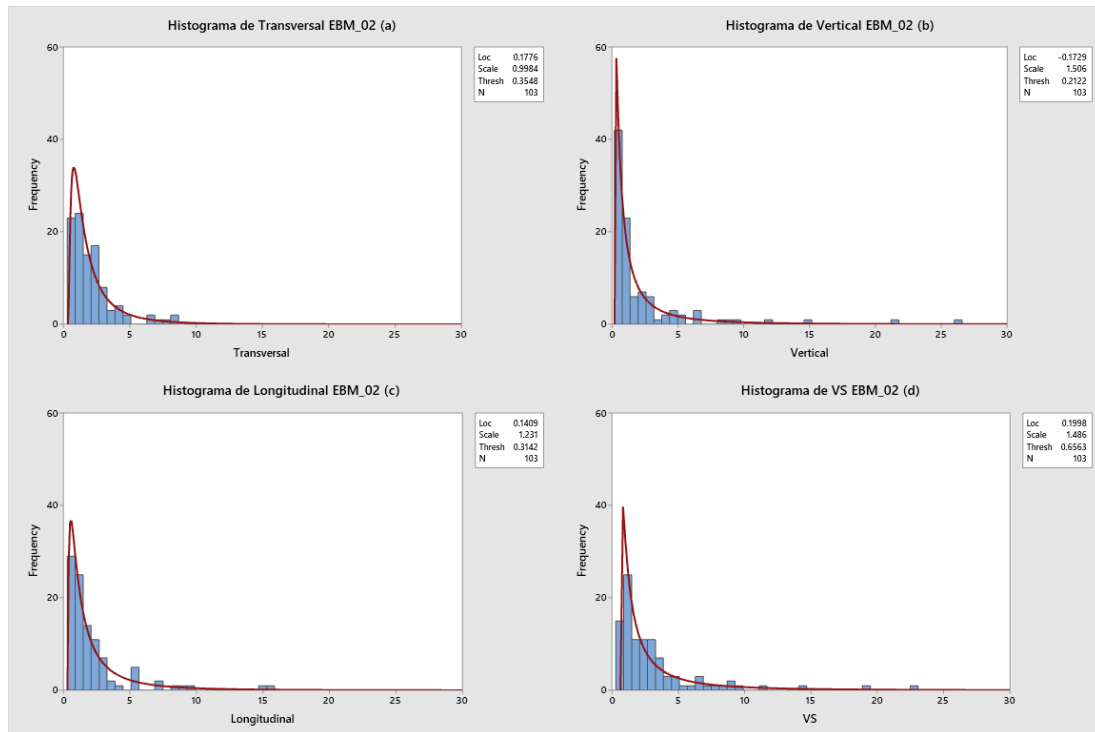


Figura 22. Histogramas de los datos para EBM_02, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

A.3. Estación de monitoreo EBM_03

En la estación EBM_03 se tiene la Tabla 22 con sus estadísticas básicas compuestas por el promedio, desviación estándar y máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 22. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_03**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	7,096	9,267	64,350
Nivel de vibración Vertical (mm/s)	6,748	11,132	95,980
Nivel de vibración Longitudinal (mm/s)	6,565	8,235	76,340
Nivel de vibración VS (mm/s)	9,870	13,528	99,300
Niveles de Frecuencias FFT Transversal (Hz)	7,519	2,231	14,250
Niveles de Frecuencias FFT Vertical (Hz)	8,480	2,537	17,000
Niveles de Frecuencias FFT Longitudinal (Hz)	7,122	2,278	22,000

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_03 se puede observar la Figura 23, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

