

**UNIVERSIDAD NACIONAL MICAELA BASTIDAS DE
APURÍMAC**

FACULTAD DE INGENIERÍA

ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA DE MINAS



**“PREDICCIÓN DE LA DISTANCIA CUBIERTA POR EL FLYROCK APLICANDO
LAS REDES NEURONALES ARTIFICIALES DEL MATLAB, TAJO FERROBAMBA-
PROYECTO MINERO LAS BAMBAS 2015”**

TESIS

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO DE MINAS.

PRESENTADO POR:

BACH. : LUIS ALBERTO SÁNCHEZ SERRANO.

ABANCAY, NOVIEMBRE DEL 2016

PERÚ

[Firma]
V. Do. Mg. Edgar Vilca M.
20/07/17.

[Firma]
R. Do. Wilfredo Huasay C.
0-07-17

[Firma]
Ing. Roberto Proyo M.
Docente
11/11/2016



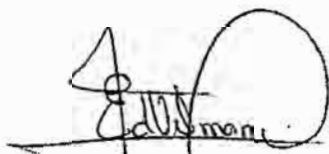
Jurado evaluador de tesis intitulado: "PREDICCIÓN DE LA DISTANCIA CUBIERTA POR EL FLYROCK APLICANDO LAS REDES NEURONALES ARTIFICIALES DEL MATLAB, TAJO FERROBAMBA-PROYECTO MINERO LAS BAMBAS 2015".



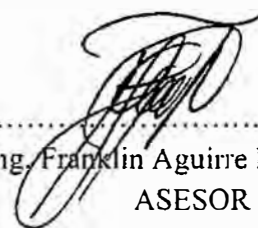
.....
Ing. Walquer Huacani Calsín
PRESIDENTE JURADO



.....
Ing. Roberto Pfuyo Muñoz
PRIMER MIEMBRO



.....
Ing. Edgar Zenon Witea Mansilla
SEGUNDO MIEMBRO



.....
Ing. Franklin Aguirre Huillcas
ASESOR



.....
Bach. Luis Alberto Sanchez Serrano
TESISTA

**“PREDICCIÓN DE LA DISTANCIA CUBIERTA POR EL FLYROCK APLICANDO
LAS REDES NEURONALES ARTIFICIALES DEL MATLAB, TAJO FERROBAMBA-
PROYECTO MINERO LAS BAMBAS 2015”**



DEDICATORIA

Esta tesis se lo dedico a mi madre por todo el esfuerzo y sacrificio que hizo, para brindarme todo el amor y la comprensión, el apoyo incondicional y la confianza en cada momento de mi vida y sobre todo en mis estudios universitarios.

A mi padre y mis hermanos por hacerme una persona de bien, y por el apoyo incondicional en todo momento y habido sabido guiarme en el camino que ahora emprendo.



AGRADECIMIENTO

Al señor mi Dios por brindarme la maravillosa oportunidad de vivir y a mis padres por haberme sabido guiar en este largo camino, a mis hermanas Hermelinda y Luz Marina, quienes como mayores supieron tomar las riendas en los momentos más difíciles y supieron guiarnos, a toda mi familia por creer en mí y darme fortaleza para crecer día a día, a mis tíos por su apoyo incondicional, a mis amigos por permitirme compartir experiencias de vida, a mis profesores por su constante apoyo y haber compartido sus conocimientos y todos a los que de una u otra forma supieron extender sus brazos para forjar la carrera que empiezo, les estaré eternamente agradecido



ÍNDICE

RESUMEN.....	1
ABSTRACT.....	2
INTRODUCCIÓN	3
CAPÍTULO I.....	4
1.1 FORMULACIÓN DEL PROBLEMA	4
1.1.1 Problema general.	4
1.1.2 Problema específico.....	4
1.2 PLANTEAMIENTO DEL PROBLEMA DE LA INVESTIGACIÓN.....	5
1.2.1 Descripción del problema.	5
1.3 JUSTIFICACIÓN	6
1.4 OBJETIVOS DE LA INVESTIGACIÓN.....	7
1.4.1 Objetivos generales.....	7
1.4.2 Objetivos específicos.....	7
CAPÍTULO II	8
2.1 ANTECEDENTES DE LA INVESTIGACIÓN.....	8
2.2 GENERALIDADES	9
2.2.1 Localización geográfica y política del proyecto minero las bambas.	9
2.2.1.1 Ubicación Geográfica.	9
2.2.1.2 Ubicación Política.....	10
2.2.1.3 Ubicación Geodésica	10
2.2.1.4 Accesibilidad.	11
2.2.2 Recursos.	13
2.2.2.1 Clima.....	13
2.2.2.2 Flora.....	13



2.2.2.3	Fauna.....	14
2.2.2.4	Topografía.....	14
2.2.3	Reseña histórica.....	15
2.2.4	Geología.....	17
2.2.4.1	Geomorfología e hidrogeología.....	17
2.2.4.2	Geología regional.....	17
2.2.4.3	Geología local.....	18
2.2.4.4	Geología del tajo Ferrobamba.....	18
2.2.4.4.1	Reservas y recursos.....	19
2.3	BASES TEÓRICAS.....	20
2.3.1	Predicciones.....	20
2.3.2	Métodos de predicciones.....	20
2.3.3	Medición de Errores.....	21
2.3.4	Fundamentos teóricos de las redes neuronales.....	21
2.3.4.1	Fundamentos biológicos de las redes neuronales.....	21
2.3.4.2	Redes neuronales artificiales.....	23
2.3.5	Redes Perceptron Multicapa.....	26
2.3.5.1	Introducción.....	26
2.3.5.2	Arquitecturas.....	26
2.3.5.2.1	Arquitectura del perpectron multicapa.....	28
2.3.5.3	Algoritmo de retropropagación.....	29
2.3.6	Matlab.....	31
2.3.6.1	Matlab.....	31
2.3.6.2	Neural network toolbox del Matlab.....	32
2.3.6.3	Redes neuronales en Matlab.....	33
2.3.6.3.1	Creación de la red neuronal.....	33
2.3.6.3.2	Simulación de la red neuronal.....	34



2.3.6.3.3 Entrenamiento	35
2.3.6.3.4 Preproceso y postproceso.....	36
2.3.6.4 Algoritmo backpropagation (Pepectrón Multicapa).	36
2.3.7 Regresión multivariable.....	37
2.3.7.1 Definición de análisis multivariante.	37
2.3.7.2 Áreas de aplicación del análisis multivariante.....	37
2.3.7.3 Clasificación de las técnicas multivariantes.....	38
2.3.8 Kinovea.....	40
2.3.9 Explosivo.....	41
2.3.10 Clasificación de los explosivos.	42
2.3.10.1 Explosivos Mecánicos.....	42
2.3.10.2 Explosivos Nucleares	42
2.3.10.3 Explosivos Químicos.....	43
2.3.10.3.1 Altos explosivos.....	43
2.3.10.3.2 Bajos explosivos.....	44
2.3.10.4 Explosivos Comerciales.	45
2.3.10.5 Explosivos Deflagrantes.....	45
2.3.10.6 Detonación y deflagración.	45
2.3.11 Propiedades de los explosivos.....	47
2.3.12 Tecnología de las emulsiones.....	54
2.3.12.1 Emulsión.	54
2.3.12.2 Características de una emulsión.	54
2.3.12.2.1 Emulsificación gasificada.....	55
2.3.12.2.2 Productos gasificables.	56
2.3.13 Geomecánica aplicado a la voladura.	57
2.3.13.1 Los efectos de la geología en la voladura.....	58
2.3.13.2 Macizo rocoso.	59

2.3.13.2.1 Propiedades de las rocas.....	60
2.3.13.3 Técnicas de clasificación de macizos rocosos.....	68
2.3.13.3.1 Clasificación geomecánica de Protodyakonov.....	69
2.3.13.3.2 Clasificación geomecánica de Bieniawski.....	70
2.3.13.4 Resistencia compresiva de la roca.....	71
2.3.13.5 Índice de la calidad de la roca – RQD.....	71
2.3.13.6 Espaciamiento de juntas.....	72
2.3.13.7 Condición de juntas.....	73
2.3.13.8 Corrección por orientación.....	74
2.3.14 Uso de las clasificaciones geomecánicas del macizo rocoso para la estimación.....	75
2.3.14.1.1 Clasificación geomecánica RMR de Bieniawski de 1976.....	76
2.3.14.1.2 Clasificación geomecánica de Bieniawski de 1989.....	77
2.3.14.1.3 Clasificación geomecánica “q” modificada de barton lien y lunde.....	78
2.3.15 Voladura en superficie.....	78
2.3.15.1 Objetivos de la voladura.....	79
2.3.15.2 Voladura en bancos.....	79
2.3.15.3 Tipos.....	81
2.3.15.3.1 Según la envergadura.....	81
2.3.15.3.2 Según su aplicación y finalidad.....	81
2.3.15.4 Parámetros de voladura en los bancos.....	82
2.3.15.4.1 Diámetro del taladro.....	83
2.3.15.4.2 Altura de banco.....	84
2.3.15.4.3 Sobreperforación.....	85
2.3.15.4.4 Longitud de taco.....	86
2.3.15.4.5 Burden y espaciamiento.....	86
2.3.15.4.6 Desviación de los taladros.....	87
2.3.15.4.7 Columna explosiva.....	89

2.3.15.5 Tareas en la voladura.....	92
2.3.15.6 Criterio de selección de explosivos.....	93
2.4 MARCO CONCEPTUAL.....	95
CAPÍTULO III.....	98
3.1 HIPÓTESIS DE LA INVESTIGACIÓN.....	98
3.1.1 Hipótesis general.....	98
3.1.2 Hipótesis específico.....	98
3.2 VARIABLES.....	98
CAPÍTULO IV.....	99
4.1 TIPO Y ALCANCE DE LA INVESTIGACIÓN.....	99
4.2 MÉTODO Y DISEÑO DE LA INVESTIGACIÓN.....	99
4.2.1 Método.....	99
4.2.2 Métodos de predicción.....	99
4.2.3 Diseño de la investigación.....	100
4.3 POBLACIÓN Y MUESTRA.....	100
4.3.1 Población.....	100
4.3.2 Muestra.....	100
4.4 METODOS TECNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS....	100
4.4.1 Metodología.....	100
4.4.1.1 Metodología usada en la generación de datos.....	101
4.4.1.1.1 Sobre datos de distancia observada.....	101
4.4.1.1.2 Sobre datos geotécnicos.....	103
4.4.1.2 Sobre datos para la regresión multivariable.....	105
4.4.1.3 Sobre datos para el kinovea.....	105
4.4.1.4 Métodos de pronóstico.....	106
4.4.1.5 Metodología para la implementación de las redes neuronales.....	106



4.4.2	Técnicas a utilizar.....	107
4.4.3	Herramientas.....	107
4.4.4	Fuente.	107
4.5	ANÁLISIS E INTERPRETACIÓN DE DATOS	107
4.5.1	Predicción de flyrock por el KINOVEA.	107
4.5.2	Predicción de flyrock por el análisis de la regresión multivariable MVRA.	112
CAPÍTULO V.....		114
5.1	METODOLOGÍA PARA LAS REDES NEURONALES.....	114
5.1.1	Diseñar modelo de RNA.....	114
5.1.1.1	Selección de la Variable.....	114
5.1.1.2	Recolección de datos.....	115
5.1.1.3	Pre-procesamiento de Datos.	117
5.1.1.4	Definición del conjunto de entrenamiento, validación y prueba.....	117
5.1.1.4.1	El conjunto de entrenamiento.	117
5.1.1.4.2	El conjunto de validación.....	117
5.1.1.4.3	Conjunto de prueba.....	118
5.1.1.5	Selección de la arquitectura de redes neuronales.....	119
5.1.1.5.1	Número de neuronas de entrada.....	119
5.1.1.5.2	Número de Capas Ocultas.....	120
5.1.1.5.3	Número de neuronas ocultas.	120
5.1.1.5.4	Número de Neuronas de Salida.....	121
5.1.1.5.5	Función de Transferencia.....	121
5.1.1.6	Criterios de evaluación.	122
5.1.1.7	Entrenamiento de la Red Neuronal.	122
5.1.1.7.1	Número de Iteraciones (Épocas) Entrenamiento.....	123
5.1.1.7.2	Tasa de Aprendizaje y Momento.	123
5.1.1.8	Implementar modelo de las RNA.....	124



5.1.1.8.1 Performance de la red neuronal.	130
5.1.1.8.2 Correlación entre los valores reales y predecidos.	130
5.1.1.8.3 Cálculo del error del modelo de redes neuronales artificial.....	131
5.1.1.9 Resultados del modelo de la red neuronal.	133
5.1.1.10 Análisis de sensibilidad.....	134
5.1.1.10.1 Resultados del análisis de sensibilidad.....	142
CONCLUSIONES	143
RECOMENDACIONES	145
BIBLIOGRAFÍA	146
ANEXOS	148



INDICE DE FIGURAS

FIGURA 1. Ubicación del proyecto minero las bambas.	9
FIGURA 2. Vehículo de transporte para llegar a la unidad minera las bambas.	11
FIGURA 3. Medio de transporte aéreo para llegar al proyecto minero las bambas.....	12
FIGURA 4. Modelo geológico del skam ferrobamba.	19
FIGURA 5. Vista panorámica del tajo ferrobamba.....	19
FIGURA 6. Esquema de funcionamiento de una neurona.	23
FIGURA 7. Esquema de la arquitectura de una red.	25
FIGURA 8. Arquitectura freed-forward.....	27
FIGURA 9. Arquitectura recurrente.....	27
FIGURA 10. Métodos explicativos.....	39
FIGURA 11. Métodos descriptivos.....	40
FIGURA 12. Simulación de movimiento en Kinovea.....	41
FIGURA 13. Clasificación de explosivos.	42
FIGURA 14. Curvas detonación y deflagración.	46
FIGURA 15. Propagación de la onda de choque.	46
FIGURA 16. Toma de densidades de la emulsión gasificada.	47
FIGURA 17. Proceso de detonación del explosivo.....	48
FIGURA 18. Presión de detonación del explosivo.	50
FIGURA 19. Rendimiento del ANFO.....	52
FIGURA 20. Emulsión fortis extra73 gasificadando.	56
FIGURA 21. Proceso de la gasificación de la emulsión.	57
FIGURA 22. Variables controlables e incontrolables.....	58
FIGURA 23. Secuencia del diseño de una voladura.	59
FIGURA 24. Ejecución correcta de la carga de un explosivo a granel con cavernas o huecos.	61
FIGURA 25. Efectos de las propiedades en la roca intacta.....	62
FIGURA 26. Cambio de esquema recomendado.	63

FIGURA 27. Casos típicos de cambios litológicos con contactos entre rocas competentes.....	64
FIGURA 28. Resultados previsibles para los diferentes casos que pueden presentarse con respecto a la inclinación de las discontinuidades y el ángulo relativo de las direcciones.	66
FIGURA 29. Información requerida por geotecnia.....	68
FIGURA 30. Zonificación geotécnica en función al índice GSI.....	75
FIGURA 31. Clasificación de dominios estructurales.	77
FIGURA 32. Nomenclatura de los bancos de voladura.	83
FIGURA 33. Relación burden y altura de banco.	85
FIGURA 34. Sobreperforación.	85
FIGURA 35. Burden.	86
FIGURA 36. Espaciamiento.....	87
FIGURA 37. Eyección de taladros por un burden inadecuado.	87
FIGURA 38. Efecto de un inadecuado burden-espaciamiento.....	88
FIGURA 39. Uso de explosivo según los fines requeridos.....	94
FIGURA 40. Uso de los explosivos en función a la calidad de roca.	95
FIGURA 41. Medición de fragmentos después de la voladura con GPS.....	101
FIGURA 42. Entorno del Kinovea.....	105
FIGURA 43. Configuración de los cuadros por segundo.....	108
FIGURA 44. Configuración de la trayectoria.	109
FIGURA 45. Análisis de movimiento lento en el KINOVEA.	110
FIGURA 47. Conjunto de entrenamiento, validación y prueba.	118
FIGURA 48. Selección del algoritmo backpropagation.....	119
FIGURA 49. Arquitectura de las neuronas.	121
FIGURA 50. Función sigmoïdal.	122
FIGURA 51. Entrenamiento de backpropagation con las redes neuronales.	124
FIGURA 52. Editor de control de Matlab.	125
FIGURA 53. Importación de datos en Exel y definición de variables.	126

FIGURA 54. Resultados del entrenamiento en modo gráfico.....	129
FIGURA 55. Mejor performance en el entrenamiento de la red.	130
FIGURA 56. Correlación entre los valores reales y predecidos.....	131
FIGURA 57. Histograma de error.....	132
FIGURA 58. Correlación entre la distancia real y la predecida por la regresión multivariable.....	133
FIGURA 59. Correlación entre la distancia real y la predecida por RNA.	134
FIGURA 60. Efecto de la concentración de carga lineal en la máxima distancia cubierta por el flyrock. 135	
FIGURA 61. Efecto del burden en la máxima distancia cubierta por el flyrock.....	136
FIGURA 62. Efecto del stemming en la máxima distancia cubierta por el flyrock	137
FIGURA 63. Efecto del factor de carga en la máxima distancia cubierta por el flyrock.....	138
FIGURA 64. Efecto RQD en la máxima distancia cubierta por el flyrock.	139
FIGURA 65. Efecto del RMR en la máxima distancia cubierta por el flyrock.....	140

INDICE DE TABLAS

TABLA 1. Coordenadas de ubicación del proyecto minero las bambas.....	10
TABLA 2. Área de concesión del proyecto minero las bambas.	11
TABLA 3. Distancias y tiempo de recorrido al proyecto minero las bambas.	11
TABLA 4. Tiempos recorridos al proyecto minero las bambas mediante transporte aéreo.....	12
TABLA 5. Temperatura media mensual del proyecto.	13
TABLA 6. Método general de diseño de pronóstico.....	21
TABLA 7. Técnicas multivariantes.....	39
TABLA 8. Clasificación de explosivos secundarios.....	44
TABLA 9. Concentración (mol/ Kg) de Gases de Explosión de un.....	52
TABLA 10. Límites permisibles de concentración de gases.....	53
TABLA 11. Clasificación del macizo rocoso.....	69
TABLA 12. Valores del coeficiente “f” según el tipo de roca.	69
TABLA 13. Estimación del valor RMR en función a la calidad de la roca.	71

TABLA 14. Determinación del tipo de macizo rocoso en función a las juntas	73
TABLA 15. Condiciones de las juntas.....	73
TABLA 16. Corrección por orientación del RMR.....	74
TABLA 17. Métodos de predicción.....	99
TABLA 18. Registro de distancias observadas.....	102
TABLA 19. Datos geotécnicos generados desde el Minesigth 3D.	104
TABLA 20. Método General de Diseño de Pronóstico.....	106
TABLA 21. Registro de ángulos y velocidades, y cálculo de distancias “Dk (m)”.....	111
TABLA 22. Registro de parámetros y cálculo de distancias “Drm (m)”.....	113
TABLA 23. Registro de datos tomados en campo.....	116
TABLA 24. Resumen de datos de la red neuronal.....	125
TABLA 25. Coeficiente de correlación Pearson para desmonte.....	141
TABLA 26. Coeficiente de correlación Pearson para Mineral.	141
TABLA 27. Resultados del análisis de sensibilidad.	142



RESUMEN

Entiéndase que se denomina “flyrock” a toda proyección de roca que exceda los límites de seguridad y/o radio de evacuación para personas y equipos, tales eventos descontrolados son un peligro inminente; más aún cuando el minado es a cortas distancias de instalaciones, equipos, poblados, etc. La frecuencia de ocurrir acontecimientos de flyrock aumentan, estos se ven reflejados en la producción de mineral principalmente, teniendo como objetivo la fragmentación, esponjamiento y desplazamiento óptimos, ajustando diseños de malla y carga, que implica el uso explosivos potentes, aumentado así la probabilidad de tener eventos.

El estudio predice las distancias cubiertas por el flyrock usando las redes neurales artificiales del Matlab (RNA). Se hizo la comparación del análisis de videos con el software KINOVEA para fragmentos mayores a 10 cm, y el análisis de la regresión multivariable (MVRA) finalmente haciendo el análisis de datos de cada variable independiente que influye en en flyrock. Para la predicción con las RNA se consideró los parámetros de voladura y datos geotécnicos, tales como la concentración de la carga lineal, burden, stemming, factor de carga, el RMR de Bienaski y el índice de calidad de la roca (RQD), estos parámetros han sido considerados como entradas de la red neuronal y la distancias observadas como salidas de esta red. El entrenamiento de las RNA han sido adiestradas usando 152 registros de voladura en los bancos: 3735, 3750, 3765, 3780, 3795, 3825, 3840, 3855, 3870, 3885 y 3900 del tajo Ferrobamba, se han utilizado 106 datas para el entrenamiento, 23 datas de prueba y 23 de validación para esta red . El algoritmo de propagación hacia atrás (backpropagation) de la red neuronal es sin duda una potente herramienta de predicción a diferencia del MVRA y otros métodos tradicionales de predicción.

Palabras claves: **Predicción, Flyrock, RNA (redes nerurinales artificiales), Kinovea, Matlab, Backpropagation.**



ABSTRACT

Get along well than names it flyrock to all boulders projection than exceed the safety limits and or area of evacuation for people and teams in open pit mining, such uncontrolled events suppose in orderly risk to the distance once was projected, in case of becoming manifest they admit an imminent danger; Furthermore when mining is to fellings of trees facilities distances, teams, towns, etc. The frequency of to occur flyrock's events grow larger they see these reflected in the ore production principally aiming at fragmentation, esponjamiento and displacement optimal, adjusting mesh designs and hole charges, that implies the use potents explosives enlarged thus to have events probability.

The study predicts the distances covered by the flyrock using the artificial neural networks of Matlab (ANN). We compared the video analysis with the KINOVEA software for fragments greater than 10 cm, and the multivariable regression analysis (MVRA) finally doing the data analysis of each independent variable that influences in flyrock. For blast parameters and geotechnical data, such as linear load concentration burden, stemming, load factor, the RMR of Bienaski and the rock quality index (RQD) were considered for ANN prediction. Parameters have been considered as inputs of the neural network and the distances observed as outputs of this network. ANN training has been trained using 152 benches: 3735, 3750, 3765, 3780, 3795, 3825, 3840, 3855, 3870, 3870, 3885 and 3900 of the Ferrobamba pit, 106 training dates have been used 23 test dates and 23 validation dates for this network. The backpropagation algorithm of the neural network is undoubtedly a powerful prediction tool unlike MVRA and other traditional prediction methods.

Key words: Prediction, Flyrock, ANN (artificial nerf nets), Kinovea, Matlab, Backpropagation.

INTRODUCCIÓN

El proceso de explosión se da en la interacción del explosivo y la roca cuando este al ser iniciado reacciona violentamente generando la onda de choque acompañado de grandes volúmenes de gases generando altas presiones y altas temperaturas, gran parte de la energía se libera en forma de vibraciones, ruidos etc. Debido a esta fuerza explosiva, se impulsan los fragmentos de rocas al aire las cuales muchas o pocas veces superan la seguridad límite del radio de evacuación de equipos y personas denominándose a este fenómeno como flyrock.

El flyrock es uno de los eventos más significativos en la voladura de bancos a cielo abierto, a diferencia de las vibraciones el flyrock tiene la probabilidad de ocasionar fatalidad y lesiones severas, esta probabilidad aumenta cuando se tiene instalaciones, infraestructuras, equipos, poblaciones, viviendas, caseríos, construcciones locales etc. Próximas al proyecto de voladura primaria y secundaria que se pudiera realizar.

Actualmente no hay modelos de predicción de flyrock sofisticados, aunque las ecuaciones cinemáticas presentan una base para la estimación de la distancia de flyrock, estos padecen del inconveniente de ignorar los efectos de variables incontrolables importantes como los datos de la geología y geotecnia por lo que los modelos predictivos que se basan en ecuaciones solo cinemáticas y realizan malas predicciones. Sin embargo en la actualidad contamos con software potentes que al ser utilizados adecuadamente nos resulta una herramienta útil para predicciones ya que considera, variables controlables e incontrolables, tal es así que las redes neuronales del matlab utilizado en la elaboración de este trabajo, busca correlaciones no lineales mediante el algoritmo de retropropagación (backpropagation), entre estas variables razón de este trabajo; este estudio finaliza con el análisis, interpretación y predicción de la distancia cubierta por el el flyrock en el tajo Ferrobamba.

CAPÍTULO I

EL PROBLEMA DE LA INVESTIGACIÓN

1.1 FORMULACIÓN DEL PROBLEMA

Del análisis anterior se pudo plantear y/o formular los siguientes problemas.

1.1.1 Problema general.

- ¿Es posible, predecir la distancia cubierta por el flyrock, inducido por la explosión de la voladura usando las redes neuronales artificiales del Matlab, aplicado al proyecto minero las Bambas?

1.1.2 Problema específico.

- ¿Cuál es el comportamiento de las variables, en la proyección de rocas del tajo Ferrobamba?
- ¿Cómo es el grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección?
- ¿Cómo influyen los parámetros de voladura y datos geotécnicos en el cálculo de la predicción de la distancia cubierta por el fryrock en el tajo Ferrobamba?
- ¿Cuál es la importancia de utilizar las redes neuronales del Matlab a diferencia de otros métodos tradicionales de predicción de flyrock?

1.2 PLANTEAMIENTO DEL PROBLEMA DE LA INVESTIGACIÓN.

1.2.1 Descripción del problema.

La fragmentación es el objetivo más deseado de una voladura, asociado al desplazamiento y esponjamiento de mineral, para lograr esto, se requiere de voladuras que garanticen el rendimiento óptimo de carguío de palas y transporte de mineral hacia la chancadora primaria, con un porcentaje de pasantes finos superiores al 70%, exigidos por planta. Para garantizar tal objetivo se realizan ajustes en diseños de voladura, aumentando las probabilidades de tener eventos ya que se requiere de controles minuciosos, los eventos más significativos antes, durante y después de una voladura son: el flyrock, taladros quedados, resultados inesperados, etc. Durante la explosión una parte de la energía es aprovechada en la fragmentación, esponjamiento y desplazamiento de la roca, mientras que el resto de la energía (que es la mayor parte), se manifiesta en forma de vibraciones, explosiones en el aire, ruidos, polvo y gases, finalmente en proyección de roca que al superar los límites de seguridad termina siendo flyrock y que estos podrían causar daños, lesiones y fatalidad. La ocurrencia de flyrock puede ser explicado con la ayuda de tres mecanismos básicos: cráteres, soplado (rifting) y explosión en la cara del banco (face burst). Otras variables controlables que nos podrían ayudar a entender serían un inadecuado burden y taco, taladros cortos, sobrerotura, sobrecarga de taladros, presencia de agua, secuencia de salida y tiempos de retardo inapropiados, por otro lado las variables incontrolables tales como las condiciones geológicas desfavorables como fallas, fracturas, juntas abiertas, zonas débiles han sido identificadas como las mayores causas de flyrock. El desempeño de una voladura está gobernada entonces básicamente por los datos geológicos y geotécnicos tales como el RQD, compresión uniaxial de la roca (Mpa).

1.3 JUSTIFICACIÓN

El pasante de finos solicitado por planta es de 2.5"-3" de diámetro, para tal objetivo se requiere de explosivos potentes, con diseños de malla y carga ajustados a la optimización de la fragmentación, por lo que es un reto cotidiano cumplir estas solicitudes de un cliente exigente en seguridad y resultados a la vez. Por otro lado muchas veces se dejan equipos e instalaciones cercanas a los frentes de voladura como: Palas eléctricas, Palas mecánicas, puentes etc., que se ven limitados a ser transportados a lugares más lejanos por diferentes factores (tiempo, costos, tormentas eléctricas, áreas restringidas, profundización, etc.) arriesgando prácticamente la seguridad de los equipos e instalaciones próximos a la voladura, en este sentido es necesario tomar el control que permita minimizar las posibilidades de impacto ocasionados por la proyección de roca. El flyock es incontrolable y a lo largo de años no han tenido una solución adecuada debido a una interpretación deficiente del fenómeno, utilizando métodos tradicionales de predicción, por tener varios factores que lo originan y que intervienen en la ocurrencia del mismo, haciendo complejo el análisis; sin embargo en la actualidad contamos con el desarrollo de las soluciones informáticas que desde buen tiempo han ayudado mucho al desarrollo de varios sectores, tal es así que las redes neurales del Matlab (RNA), es una herramienta potente en la interpretación de correlaciones no lineales, por ello nace este trabajo de tesis que justifica y propone "PREDICCIÓN DE LA DISTANCIA CUBIERTA POR EL FLYROCK APLICANDO LAS REDES NEURONALES ARTIFICIALES DEL MATLAB, TAJO FERROBAMBA-PROYECTO MINERO LAS BAMBAS 2015", que utilizado correctamente da una alternativa de solución a este problema ayudando en la toma de decisión, para el radio de evacuación de equipos, instalaciones y personas así como tomar medidas, precautivas que ayuden a evitar situaciones lamentables y significativas.

1.4 OBJETIVOS DE LA INVESTIGACIÓN

1.4.1 Objetivos generales.

- Predecir las distancias, cubiertas por el flyrock usando las redes neuronales artificiales del Matlab en el tajo Ferrobamba, proyecto minero las Bambas.

1.4.2 Objetivos específicos.

- Determinar cómo es el comportamiento de las variables en la proyección de rocas en el tajo Ferrobamba, mediante el análisis de sensibilidad.
- Establecer el grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección.
- Determinar los parámetros de voladura y datos geotécnicos para el cálculo de la predicción de la distancia cubierta por el flyrock en el tajo Ferrobamba del proyecto minero las Bambas.
- Mostrar que las redes neuronales del Matlab son una herramienta superior de predicción a diferencia de otros métodos tradicionales de predicción de flyrock.

CAPÍTULO II

MARCO TEÓRICO

2.1 ANTECEDENTES DE LA INVESTIGACIÓN

Según Rojas.N & Vásquez,V. (2012), han realizado la predicción mediante Redes Neuronales Artificiales (RNA) de la difusividad, masa, humedad, volumen y sólidos en yacón (*Smallantus sonchifolius*) deshidratado osmóticamente evaluando la capacidad predictiva de la Red Neuronal Artificial (RNA) en el efecto de la concentración (30, 40, 50 y 60 % p/p) y temperatura (30, 40 y 50°C) de la solución de fructooligosacaridos (FOS) en la masa, humedad, volumen y sólidos en cubos de yacón osmodeshidratados, y en el coeficiente de difusividad efectiva media del agua, con y sin encogimiento. Se aplicó la RNA del tipo Feedforward con los algoritmos de entrenamiento Backpropagation y de ajuste de pesos Levenberg-Marquardt, usando la topología: error meta de 10^{-5} , tasa de aprendizaje de 0.01, coeficiente de momento de 0.5, 2 neuronas de entrada, 6 neuronas de salida, una capa oculta con 18 neuronas, 15 etapas de entrenamiento y funciones de transferencia logsig-purelin. El error promedio global por la RNA fue 3.44% y los coeficientes de correlación fueron mayores a 0.9. No se encontraron diferencias significativas entre los valores experimentales con los valores predichos por la RNA y con los valores predichos por un modelo estadístico de regresión polinomial de segundo orden ($p > 0.95$).

González .M, (2005); En el trabajo de investigación “predicción de la demanda eléctrica horaria mediante redes neuronales artificiales”, realiza una introducción a los modelos neuronales y se explora su aplicabilidad en el terreno de la economía cuantitativa como instrumento de modelización y predicción no paramétrica. A tal objeto se han desarrollado un modelo de red neuronal artificial que posteriormente se aplica en la

predicción de la demanda horaria de energía eléctrica con datos reales. Los resultados así obtenidos fueron comparados con los ofrecidos por las metodologías convencionales de ajuste y predicción. El modelo neuronal propuesto ha sido capaz de predecir la evolución horaria de la demanda eléctrica con una precisión del 98%.

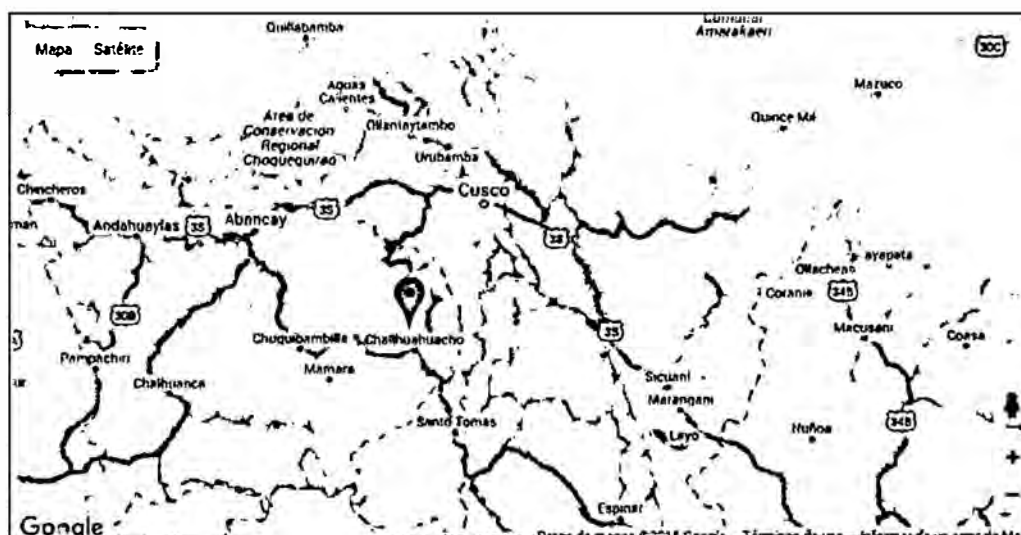
2.2 GENERALIDADES

2.2.1 Localización geográfica y política del proyecto minero las bambas.

2.2.1.1 Ubicación Geográfica.

El proyecto minero las BAMBAS es un yacimiento situado a más de 4.000 m.s.n.m., que se encuentra, entre los distritos de Chalhuanhuacho, Tambobamba y Ccoyllurqui, en la provincia de Cotabambas y el distrito de Progreso en la Provincia de Grau, región Apurímac a 72 km al suroeste de la ciudad de Cusco.

FIGURA 1. Ubicación del proyecto minero las bambas.



FUENTE: Captura de pantalla googlemaps.

2.2.1.2 Ubicación Política.

El proyecto minero las BAMBAS se encuentra dentro de las 19 comunidades. Las comunidades asentadas dentro del “Área de admisión de Petitorios” son: Fuerabamba, Huncuire, Chicñahui, z Pamputa, Cconccacca, Chucuini, Pumamarca, Choquecca Antío, Manuel Seoane Corrales, Quehuira, Allahui, Asaccasi, Sorcco, Patrón Santiago, Progreso, Pallca Picosayhuas, Escohorno, Ccahuapirhua y Carmen Alto de Chalhuhhuacho.

2.2.1.3 Ubicación Geodésica

Elipsoide : WGS8

Datum horizontal : WGS84

Datum vertical : Nivel del Mar

Proyección : Universal Transversal Mercator (UTM)

Zona : 18 SUR

Franja : L

TABLA 1. Coordenadas de ubicación del proyecto minero las bambas.

coordenadas	coordenadas	COTA	DATUM
72°17'1.65" Longitud	E793388	4200	WGS84
14° 5'31.18" Latitud	N8440530	4200	WGS84

Fuente: earth google

➤ CONSESIONES MINERAS

El Proyecto Minero Las Bambas cuenta con un derecho especial denominado "área de no admisión de petitorios" de 33,063 ha, dentro de la cual existen cuatro concesiones mineras que corresponden a Activos Mineros S.A.C. (antes Centromín Perú) que tienen una extensión total de 1,800 ha.

TABLA 2. Área de concesión del proyecto minero las bambas.

CONSECIÓN	AREA (ha)
FERROBAMBA	400
CHALCOBAMBA	600
SULFOBAMBA	400
CHARCAS	400

Fuente: Estudio Técnico las BAMBAS.

2.2.1.4 Accesibilidad.

Por Via Terrestre: El acceso por vía terrestre es el siguiente:

TABLA 3. Distancias y tiempo de recorrido al proyecto minero las bambas.

CIUDAD		DISTANCIA (km)	TIEMPO (horas)	TIPO DE ACCESO
Cusco	Chalhuahuacho	220	7	Carretera Asfaltada
Chalhuahuacho	Las Bambas	15	0.5	Carretera afirmada
Abancay	Chuquibambilla	105	6	Asfaltado
Chuquibambilla	Las bambas	80	5	Carretera afirmadada

Fuente: Estudio de tiempos.

FIGURA 2. Vehículo de transporte para llegar a la unidad minera las bambas.



FUENTE: Elaboración Propia.

Por Vía Aérea: El acceso por vía aérea en avioneta, se realiza hasta un aeródromo ubicado en el campamento PIONEROS 1, y PIONEROS 2 en FUERABAMBA.

TABLA 4. Tiempos recorridos al proyecto minero las bambas mediante transporte aéreo.

CIUDAD		TIEMPO (Hr)
Lima	Cusco	1
Cusco	Las BAMBAS	0.5

FUENTE: Elaboración propia.

FIGURA 3. Medio de transporte aéreo para llegar al proyecto minero las bambas.



Fuente: Elaboración propia.

2.2.2 Recursos.

2.2.2.1 Clima.

El clima de la región es variado. La presencia de la cadena central constituye un factor determinante en el modelamiento del clima, puesto que impide el paso de las nubes y genera su precipitación. De las 5 estaciones Meteorológicas cercanas al proyecto se ha tomado a la estación Tambobamba por presentar características similares al área de estudio (D&E Desarrollo y Ecología SAC)). Para el año 2003 se reporta una Temperatura Media Anual de 13,6 C.

TABLA 5. TEMPERATURA MEDIA MENSUAL DEL PROYECTO.

AÑO/MES	ENE	FEB	MAR	ABRIL	MAY	JUN	JUL	AGO	SEPT	OCT	NOV	DIC	Media Anual
2003	14.1	13.7	13.4	13.5	12.8	12.0	11.9	12.5	13.4	15.7	16.1	14.4	13.6

Fuente: D&E Desarrollo y Ecología SAC.

2.2.2.2 Flora.

Se identificaron 79 variedades de especies botánicas, agrupadas dentro de 37 familias diferentes, entre fanerógamas y criptógamas. Las dicotiledóneas son la categoría taxonómica más representada, con el 59,5 % (54 especies) del total de familias. Por otro lado las familias de las monocotiledóneas están presentes en un 10,8 % (12 especies). Entre las dicotiledóneas, la familia más representativa son las asteraceas con el 42,6 % de especies (23 especies) y entre las monocotiledóneas lo son las poaceas con el 50 % de las especies (6 especies). Para una mejor comprensión de la composición florística del entorno es necesaria una evaluación más completa que abarque la temporada húmeda. (D&E Desarrollo y Ecología SAC).

2.2.2.3 Fauna.

Se identificó un total de 32 especies diferentes de aves en el área de influencia del Proyecto Minero Las Bambas. Estas especies han sido determinadas durante la estación seca, por lo que sería necesaria una posterior evaluación en la temporada húmeda. En el área del proyecto existen vizcachas, perdices, wallatas, patos silvestres, zorros y venados; así como también ganados domésticos como vacuno, ovino y auquénidos.

En el área de estudio existen 5 lagunas, reportándose la presencia de avifauna acuática en tres de ellas, Estas fueron las lagunas de Quelloacocha, Casanacocha y Totoracocha. En las dos lagunas restantes, Llancope y Jalancere, no se reportó su presencia.

De las cinco lagunas, es la Laguna Casanacocha la que presenta una mayor riqueza de especies, número de individuos y diversidad, con respecto a la avifauna estrechamente relacionada a ambientes acuáticos. (D&E Desarrollo y Ecología SAC).

2.2.2.4 Topografía.

El área del proyecto presenta una topografía bastante irregular, caracterizada por cumbres, quebradas poco profundas, llanuras y laderas de relieve suave. Las cumbres más altas son el cerro Chonta en Sulfobamba (4,682 msnm) y Pichacani en Chalcobamba (4,663 msnm); el relieve más bajo lo constituye las márgenes del Río Challhuahuacho (3,700 msnm).

Los relieves elevados y las superficies irregulares generalmente corresponden a afloramientos de calizas y rocas intrusivas y los relieves suaves corresponde a morrenas y rocas intrusivas de grano grueso; mientras que las

llanuras están conformadas por sedimentos fluvio-glaciales en el sector norte de proyecto (Pamputa) y Noreste (Pumamarca), lo cual es propio de la Cordillera Oriental.

2.2.3 Reseña histórica.

Los yacimientos de Las Bambas fueron descubiertos en 1911, época desde la cual se han realizado diversos estudios.

- 1911 - Las exploraciones fueron realizadas por la Empresa Ferrobamba Ltd. en el sector Las Bambas, se realizaron perforaciones con seis taladros diamantinos.
- 1942 – La Empresa Jenks realizó estudios geológicos en la zona de Las Bambas.
- 1952 - Se realizaron 366 estudios de comprobación de los metales para verificar sus leyes en la zona de Las Bambas, la empresa a cargo se llamaba Kruger.
- 1966 – La Empresa Cerro de Pasco Corporation realizó el mapeo geológico y perforaciones con sus taladros (llegando a 914 metros de profundidad) en la zona de Chalcobamba.
- 1993 – La Empresa Tintaya realizó ensayos químicos del mineral, con presencia de oro y plata. El estudio se realizó en las zonas de Chalcobamba y Ferrobamba.
- 1996 – La Empresa Cyprus hizo estudios en la zona de Chalcobamba, realizando perforaciones con seis taladros (933 metros).
- 1997 - La Empresa Phelps Dodge realizó perforaciones con ocho taladros (1,390 metros) en las zonas de Chalcobamba y Ferrobamba. Posteriormente Teck-Cominco realizó perforaciones con cuatro taladros (875 metros) en Chalcobamba. Al finalizar el año, BHP Tintaya, se ubicó en las zonas de Chalcobamba y Ferrobamba, realizando perforaciones con siete taladros (1,024 metros).

- 2002 – Centromín retoma el proyecto realizando 35 ensayos químicos por oro y plata en la zona de Las Bambas.
- 2003 – El proyecto pasa a Proinversión, en agosto se aprueba la estrategia de promoción y la convocatoria a precalificación. Durante los meses de setiembre a diciembre se realizaron perforaciones con 11 taladros (2,328 metros) para actualizar información. Asimismo, en el mes de setiembre se realizó la suscripción del convenio de Promoción de la Inversión Privada en Apurímac (Gobierno Regional-Ministerio de Energía y Minas- Proinversión).
- 2004 – El 31 de agosto, Xstrata Copper (Suiza) ganó la licitación del proyecto las Bambas, ofreciendo US\$ 121 millones, el triple del precio base.
- 2010 - El 2 de setiembre, culminada ya la fase exploratoria, se suscribió el contrato en el que se le transfiere la titularidad de las concesiones mineras del proyecto a Xstrata Copper.
- 2013 - El grupo de minería y metales Glencore International PLC se fusiono con Xstrata PLC para formar la cuarta minera mundial y el mayor corredor de materias primas del mundo.
- 2014 - Glencore Xstrata logró vender el 100% de participación en la mina de cobre Las Bambas, por cerca de US\$5,850 millones, a las compañías MMG Ltd, filial externa de China Minmetals Corp, el grupo de recursos naturales e infraestructura Guoxin Investment Corp International Ltd. (Sociedad Nacional de Minería Petróleo Y Energía, Octubre, 2010).

2.2.4 Geología.

2.2.4.1 Geomorfología e hidrogeología.

Las características geológicas de la zona determinan un tipo de fisiografía en la que la roca aflorante, en muchos casos, puede ser parte del yacimiento; de cumbres redondeadas con presencia de detritos finos formados por el meteorismo de las heladas, lluvias o por el intenso calor durante el día. De laderas entre suaves y agrestes, como pequeñas plataformas, que dan origen al nacimiento de ojos de agua o a la formación de bofedales. Por lo que en las partes altas y planas existen cinco lagunas que conforman un acuífero, cuya caracterización es de suma importancia. La calidad del acuífero en mención, dados los afloramientos aguas abajo, puede determinar su uso adecuado.

2.2.4.2 Geología regional.

El Proyecto las Bambas se ubica en la franja de yacimientos de skarn de Cu (Mo-Au), asociados a sistemas tipo pórfido, ubicados en la parte sureste del Perú.

Esta franja metalogenética está controlada por el batolito Andahuaylas-Yauri del Eoceno- Oligoceno, que se ha emplazado en unidades sedimentarias del Mesozoico, siendo la de mayor importancia la formación Ferrobamba (Cretáceo inferior a superior). Las rocas intrusivas del batolito, en contacto con las calizas Ferrobamba, originaron metamorfismo de contacto y en algunos lugares cuerpos de skarn con mineralización de Cu (Mo-Au). El batolito Andahuaylas-Yauri se ha emplazado al sur de la “Deflexión de Abancay”, con lineamientos de dirección NO-SE, NE-SO y otros que fueron generados principalmente por la Orogenia Andina.

2.2.4.3 Geología local.


La mineralización de cobre en las Bambas está principalmente emplazada en los contactos de calizas de la formación Ferrobamba y las rocas intrusivas de la Era Terciaria (granodiorita, cuarzo monzonita y cuarzo diorita). Las calizas corresponden a la Era Cretácea, similar a los depósitos de Skarn en Tintaya, Antamina y Magistral.

La forma de mineralización más común es la calcopirita, que contiene oro y plata, asociados con cobre. La mineralización se distribuye en bloques fallados de granate y magnetita en Skarn. Las rocas con alteración potásica y silicificación presentan calcopirita diseminada. La mineralización de enriquecimiento secundario es ligera, debido a la erosión glacial intensa y a la densidad de skarn. Las unidades litológicas ígneas y sedimentarias que afloran en el distrito minero de Las Bambas son las formaciones Hualhauani, Mara y Ferrobamba, cuyas eras van desde el Jurásico Superior al Cretáceo Superior.

2.2.4.4 Geología del tajo Ferrobamba.

La mineralización de cobre más común es la Calcopirita, que contiene oro y plata asociados con Cobre, el cual se encuentra principalmente emplazada en los contactos de calizas de la formación Ferrobamba y las rocas intrusivas de la Era Terciaria (granodiorita, cuarzo monzonita y cuarzo diorita). Las unidades litológicas ígneas y sedimentarias que afloran en el Distrito Minero, son las formaciones Hualhuani, Mara y Ferrobamba, cuyas eras van desde el Jurásico Superior al Cretáceo Superior; tiene una extensión con evidencias de mineralización de 300 ha aproximadamente. (D&E Desarrollo y Ecología SAC)

FIGURA 4. Modelo geológico del skarn ferrobamba.