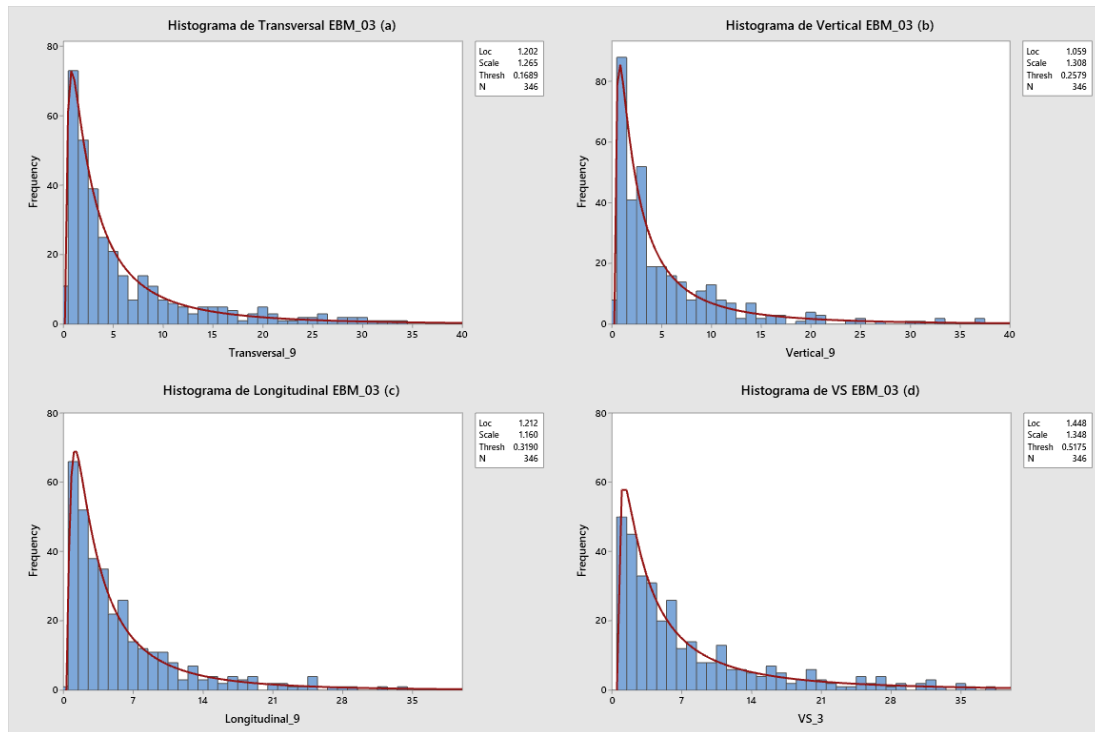


Figura 23. Histogramas de los datos para **EBM_03**, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

A.4. Estación de monitoreo EBM_04

En la estación EBM_04 se tiene la Tabla 23 con sus estadísticas básicas compuestas por el promedio, la desviación estándar y los máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 23. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_04**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	5,872	5,201	38,830
Nivel de vibración Vertical (mm/s)	4,991	5,502	43,940
Nivel de vibración Longitudinal (mm/s)	6,575	6,291	42,050
Nivel de vibración VS (mm/s)	8,102	7,338	49,980
Niveles de Frecuencias FFT Transversal (Hz)	8,049	3,074	29,000
Niveles de Frecuencias FFT Vertical (Hz)	8,276	3,469	29,000
Niveles de Frecuencias FFT Longitudinal (Hz)	7,772	2,166	12,250

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_04 se puede observar la Figura 24, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

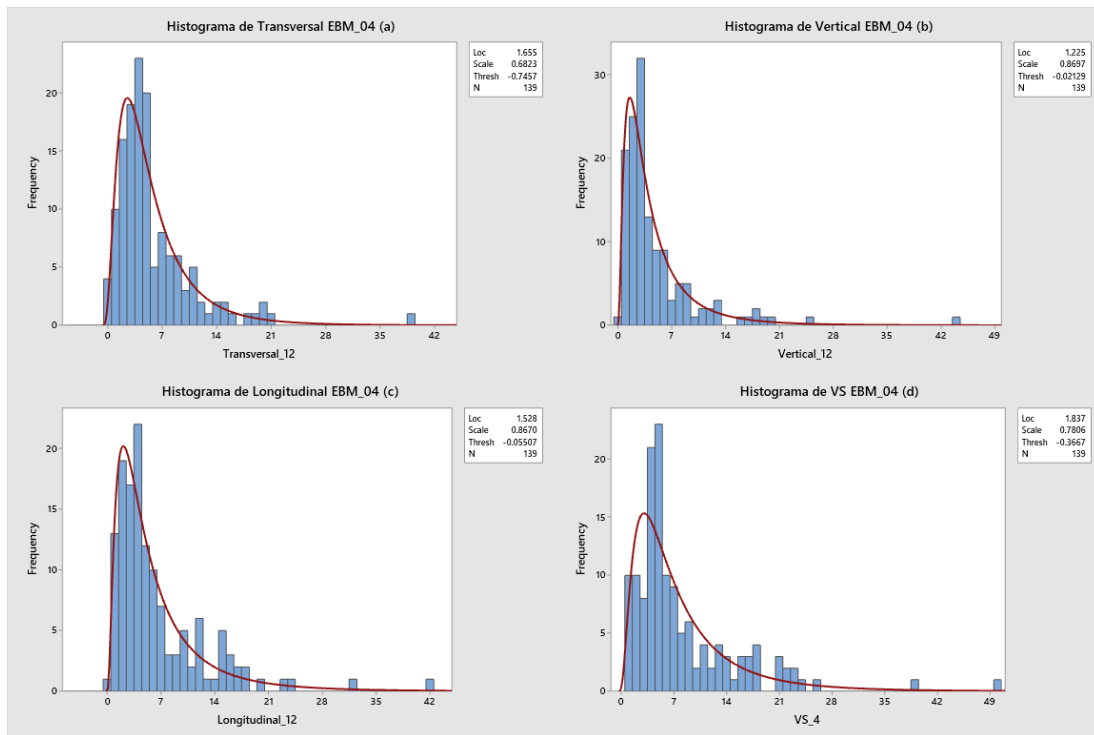


Figura 24. Histogramas de los datos para **EBM_04**, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

A.5. Estación de monitoreo EBM_05

En la estación EBM_05 se tiene la Tabla 24 con sus estadísticas básicas compuestas por el promedio, la desviación estándar y los máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 24. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_05**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	2,910	2,841	17,810
Nivel de vibración Vertical (mm/s)	2,264	2,228	11,970
Nivel de vibración Longitudinal (mm/s)	3,564	3,934	27,850
Nivel de vibración VS (mm/s)	4,200	4,410	29,430
Niveles de Frecuencias FFT Transversal (Hz)	9,707	2,672	15,800
Niveles de Frecuencias FFT Vertical (Hz)	8,920	3,351	26,500
Niveles de Frecuencias FFT Longitudinal (Hz)	8,993	2,410	18,200

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_05 se puede observar la Figura 25, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

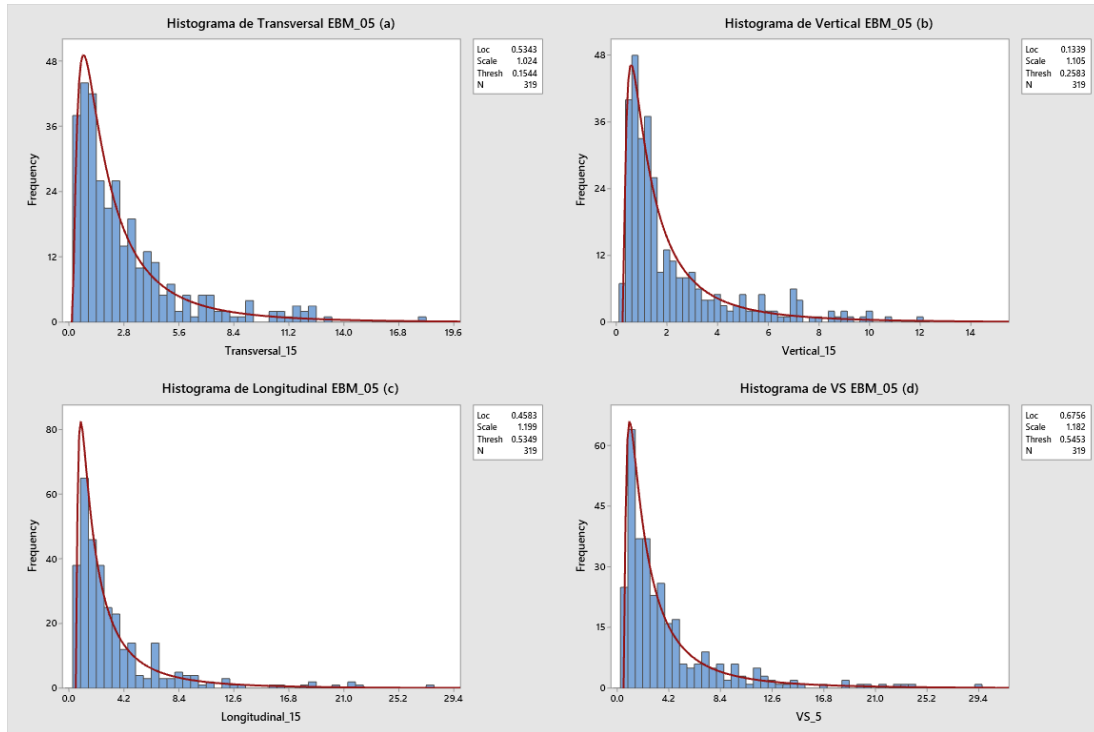


Figura 25. Histogramas de los datos para EBM_05, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

A.6. Estación de monitoreo EBM_06

En la estación EBM_06 se tiene la Tabla 25 con sus estadísticas básicas compuestas por el promedio, la desviación estándar y los máximos de cada componente de velocidad y frecuencia (Transversal, Vertical y Longitudinal), también para el Vector Suma (VS).