Fuente: Coffey mining.

FIGURA 5. Vista panorámica del tajo ferrobamba



Fuente: Vista extraída del tajo ferrobamba.

2.2.4.4.1 Reservas y recursos.

➤ Reserva de mineral:

6,9 millones de toneladas métricas de cobre (ley de cobre de 0,73 %).

➤ Recurso mineral:

10,5 millones de toneladas métricas de cobre (ley de cobre de 0,61 %).

2.3 BASES TEÓRICAS.

2.3.1 Predicciones.

Bowerman, K,(2007). Menciona que pronosticar es muy importante en muchos tipos de empresas, ya que las predicciones de hechos futuros se pueden incorporar al proceso de toma de decisiones.

Al predecir hechos que ocurrirán en el futuro, quien elabora los pronósticos debe confiar en la información de los hechos que han ocurrido en el pasado y que le interesan. Es decir, con objeto de preparar un pronóstico, quien elabora el pronóstico tiene que analizar la información anterior y basar la predicción en los resultados del análisis. Las personas que elaboran los pronósticos utilizan los datos pasados de la manera siguiente: Primero, dicha persona analiza los datos para poder identificar un patrón que se pueda utilizar para describirlo. Esta es la forma básica para construir pronósticos basándonos en que el patrón permanecerá igual en el futuro. Si el patrón que se identificó no persiste en el futuro, entonces las predicciones no serán exactas, razón por la cual lo más aconsejable es prever cuando será el cambio de dicho patrón y hacer los cambios necesarios a nuestro sistema de pronósticos mediante la aplicación de otras técnicas para otros tipos de patrones.

2.3.2 Métodos de predicciones.

Se podría hablar de la existencia de un método general para diseñar modelos de pronósticos el cual se describe en la cuadro 3.1, aplicable a cualquier caso.

TABLA 6. Método general de diseño de pronóstico.

	Pasos	Descripción
1	Temporal	Es decir el corto, mediano y largo plazo.
2	Observar los Hechos	Identificar las variables a predecir y sus dependencias
3	Seleccionar una Técnica	Seleccionar las técnicas que más se ajustan al tipo de problemas presentado.
4	Aplicar Técnicas	Implementar el pronóstico con la técnica seleccionada.

Fuente: Bowerman, (2007).

2.3.3 Medición de Errores.

La presencia del componente irregular en una serie de tiempo que representa fluctuaciones impredecibles en los datos, quiere decir que es de esperarse algún error en el pronóstico. Para saber que tan eficaz es un pronóstico, es decir que tan lejos está del valor real de la variable a predecir, existen ciertas métricas estándares que nos permiten medir los errores en los pronósticos. El error cuadrático medio y el error absoluto, las cuales consideran la suma de todos los errores de predicción en el tiempo, arrojando un resultado total.

2.3.4 Fundamentos teóricos de las redes neuronales.

2.3.4.1 Fundamentos biológicos de las redes neuronales.

Las redes neuronales artificiales se basan en el funcionamiento del sistema neuronal del cuerpo humano. En el cuerpo humano encontramos 3 elementos fundamentales: los órganos receptores que recogen información del exterior; el sistema nervioso que transmite la información, la analiza y en parte almacena, y envía

la información elaborada y, los órganos efectores que reciben la información de parte del sistema nervioso y la convierte en una cierta acción.

La unidad fundamental del sistema nervioso es la neurona. Las neuronas se unen unas con otras formando redes. Se componen de un cuerpo o núcleo, del axón, que es una ramificación de salida de la neurona, y de un gran número de ramificaciones de entrada llamadas dendritas. Su funcionamiento es el siguiente. Las señales de entrada llegan a la neurona a través de la sinapsis, que es la zona de contacto entre neuronas (u otro tipo de células, como las receptoras). La sinapsis recoge información electro-química procedente de las células adyacentes que están conectadas a la neurona en cuestión. Esta información llega al núcleo de la neurona, a través de las dendritas, que la procesa hasta generar una respuesta, la cual es posteriormente propagada por el axón.

La sinapsis está compuesta de un espacio líquido donde existe una cierta concentración de iones. Este espacio tiene unas determinadas características eléctricas que permiten inhibir o potenciar la señal eléctrica a conveniencia.

Por ello, se puede ver que el sistema neuronal es un conjunto de neuronas conectadas entre sí, que reciben, elaboran y transmiten información a otras neuronas, y que dicha información se ve potenciada o inhibida en la siguiente neurona a conveniencia, gracias a las propiedades del espacio intersináptico.

De hecho, esta propiedad de poder alterar el peso de cada información en la red neuronal nos otorga en cierta medida la capacidad de aprender.

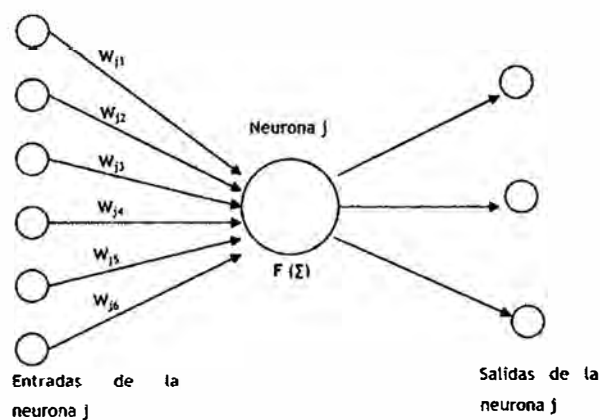
2.3.4.2 Redes neuronales artificiales.

Las redes neuronales artificiales tratan de emular las características y propiedades de las redes neuronales biológicas. En general, consisten en una serie de unidades denominadas neuronas, conectadas entre sí.

Cada neurona recibe un valor de entrada, el cual transforma según una función específica denominada función de activación. Dicha señal transformada pasa a ser la salida de la neurona.

Las neuronas se conectan entre sí según una determinada arquitectura. Cada conexión tiene un determinado peso que pondera cada entrada a la neurona. De esta manera la entrada de cada neurona es la suma de las salidas de las neuronas conectadas a ella, multiplicadas por el peso de la respectiva conexión. La figura siguiente ilustra dicho concepto:

FIGURA 6. Esquema de funcionamiento de una neurona.



Fuente: Simulación de redes neuronales con Matlab.

En este modelo, la neurona j recibe una serie de entradas x_1, x_2, \dots, x_n . Cada señal se multiplica por el peso asociado a su conexión, w_1, w_2, \dots, w_n . Luego, se suman estas entradas ponderadas y se les aplica la función de

activación $F(.)$ para generar la señal de salida de la neurona j . Los valores de los pesos son ajustados durante la fase de aprendizaje.

Como se ha comentado anteriormente, estas neuronas están conectadas entre sí de acuerdo a una determinada arquitectura. Es decir, las neuronas se agrupan en distintas capas: una capa de entrada, otra de salida, y en el caso de existir, una o varias capas ocultas. La salida de cada neurona se propaga por igual por estas conexiones hasta las neuronas de destino. Cada conexión tiene un peso asociado que pondera el valor numérico de la señal que viaja por ésta. Así pues, una red de neuronas artificial puede verse como un grafo cuyos nodos tienen funcionamiento similar, los cuales propagan la información a través de las distintas conexiones.

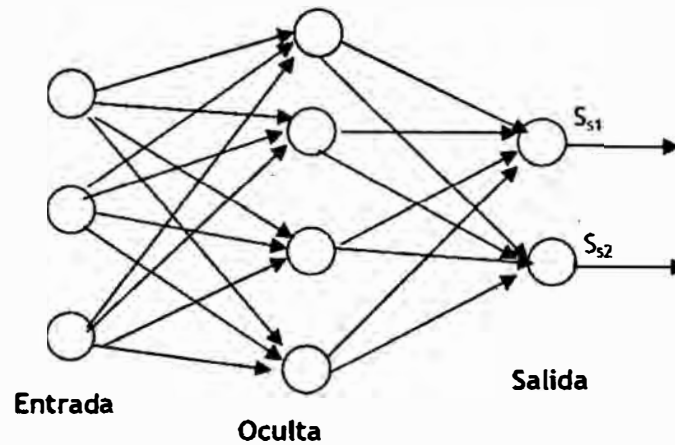
$$S_{2j} = F_{2j}(X_1 W_{1j}) \quad (1)$$

Donde X_1 es el vector de entradas de la capa 1 y W_{1j} el vector de pesos correspondientes a las conexiones que van de todas las neuronas de la primera capa a la neurona j de la segunda capa. La función F_{2j} es la función de activación de la neurona j de la segunda capa. Así con todas las neuronas de la segunda capa. Estas salidas son propagadas a las neuronas de la capa de salida. Estas neuronas generan las salidas de la red. Cada neurona i de la capa de salida generará una salida de valor:

$$S_{si} = F_{si}(W_{2i} S_2) \quad (2)$$

Donde W_{2i} es el vector de pesos correspondientes a las conexiones que van de las neuronas de la segunda capa a la neurona i de la capa de salida, y S_2 el vector de salidas de las neuronas de la capa dos, que a su vez son entradas de las neuronas de la capa de salida.

FIGURA 7. Esquema de la arquitectura de una red.



Fuente: Simulación de redes neuronales con Matlab.

Por último hablar del aspecto más importante y delicado de redes neuronales, el aprendizaje. Las RNA son sistemas de aprendizaje basadas en datos que son utilizados como patrones. Por ello la capacidad de una red de resolver un problema está muy ligada a los patrones utilizados durante su fase de aprendizaje.

El aprendizaje de una red neuronal consiste en hallar los valores precisos de los pesos de sus conexiones para que pueda resolver un determinado problema. El proceso general consiste en ir introduciendo una serie de datos patrón y ajustar los pesos siguiendo un determinado criterio. Los criterios que se van a utilizar en este proyecto se fundamentan en el error cometido por la red, lo que nos obliga a conocer la salida que se debería obtener para cada uno de ellos. Es lo que se conoce como entrenamiento supervisado. De esta manera, primero se introducen los patrones, se reajustan los pesos, posteriormente se comprueba si se ha cumplido un determinado criterio de convergencia, de no ser así se repite todo el proceso.

2.3.5 Redes Perceptron Multicapa.

2.3.5.1 Introducción.


El perceptron multicapa con conexiones hacia adelante es una generalización del perceptron simple. Surge como respuesta a los problemas que tenía dicha red, como por ejemplo, no poder resolver problemas que no fueran linealmente separables. De hecho, algunos autores han demostrado que el perceptron multicapa es un aproximador universal de cualquier función continua en el espacio R^2 .

2.3.5.2 Arquitecturas.

Se pueden clasificar las arquitecturas de una red neuronal de dos maneras; la primera es según el número de capas de neuronas que presenta la red (puede ser unicapa o multicapa) y la otra forma, es de acuerdo a los patrones de conexión entre las neuronas y la propagación de los datos. En base a esta última clasificación podemos distinguir dos tipos de arquitecturas.

A) *Redes Freed-forward*. En este tipo de redes, el flujo de datos desde la entrada hasta la salida es estrictamente hacia adelante. El procesamiento de datos puede extenderse sobre múltiples capas de neuronas, pero no existen conexiones hacia atrás, ósea conexiones que se extienden desde la salida de una neurona a la entrada de otra en la misma capa o capa anterior.

FIGURA 8. Arquitectura freed-forward.




Fuente: Easigning a neural network for forecasting financial and economic times.

En la figura N° 8, se aprecia la dinámica de esta arquitectura y entre sus principales representantes podríamos nombrar al perceptron monocapa, el perceptron multicapa que es muy útil para aproximar relaciones no lineales entre datos de entrada y de salida, Adeline, entre otras.

B) *Redes Recurrentes.* Estas redes a diferencia de las primeras, sí contienen conexiones hacia atrás.

FIGURA 9. Arquitectura recurrente



Fuente: Easigning a neural network for forecasting financial and economic times.

En la figura N° 9 , se puede observar como el flujo de datos se desplaza de la salida una neurona ubicada en capa posterior a la entrada de una neurona ubicada en una capa anterior. Entre los representantes de esta arquitectura tenemos las redes de base radical, redes de Hopfield y los mapas Auto-Organizativos de Kohonen, éstos últimos de mucha utilidad.

2.3.5.2.1 Arquitectura del perceptron multicapa.

La arquitectura de este tipo de red se caracteriza porque tiene todas sus neuronas agrupadas en distintos niveles llamados capas. El primer nivel corresponde a la capa de entrada, que se encarga únicamente de propagar por el resto de la red las entradas recibidas. El último nivel es el de la capa de salida. Se encarga de proporcionar los valores de salida de la red. En las capas intermedias denominadas capas ocultas, se realiza un procesamiento no lineal de los patrones recibidos.

Las conexiones del perceptron multicapa son hacia adelante. Generalmente todas las neuronas de un nivel se conectan con todas las neuronas de la capa inmediatamente posterior. A veces, dependiendo de la red, se encuentran conexiones de neuronas que no están en niveles consecutivos, o alguna de las conexiones entre dos neuronas de niveles consecutivos no existe, es decir, el peso asociado a dicha conexión es constante e igual a cero. Además, todas las neuronas de la red tienen un valor umbral asociado. Se suele tratar como una entrada cuyo valor es constante e igual a uno, y lo único que varía es el peso asociado a dicha conexión (que es el umbral realmente).

Por otro lado, las funciones de activación que se suelen utilizar son la función identidad, la función sigmoideal y la función tangente hiperbólica. A continuación se muestran sus respectivas expresiones.

Función identidad.

$$f_1(x) = x \quad (3)$$

Función sigmoideal.

$$f_2(x) = \frac{1}{1+e^{-x}} \quad (4)$$

Función tangente hiperbólica.

$$f_3(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (5)$$

La principal diferencia entre la función sigmoïdal y la función tangente hiperbólica es el rango de sus valores de salida. Mientras que para la primera su rango es $[0,1]$, para la segunda es $[-1,1]$. De hecho existe una relación entre las dos. Se relacionan mediante la expresión $f_2(x) = 2f_3(x) - 1$, por lo que la elección entre una u otra se elige en función del recorrido que interese.

2.3.5.3 Algoritmo de retropropagación.

El algoritmo de aprendizaje de retropropagación, consiste básicamente en propagar el error hacia atrás, desde la capa de salida hasta la de entrada, permitiendo así la adaptación de los pesos con el fin de reducir dicho error. González.H y Martínez.H, (2000).

En forma simplificada, el funcionamiento de una red “backpropagation” consiste en el aprendizaje de un conjunto predefinido de pares de entradas y salidas dados como ejemplos, empleando un ciclo de propagación-adaptación de dos fases:

- En la primera fase, o paso hacia delante, se aplica un primer patrón como estímulo para la capa de entrada de la red, éste se va propagando a través de las capas siguientes para generar la salida, la cual proporciona el valor del error al compararse con la que se desea obtener.
- En la siguiente fase o paso hacia atrás, estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta intermedia que contribuyan directamente a la salida, recibiendo el porcentaje del error aproximado a la participación de las mismas en la salida original.

Este proceso se repite hacia atrás, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aporte relativo al error total. Basándose en esta información recibida, se reajustan todos los pesos de conexión, de manera que la siguiente vez que se presente el mismo patrón disminuya la diferencia entre la salida calculada y la deseada

La importancia de la red backpropagation consiste en su capacidad de auto adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplos y sus salidas correspondientes

Este algoritmo es el algoritmo básico de aprendizaje que usa el perceptron multicapa. Es el algoritmo mediante el cual se van adaptando todos los parámetros de la red. El tipo de entrenamiento que sigue este tipo de red es supervisado.

El aprendizaje de la red se plantea como un problema de minimización de una determinada función de error. En general se usa como función del error, el error medio cuadrático, es decir:

$$E = \frac{1}{N} \sum_{k=1}^N e^n \quad (6)$$

$$e(n) = \frac{1}{2} \sum_{n=1}^t (s(n) - y(n))^2 \quad (7)$$

Donde $s(n)$ es la salida patrón, $y(n)$ la salida obtenida de la red, t el número de neuronas de salida y N el número de patrones.

El problema es no lineal y como tal, el problema de minimización de la función error se resuelve por técnicas de optimización no lineales que se basan en ajustar los parámetros siguiendo una determinada dirección.

2.3.6 Matlab

2.3.6.1 Matlab.

Fernandez, D.(2015). Resume que el MATLAB es la abreviatura de MATrix LABoratory (laboratorio de matrices). Se trata de un software matemático para cálculo científico (aritmético y simbólico) basado en matrices. MATLAB ofrece un entorno de desarrollo integrado (IDE) muy versátil con un lenguaje de programación propio (lenguaje M). MATLAB está disponible para sistemas operativos Windows, Unix y Apple Mac OS X. Entre sus usos básicos podemos mencionar:

- Realizar cálculos simbólico (con la posibilidad de hacer operaciones como derivar funciones, calcular primitivas, etc.).
- Programar en un lenguaje no compilado (script).
- Realizar gráficos en dos y tres dimensiones.
- La representación de datos y funciones.
- La implementación de algoritmos.
- La creación de interfaces de usuario (GUI).
- La comunicación con programas en otros lenguajes y con otros dispositivos hardware.

Así, por ejemplo, se pueden utilizar toolboxes de matemáticas y optimización, estadística y análisis de datos, diseño de sistemas de control y análisis, procesamiento de señal y comunicaciones, procesamiento de imagen, pruebas y medidas, biológica computacional, redes neuronales artificiales, modelado y análisis financiero, desarrollo de aplicaciones o informes y conexión a bases de datos.

2.3.6.2 *Neural network toolbox del Matlab*

Este toolbox proporciona funciones para el diseño, inicialización, simulación y entrenamiento de los modelos neuronales de uso más extendido en la actualidad:

Perceptrón, redes lineales, redes de retropropagación, redes de base radial, aprendizaje asociativo y competitivo, aplicaciones auto-organizativas, aprendizaje de cuantización vectorial, redes de Elman y redes de Hopfield. Mediante la inclusión de un amplio abanico de funciones y procedimientos escritos para MATLAB, el usuario puede mediante el Neural Network Toolbox efectuar el diseño de arquitecturas complejas, combinando los modelos que ya están proporcionados por defecto en el toolbox. Asimismo, el usuario puede definir sus propias funciones de transferencia e inicialización, reglas de aprendizaje, funciones de entrenamiento y estimación de error para usarlas posteriormente con las funciones básicas.

El toolbox, aporta las facilidades y prestaciones gráficas de MATLAB para el estudio del comportamiento de las redes: visualización gráfica de la matriz de pesos y vector de desplazamiento mediante diagramas de Hinton, representación de errores a lo largo del entrenamiento, mapas de superficie de error en función de pesos y vector de desplazamiento, etc. Estos gráficos resultan muy útiles en el estudio de la convergencia y estabilidad de los algoritmos de aprendizaje. Este toolbox incluye un manual de introducción al campo de las redes neuronales junto con una colección de demostraciones y aplicaciones muy didácticas, útiles para el estudio y la profundización en las cuestiones fundamentales de los paradigmas de redes neuronales básicos. Asimismo, se

proporcionan las referencias bibliográficas más significativas referidas a los distintos modelos que aparecen en la aplicación.

A pesar de que el estudio de las redes neuronales se inició ya hace algunas décadas, las primeras aplicaciones sólidas dentro de este campo no han tenido lugar hasta hace unos doce años y aun ahora constituyen un área de investigación en rápido desarrollo. Este toolbox tiene por tanto una orientación diferente a aquellos destinados a campos como el de sistemas de control u optimización donde la terminología, fundamentos matemáticos y procedimientos de diseño están ya firmemente establecidos y se han aplicado durante años. Este toolbox pretende que sea utilizado para la valoración y diseño de diseños neuronales en la industria y sobre todo en educación e investigación.

Esta herramienta tiene el soporte de MATLAB 4.2c y SIMULINK. La librería de SIMULINK contiene modelos de capas de redes neuronales de cada tipo de neurona implementada en el toolbox de redes neuronales. Es posible por tanto diseñar sistemas SIMULINK para simular redes neuronales creadas usando esta herramienta. Simplemente, las capas se conectan de acuerdo con la arquitectura de la red y se proporcionan como entrada a la caja de diálogo de cada capa la matriz de pesos apropiada y el vector de desplazamiento. Usando el generador de código C de SIMULINK es posible generar automáticamente el código correspondiente a un diseño neuronal.

2.3.6.3 Redes neuronales en Matlab.

2.3.6.3.1 Creación de la red neuronal.

En Matlab se crea una red perceptron multicapa con conexiones hacia delante utilizando la función `newff`. Esta función devuelve una variable que

representa a la red. Los argumentos de entrada de esta función (descritos en el orden en el que se colocan) son:

- ✓ R que es una matriz cuyo número de filas es el número de entradas, y su número de columnas es igual a 2. Esta matriz debe señalar los valores mínimos y máximos que pueden tomar cada una de las entradas a la red.
- ✓ [Slayer1, Slayer2,...] es un vector que describe el número de neuronas que tienen todas las capas ocultas de la red y el número de neuronas de salida. Asimismo el tamaño de dicho vector permite conocer al programa el número de capas que debe tener la red que se va a crear.
- ✓ {Funciones} es un vector de varias cadenas de caracteres en el que se señala las funciones de activación que va a poseer todas las neuronas de una capa. Así, la primera cadena señalará la función de activación de las neuronas de la primera capa oculta, la segunda señalará la función de las neuronas de la segunda capa, y así sucesivamente. Por ello, este vector debe tener tantas cadenas como capas vaya a tener nuestra red. Para que la función de activación sea lineal, la cadena debe ser 'purelin', para que ésta sea una función tangente hiperbólica se debe escribir 'tansig', y para indicar que queremos una función sigmoideal escribiremos 'logsig'. Por defecto Matlab utiliza la función tangente hiperbólica.
- ✓ En el siguiente argumento se indica el tipo de entrenamiento que va a seguir nuestra red. De los diferentes entrenamientos que tiene Matlab se hablará en el 2.1.3. Si no se indica nada el entrenamiento que seguirá es el trainlm (ver apartado 2.1.3).

2.3.6.3.2 Simulación de la red neuronal.

Para obtener las salidas de una determinada red ante unas ciertas entradas se utiliza la función sim. Esta función devuelve un vector cuyas

componentes son las salidas que se obtienen de cada neurona de salida de la red. A dicha función se le introducen como argumentos el nombre el objeto que representa a la red en Matlab, y el vector de entradas a la red.

Se pueden obtener varias simulaciones de un tiempo introduciendo una matriz, cuyos vectores sea cada uno de los vectores de entrada de los que se quiere obtener su salida. De esta manera, si se tiene una red “net” de la que se quiere obtener su respuesta ante unas entradas “a”, se escribe en Matlab la siguiente línea de código. $P = \text{sim}(\text{net}, a);$

2.3.6.3.3 Entrenamiento

Como se ha comentado anteriormente, el entrenamiento de la red (el que se utiliza en este proyecto) consiste en presentarle unas entradas y sus correspondientes salidas (que son conocidas por nosotros), para que la red vaya reajustando su salida mediante la modificación de sus pesos y valores umbrales, de manera que el error de actuación de la red se minimice. Dicho valor Matlab lo almacena en la variable `net.performFcn`. La medida del error por defecto en Matlab es el error medio cuadrático. Para indicar que se quiere utilizar esta definición del error en Matlab, la variable `net.performFcn` debe igualarse a `mse` (en cualquier caso, este valor lo toma por defecto).