Tabla 25. Resumen estadístico de vibraciones en sus tres dimensiones y sus frecuencias para datos de **EBM_06**.

Variable	Promedio	Desviación estándar	Máximo
Nivel de vibración Transversal (mm/s)	2,698	4,418	37,080
Nivel de vibración Vertical (mm/s)	2,606	4,692	41,730
Nivel de vibración Longitudinal (mm/s)	2,564	3,723	31,640
Nivel de vibración VS (mm/s)	3,652	5,641	48,420
Niveles de Frecuencias FFT Transversal (Hz)	8,971	4,768	35,500
Niveles de Frecuencias FFT Vertical (Hz)	8,900	2,913	20,500
Niveles de Frecuencias FFT Longitudinal (Hz)	7,727	1,957	13,000

Para tener una visualización del comportamiento de los datos de la estación de monitoreo EBM_06 se puede observar la Figura 26, donde se aprecian los histogramas y la curva de tendencias de cada componente de velocidad y también del Vector Suma (VS). La curva de tendencia se ajusta a distribuciones Log-normales cuyos parámetros son los que se ven en la figura (Loc, Scale y Thresh).

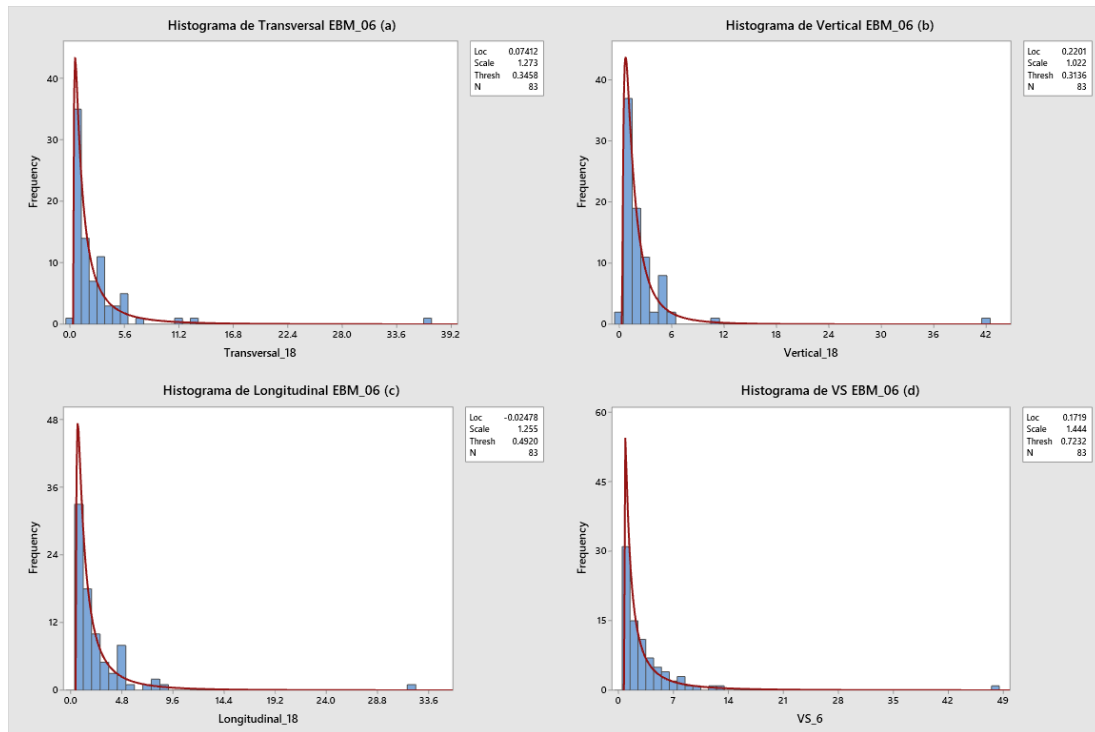


Figura 26. Histogramas de los datos para **EBM_06**, (a) Histograma velocidad transversal, (b) Histograma velocidad vertical, (c) Histograma velocidad longitudinal, (d) Histograma velocidad VS.

Anexo B. Modelo de vibración de campo lejano por estaciones

En esta sección, se presentan los modelos de vibración de campo lejano para cada estación de monitoreo. Se muestran diferentes direcciones ortogonales, así como el vector suma. Se proporciona un resumen de los modelos obtenidos y el coeficiente de correlación para cada modelo encontrado.