Para entrenar una red en Matlab se utiliza la función `train`. Dicha función utiliza como argumentos el nombre de la red que se quiere entrenar (y que anteriormente ha debido ser creada) y los patrones, compuestos por unos vectores de entradas (unidos en una matriz “a”) y sus correspondientes salidas (todas ellas en una matriz “p”). De esta manera la línea de código que se debería escribir es: $[\text{net}, \text{pr}] = \text{train}(\text{net}, a, p);$

2.3.6.3.4 Preproceso y postproceso

El entrenamiento de la red puede ser más eficiente si se realiza una serie de transformaciones en las entradas y salidas de la red.

A menudo es útil investigar la respuesta de la red con más detalle. Una manera es realizar un análisis de regresión entre la respuesta de la red y sus salidas patrón. Esto se hace con ayuda de la función `postreg`. A la función `postreg` hay que introducirle la salida de la red y la salida esperada de la misma. Ésta te devuelve tres valores, los dos primeros corresponden a la pendiente y a la ordenada en el origen de la recta de regresión, y el tercero al grado de correlación de los datos. Si el grado de correlación de datos es igual a la unidad quiere decir que la respuesta de la red ante esas entradas es perfecta.

2.3.6.4 Algoritmo *backpropagation* (Pepectrón Multicapa).

González. H & Hernando.M (2000). El algoritmo de aprendizaje de retropropagación, consiste básicamente en propagar el error hacia atrás, desde la capa de salida hasta la de entrada, permitiendo así la adaptación de los pesos con el fin de reducir dicho error.

En forma simplificada, el funcionamiento de una red “*backpropagation*” consiste en el aprendizaje de un conjunto predefinido de pares de entradas y salidas dados como ejemplos, empleando un ciclo de propagación-adaptación de dos fases:

En la primera fase, o paso hacia delante, se aplica un primer patrón como estímulo para la capa de entrada de la red, éste se va propagando a través de las capas siguientes para generar la salida, la cual proporciona el valor del error al compararse con la que se desea obtener.

En la siguiente fase o paso hacia atrás, estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta intermedia que contribuyan directamente a la salida, recibiendo el porcentaje del error aproximado a la participación de las mismas en la salida original.

Este proceso se repite hacia atrás, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aporte relativo al error total. Basándose en esta información recibida, se reajustan todos los pesos de conexión, de manera que la siguiente vez que se presente el mismo patrón disminuya la diferencia entre la salida calculada y la deseada.

2.3.7 Regresión multivariable.

2.3.7.1 Definición de análisis multivariante.

Marqués, E. (2004). Podemos definir las técnicas multivariantes como, un conjunto de métodos estadísticos que permiten el análisis de forma simultánea de más de dos variables observadas en una Investigación de toda índole. Desde una concepción amplia podemos definir el Análisis Multivariante como un conjunto de métodos que analizan las relaciones entre un número razonablemente amplio de variables (medidas), tomadas sobre cada elemento de análisis, en una o más muestras simultáneamente.

2.3.7.2 Áreas de aplicación del análisis multivariante.

El análisis Multivariante es de aplicación en la Investigación, en las siguientes circunstancias:

- Reducción de datos: Se trata de simplificar la estructura del fenómeno investigado buscando la mayor simplicidad, lo que permitirá una interpretación muy fácil.
- Clasificación y agrupación: Por ejemplo las técnicas de segmentación y tipología.
- Análisis de las relaciones de dependencia, con el fin de predecir o bien explicar.
- En la construcción de modelos: Econometría

2.3.7.3 Clasificación de las técnicas multivariantes.

Los diferentes métodos de análisis multivariante no solo difieren entre sí por el objetivo o tipo de resultados obtenidos sino que existen ya diferencias en la tabulación, forma de codificar y en el trabajo con las variables ya que algunos métodos pueden trabajar con variables nominales, mientras que otros solo lo hacen con variables ordinales y métricas.

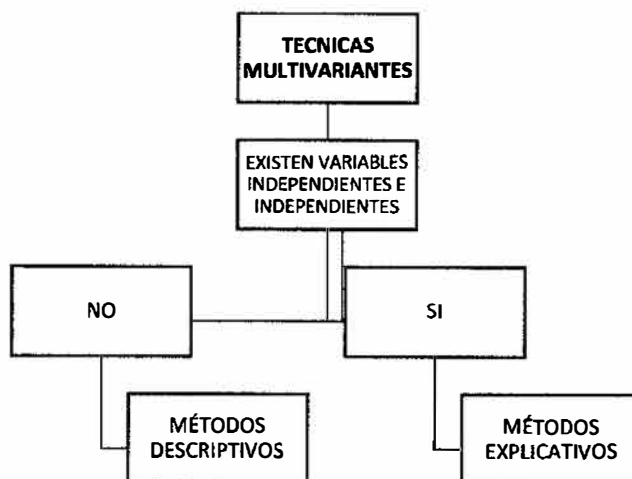
Una clasificación de gran utilidad es el diferenciar las técnicas multivariantes en dos grupos básicos:

Métodos descriptivos o de interdependencia y métodos explicativos o de dependencia.

Los métodos explicativos o de dependencia se emplean para explicar o proyectar la(s) variable(s) dependiente(s) con base en dos o más variables independientes.

Marqués. E (2004). Hace la clasificación de las técnicas multivariantes las podemos resumir en el siguiente esquema.

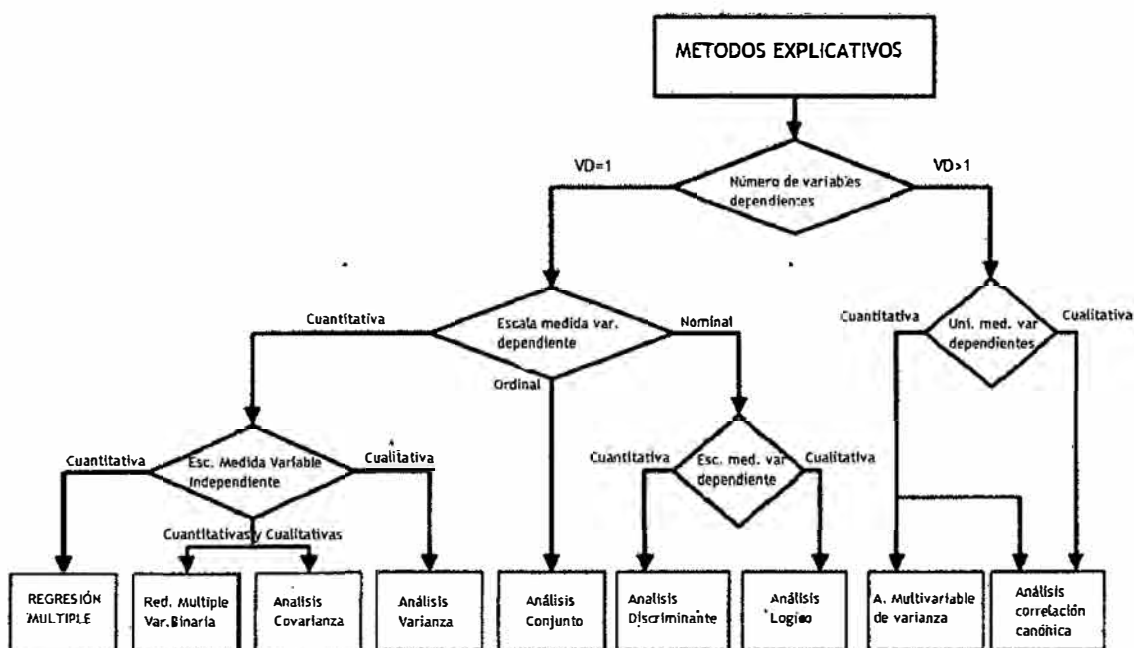
TABLA 7. Técnicas multivariantes.



FUENTE: Marqués., E. J. (2004). "Introducción Al Análisis Multivariable".

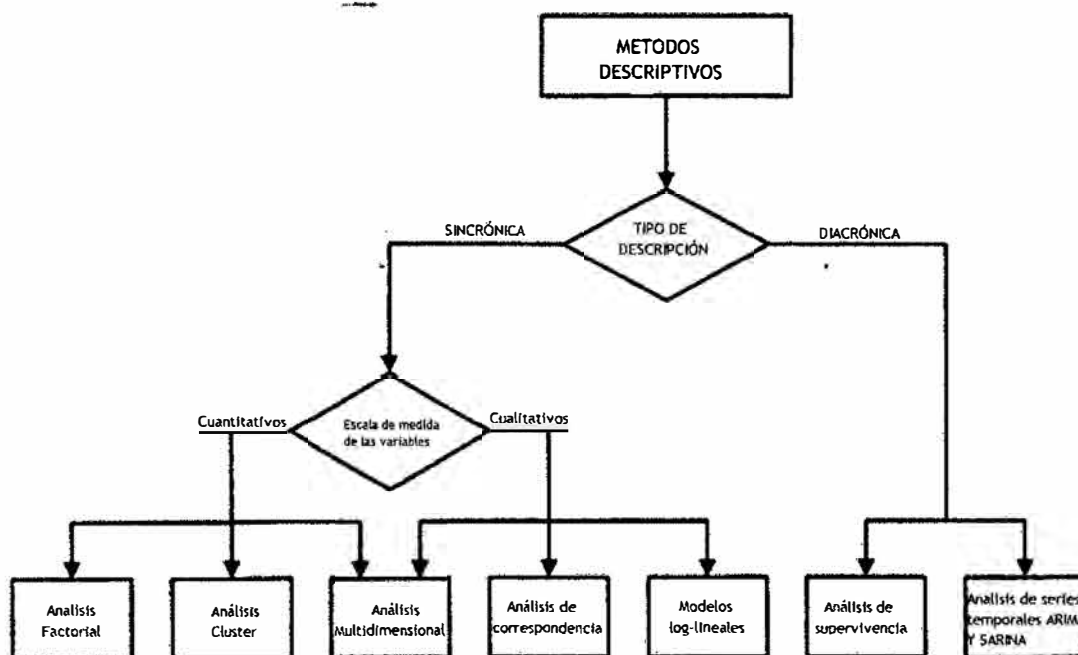
Los métodos explicativos y descriptivos, a su vez se dividen de acuerdo con diferentes criterios los más habituales son los que reseñamos en los siguientes esquemas.

FIGURA 10. Métodos explicativos.



Fuente: <http://www.slideshare.net/tecnomexico/analisis-multivariable>.

FIGURA 11. Métodos descriptivos.



FUENTE: <http://www.slideshare.net/tecnomexico/analisis-multivariable>.

2.3.8 Kinovea.

Kinovea proporciona herramientas para el análisis de movimientos que pueden ser aplicadas a videos o una secuencia de imágenes, es un software muy dinámico capaz de interpretar vectorialmente movimientos en todas las direcciones, proporcionando un método de evaluar movimientos y actuación de una distancia.

El análisis del movimiento de video proporciona los datos dependientes del tiempo, y valores numéricos en cualquier actividad basado en el movimiento, del nivel microscópico a los eventos de gran potencia.

FIGURA 12. Simulación de movimiento en Kinovea.



Fuente: www.kinovea.org

2.3.9 Explosivo.

EXSA, (2002). Los materiales explosivos son compuestos o mezclas de sustancias en estado sólido, líquido o gaseoso, que por medio de reacciones químicas de óxido-reducción, son capaces de transformarse en un tiempo muy breve, del orden de una fracción de microsegundo, en productos gaseosos y condensados, cuyo volumen inicial se convierte en una masa gaseosa que llega a alcanzar muy altas temperaturas y en consecuencia muy elevadas presiones.

2.3.10 Clasificación de los explosivos.

Los explosivos se clasifican según la forma de producir la energía, como se puede apreciar en el siguiente gráfico:

FIGURA 13. Clasificación de explosivos.



FUENTE: Búsqueda de imágenes google.

2.3.10.1 Explosivos Mecánicos

La energía se genera a través de la vaporización repentina de materias inertes, por medio de la introducción de un material a muy alta. Artefacto (cardox) que consiste en un tubo ajustado con un disco de ruptura y lleno de dióxido de carbono líquido. Al encenderse el elemento calefactor, el disco se rompe y los gases emanados se expanden dentro de la perforación provocando el rompimiento de la roca.

2.3.10.2 Explosivos Nucleares

La liberación de la energía se realiza por fusión o fisión nuclear. Consiste en Plutonio, Uranio 235 o materiales similares, lo que se activan atómicamente y se controlan hasta un nivel crítico que al ser sobrepasado se genera una explosión del orden de los 10^{15} pie-lb/lb mientras que en los químicos se produce un trabajo del orden de los 8×10^4 pie-lb/lb

Los explosivos químicos industriales están constituidos por una mezcla de materiales combustibles y oxidantes que al ser iniciados apropiadamente dan lugar a una reacción química muy rápida. En la reacción, el explosivo libera grandes volúmenes de gases y energía hacia la roca, causando fragmentación, fisuras y grietas. Cada explosivo posee una composición química específica:

Explosivos Ideales: poseen las mismas características (velocidad, presión de detonación) cualquiera sea su diámetro, forma o condiciones ambientales (TNT, PETN, NG).

Explosivos No Ideales: dependen del diámetro, temperatura, confinamiento, etc. (ANFO, el ANFO pesado), emulsiones, acuageles, slurries.

2.3.10.3 Explosivos Químicos

Por sus características de explosión se dividen en altos y bajos explosivos, a su vez, los altos explosivos se clasifican en primarios y secundarios. Los primarios por su alta energía y sensibilidad se emplean como iniciadores para detonar a los secundarios

2.3.10.3.1 Altos explosivos.

Detonan cuando son iniciados y alcanzan presiones de hasta 70.000 Kg/cm².

a) Primarios.

Las características de los primarios son las siguientes:

- Extremadamente sensibles a la iniciación ya sea por fricción, calor o impacto
- Inician explosivos secundarios
- Se utilizan en los detonadores

- Azida de Plomo
- Fulminato de Mercurio

b) *Secundarios.*

Las características de los secundarios son las siguientes:

- Llamados Altos explosivos, menos sensibles a la iniciación, algunos deflagran.
- Carga principal en explosivos militar.
- Cebos para explosivos comerciales.
- TNT, PETN, RDX, o mezcla de ellos, como la Pentolita, Octol, Etc.

TABLA 8. Clasificación de explosivos secundarios.



Fuente: Manual orica.

2.3.10.3.2 *Bajos explosivos*

Deflagran cuando son iniciados y alcanzan presiones de hasta 10.500 Kg / cm².

2.3.10.4 Explosivos Comerciales.

Se basan en mezclas de nitrato de amonio y/o nitroglicerina como principal ingrediente y se clasifican en:

- **Dinamitas:** Regulares o Amoniacales, algunas pueden considerarse altos explosivos.
- **Gelatinas:** son dinamitas regulares o amoniacaes que han sido gelificadas mediante nitrocelulosa para darle mayor resistencia al agua.
- **Agentes Explosivos:** agente explosivos secos, slurries y emulsiones.


2.3.10.5 Explosivos Deflagrantes.

Llamados explosivos bajos, detonación y combustión rápida o deflagran dentro de estos también está la pólvora que se utiliza para mecha de seguridad o para composiciones pirotécnicas.

2.3.10.6 Detonación y deflagración.


- a) **Deflagración:** Es un proceso exotérmico en el que la transmisión de la reacción de descomposición se basa, principalmente, en la conductividad térmica. Es un fenómeno superficial en el que la fuente de deflagración se propaga por el explosivo en capas paralelas, a una velocidad baja que, generalmente, no supera los 1000 m/seg.
- b) **Detonación:** Es un proceso Físico - Químico, caracterizado por su gran velocidad de reacción y formación de gran cantidad de productos gaseosos a elevada temperatura, los que adquieren una gran fuerza expansiva.

FIGURA 14. Curvas detonación y deflagración.



Fuente: manual de exsa.

FIGURA 15. Propagación de la onda de choque.



Fuente: Ames Lara, V. (2012) Tecnología de Explosivos


2.3.11 Propiedades de los explosivos.

- a) *Densidad*. Es el peso específico, expresado en gramos por centímetro cúbico.

Este es el peso por unidad de volumen o gravedad específica. Generalmente en la energía de las dinamitas incrementan con la densidad del cartucho, en cambio en los explosivos a base de agua (emulsiones) la densidad y la energía no están relacionadas. La densidad de un explosivo, permite determinar el peso de la carga explosiva por metro.

En la mayoría de los explosivos varía entre 0.78 - 1.6 g/cc.

FIGURA 16. Toma de densidades de la emulsión gasificada.



Fuente: Muestreo en campo

- b) *Velocidad de detonación (vod)*.

Es la razón a la cual las ondas de detonación viajan a través de la columna explosiva.


- El VOD es importante para determinar la funcionalidad y desempeño del explosivo (efectividad).

- La VOD fluctúa entre 2438 a 7925 m/s, menores a 2000 m/s, se dice que el explosivo deflagra.
- El VOD es afectado por: Composición, tamaño de partícula, densidad (grado de confinamiento/diámetro del explosivo).
- El VOD alto favorece para quebrar roca dura, mientras que un explosivo con baja VOD tiende a liberar presión de gas por mayor tiempo (mayor desplazamiento).

c) *Presión de detonación.*

Es la presión en la zona de reacción detrás del frente de detonación plano C-J. Es un indicador significativo de la habilidad de un explosivo para producir fragmentación deseada en un burden bien consolidado. Esta presión a menudo se mide en kilobares.

FIGURA 17. Proceso de detonación del explosivo.



Fuente: Imágen obtenida de Teoría de la Voladura.

Una alta presión de detonación es una de las características más importante que un explosivo debe tener si es usado como prima.

La presión de detonación es medida por medio del test acuático:

Fórmula de la presión de detonación:

$$PD = \frac{\rho_e * VOD^2}{4} \quad (8)$$

Donde:

PD: Presión de detonación (Kpa).

ρ_e : Densidad del explosivo (g/cm^3)

VOD: Velocidad de detonación (m/s)

La presión desarrollada por la partícula del explosivo en el agua puede ser calculada usando la ecuación (ley de conservación de la energía).

$$PD = \rho_e * VOD^2 * 2.354 * 10^{-7} \quad (9)$$

Donde:


PD: Presión de detonación (Kpa).

ρ_e : Densidad del explosivo (g/cm^3)

VOD: Velocidad de detonación (m/s)

La presión en el pozo es aproximadamente un 50% de la presión de detonación, aunque podría variar desde un 30% a 70% dependiendo de la formulación del explosivo.

FIGURA 18. Presión de detonación del explosivo.



Fuente: capacitación presión dinámica Orica.

d) *Sensibilidad*

Respecto a la sensibilidad de un explosivo hay dos tipos de sensibilidad.

Sensibilidad a la Iniciación.- facilidad con que el explosivo puede ser iniciado (Se somete el explosivo a ensayos tales como el de la sensibilidad al detonador, el de fricción, de caída, de impacto o choque, de calor, etc.).

Sensibilidad a la propagación.- habilidad de un explosivo para propagarse a lo largo del mismo; Esta propiedad es muy importante en operaciones de voladura, ya que una mayor sensibilidad puede producir traslape en la voladura, esto debido a la reducción de los beneficios de retardos, generando mala fragmentación, vibraciones excesiva, ruido, etc.

e) **Energía (potencia/ fuerza.)**

La energía de un explosivo es una medida de su habilidad para trabajar en sus alrededores. La energía de un explosivo es utilizada para: quebrar en

los alrededores de las paredes del pozo, formar fracturas, calor y luz, movimiento del material, vibración, air blast, corte por cizalle (shearing). Esta energía puede ser calculada ó medida (mortero balístico, energía de burbuja).

La energía se expresa en términos de peso ó volumen del explosivo.

La energía también puede ser expresada en números relativos ó absolutos.

La energía se expresa en cal/g ó cal/cc, es decir, cantidad de energía en calorías disponibles en cada gramo o centímetro de explosivo.

f) *Resistencia al agua.*

Se refiere a la habilidad para detonar después de que un explosivo es expuesto al agua, pruebas diseñadas para medir esta propiedad varían de las intenciones y condiciones de uso y de la sensibilidad del producto.

g) *Características de seguridad.*

Se refiere a la capacidad de soportar adversidades que pueden tener los explosivos ante situaciones como: Impactos, fricción, al fuego, electricidad estática, transporte, etc.

h) *Estabilidad a la temperatura.*

La temperatura a la cual los explosivos son almacenados y usados pueden tener un efecto determinante. En temperaturas bajas la dinamita se endurecerá y su efectividad será incierta. Las emulsiones modernas soportan de buena forma temperaturas bajas.

i) *Generación de humos.*

Un exceso de oxígeno en el explosivo generará óxidos nitrosos (NO y NO₂) y un déficit de oxígeno pueden causar la formación de monóxido de carbono (CO). Estos gases son tóxicos y una exposición puede ser fatal.


TABLA 9. Concentración (mol/ Kg) de Gases de Explosión de un ANFO a varios B.O.

Gases de Explosión	B.O 9.00 %	B.O 0.00 %	B.O -16.00 %
H ₂ O	26.40	27.50	27.20
N ₂	9.30	11.80	11.20
NO	5.70	0.00	0.00
CO ₂	2.10	3.90	2.70
CO	0.00	0.00	1.10
CH ₄	0.00	0.00	0.20
H ₂	0.00	0.00	1.90
NH ₃	0.00	0.00	0.10

Fuente: Termoquímica de explosivos.

FIGURA 19. Rendimiento del ANFO

ANFO Performance



Fuente: Termoquímica de explosivos.

j) *Vida útil.*

Tiempo de un explosivo puede ser almacenado sin que su performance o seguridad sean afectadas, dicho explosivo dependerá del tipo de explosivo y de las condiciones de temperatura y humedad existentes.

En particular interés son las dinamitas; el proceso natural de deterioro que sufre la nitroglicerina que la compone, afectará su sensibilidad, haciéndoles más peligrosas de manipular. Los slurries sensibles al detonador puede llegar a insensibilizarse en condiciones de baja temperatura; las dinamitas a pesar de contener sustancias anticongelantes, pueden ser sumamente peligrosas en caso de congelamiento.

k) *gases tóxicos.*

Los principales gases durante la detonación son:

- CO₂ , N , H₂O (No tóxicos).
- CO, NO , NO₂ (Tóxicos).
- Exceso de oxígeno
- Óxidos de nitrógeno
- Defecto de oxígeno monóxido de carbono

TABLA 10. Límites permisibles de concentración de gases.

Explosivos Permisibles USBM			Explosivos NO Permisibles IME		
Clase	Concentración de gases tóxicos (Pie ³ /libras)	Concentración de gases tóxicos (Litros/Kg)	Clase	Concentración de gases tóxicos (Pie ³ /libras)	Concentración de gases tóxicos (Litros/Kg)
A	< 1.5	<78	1	<0.16	<10
B	1.25 a 2.5	78 a 156	2	0.16 a 0.33	10 a 21
C	2.5 a 3.75	156 a 234	3	0.33 a 0.67	21 a 42

Fuente: Manual de geomecánica.