B.1. Modelo de vibración de campo lejano EBM_01

En la Figura 27 se muestra gráficamente los distintos modelos tanto para las diferentes direcciones ortogonales y como para el vector suma del conjunto de datos de la estación de monitoreo EBM_01. La Tabla 26 muestra los detalles de los modelos resultantes de las regresiones para la predicción de la velocidad máxima de partículas o PPV, para las distintas direcciones ortogonales, así como del vector suma. Cada modelo está etiquetado desde la “a” a la “d” indicando distintas direcciones: transversal (a), vertical (b), longitudinal (c) y vector suma o PVS (d) para el conjunto completo de datos. Los modelos se encuentran en su versión lineal transformada y también en su versión original como se muestra en la Ecuación 1. En la tercera columna de la tabla se muestra el coeficiente de determinación que en este caso varía de 79,1% al 83,2%, indicando la calidad de ajuste para cada modelo.

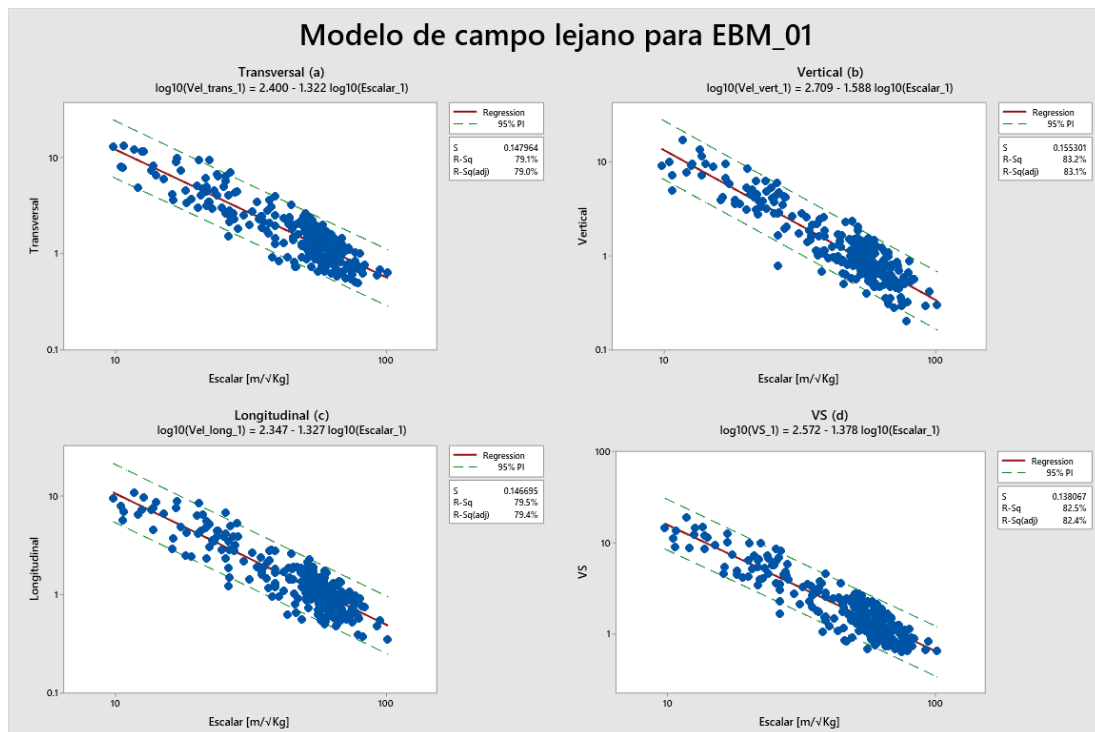


Figura 27. Modelo de campo lejano para la estación EBM_01, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 26. Modelos encontrados para la estación **EBM_01** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 2,400 - 1,322 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 251,188 \cdot (D_e)^{-1,322}$	79,1%
b)	$\log_{10}(PPV_V) = 2,709 - 1,588 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 511,681 \cdot (D_e)^{-1,588}$	83,2%
c)	$\log_{10}(PPV_L) = 2,347 - 1,327 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 222,331 \cdot (D_e)^{-1,327}$	79,5%
d)	$\log_{10}(PVS) = 2,572 - 1,378 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 372,250 \cdot (D_e)^{-1,378}$	82,5%

B.2. Modelo de vibración de campo lejano EBM_02

En la Figura 28 se muestra los modelos para las direcciones ortogonales y el vector suma para la estación EBM_02. Los modelos, junto con el coeficiente de determinación, se resumen en la Tabla 27. Los valores de R^2 varían entre el 67,2% y el 85,4%, indicando la calidad de ajuste para cada modelo.