* No se considera la toxicidad relativa de los distintos clases de explosivo

(NO = 6 CO)

Los principales factores que afectan la producción de gases tóxicos son:

Balance de Oxígeno en la formulación Química

Cebado Inadecuado

Ataque de agua

Diámetro de Carga cercano al diámetro crítico

Mala práctica de carga en el taladro (Cavidades en la columna de explosivo)

Deflagración del Explosivo (Reacción Incompleta)

1) *Impedancia.*

Es el producto de la velocidad y la densidad. La máxima utilización de la energía del explosivo en el proceso de fragmentación es necesario equiparar la impedancia del explosivo lo más cercanamente posible a la impedancia de la roca.

2.3.12 Tecnología de las emulsiones.

2.3.12.1 Emulsión.

Es una mezcla estable de al menos dos líquidos inmiscibles entre sí, en que cada uno de éstos forma una fase independiente. Una fase se dispersa en forma de pequeñas gotas o celdas dentro de otra que forma la matriz o fase continua. Para lograr su estabilización se agrega agente tenso activos (emulsificantes). Las emulsiones explosivas son del tipo “agua en aceite”.

2.3.12.2 Características de una emulsión.

a) *Eficiencia*

Mayor Aprovechamiento de la Energía Teórica

Altas Velocidades de Detonación (VOD)

b) *Flexibilidad.*

Puede formularse un amplio rango de productos, según los requerimientos:

- Encartuchados (papel o plástico)

- Vaciables
- Bombeables

Para diámetros pequeños, intermedios o grandes, con o sin sensibilidad al fulminante.

c) *Estabilidad - transporte y bombeo.*

- Transportable y Rebombeable
- Bombeable a Bajas Temperaturas

2.3.12.2.1 *Emulsificación gasificada.*

La emulsión gasificada consiste en la incorporación de microburbujas de gas generadas in-situ en la masa de emulsión (hot spots), por una reacción química catalizada, a temperatura ambiente, de nitrito de sodio y nitrato de amonio, lo cual genera gas nitrógeno.

Dicha reacción se lleva a cabo de manera muy lenta y con la finalidad de acelerarla se agrega ácido acético, el cual cumple la función de romper algunas microgotas de emulsión y liberar al nitrato de amonio en su interior para que reaccione con el nitrito de sodio, además también cumple la función de acelerar la reacción de formación del gas nitrógeno.

Mediante la incorporación de microburbujas de gas generadas in-situ en la masa de emulsión, por una reacción química catalizada, a temperatura ambiente, de nitrito de sodio y nitrato de amonio, se aumenta la sensibilidad de la mezcla y se reduce su densidad.

La gasificación química permite fabricar explosivos de alta eficiencia y gran versatilidad de uso, con un costo menor que la aplicación de agentes de control de densidad sólidos (como las microesferas de vidrio o cerámica) que son una solución costo-efectiva cuando no se requiere una VOD especialmente alta.

La densidad puede ser variada dentro de un amplio rango, usualmente entre 0,8 y 1,3 g/cc, modificando la proporción de aditivos.

2.3.12.2.2 *Productos gasificables.*


Los objetivos son: Reducir y regular la densidad del producto explosivo.

Disminución del factor de carga sobre 10 % (aproximadamente 12 - 14 %, según las condiciones de terreno).

Mejores propiedades de la voladura, debido a mayores VOD y sensibilidad del explosivo.

Por su mayor temperatura de reacción química permiten una reacción más completa y más eficiente, ayudando a reducir la generación de gases nitrosos (humos rojos), en terrenos saturados de agua, especialmente si estás son dinámicas y/o de muy baja temperatura.

FIGURA 20. Emulsión fortis extra73 gasificadando.



Fuente: Muestreo en campo.

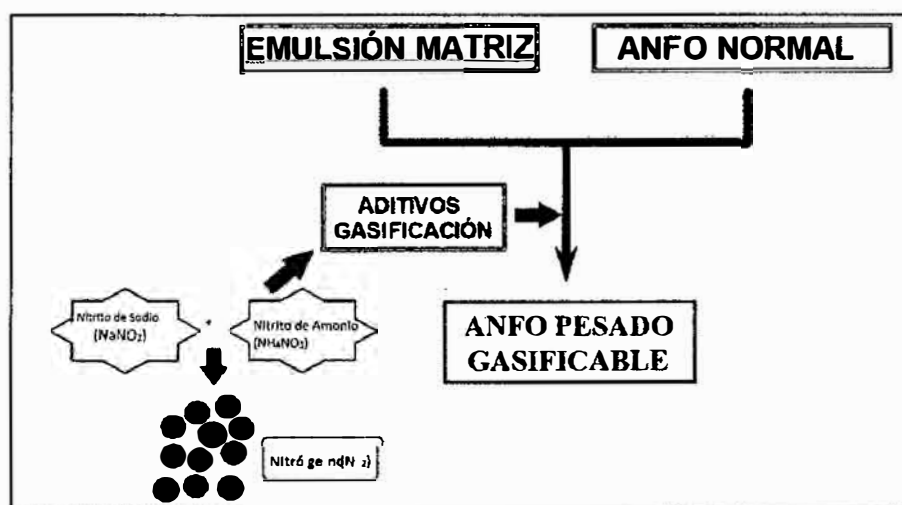
Ventajas:

Mayor velocidad de detonación que las mezclas Emulsión / Anfo regulares y las gasificadas químicamente.

Permite optimizar la fragmentación del material volado. Esto, a su vez, permite reducir los costos de extracción y conminución del mineral.

Mayor eficiencia termodinámica de su proceso de detonación que los Anfos Pesados Regulares, en particular en presencia de agua. Esto permite ampliar las mallas de perforación u obtener mejor fragmentación y mayor desplazamiento de la pila de material tronado al usar similar factor de carga, en condiciones similares de roca, según se requiera

FIGURA 21. Proceso de la gasificación de la emulsión.



Fuente: manual orica.

2.3.13 Geomecánica aplicado a la voladura.

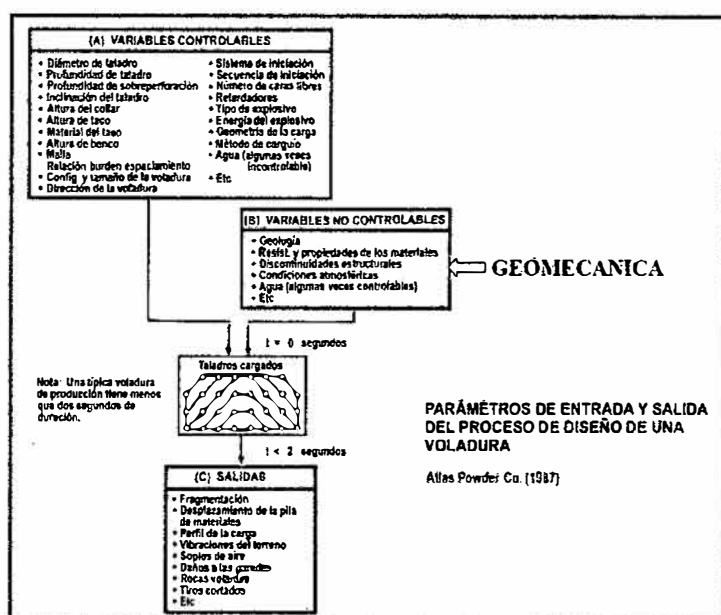
La problemática de la geomecánica en todos los diseños estructurales es la predicción del comportamiento de la estructura bajo las cargas actuantes o durante su vida útil. La temática de la mecánica de rocas, como una práctica aplicada a la ingeniería de minas, es concerniente a las aplicaciones de los principios de la ingeniería mecánica y al diseño de las estructuras de roca generadas por la actividad minera. Esta disciplina está estrechamente relacionada con las corrientes principales

de la mecánica de rocas clásica y de la mecánica de materiales, pero hay varios factores específicos que la identifican como un campo distinto y coherente de la ingeniería.

2.3.13.1 Los efectos de la geología en la voladura.

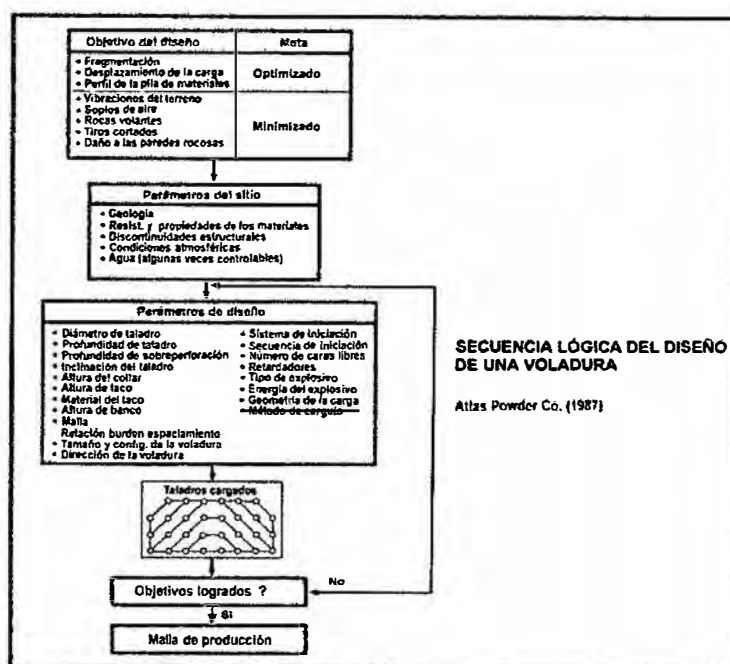
Los resultados de las voladuras son influenciados más por las propiedades de la roca que por las propiedades de los explosivos.

FIGURA 22. Variables controlables e incontrolables.



Fuente: Atlas poder co. (1987)

FIGURA 23. Secuencia del diseño de una voladura.



Fuente: Atlas poder co. (1987)

2.3.13.2 Macizo rocoso.

Para efectos de ingeniería debe considerarse que el macizo rocoso es un volumen “importante” de roca que se encuentra intersectado total o parcialmente por estructuras geológicas, las cuales definen numerosos bloques que en conjunto, conforman el macizo rocoso.

El macizo rocoso está conformado por un conjunto de bloques (los más pequeños de los cuales corresponden a lo que usualmente se denominan “roca intacta, cuyas geometrías y distribución de tamaños queda definida por las estructuras geológicas.

El comportamiento de los macizos rocosos dependerá de los siguientes factores:

- Propiedades mecánicas de los bloques que lo constituyen (estas serán similares a los de la roca intacta para bloques de menor tamaño y menos competentes que las de la roca intacta, para los bloques de mayor tamaño).
- Propiedades de las estructuras presentes en el macizo rocoso (de mucha menor competencia que la roca intacta), las que son especialmente relevantes cuando estas estructuras definen cinemáticas de una eventual falla o ruptura del macizo rocoso.
- Interacción del conjunto de bloques.

2.3.13.2.1 Propiedades de las rocas.

Los materiales que constituyen la masa rocosa poseen ciertas características físicas que son función de su origen y de los procesos geológicos posteriores que sobre ellos han actuado.

- a) *densidad*. La densidad y la resistencia de las rocas presentan normalmente una correlación. En general, las rocas de baja densidad se deforman y rompen con facilidad, sucediendo lo contrario con las rocas más densas, necesitando ellos mayor cantidad de energía para lograr una fragmentación satisfactoria, buen desplazamiento y esponjamiento.
- b) *Resistencias dinámicas de las rocas*. Las resistencias estáticas a compresión y tracción se utilizaron en un principio como parámetros indicativos de la roca a la voladura. El tratamiento de los problemas reales obliga a considerar las resistencias dinámicas, ya que éstas aumentan con el índice de carga, pudiendo alcanzar valores entre 5 y 13 veces el valor de las estáticas.

c) *Porosidad*. Existen dos tipos de porosidad, la intergranular o de formación y la de disolución o post-formación. La primera, que puede considerarse uniforme en la masa rocosa, provoca dos efectos:


- Reducción de la resistencia dinámica a la compresión, y en consecuencia incremento de la trituración y porcentaje de finos.

El trabajo de fragmentación de rocas muy porosas se realiza fundamentalmente por la energía de burbuja.

La segunda es la causada por los huecos y cavidades que resultan de la disolución del material rocoso por las aguas subterráneas (karstificación).

Los espacios vacíos son muchos mayores siendo su distribución menos uniforme que la porosidad intergranular. Las cavidades intersectadas por los taladros no solo dificultan la perforación con la pérdida de varillaje, sino incluso la eficiencia de la voladura, especialmente cuando se utilizan explosivos a granel.

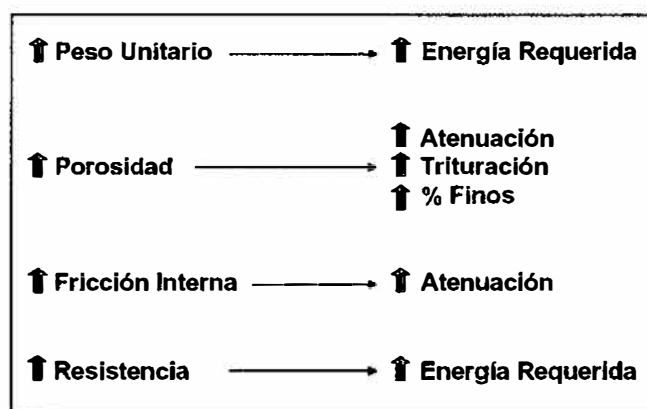
FIGURA 24. Ejecución correcta de la carga de un explosivo a granel en un terreno con cavernas o huecos.



FUENTE: Capacitación en geomecánica.

- d) *Fricción interna*. Como las rocas no constituyen un medio elástico, parte de la energía de la onda de tensión que se propaga se convierte en calor por diversos mecanismos. Estos mecanismos son conocidos por fricción interna o capacidad de amortiguación específica (SDC), que mide la disponibilidad de las rocas para atenuar la onda de tensión generada por la detonación del explosivo.
- e) *Conductividad*. Las fugas o derivaciones de corriente pueden ocurrir cuando los detonadores se colocan dentro de los taladros en rocas con cierta conductividad, como por ejemplo, los sulfuros complejos, magnetitas, etc, especialmente cuando las rocas son abrasivas y hay existencia de agua en el entorno de la voladura.
- f) *Composición de la roca*. Las explosiones secundarias de polvo suelen producirse en minas de carbón y también de sulfuros metálicos, en áreas con alto contenido en pirita, y son cada día más frecuentes por la utilización de taladros de gran diámetro. Las primeras cargas que se disparan en una voladura crean por un lado, una alta cantidad de finos que son lanzados a la atmósfera y por otro, remueven con la onda aérea y la vibraciones inducidas el polvo depositado en los hastiales y el piso del hueco de la excavación.

FIGURA 25. Efectos de las propiedades en la roca intacta.




Fuente: Introducción a la geomecánica.

g) *Litología*. La voladura en zonas donde se produce un cambio litológico brusco, por ejemplo estéril y mineral, y consecuentemente una variación de las propiedades resistentes de las rocas obliga a reconsiderar el diseño, pudiendo seguir dos alternativas:

- Esquemas iguales para los dos tipos de roca y variación de las cargas unitarias.
- Esquemas distintos pero con igual carga por taladro.

FIGURA 26. Cambio de esquema recomendado.




Fuente: Introducción a la geomecánica.

En los yacimientos estratiformes que presentan algún horizonte muy resistente, es conveniente que las cargas estén confinadas y ubicadas en tales horizontes, a fin de aprovechar al máximo la energía de tensión desarrollada.

Cuando los taladros atraviesan un contacto de dos materiales de características diferentes, como por ejemplo una caliza competente en contacto con arcillas muy plásticas, se tendrá una gran pérdida de energía asociada a la

caída de presión y escape de los gases al producirse deformaciones rápidas de dichos materiales blandos, dando como resultado una mala fragmentación.

FIGURA 27. Casos típicos de cambios litológicos con contactos entre rocas competentes y materiales plásticos.



Fuente: Introducción a la geomecánica.

Para aumentar el rendimiento de la voladura en estos casos se recomienda:


- Retacar con material adecuado aquellas zonas del taladro que estén en contacto con material plástico o próximo a ellas.
- Emplear cargas de explosivo totalmente acopladas a la roca competente con una gran velocidad de detonación.
- Situar los multiplicadores en el punto medio de la roca dura para incrementar la resultante de la onda de tensión.

- Evitar el escape prematuro de los gases al aire asegurando con una buena longitud del taco (al menos 20 D).
- h) *Fracturas preexistentes*. Todas las rocas presentan discontinuidades, microfisuras y macrofisuras, que influyen de manera directa en las propiedades físicas y mecánicas de las rocas y consecuentemente en los resultados de la voladura. Las superficies de discontinuidad pueden ser de distintos tipos: planos de estratificación, planos de laminación y foliación primaria, planos de esquistosidad y pizarrosidad, fracturas y juntas.

Las discontinuidades pueden ser abiertas, cerradas o rellenas y por ello, tienen diferentes grados de transmisión de la energía del explosivo.

Otro aspecto del diseño de voladura es el control geoestructural de la masa rocosa en referencia a la orientación relativa del frente y dirección de salida del disparo con respecto a la dirección y buzamiento de los estratos.

FIGURA 28. Resultados previsibles para los diferentes casos que pueden presentarse con respecto a la inclinación de las discontinuidades y el ángulo relativo de las direcciones.



Fuente: Introducción a la geomecánica

- i) *Tensiones de campo.* Cuando actúan las tensiones de cargas residuales, tectónicas y/o gravitacionales, el esquema de fracturas generado alrededor de los taladros puede estar influenciado por la concentración no uniforme de tensiones alrededor del mismo. En rocas masivas homogéneas, las grietas que empiezan a propagarse

radialmente desde los taladros tienden a seguir la dirección de las tensiones principales.

j) *Presencia de agua.* Las rocas porosas y los macizos rocosos intensamente fracturados, cuando se encuentran saturados de agua presentan habitualmente ciertos problemas:

- Obligan a seleccionar explosivos no alterables por agua.
- Producen la pérdida de taladros por hundimientos internos.
- Dificultan la perforación inclinada.

Por otro lado, el agua afecta a las rocas y a los macizos rocosos en los siguientes aspectos:

- Aumentan la velocidad de propagación de las ondas elásticas en terrenos porosos y agrietados.
- Reduce la resistencia de compresión y tracción de las rocas.
- Reduce la atenuación de las ondas de choque.
- Las juntas llenas de agua permiten el paso de las ondas de choque.

k) *Temperatura del macizo rocoso.*

Los yacimientos que contienen piritas suelen presentar problemas de altas temperaturas de la roca por efecto de la oxidación, haciendo que los agentes explosivos del ANFO reaccionen a partir de una temperatura de 120°. La sensibilidad de los explosivos tipo hidrogel depende también de la temperatura de la roca con la que está en contacto.

Una recomendación general cuando se presentan estos problemas es delimitar el número de taladros por voladura a fin de disminuir el tiempo que transcurre entre la carga y el disparo.

FIGURA 29. Información requerida por geotecnia.

Fuente: fotografía de campo.

2.3.13.3 *Técnicas de clasificación de macizos rocosos.*

La clasificación de los macizos rocosos se basa en sistemas que le asignan diversos factores de peso a los valores de ciertas cantidades medibles para obtener un índice global. Debido a los diferentes factores de peso y a las diferencias en la experiencia inherente al desarrollo de cada sistema, no existe una relación uno a uno entre sistemas de clasificación.

TABLA 11. Clasificación del macizo rocoso.

Q	Rock Mass Quality	Barton et al (1974)
RMR	Rock Mass Rating	Bieniawski (1976)
MRMR	Mining Rock Mass Rating	Laubscher (1977)
RMS	Rock Mass Strength	Selby (1980)
SMR	Slope Mass Rating	Romana (1985)
SRMR	Slope Rock Mass Rating	Robertson (1988)
BQ	Index of rock mass basic quality	Lin (1988)
GSI	Geologic Strength Index	Hoek (1994)
CSMR	Chinese system for SRMR	Chen (1995)
RMI	Rock Mass index	Palmström (1995)
M-RMR	Modified rock mass classification	Unal (1996)

Fuente: google images.

2.3.13.3.1 Clasificación geomecánica de Protodyakonov.

Según Pérez, A. (2008). Mediante esta clasificación geomecánica se define la calidad del macizo rocoso, por medio de un parámetro “f”, que es el coeficiente de resistencia.

TABLA 12. Valores del coeficiente “f” según el tipo de roca.

CATEGORIA	DESCRIPCION	"f"
Excepcional	Cuarcita, Basalto y rocas de resistencia excepcional	20
Alta resistencia	Granito, areniscas silíceas y calizas muy competentes	15 - 20
Resistencia media	Calizas, granito algo alterado y areniscas	8-6
	Areniscas medias y Pizarras	5
	Lutitas, areniscas flojas y conglomerados friables	4
	Lutitas, esquistos y margas compactas	3
Resistencia baja	Calizas, lutitas blandas, margas, areniscas friables,	2
	Gravas, bolos cementados	
	Lutitas fisuradas y rotas, gravas compactas y arcillas	1.5
	Preconsolidas	

Fuente: Manual de geomecánica Carlos Arturo Pérez Macavilca.

El coeficiente “f” está dado por la siguiente fórmula matemática, el valor del coeficiente es adimensional.

$$f = \sigma_c / 10 \text{ (10)}$$

Dónde: σ_c = resistencia a la compresión simple de la roca en Mpa.

2.3.13.3.2 Clasificación geomecánica de Bieniawski.

Según Carlos Arturo Pérez Macavilca, (2008) el RMR es una clasificación geomecánica, en la que se tienen en cuenta los siguientes parámetros del macizo rocoso.2

- Resistencia Compresiva de la roca.
- Índice de la Calidad de la Roca - RQD.
- Espaciamiento de Juntas.
- Condición de Juntas.
- Presencia de Agua.
- Corrección por orientación.

Estos factores se cuantifican mediante una serie de parámetros definiéndose unos valores para dichos parámetros, cuya suma, en cada caso nos da el índice de Calidad del RMR que varía entre 0 – 100.

Los objetivos de esta clasificación son:

- Determinar y/o Estimar la calidad del macizo rocoso.
- Dividir el macizo rocoso en grupos de conducta análoga.
- Proporcionar una buena base de entendimiento de las características del macizo rocoso.

TABLA 13. Estimación del valor RMR en función a la calidad de la roca.

Clase	Calidad	RMR	Cohesión (Kpa)	Angulo de fricción (°)
I	muy buena	81-100	> 400	> 45
II	buena	61-80	300-400	35-45
III	regular	41-60	200-300	25-35
IV	mala	21-40	100-200	15-25
V	muy mala	0-20	< 100	< 15

Fuente: "Engineering Rock Mass Classifications", Bieniawski, Z. T.

2.3.13.4 Resistencia compresiva de la roca.

Según Pérez, A. (2008) la resistencia compresiva de una roca se puede determinar por tres procedimientos.

Primer Procedimiento

Estimación de la Resistencia Compresiva mediante el martillo Schmidt de Dureza.

Segundo Procedimiento

Determinación de la Resistencia Compresiva mediante el Ensayo de Carga Puntual "Franklin".

Tercer Procedimiento

Determinación de la Resistencia Compresiva mediante el Ensayo de Compresión Simple y/o Uniaxial.

2.3.13.5 Índice de la calidad de la roca – RQD.