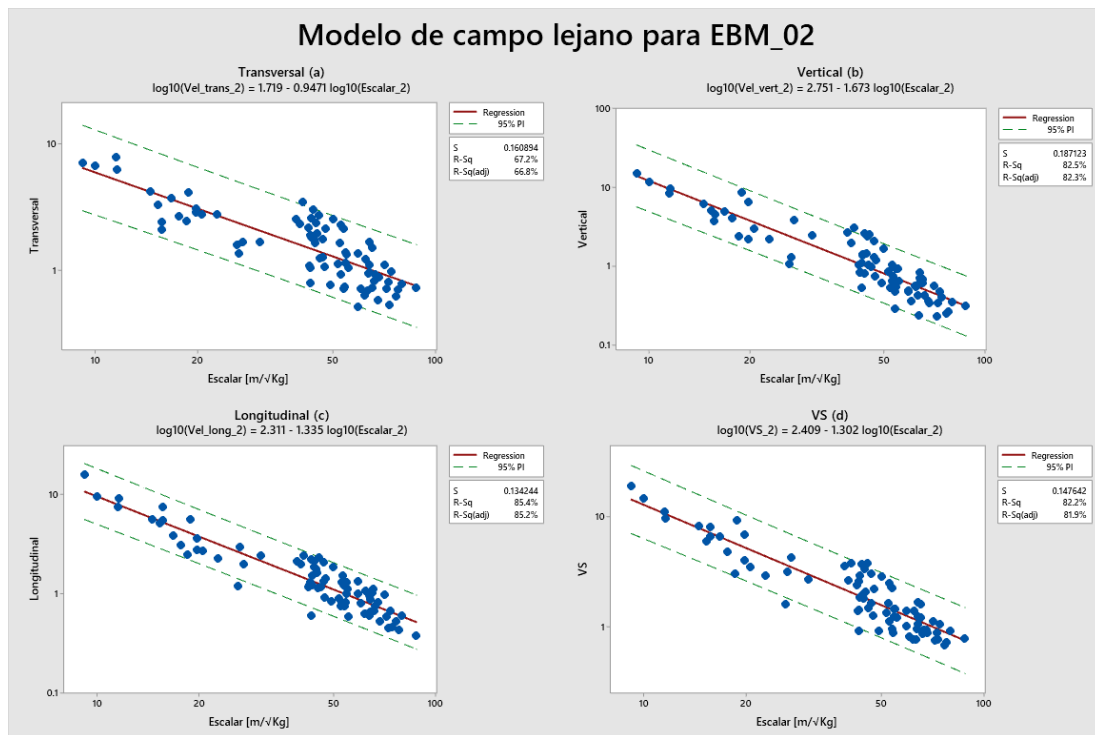


Figura 28. Modelo de campo lejano para la estación **EBM_02**, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 27. Modelos encontrados para la estación **EBM_02** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 1,719 - 0,941 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 51,360 \cdot (D_e)^{-0,941}$	67,2%
b)	$\log_{10}(PPV_V) = 2,751 - 1,673 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 563,637 \cdot (D_e)^{-1,673}$	82,5%
c)	$\log_{10}(PPV_L) = 2,311 - 1,335 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 204,644 \cdot (D_e)^{-1,335}$	85,4%
d)	$\log_{10}(PVS) = 2,409 - 1,302 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 256,448 \cdot (D_e)^{-1,302}$	82,2%

B.3. Modelo de vibración de campo lejano EBM_03

La Figura 29 muestra los modelos para las direcciones ortogonales y el vector suma en la estación EBM_03. La Tabla 28 incluye los resultados de las regresiones y los valores de R^2 , que en este caso oscilan entre el 69,5% y el 77,2%, indicando la calidad de los modelos encontrados.




Figura 29. Modelo de campo lejano para la estación **EBM_03**, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 28. Modelos encontrados para la estación **EBM_03** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 2,825 - 1,787 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 668,344 \cdot (D_e)^{-1,787}$	77,2%
b)	$\log_{10}(PPV_V) = 2,782 - 1,770 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 605,341 \cdot (D_e)^{-1,770}$	69,5%
c)	$\log_{10}(PPV_L) = 2,619 - 1,595 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 415,911 \cdot (D_e)^{-1,595}$	72,1%
d)	$\log_{10}(PVS) = 2,907 - 1,727 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 807,235 \cdot (D_e)^{-1,727}$	74,7%

B.4. Modelo de vibración de campo lejano EBM_04

En la Figura 30, se presentan los modelos correspondientes a la estación de monitoreo EBM_04. Los coeficientes de determinación para las diferentes direcciones, que varían entre el 63,9% y el 71,2%, se resumen en la Tabla 29.

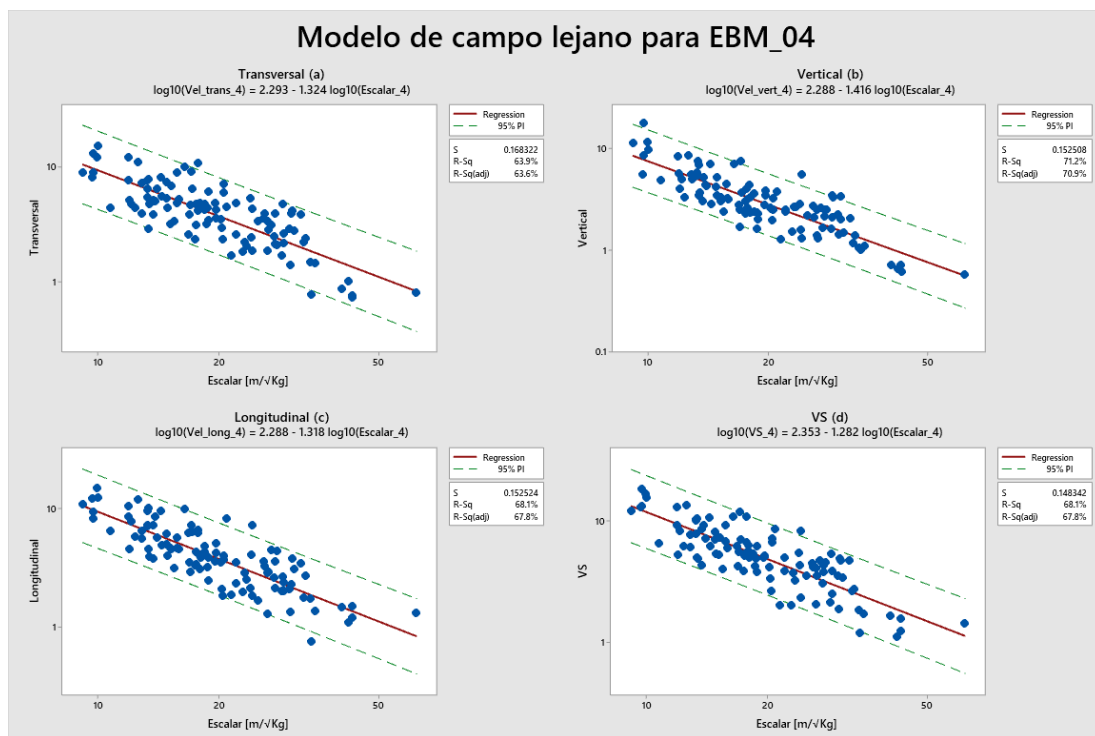


Figura 30. Modelo de campo lejano para la estación **EBM_04**, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 29. Modelos encontrados para la estación **EBM_04** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 2,293 - 1,324 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 196,336 \cdot (D_e)^{-1,324}$	63,9%
b)	$\log_{10}(PPV_V) = 2,288 - 1,416 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 194,089 \cdot (D_e)^{-1,416}$	71,2%
c)	$\log_{10}(PPV_L) = 2,288 - 1,318 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 194,089 \cdot (D_e)^{-1,318}$	68,1%
d)	$\log_{10}(PVS) = 2,353 - 1,282 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 225,424 \cdot (D_e)^{-1,282}$	68,1%

B.5. Modelo de vibración de campo lejano EBM_05

La Figura 31 se presenta los modelos para las diferentes direcciones ortogonales y el vector suma para la estación de monitoreo EBM_05. Los modelos obtenidos, junto a los valores de R^2 que en este caso varían entre 69,1% y el 73,7%, se resumen en la Tabla 30.




Figura 31. Modelo de campo lejano para la estación **EBM_05**, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 30. Modelos encontrados para la estación **EBM_05** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 2,599 - 1,551 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 397,192 \cdot (D_e)^{-1,551}$	70,2%
b)	$\log_{10}(PPV_V) = 2,425 - 1,509 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 266,073 \cdot (D_e)^{-1,509}$	72,8%
c)	$\log_{10}(PPV_L) = 2,409 - 1,373 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 256,448 \cdot (D_e)^{-1,373}$	69,1%
d)	$\log_{10}(PVS) = 2,653 - 1,488 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 449,780 \cdot (D_e)^{-1,488}$	73,7%

B.6. Modelo de vibración de campo lejano EBM_06

Finalmente, en la Figura 32, se muestran los modelos para la estación EBM_06. La Tabla 31, presenta los detalles de las regresiones, con los coeficientes de determinación que oscilan entre 68,9% al 74,7%.