Según Bieniawski, Z. T. (1989) Para determinar el RQD (Rock Quality Designation) en el campo y /o zona de estudio de una operación minera, existen hoy en día tres procedimientos de cálculo.3

Primer Procedimiento

Se calcula midiendo y sumando el largo de todos los trozos de testigo mayores que 10 cm en el intervalo de testigo de 1.5 m³.

$$RQD = \frac{\sum \text{Trozos} > \text{ó} = 10 \text{ cm}}{\text{Longitud total de taladro}} \times 100 \quad (11)$$

Segundo Procedimiento

Comprende el cálculo del RQD en función del número de fisuras, por metro lineal, determinadas al realizar el levantamiento litológico-estructural (Detail line) en el área y/o zona predeterminada de la operación minera.3

Fórmula matemática:

$$RQD = 100\lambda^2(0.1\lambda + 1) \quad (12)$$

Donde:

λ = N° de fisuras/espaciamento

Tercer Procedimiento

Comprende el cálculo del RQD en función del número de fisuras, por metro cúbico, determinadas al realizar el levantamiento litológico-estructural (Detail line) en el área y/o zona predeterminada de la operación minera.

Fórmula matemática de Palmstrom:

$$RQD = 115 - 3.3(Jv) \quad (13)$$

Siendo:

Jv = Número de fisuras por metro cúbico.

2.3.13.6 Espaciamento de juntas.

Según Bieniawski, Z. T. (1989) Se ha comprobado que el espaciamento de juntas tiene gran influencia sobre la estructura del macizo rocoso. La resistencia del macizo rocoso va disminuyendo según va aumentando el número

de juntas, siendo el espaciado de las juntas el factor más influyente en esta disminución de resistencia. Así resulta que un material rocoso de alta resistencia de 100MPa a 200 MPa, que esté muy fracturado con un espaciado de juntas de 5 cm, corresponde a un macizo rocoso débil. A continuación se presenta la clasificación de Deere de los macizos rocosos. Se recomienda utilizar en la clasificación geomecánica de Bieniawski.³

TABLA 14. Determinación del tipo de macizo rocoso en función a las juntas

DESCRIPCIÓN ESPACIAMIENTO	ESPACIO DE JUNTAS	TIPO MACIZO ROCOSO
Muy ancho	> 3 m	Sólido
Ancho	1 - 3 m	Masivo
Moderadamente	0.3 - 1 m	En bloques
Cerrado	50 - 300	Fracturado
Muy cerrado	mm	Machacado

Fuente: "Engineering Rock Mass Classifications", Bieniawski, Z. T.

2.3.13.7 Condición de juntas.

En este apartado se tienen en cuenta los siguientes parámetros:

a) Apertura.

La apertura de las juntas es un criterio para descripción cuantitativa de un macizo rocoso. La clasificación de Bieniawski es la siguiente:

TABLA 15. Condiciones de las juntas.

Descripción	Separación
Abierta	> 5 mm
Moderadamente abierta	1 - 5 mm
Cerrada	0.1 – 1 mm
Muy cerrada	< 0.1

Fuente: "Engineering Rock Mass Classifications", Bieniawski, Z. T.

- b) Tamaño. El tamaño de las juntas influye en la importancia que el material rocoso y la separación de las juntas tienen en el comportamiento del macizo rocoso.
- c) Rugosidad. En esta clasificación se establecen 5 categorías de rugosidad: muy rugosa, rugosa, ligeramente rugosa, suave y espejo de falla.
- d) Dureza De Los Labios De La Discontinuidad. Se consideran 3 categorías de dureza: dura, media y blanda.
- e) Relleno. Se define por su espesor, tipo de material, consistencia y continuidad.

2.3.13.8 Corrección por orientación.

A la hora de considerar los efectos de la orientación de las discontinuidades para la clasificación del macizo rocoso, con vistas a la construcción de una excavación subterránea y una labor minera superficial, es suficiente considerar si las orientaciones del rumbo y del buzamiento son más o menos favorables con relación a la labor minera que se va ejecutar.

Bieniawski ha propuesto la siguiente clasificación:

TABLA 16. Corrección por orientación del RMR.

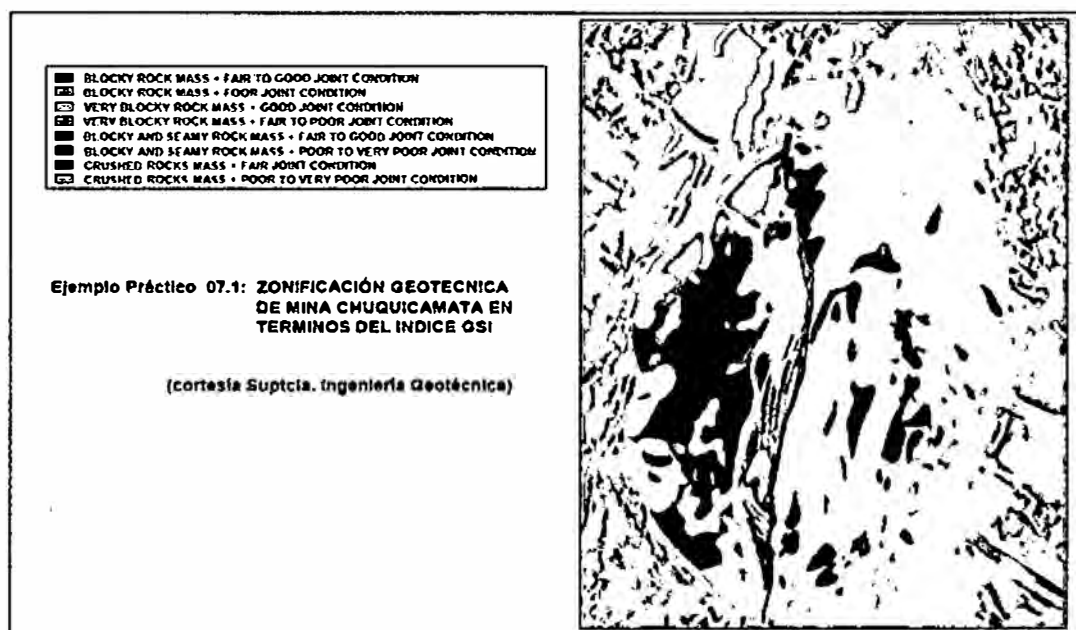
RUMBO PERPENDICULAR AL EJE				RUMBO PARALELO AL EJE DEL TÚNEL		BUZAMIENTO 0 – 20° (independiente del rumbo)
Dirección según buzamiento		Dirección contra buzamiento		Buzamiento o 45 – 90°	Buzamiento 20 – 45°	
Buzamiento 45 – 90°	Buzamiento 20 – 45°	Buzamiento 45 – 90°	Buzamiento o 20 – 45°	Buzamiento o 45 – 90°	Buzamiento 20 – 45°	
Muy favorable	Favorable	Regular	Desfavorable	Muy desfavorable	Regular	Desfavorable
0	-2	-5	-10	-12	0	-2

Fuente: “Engineering Rock Mass Classifications”, Bieniawski, Z. T.

2.3.14 Uso de las clasificaciones geomecánicas del macizo rocoso para la estimación del GSI.

Según Hoek and Brown (1980), propusieron utilizar para la estimación de las constantes del material: m y s , las clasificaciones geomecánicas de Bieniawski (1974) y de Barton (1974), sin embargo, hay un problema potencial en el uso de estos sistemas de clasificación geomecánica, de tomar en cuenta doblemente algún factor. A fin de minimizar estos problemas potenciales, se ofrecen las siguientes guías para la selección de parámetros cuando se utilizan las clasificaciones geomecánicas del macizo rocoso como base para la estimación de los valores m y s del criterio de falla de Hoek and Brown.

FIGURA 30. Zonificación geotécnica en función al índice GSI.



Fuente: Cortesía, ingeniería geotécnica.

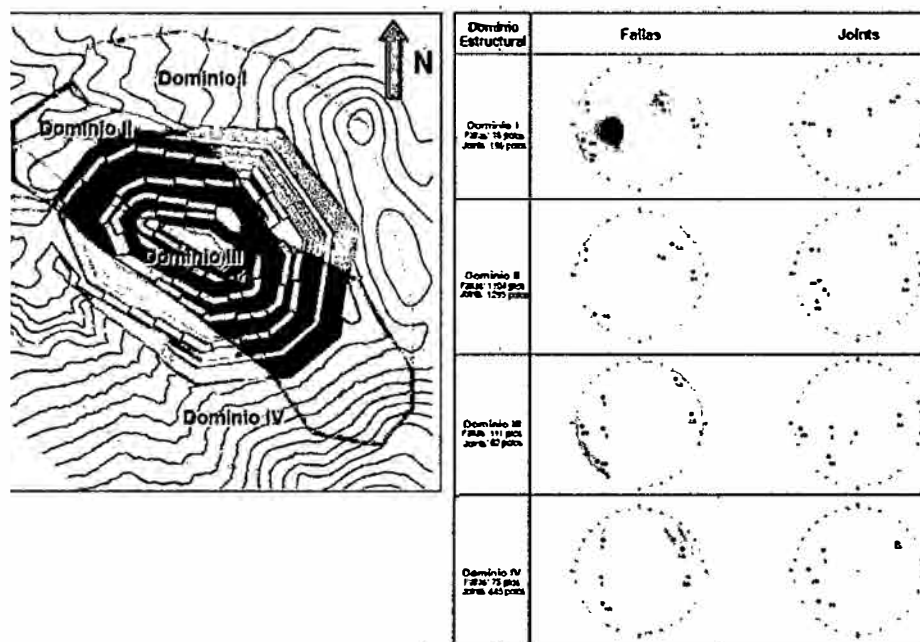
2.3.14.1.1 Clasificación geomecánica RMR de Bieniawski de 1976.

Según el artículo de Bieniawski (1976) es la referencia básica para el presente análisis se muestra los parámetros que se consideran para determinar la calidad del macizo rocoso. que define la Clasificación Geomecánica o valoración del macizo rocoso (RMR), los parámetros que se tomaran en cuenta para los cálculos estarán referidos a:

- Resistencia Compresiva de la roca.
- RQD (Rock Quality designation).
- Espaciamiento de juntas.
- Condición de juntas.

Para estimar el valor de utilizando la valoración del macizo rocoso (RMR) de Bieniawski de 1976, con los parámetros descritos anteriormente, asumiendo que el macizo rocoso está completamente seco y al valor de la presencia de agua subterránea se le debe asignar una valoración de 10, También se deberá asumir que la orientación de juntas corresponde a una condición favorable y el valor de ajuste por orientación de juntas será (0). La valoración final, llamada RMR76, puede luego ser utilizada para estimar el valor de GSI.

FIGURA 31. Clasificación de dominios estructurales.



Fuente: Cortesía, ingeniería geotécnica

2.3.14.1.2 Clasificación geomecánica de Bieniawski de 1989.

Según la clasificación geomecánica de Bieniawski, Z. T de (1989), puede ser utilizada para estimar el valor GSI de una manera similar a lo descrito para versión de 1976. En este caso, se asigna un valor de 15 a la valoración del agua subterránea y de nuevo se considera como cero (0) el ajuste por orientación de Juntas. Nótese que el valor mínimo que se puede obtener con la clasificación geomecánica de 1989 es 23 y que, en general, esta da un valor ligeramente más alto que la clasificación de 1976 la valorización final, llamada RMR89, puede ser utilizada para estimar el valor de GSI.

No se puede utilizar la clasificación geomecánica de Bieniawski de 1989 para estimar el valor GSI, en cambio se debería usar el valor de Q de Barton, Lien y Lunde.

2.3.14.1.3 Clasificación geomecánica “q” modificada de barton lien y lunde.

Según Barton, N., Lien, R., & Lunde, J. (1988), Para estimar el valor de GSI utilizando esta clasificación geomecánica, se deben usar el RQD (Rock Quality Designation), el número del sistema de juntas (J_n), el número de la rugosidad de las Juntas (J_r) y el número de alteración de las Junta (J_a), exactamente como están definidas en las figuras N° 02, 03 y 04 de Barton (1974). Para el factor de reducción por agua en juntas (J_w) y el factor de reducción por esfuerzos (SRF), se debe utilizar un valor de 1 para ambos parámetros, lo que equivale a condiciones secas del macizo rocoso sometido a esfuerzos medios.

2.3.15 Voladura en superficie.

La operación unitaria o proceso productivo de “Voladura”, tiene como objetivo arrancar el material involucrado desde su lugar original, de modo que este material triturado puede ser cargado y retirado por los equipos respectivos (y procesado según se requiera), por lo que este material tendrá que cumplir con una granulometría y una disposición espacial apta para los posteriores procesos asociados.

El primer proceso de conminución que se aplica al material es la voladura, por lo que su éxito permitirá realizar un buen manejo de este material por parte de los procesos posteriores (chancado por ejemplo).

Como sabemos la granulometría dependerá de las características de la roca misma y de energía aplicada sobre ella, por lo que si deseamos una granulometría fina debemos utilizar mayor cantidad de recursos (explosivos) o aumentar su potencia, es decir aumentar el Factor de carga de nuestra voladura.

2.3.15.1 Objetivos de la voladura.

Controlar en forma eficiente la energía del explosivo para obtener una óptima fragmentación, adecuada forma de la pila y esponjamiento para maximizar los rendimientos del ítem carguío, minimizar la dilución de la mena y disminuir el daño producido en el entorno del disparo.

2.3.15.2 Voladura en bancos.

Las voladuras en banco son las excavaciones similares en escalones en el terreno, que se realizan mediante la detonación de taladros verticales o sub verticales, su característica principal es la de tener, como mínimo dos caras libres, la superior y la frontal.

La proyección del material es también un tema muy importante, ya que no queremos que el material quede esparcido en un área muy grande, sino que deberá quedar dispuesto espacialmente de modo que el equipo que se encargue de su manejo posterior pueda hacerlo en condiciones acordes a su diseño de operación.


Algunas formas para el material volado son las siguientes:

- a) En este caso se tiene una “ola” de mayor altura y menor expansión, ideal para la operación de palas cable, ya que se posiciona frente a la saca sin tener que realizar muchos movimientos. Se puede agregar que reviste bastante riesgo el circular en las cercanías de la ola de material. El trabajo de los equipos de apoyo son mínimos. La voladura se ha realizado de modo que la proyección sea mínima.



Fuente: Diseño de voladuras a cielo abierto.

- b) En este caso se tiene una “ola” de altura y expansión intermedia, recomendable para la operación de palas hidráulicas, ya que se posiciona frente al material movido y deberá realizar algunos movimientos. Se puede agregar que no reviste mucho riesgo el circular en las cercanías de la ola de material. El trabajo de los equipos de apoyo es considerable.



Fuente: Diseño de voladuras a cielo abierto.

- c) En este caso se tiene una “ola” de poca altura y mucha expansión, ideal para la operación de cargadores frontales, ya que deberá realizar muchos movimientos.

Se puede agregar que reviste muy poco riesgo el circular en las cercanías de la ola de material. El trabajo de los equipos de apoyo son altos. La voladura se ha realizado de modo que la proyección sea relevante.



Fuente: Diseño de voladuras a cielo abierto.

2.3.15.3 Tipos.

2.3.15.3.1 Según la envergadura.

En el proyecto las bambas se consideran de 2 tipos

- Voladuras con taladros de pequeño diámetro, de 4 pulg. (102 mm) y 5 pulg. (127) respectivamente a la zona del proyecto.
- Voladuras con taladro de gran diámetro, de 12 1/4 pulg. (318 mm), que se utilizan únicamente en la voladura primaria.

2.3.15.3.2 Según su aplicación y finalidad.

- a) *Voladura sobre mineral.* Son voladuras que se realizan con taladros de gran diámetro, en donde se persigue la máxima fragmentación y esponjamiento de la roca, generalmente se desarrollan en plataformas amplias con relaciones al burden- espaciamiento como se muestra en la siguiente figura.
- C) *Voladura sobre desmonte.* Busca la máxima concentración, esponjamiento y desplazamiento del material roto, adecuado para una fácil limpieza y transporte hacia los botaderos, se aprovecha mallas con burden espaciamientos más amplios y tacos superiores a 9m, en este tipo de voladuras las proyecciones son mucho menores que las mallas de mineral.
- b) *Voladura controlada.* Las penúltimas filas son taladros amortiguados o más conocidos como “buffer”. Su finalidad es la formación de una pared más estable, generar el límite de penetración de la pala, obtener las bermas programadas, crear la percepción de seguridad y una reducción de la roca suelta colgada, el

espaciamiento y burden para el buffer varía entre como se muestra en la figura., el burffer suele ser el contorneo y el quiebre de la última parte del arranque del material.

El precorte a diferencia del buffer debe detonar en un promedio de 200 a 250 milisegundos antes de la detonación del primer taladro de la voladura primaria.

Para le perforación de los taladros de precorte se utiliza la perforadora atlas Copco ROC L8 que perfora taladros de 5” de diámetro con un ángulo de talud variable entre 65°-75° y una profundidad de 12-18m.

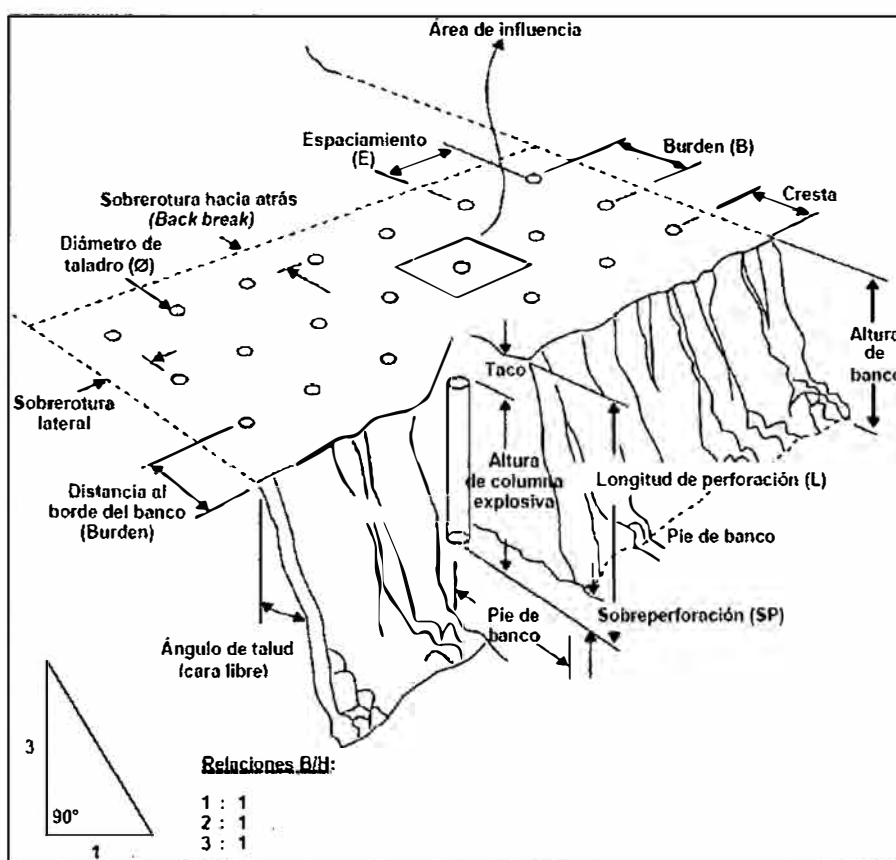
2.3.15.4 Parámetros de voladura en los bancos.

Son los datos empleados en el cálculo y diseño de disparos unos son invariables como los correspondientes a las características físicas de las roca: densidad, dureza, grado de fisuramiento, coeficientes de resistencia a deformación y rotura, etc; y otros son variables, es decir que podemos modificarlos a voluntad, de acuerdo a las necesidades reales del trabajo y condiciones del terreno.

Estos parámetros controlables se pueden agrupar en:

- a) Geométricos: altura, ancho y largo del banco, talud, cara libre.
- b) De perforación: diámetro y longitud del taladro, malla.
- c) De carga: densidad, columna explosiva, longitud de taco, características físico-químicas del explosivo.
- d) De tiempo: tiempos de retardo entre taladros, secuencia de salidas de los disparos.

FIGURA 32. Nomenclatura de los bancos de voladura.



Fuente: Manual práctico de voladura.

2.3.15.4.1 Diámetro del taladro.

La selección del diámetro de taladro es crítica considerando que afecta a las especificaciones de los equipos de perforación, carga y acarreo, también al burden, espaciamento distribución de la carga explosiva, granulometría de la fragmentación, tiempo a emplear en la perforación y en general a la eficiencia y economía de toda la operación. Para determinar el diámetro óptimo en la práctica, se consideran tres aspectos:

a) La disponibilidad y aplicabilidad del equipo de perforación en el trabajo proyectado.

b) La altura de banco proyectada y la amplitud o envergadura de las voladuras a realizar.

c) La distancia límite de avance proyectado para el banco.

Con diámetro pequeño los costos de perforación y de preparación del disparo normalmente son altos y se emplea mucho tiempo y personal, pero se obtiene mejor distribución y consumo específico del explosivo, permitiendo también efectuar voladuras selectivas.

El máximo diámetro a adoptar depende de la profundidad del taladro y, recíprocamente, la mínima profundidad a la que puede ser perforado un taladro depende del diámetro, lo que usualmente se expresa con la igualdad:

$$L = (2 \times \varnothing) \quad (14)$$

Donde:

L : la mínima longitud del taladro, en pies.

\varnothing : es el diámetro del taladro, en pulgadas.


2.3.15.4.2 *Altura de banco.*

La altura del banco viene determinada por la distancia vertical, desde la superficie horizontal (cresta) a la proyección vertical del (toe). Para la altura de bancos hay que tener en cuenta que:

Si la relación H/B es grande, el desplazamiento y deformación de la roca es fácil.

Si $H/B = 1$, se obtendría una fragmentación gruesa con problemas de sobre-excavación y “callos”.

FIGURA 33. Relación burden y altura de banco.




Fuente: Manual práctico de voladura.

Si $H/B = 2$, se aminoran estos efectos, eliminándose en su totalidad con $H/B > 3$.

2.3.15.4.3 Sobreperforación.

La Sobreperforación “S” es la longitud de perforación, por debajo del nivel de piso, que se requiere para romper la roca a la altura del piso. El quiebre en el fondo de los taladros se produce en forma de conos invertidos, cuyo ángulo con la horizontal depende de la estructura del macizo y de las tensiones residuales.

FIGURA 34. Sobreperforación.



Fuente: Manual práctico de voladura.

$$S = 0.3 \times B \quad (15)$$

Donde:

S: sobreperforación.

B: burden

2.3.15.4.4 Longitud de taco.

El “taco” es la longitud de la perforación que en la parte superior se rellena con material inerte y tiene por misión confinar y retener los gases producidos en la detonación, para permitir que se desarrolle por completo el proceso de fragmentación de la roca.

$$\text{Tamaño ideal} = \frac{\text{Diámetro de perforación}}{20-25} \quad (16)$$

$$T = 0.7 \times B \quad (17)$$

Donde:


T: taco.

B: burden

2.3.15.4.5 Burden y espaciamento.

- a) El Burden “B” es la distancia mínima desde el eje de un taladro al frente libre.


FIGURA 35. Burden.



Fuente: vista lateral del banco.

- b) El Espaciamiento “E” es la distancia entre taladros de una misma fila de perforación.

FIGURA 36. Espaciamiento.




Fuente: vista en planta del banco.

2.3.15.4.6 Desviación de los taladros.

La desviación de los taladros afecta la fragmentación de la roca, aumenta el riesgo de generar fuertes vibraciones, proyecciones y sobreexcavación, pues la malla de perforación B x E no se mantendrá constante en las diferentes cotas del taladro.

FIGURA 37. Eyección de taladros por un burden inadecuado.