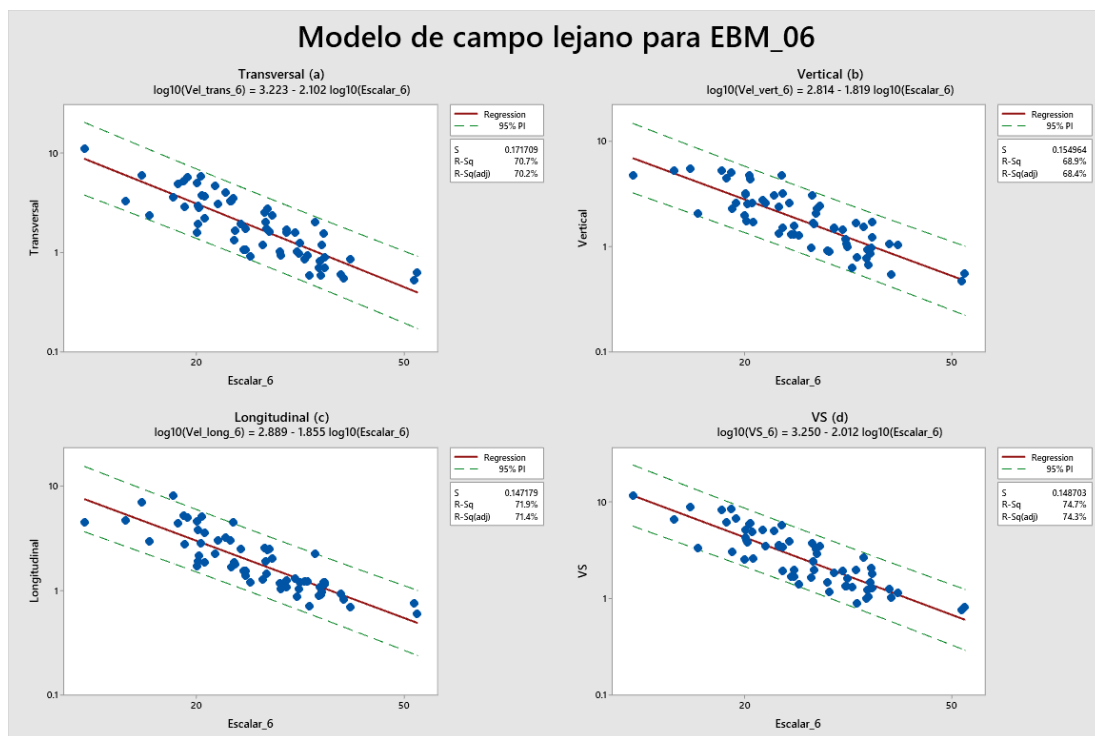


Figura 32. Modelo de campo lejano para la estación **EBM_06**, a) Modelo en la dirección transversal, b) modelo en la dirección vertical, c) modelo en la dirección longitudinal y d) modelo para el Vector Suma.

Tabla 31. Modelos encontrados para la estación **EBM_06** en las distintas direcciones: transversal (modelo a), vertical (modelo b), longitudinal (modelo c) y vector suma (modelo d), en la tercera columna se puede apreciar el coeficiente de determinación R^2 .

	Modelo de campo lejano para la totalidad de datos	R^2
a)	$\log_{10}(PPV_T) = 3,223 - 2,102 \cdot \log_{10}(D_e) \Leftrightarrow PPV_T = 1671,091 \cdot (D_e)^{-2,102}$	70,7%
b)	$\log_{10}(PPV_V) = 2,814 - 1,819 \cdot \log_{10}(D_e) \Leftrightarrow PPV_V = 651,628 \cdot (D_e)^{-1,819}$	68,9%
c)	$\log_{10}(PPV_L) = 2,889 - 1,855 \cdot \log_{10}(D_e) \Leftrightarrow PPV_L = 774,462 \cdot (D_e)^{-1,855}$	71,9%
d)	$\log_{10}(PVS) = 3,250 - 2,012 \cdot \log_{10}(D_e) \Leftrightarrow PVS = 1778,279 \cdot (D_e)^{-2,012}$	74,7%