Fuente: Capacitación orica.

Existen numerosos métodos para determinarlo. Por lo general es:

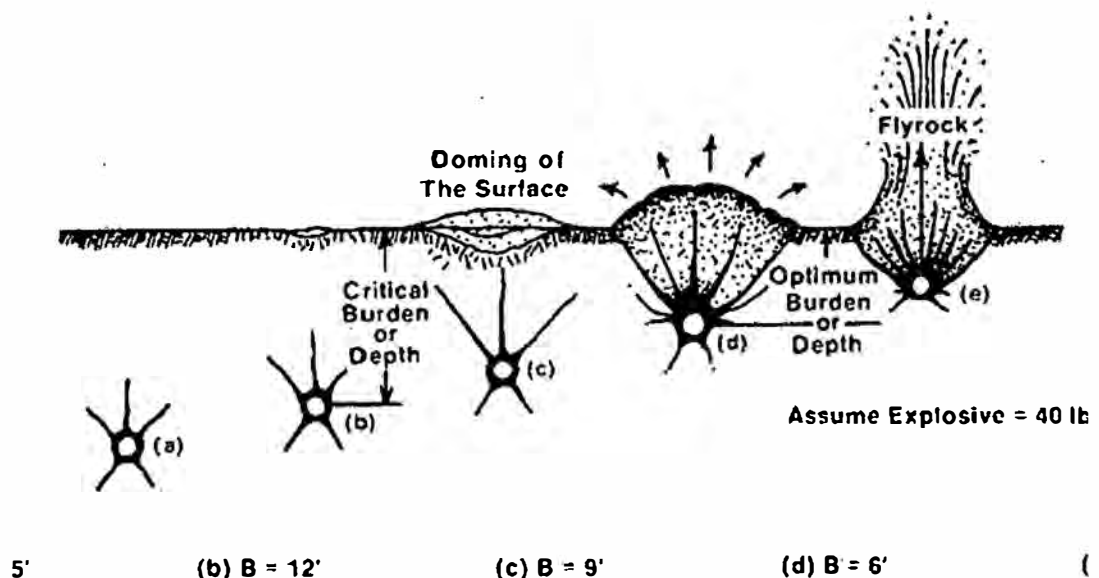
$$0.6 - 0.9 \times D \quad (18)$$

Si el burden ("B") es excesivo, los gases de la detonación encuentran mucha resistencia para agrietar y desplazar la roca y parte de la energía se transforma en vibración que daña la roca e instalaciones críticas; si es reducido, los gases de la detonación escapan y expanden a una velocidad muy alta hacia el frente libre, impulsando los fragmentos de roca en forma incontrolada, y provocando, aumento de la sobreperforación, airblast y altos niveles de ruido.

Si el espaciamiento ("E"), es muy reducidos producen entre las cargas excesivo trituramiento y fracturas superficiales.

Si es muy amplio, se produce fracturamiento inadecuado entre las cargas, acompañado por problemas de "Toes" y un frente muy irregular, con sobresalientes de roca en la cara del banco.

FIGURA 38. Efecto de un inadecuado burden-espaciamiento.



Fuente: surfaces mining blasting.

2.3.15.4.7 Columna explosiva.

Es la parte activa del taladro de voladura, también denominado “longitud de carga”, donde se produce la reacción explosiva y la presión inicial de los gases contra las paredes del taladro. Es importante la distribución de explosivos a lo largo del taladro, según las circunstancias o condiciones de las rocas.

Cantidad de explosivo por taladro general.

$$Wb = \frac{0.7 \cdot H \cdot \pi \cdot \phi^2 \cdot \rho_e}{4000} \quad (19)$$

Donde:

Wb = Cantidad de explosivo por taladro (kg. /Taladro).

H = Altura del banco (m.)

ϕ = Diámetro del taladro (mm.)

ρ_e = Densidad del explosivo (g/cc.)

a) Carga de fondo. Es la carga explosiva de mayor densidad y potencia requerida al fondo del taladro para romper la parte más confinada y garantizar la rotura al piso, para, junto con la sobreperforación, mantener la razante, evitando la formación de resaltos o lomos y también limitar la fragmentación gruesa con presencia de bolones. Su longitud es normalmente equivalente a la del burden más la sobreperforación: $B + 0,3 B$; luego:

$$CF = (1,3 \times B) \quad (20)$$

No debe ser menor de $0,6 B$ para que su tope superior esté al menos al nivel del piso del banco. Se expresa en kg/m o lb/pie de explosivo. Los

productos usualmente empleados son: ANFO aluminizado, hidrogeles Slurrex, emulsiones sensibilizadas, ANFOs Pesados como Slurrex- AP de 30/70 a 60/40, en razón a que la energía por unidad de longitud en el fondo del taladro debe ser al menos dos veces mayor que la requerida para romper la roca en la parte superior.

Si se toma en consideración la resistencia de la roca y el diámetro de la carga, la longitud de la carga de fondo variará entre 30 Ø para roca fácil a 45 Ø para muy dura. El cebo iniciador o booster debe colocarse en esta parte de la carga, preferentemente al nivel del piso del banco, para su mayor efectividad.

b) *Carga de columna.* Se ubica sobre la carga de fondo y puede ser de menor densidad, potencia o concentración ya que el confinamiento de la roca en este sector del taladro es menor, empleándose normalmente ANFO convencional, Examon-P o ANFO Pesado en relaciones de 10/90 a 20/80. La altura de la carga de columna se calcula por la diferencia entre la longitud del taladro y la suma la carga de fondo más el taco.

$$CC = L - (CF + T) \quad (21)$$

Usualmente $CC = 2,3 \times B$.

Donde:

CC = Carga de columna (m).

L = Longitud del taladro (m).

CF= Longitud de carga de fondo (m).

T= Longitud taco (m).

c) *Cargas segmentadas o espaciadas*. Normalmente se emplean cargas continuas en taladros de pequeña o mediana longitud, pero en taladros largos o en aquellos que se requiera disminuir la energía pero manteniéndola distribuida en toda su longitud, se emplean cargas espaciadas con tacos inertes intermedios y con un iniciador en cada una para garantizar su salida. Estas cargas pueden ser del mismo tipo de explosivo o emplearse uno de mayor densidad o potencia en la primera carga al fondo. Las salidas pueden ser simultáneas o con diferentes tiempos de salida para cada una, mediante retardos en orden ascendente o descendente, según el diseño de la voladura o los efectos que se quieran obtener.

d) *Factor de carga*.

Llamado también consumo específico o factor de carga (Powder factor).

Es la cantidad de explosivo necesaria para fragmentar 1 m³ o yd³ de roca. Se expresa en kg/m o lb/yd.

$$CE = (\text{Total de explosivo utilizado, en kg}) / (\text{Total de m}^3 \text{ rotos cubitados}) \quad (22)$$

La carga específica es una excelente unidad referencial para el cálculo de la carga total de un disparo, pero no es el mejor parámetro de por sí, ya que la distribución de este explosivo en la masa de la roca mediante los taladros tiene gran influencia en los efectos de fragmentación y desplazamiento, es decir, en el resultado de la voladura. Así, a igualdad de carga específica, una voladura efectuada

con taladros de pequeño diámetro muy próximos entre sí resultará con mejor fragmentación que si se utilizan taladros de gran diámetro pero más espaciados.

- e) *Concentración de carga lineal.* Es la cantidad de explosivos utilizado por cada metro de la carga de columna. Viene representado por la siguiente formula:

$$CCL = 0.078539 * \rho_e * \phi^2 \quad (23)$$

Donde:

CCL = concentración de carga lineal (m).

ρ_e = densidad del explosivo g/cm³

ϕ = Altura del banco (m.)

2.3.15.5 Tareas en la voladura.

Para obtener los resultados esperados, podemos resumir la tarea en los siguientes pasos:

- Definir el tonelaje requerido para la voladura.
- Diseñar la voladura.
- Chequeo de la zona a volar.
- Garantizar la seguridad de la operación.
- Realizar el amarre.
- Efectuar la voladura.
- Chequear la zona volada.
- Chequear resultados.
- Incorporar dichos resultados al sistema de información.

2.3.15.6 Criterio de selección de explosivos.

Antes de seleccionar un explosivo hay que tener en cuenta las siguientes consideraciones:

a) *Diámetro de carga.*

Considerar diámetro crítico de los explosivos.

- Diámetros pequeños (menores a 2") no usar Anfo. Es preferible usar Emulsiones empacadas ó dinamitas.
- Diámetros medianos (2 a 4"), usar Anfo en rocas blandas y medianas, pero como carga de columna. Si las rocas son duras, es preferible el uso de explosivos empacados.
- Diámetro Grande (Mayor a 4") considerar las condiciones de terreno.

b) *Condiciones de agua.*

- Nunca usar Anfo
- En gran diámetro usar mezclas 50/50 o con mayor % de emulsión
- Siempre es preferible privilegiar el uso de mezclas 50/50.

c) *Propiedades geomecánicas.*

Módulo Young, Razón de Poisson, Propiedades Resistivas, Cohesión, Fricción, Velocidad de propagación de ondas, V_p , V_s , Densidad, Dureza.

d) *Propiedades geoestructurales.*

- Litología
- Frecuencia de Fracturas (RQD)
- Orientación de la fractura


- Porosidad
- Presencia de agua

Explosivos con alta presión de detonación, generan mayor cantidad de fracturas nuevas en la roca.

Por un lado: Rocas resistentes, duras y masivas requieren explosivos de alta presión de detonación.

Por otro lado: Rocas poco resistentes, blandas y fracturadas solo requieren la acción de los gases.

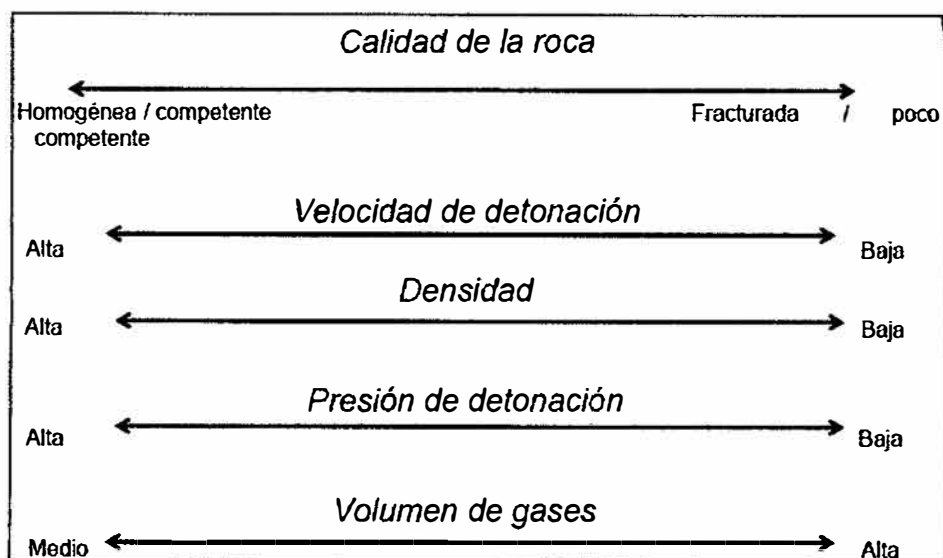
FIGURA 39. Uso de explosivo según los fines requeridos.



Fuente: Capacitación uso de explosivos.

El explosivo debe ser seleccionado de acuerdo a requerimiento de fragmentación. Los Anfos pesados, al ser más denso, permiten disminuir el gasto en perforación marco conceptual.

FIGURA 40. Uso de los explosivos en función a la calidad de roca.



Fuente: Capacitación uso de explosivos.

2.4 MARCO CONCEPTUAL.

- Algoritmo backpropagation.* La importancia de la red backpropagation consiste en su capacidad de auto adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplos y sus salidas correspondientes.
- Algoritmo de levengerd-muarquardt.* El algoritmo de Levengerd-Marquardt (LM), es un algoritmo iterativo de optimización en el que el método de iteración, presenta una ligera modificación sobre técnica tradicional de Newton, que trata minimizar la distancia euclidiana entre los datos de campo y los teóricos.
- Cratering.* Flyrock se produce porque la altura del taco es demasiado para el diámetro usado o presencia de roca débil en el collar.

- d) *Deflagración*. Es un fenómeno superficial en el que el frente de deflagración se propaga por el explosivo en capas paralelas, a una velocidad baja, que generalmente no supera los 1 000 m/s.
- e) *Detonación*. En los explosivos detonantes la velocidad de las primeras moléculas gasificadas es tan grande que no ceden su calor por conductividad a la zona inalterada de la carga, sino que los transmiten por choque, deformándola y produciendo calentamiento y explosión adiabática con generación de nuevos gases.
- f) *Face burst*. Condiciones de burden (insuficiente burden para el diámetro usado o presencia de roca dbil en la cara), suelen producir Flyrock desde el frente de la cara.
- g) *Emulsión*. Mezcla estable de al menos dos líquidos inmiscibles entre sí, en que cada uno de éstos forma una fase independiente
- h) *Entrenamiento de la red neuronal*. Presenta entradas y salidas, para que las redes neuronales, vayan ajustando la salida mediante la modificación de los pesos.
- i) *Explosivo*. EXSA, (2002). Los explosivos, dan lugar a una reacción exotérmica muy rápida, que genera una serie de productos gaseosos a alta temperatura y presión, químicamente más estables, y que ocupan un mayor volumen, aproximadamente 1 000 a 10 000 veces mayor que el volumen original del espacio donde se alojó el explosivo.
- j) *Iteración*. Se dice así cuando se realizan varias pruebas seguidas en las redes neuronales artificiales, con el objetivo de que las neuronas artificiales se

CAPÍTULO III

HIPÓTESIS

3.1 HIPÓTESIS DE LA INVESTIGACIÓN.

3.1.1 Hipótesis general.

- La determinación de las distancias, cubiertas por el flyrock, usando las redes neuronales artificiales del Matlab en el tajo Ferrobamba, proyecto minero las Bambas.

3.1.2 Hipótesis específico.

- Se conoce el comportamiento de las variables de proyección de roca para el tajo Ferrobamba, mediante el análisis de sensibilidad.
- Existe un alto grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección.
- Establecer los parámetros de voladura y datos Geotécnicos para la predicción de la distancia cubierta por el flyrock, en el Tajo Ferrobamba del proyecto minero las Bambas.
- Las redes neuronales del Matlab son una potente herramienta de predicción a diferencia de otros métodos tradicionales de predicción de flyrock.

3.2 VARIABLES.

OPERACIONALIZACIÓN DE VARIABLES	
DEPENDIENTE	UNIDADES
Predicción de la distancia	m. (metros)
INDEPENDIENTE	UNIDADES
Aplicación de las redes neuronales del Matlab	<ul style="list-style-type: none"> • Concentración de carga lineal (Kg/m) • Burden (m) • Taco (m) • Espaciamiento (m) • Factor de carga (Kg/ton) • RMR (Mpa) • RQD (%)

Fuente: matriz de consistencia.

CAPÍTULO IV

METODOLOGÍA DE LA INVESTIGACIÓN

4.1 TIPO Y ALCANCE DE LA INVESTIGACIÓN.

Según Hernández, R. (2010). El tipo de la investigación es, Cuasiexperimental, y tiene un alcance Correlacional, por que intentaremos predecir el valor aproximado de la variable de la distancia cubierta por los proyectiles de roca y/o flyrock, a partir del valor que poseen las variables de los parámetros de voladura, en artificial neural network.

4.2 MÉTODO Y DISEÑO DE INVESTIGACIÓN.

4.2.1 Método.

El método planteado para este trabajo es del tipo “Inductivo”, por otro lado también “Estadístico” en lo que se pretende sacar estadísticas mediante gráficos y correlaciones, y “analítico” para poder hacer un adecuado análisis de los resultados obtenidos.

4.2.2 Métodos de predicción.

TABLA 17. Métodos de predicción.

Nº	PASOS	DESCRIPCIÓN
1	Identificar el horizonte temporal	Es decir el corto, mediano y largo plazo.
2	Observar los hechos.	Identificar las variables a predecir y sus dependencias
3	Seleccionar una Técnica.	Seleccionar las técnicas que más se ajustan al tipo de problemas presentado.
4	Aplicar Técnicas Seleccionadas	Implementar la predicción con la técnica seleccionada.

FUENTE: (Bowerman, 2007)

- Método de diseño de modelos de predicciones con redes neuronales artificiales.

4.2.3 Diseño de la investigación.

Del libro de Hernández, R.(2010), pág.152, se obtiene, que el diseño de investigación para el presente trabajo, es el diseño Cuasi-experimental, en la clasificación de los “Diseños transeccionales exploratorios”, ya que el propósito es comenzar a conocer el comportamiento de una variable, por lo que se aplica a problemas poco conocidos.

4.3 POBLACIÓN Y MUESTRA.

4.3.1 Población.

El presente trabajo de investigación se realizara en el proyecto minero las Bambas, la población para este estudio han sido los bancos: 3735, 3750, 3765, 3780, 3795, 3825, 3840, 3855, 3870, 3885 y 3900 del tajo Ferrobamba en donde han cumplido las condiciones para las muestras.

4.3.2 Muestra.

Las muestras que se han tomado para el presente estudio son los fragmentos con tamaños mayores a 10 centímetros, obteniendo un total 152 datos de registros de voladura entre mineral y desmonte.

4.4 METODOS, TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

4.4.1 Metodología.

Las metodologías consideradas para el siguiente trabajo son: la metodología para la generación de datos, pronósticos y la implementación de las redes neuronales artificiales.

4.4.1.1 Metodología usada en la generación de datos.

4.4.1.1.1 Sobre datos de distancia observada.

Se identificó las máximas distancias proyectadas por fragmentos mayores a 10 cm, mediante el uso de GPS y winchado a partir de la pila del material volado llevando, el registro por bancos, niveles y proyectos de voladura como se muestra en la TABLA.18.

FIGURA 41. Medición de fragmentos después de la voladura con GPS.



Fuente: Fotografía de campo.

TABLA 18. Registro de distancias observadas.

DISTANCIAS OBSERVADAS DEN CAMPO		DISTANCIAS OBSERVADAS DEN CAMPO		DISTANCIAS OBSERVADAS DEN CAMPO	
Proyecto	Distancia Real (m)	Proyecto	Distancia Real (m)	Proyecto	Distancia Real (m)
3885_56	24	3855_40	45	3750_12	94
3900_55	32	3855_42	75	3840_56	51
3870_75	27	3840_23	58	3840_58	58
3870_67	30	3840_20	67	3750_13	79
3870_79	44	3840_22	81	3750_15	104
3870_83	23	3840_21	80	3750_12	111
3855_41	33	3765_23	74	3840_53	54
3855_53	25	3855_44	58	3750_16	58
3855_57	27	3840_25	54	3825_47	58
3840_24	72	3840_26	52	3825_48	63
3765_26	30	3855_50	89	3750_13	77
3855_59	35	3840_26	68	3825_39	89
3840_42	33	3840_27	76	3750_18	92
3840_43	37	3750_01	123	3825_49	54
3855_63	24	3765_26	50	3825_48	60
3825_26	26	3840_29	41	3750_16	68
3825_28	27	3840_28	76	3825_39	98
3840_47	33	3855_54	56	3750_20	97
3840_42	19	3750_02	79	3825_51	51
3840_55	34	3840_28	69	3825_52	62
3825_41	22	3840_30	54	3750_22	82
3840_57	25	3840_33	150	3840_62	52
3825_41	23	3840_31	44	3825_50	82
3840_52	31	3840_31	42	3750_21	97
3825_35	34	3840_34	72	3825_56	50
3825_42	35	3750_04	94	3825_54	44
3825_47	29	3840_41	53	3750_23	98
3825_44	28	3765_26	56	3825_57	46
3840_67	35	3855_63	56	3825_51	53
3825_55	28	3825_27	58	3750_21	74
3840_70	33	3825_26	86	3825_59	54
3840_82	30	3750_09	69	3825_60	77
3735_01	80	3765_27	75	3735_02	74
3735_01	87	3825_29	51	3840_70	53
3825_68	37	3825_28	83	3735_03	93
3825_63	34	3840_45	51	3825_64	57
3825_72	42	3840_46	51	3825_58	44
3825_72	26	3840_44	71	3825_41	31
3825_72	36	3840_44	57	3840_82	71
3825_73	37	3750_09	87	3825_68	110
3825_70	35	3825_32	37	3825_64	51
3825_74	28	3825_30	54	3825_65	47
3765_14	91	3840_49	52	3825_70	78
3765_15	99	3825_31	63	3735_03	81
3780_36	93	3840_51	60	3825_40	54
3780_37	66	3825_33	88	3825_71	55
3870_71	57	3840_50	90	3825_71	68
3855_33	53	3840_48	93	3735_05	79
3855_32	68	3750_11	108	3735_04	105
3795_35	58	3840_51	68	3825_78	76
3870_84	49	3825_33	106		

Fuente: Obtenido de datos de campo.

4.4.1.1.2 Sobre datos geotécnicos.

El RQD y RMR han sido generados a partir de ensayos ya realizados en el tajo Ferrobamba, el área de geotecnia se ha encargado de determinar estos valores para diferentes niveles durante la perforación diamantina practicada en la exploración, estos resultados fueron integrados al software minesigth 3D, los valores generados para cada nivel y taladro fueron a partir del contraste entre la información del levantamiento topográfico de los taladros a cargar y la información cargada al software, los datos obtenidos se muestran en la siguiente tabla.

TABLA 19. Datos geotécnicos generados desde el Minesigth 3D.

DATOS GEOLÓGICOS DEL TAJO FERROBAMBA			DATOS GEOLÓGICOS DEL TAJO FERROBAMBA			DATOS GEOLÓGICOS DEL TAJO FERROBAMBA		
Proyecto	RMR (Mpa)	RQD(%)	Proyecto	RMR (Mpa)	RQD(%)	Proyecto	RMR (Mpa)	RQD(%)
3885_56	71	72	3855_40	68	73	3750_12	47	50
3900_55	60	55	3855_42	62	64	3840_56	67	70
3870_75	65	70	3840_23	57	62	3840_58	75	78
3870_67	55	60	3840_20	57	62	3750_13	51	55
3870_79	50	45	3840_22	55	52	3750_15	48	55
3870_83	67	72	3840_21	50	55	3750_12	55	47
3855_41	79	82	3765_23	51	55	3840_53	72	74
3855_53	60	60	3855_44	66	68	3750_16	59	65
3855_57	57	62	3840_25	63	65	3825_47	65	63
3840_24	57	60	3840_26	62	65	3825_48	57	60
3765_26	60	65	3855_50	49	45	3750_13	50	55
3855_59	75	81	3840_26	59	57	3825_39	51	50
3840_42	55	58	3840_27	55	52	3750_18	48	55
3840_43	48	49	3750_01	40	40	3825_49	70	75
3855_63	65	60	3765_26	65	70	3825_48	55	60
3825_26	54	60	3840_29	77	83	3750_16	55	60
3825_28	60	65	3840_28	65	68	3825_39	50	50
3840_47	57	52	3855_54	60	65	3750_20	48	45
3840_42	63	65	3750_02	55	58	3825_51	67	70
3840_55	52	50	3840_28	54	60	3825_52	55	62
3825_41	68	70	3840_30	64	68	3750_22	49	55
3840_57	65	65	3840_33	40	35	3840_62	65	69
3825_41	65	60	3840_31	75	82	3825_50	50	55
3840_52	60	55	3840_31	75	81	3750_21	47	50
3825_35	61	65	3840_34	57	61	3825_56	70	74
3825_42	70	70	3750_04	47	50	3825_54	78	75
3825_47	62	68	3840_41	66	70	3750_23	53	50
3825_44	58	65	3765_26	67	72	3825_57	72	76
3840_67	55	60	3855_63	65	70	3825_51	65	72
3825_55	60	65	3825_27	65	71	3750_21	51	55
3840_70	78	83	3825_26	48	55	3825_59	65	68
3840_82	65	68	3750_09	52	56	3825_60	64	66
3735_01	49	50	3765_27	50	50	3735_02	52	55
3735_01	46	49	3825_29	65	70	3840_70	75	82
3825_68	55	60	3825_28	50	54	3735_03	48	50
3825_63	57	55	3840_45	67	70	3825_64	65	62
3825_72	52	55	3840_46	65	72	3825_58	77	80
3825_72	55	58	3840_44	65	67	3825_41	62	65
3825_72	52	55	3840_44	65	71	3840_82	54	59
3825_73	55	52	3750_09	50	50	3825_68	42	45
3825_70	50	55	3825_32	64	70	3825_64	67	70
3825_74	63	60	3825_30	65	70	3825_65	68	73
3765_14	48	50	3840_49	67	71	3825_70	50	55
3765_15	47	55	3825_31	67	73	3735_03	50	55
3780_36	48	50	3840_51	63	65	3825_40	62	65
3780_37	55	62	3825_33	49	50	3825_71	64	70
3870_71	62	65	3840_50	50	55	3825_71	54	60
3855_33	79	83	3840_48	48	50	3735_05	50	55
3855_32	65	68	3750_11	50	48	3735_04	50	45
3795_35	66	70	3840_51	60	63	3825_78	50	45
3870_84	70	75	3825_33	45	45			

Fuente: Registro de datos planeamiento mina.

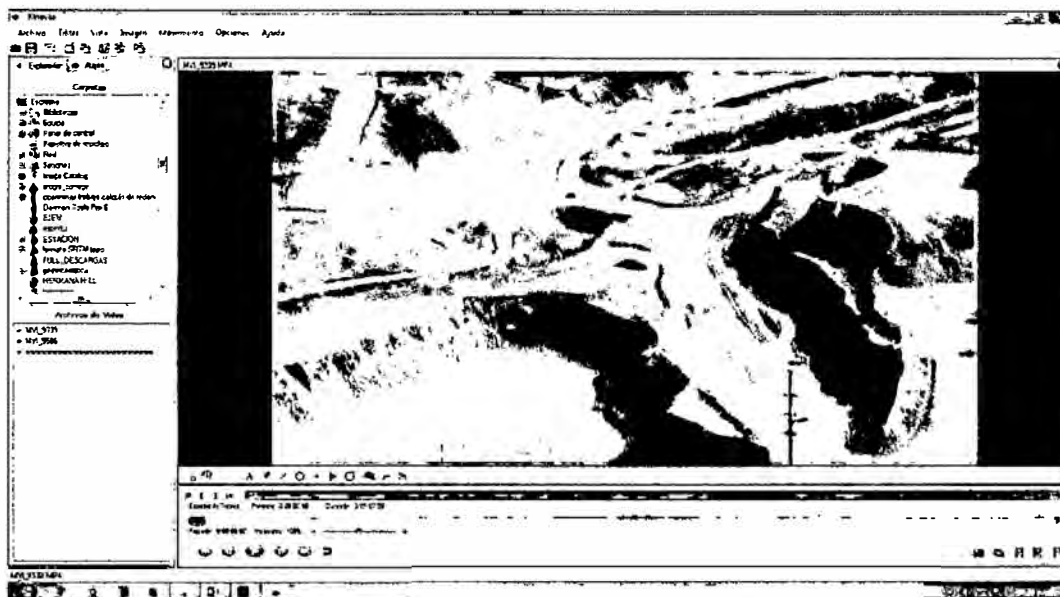
4.4.1.2 Sobre datos para la regresión multivariable.

Los datos para el uso de la regresión multivariable que se utilizaron son: concentración de carga lineal, el factor de carga, burden, RMR, y el índice de la calidad de la roca.

4.4.1.3 Sobre datos para el kinovea.

Las datos para estos experimentos fueron monitoreadas y grabados con cámara de alta resolución con una velocidad de 60 cuadros/segundo, la observación de los mismos se ha realizado desde puntos seguros y visibles, con planos de vista adecuados a la cara del banco para escalar correctamente.

FIGURA 42. Entorno del Kinovea.



Fuente: Captura en pantalla.

4.4.1.4 Métodos de pronóstico.

TABLA 20. Método General de Diseño de Pronóstico.

	Pasos	Descripción
1	Temporal	Es decir el corto, mediano y largo plazo.
2	Observar los Hechos	Identificar las variables a predecir y sus dependencias
3	Seleccionar una Técnica	Seleccionar las técnicas que más se ajustan al tipo de problemas presentado.
4	Aplicar Técnicas	Implementar el pronóstico con la técnica seleccionada.

Fuente: Método de diseño de modelos de pronósticos con redes neuronales artificiales.

4.4.1.5 Metodología para la implementación de las redes neuronales.

La metodología para la implementación de Redes Neuronales en la predicción del flyrock, se basa en el trabajo de Kaastra y Boyd 1996.

El cual está compuesto por 8 pasos:

- 1.- Selección de la Variable.
- 2.- Recolección de Datos.
- 3.- Pre-procesamiento de Datos.
- 4.- Definición de Conjunto de Entrenamiento, Validación y Prueba.
 - a) Conjunto de Entrenamiento.
 - b) Conjunto de Validación.
 - c) Conjunto de Prueba.
- 5.- Selección de la Arquitectura de Redes Neuronales.
 - a) Número de Neuronas de Entrada.
 - b) Número de Capaz Ocultas.
 - c) Número de Neuronas Ocultas.
 - d) Número de Neuronas de Salida.

e) Función de Transferencia.

6.- Criterios de Evaluación.

7.- Entrenamiento de la Red Neuronal.

a) Número de Iteraciones.

b) Tasa de Aprendizaje y Momentum.

8.- Implementación del Modelo de Redes Neuronales Artificiales.

4.4.2 Técnicas a utilizar.

- Análisis de videos
- Redes neuronales artificiales.
- Regresión multivariable.

4.4.3 Herramientas.

- MATLAB 8.5.0
- MATLAB Neural Network Toolbox, KINOVEA
- Microsoft Excel 2013, GPS, wincha.
- CAMARA FOTOGRÁFICA (61 frames for second)

4.4.4 Fuente.

Los datos geológicos y geotécnicos a emplear fueron proporcionados por el área de planeamiento mina.

4.5 ANÁLISIS E INTERPRETACIÓN DE DATOS

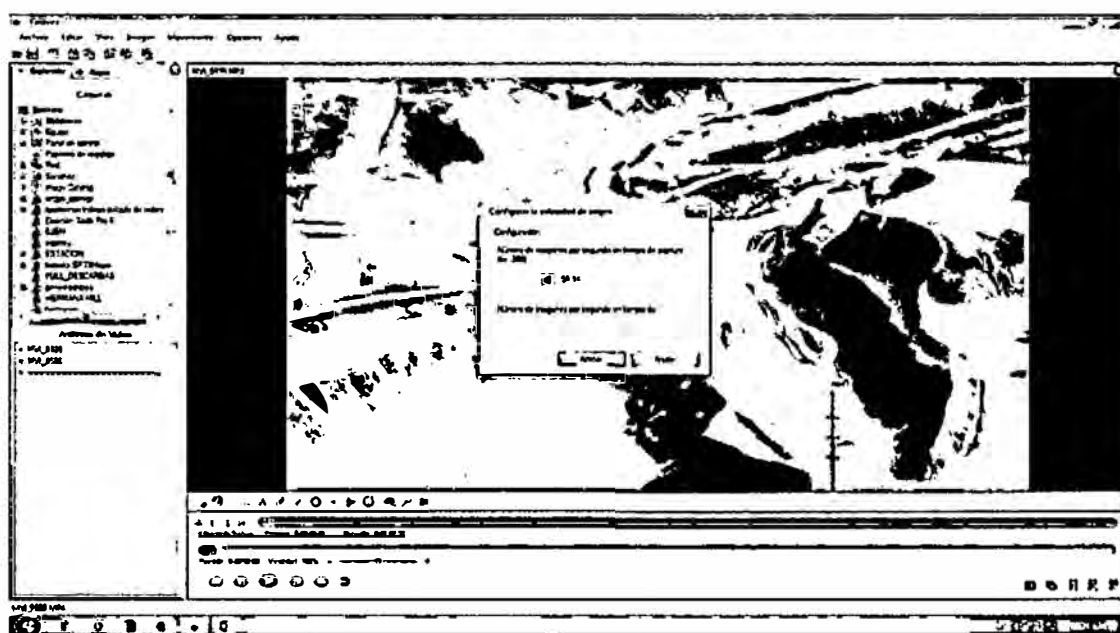
4.5.1 Predicción de flyrock por el KINOVEA.

Las voladuras se registraron en los diferentes proyectos, mediante la cámara fotográfica, asegurándose de que esta coincida con el plano horizontal de la malla, y de que se pueda escalar correctamente mediante los patrones de burden-espaciamento.

Estos registros han sido descargados a la computadora en formato .mp4, archivo soportado por el software KINOVEA, para realizar el análisis de movimiento lento. Dicho análisis se realizó calibrando la escala con el burden, espaciamiento y altura de banco como se muestra en la Figura. 45.

Para un correcto análisis con el software KINOVEA hay que conocer la velocidad de grabado de la cámara, el mismo que es de vital importancia para el trabajo, ya que el cálculo de la velocidad se da en base a los cuadros por segundo grabados por la cámara, la calibración de la velocidad se realiza en la pestaña Opciones<preferencia<general, (ver Figura.43), además en esta pestaña se configura el formato del tiempo, la velocidad de la cámara utilizada es de 59.94 frames for second.

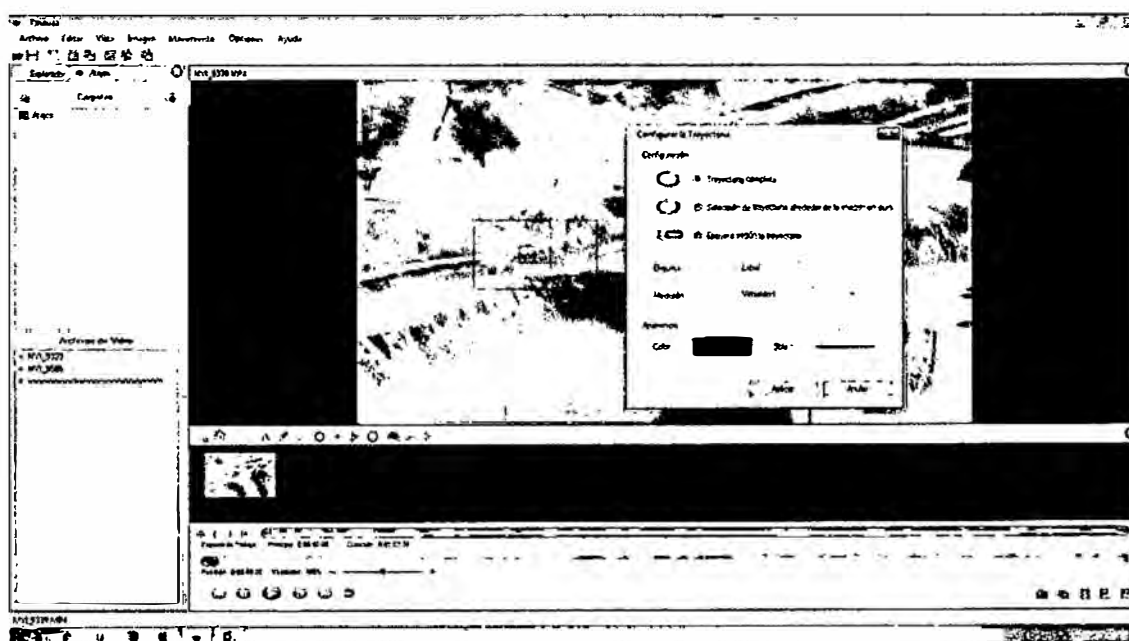
FIGURA 43. Configuración de los cuadros por segundo.



Fuente: Captura en pantalla del software Kinovea.

En el análisis de la trayectoria se determinó los fragmentos a analizar utilizando el marcador en la pantalla principal, este marcador tiene propiedades que se ingresan presionando el anticlic del mouse, sobre el macador antes mencionado, en él se configura las etiquetas de velocidad del proyectil (ver Figura .44).

FIGURA 44. Configuración de la trayectoria.



Fuente: captura en pantalla en el software Kinovea.

Seguidamente se procedió a analizar las proyecciones de los fragmentos con mayores alcances, siguiendo la trayectoria del movimiento, para calcular el ángulo inicial con que este sale proyectado y la velocidad a la cual viaja (Ver. Figura.45).

FIGURA 45. Análisis de movimiento lento en el KINOVEA.



Fuente: Fotografía extraída del entorno KINOVEA.

Las distancias del flyrock han sido calculados por la formula física del alcance máximo.

$$Dk = \frac{Vo^2 \text{sen}(2\theta o)}{g} \quad (24)$$

Donde:

Dk: Distancia calculada por el software Kinovea (m)

Vo: Velocidad inicial del con que sale el flyrock (m/s)

θo : Angulo inicial con que sale el flyrock

g: gravedad (m/s)

En total se ha realizado el análisis para 152 voladuras obteniéndose los siguientes resultados como se muestra en la TABLA .21.

TABLA 21. Registro de ángulos y velocidades, y cálculo de distancias “Dk (m)”.

Proyecto	Vo	Bo	g	Dk
3885_56	28.5	79	9.8	31.1
3900_55	29.4	77	9.8	38.7
3765_14	34.0	58	9.8	106.2
3765_15	35.3	56	9.8	118.3
3780_36	33.8	59	9.8	103.1
3780_37	31.0	68	9.8	68.2
3870_71	31.7	69	9.8	68.7
3855_33	30.8	71	9.8	59.7
3855_32	32.1	66	9.8	78.3
3870_75	28.9	79	9.8	32.0
3795_35	31.6	70	9.8	65.6
3870_67	30.1	76	9.8	43.4
3870_79	31.3	72	9.8	58.9
3870_83	29.5	79	9.8	33.3
3870_84	30.9	74	9.8	51.8
3855_41	29.0	78	9.8	35.0
3855_40	31.1	73	9.8	55.2
3855_42	32.0	64	9.8	82.5
3840_23	31.6	69	9.8	68.3
3840_20	32.3	68	9.8	74.1
3840_22	32.8	62	9.8	91.2
3840_21	33.1	62	9.8	92.6
3765_23	32.5	65	9.8	82.7
3855_44	31.0	70	9.8	63.1
3840_25	29.2	70	9.8	56.0
3840_26	31.4	71	9.8	62.0
3855_50	34.0	57	9.8	107.9
3840_26	32.3	66	9.8	79.3
3840_27	32.2	65	9.8	80.9
3750_01	38.5	43	9.8	150.8
3765_26	30.8	71	9.8	59.7
3855_53	29.3	79	9.8	32.9
3855_57	29.3	78	9.8	35.8
3840_24	32.4	67	9.8	77.2
3840_29	30.0	75	9.8	46.1
3840_28	32.2	65	9.8	81.0
3855_54	31.5	69	9.8	67.9
3750_02	32.3	66	9.8	79.3
3840_28	32.3	64	9.8	84.0
3840_30	30.3	68	9.8	65.2
3840_33	39.0	45	9.8	155.6
3840_31	30.2	73	9.8	52.1
3840_31	30.8	74	9.8	51.3
3840_34	32.7	68	9.8	75.9
3765_26	29.4	78	9.8	35.9
3750_04	33.8	59	9.8	103.1
3855_59	28.7	78	9.8	34.2
3840_41	31.0	71	9.8	60.5
3765_26	31.1	72	9.8	58.1
3855_63	31.4	70	9.8	64.8
3840_42	29.7	80	9.8	30.8
3840_43	31.0	77	9.8	43.1
3825_27	31.1	70	9.8	63.6
3825_26	33.1	63	9.8	90.6
3855_63	28.3	78	9.8	33.2
3825_26	28.4	78	9.8	33.6
3825_28	28.4	78	9.8	33.6
3750_09	32.3	64	9.8	84.0
3765_27	33.0	62	9.8	92.3
3825_29	31.3	71	9.8	61.7
3825_28	33.1	62	9.8	92.8
3840_45	31.1	73	9.8	55.1
3840_46	31.1	74	9.8	52.5
3840_44	32.0	67	9.8	75.3
3840_47	29.1	77	9.8	37.8
3840_44	30.7	70	9.8	61.9
3750_09	33.5	62	9.8	95.1
3840_42	28.9	79	9.8	32.0
3825_32	30.1	76	9.8	43.5
3825_30	30.8	70	9.8	62.3
3840_49	31.0	70	9.8	63.1
3825_31	31.4	89	9.8	67.4
3840_51	31.2	89	9.8	66.6
3825_33	33.2	62	9.8	93.4
3840_50	33.7	80	9.8	100.5
3840_48	34.2	58	9.8	107.1
3750_11	35.0	56	9.8	116.1
3840_55	30.1	75	9.8	46.2
3840_51	31.6	67	9.8	73.4
3825_33	37.5	57	9.8	131.5
3750_12	34.1	57	9.8	108.6
3840_56	31.1	72	9.8	58.1
3840_58	31.3	71	9.8	61.7
3825_41	28.5	79	9.8	31.1
3750_13	32.7	61	9.8	92.7
3750_15	34.2	59	9.8	105.3
3750_12	36.4	57	9.8	123.9
3840_57	29.2	80	9.8	29.8
3825_41	29.3	78	9.8	35.8
3840_52	29.2	78	9.8	35.4
3840_53	30.5	75	9.8	47.5
3750_16	32.0	69	9.8	70.2
3825_35	30.7	75	9.8	48.2
3825_42	29.0	74	9.8	45.6
3825_47	31.2	89	9.8	66.6
3825_48	32.2	67	9.8	76.2
3750_13	32.1	66	9.8	78.3
3825_39	33.6	61	9.8	97.9
3750_18	34.1	59	9.8	104.9
3825_47	29.2	79	9.8	32.6
3825_44	29.0	78	9.8	35.0
3825_49	31.1	72	9.8	58.1
3825_48	31.3	69	9.8	67.0
3750_16	32.0	65	9.8	80.2
3825_39	34.1	58	9.8	106.5
3750_20	34.2	55	9.8	112.3
3825_51	32.3	72	9.8	62.7
3840_67	30.1	76	9.8	43.4
3825_52	32.1	68	9.8	73.2
3750_22	32.7	63	9.8	88.4
3840_62	31.0	70	9.8	63.1
3825_50	32.4	64	9.8	84.6
3750_21	34.0	57	9.8	107.9
3825_56	31.0	73	9.8	55.0
3825_55	29.4	79	9.8	33.1
3825_54	31.0	74	9.8	52.1
3750_23	34.4	55	9.8	113.7
3840_70	29.4	78	9.8	35.8
3825_57	30.5	72	9.8	55.9
3825_51	31.1	70	9.8	63.6
3840_82	29.2	78	9.8	35.3
3735_01	34.1	59	9.8	104.9
3750_21	32.5	64	9.8	85.1
3825_59	31.8	69	9.8	69.2
3735_01	33.6	61	9.8	97.9
3825_60	31.6	66	9.8	75.9
3735_02	32.5	66	9.8	80.2
3840_70	31.7	73	9.8	57.4
3735_03	33.8	60	9.8	101.1
3825_64	32.3	69	9.8	71.4
3825_58	31.0	73	9.8	54.9
3825_68	29.4	78	9.8	35.9
3825_41	28.9	77	9.8	37.3
3840_82	32.3	67	9.8	76.7
3825_68	37.3	58	9.8	127.8
3825_64	30.6	70	9.8	61.5
3825_63	30.5	69	9.8	63.6
3825_65	31.0	72	9.8	57.7
3825_72	30.8	75	9.8	48.5
3825_70	32.2	65	9.8	81.2
3825_72	29.4	79	9.8	33.1
3735_03	32.5	61	9.8	91.6
3825_40	31.3	72	9.8	58.9
3825_72	30.0	78	9.8	37.4
3825_73	31.1	74	9.8	52.4
3825_70	31.3	73	9.8	56.0
3825_71	31.0	69	9.8	65.7
3825_71	31.9	65	9.8	79.7
3735_05	33.0	63	9.8	90.1
3735_04	34.3	56	9.8	111.5
3825_74	28.3	78	9.8	33.3
3825_78	32.0	66	9.8	77.8

Fuente: Resultado de cálculos de distancias en el KINOVEA.

4.5.2 Predicción de flyrock por el análisis de la regresión multivariable MVRA.

Las relaciones entre las variables pueden ser calculadas usando el método de los mínimos cuadrados y el análisis de la regresión multivariable, la regresión de las matrices resuelven las ecuaciones así creadas. Para el cálculo mediante la regresión multivariable, se utilizó los mismos valores de entrada que se utilizó para el cálculo con las redes neuronales; la ecuación para la predicción del flyrock mediante este método es el siguiente:

$$Drm = \frac{10^{5.1} q_1^{0.51} q^{0.14}}{B^{0.93} S^{0.64} RMR^{0.75} RQD^{0.93}} \quad (25)$$

Donde:

Dr_m: Distancia calculada por la regresión multivariable (m)

q₁: Concentración de carga lineal (kg/m)

q: Factor de carga (Kg/ton).

B: Burden (m)

S: Stemming o taco (m)

RMR: Clasificación de bienaski (Mpa)

RQD: Índice de calidad de la roca (%).

Los cálculos realizados para hallar la distancia por la regresión multivariable se muestran en la TABLA.23 y fueron calculados en una hoja Excel, los datos son los mismos parámetros de entrada que se utilizan en el cálculo de la distancia predecida por las redes neuronales artificiales.

TABLA 22. Registro de parámetros y cálculo de distancias “D_{rm} (m)”.

DATOS PARA CÁLCULO DE LA REGRESIÓN MULTIVARIABLE								DATOS PARA CÁLCULO DE LA REGRESIÓN MULTIVARIABLE							
Proyecto	Concentración de carga (kg/m ²)	Burden	Stomping	Factor de carga	RWR	RQD	D _{rm}	Proyecto	Concentración de carga (kg/m ²)	Burden	Stomping	Factor de carga	RWR	RQD	D _{rm}
	(kg/m ²)	(m)	(m)	(kg/ton)	(%)	(%)	(m)		(kg/m ²)	(m)	(m)	(kg/ton)	(%)	(%)	(m)
3885_56	97.2	8.7	9	0.17	71	72	25.40	3750_04	96.9	6	6.5	0.51	47	50	98.69
3900_55	109.2	9.5	9.5	0.16	60	55	34.65	3840_41	92.7	6	6.5	0.53	66	70	55.01
3870_75	103.3	9	9.5	0.17	63	70	26.90	3765_26	101.8	6	7	0.50	67	72	52.57
3870_67	99.0	8.7	9.5	0.16	55	60	35.35	3855_63	99.0	6	6.5	0.54	65	70	57.62
3870_79	87.3	8	8.5	0.19	50	45	55.35	3825_27	98.0	6.2	6.5	0.50	65	71	54.24
3870_83	96.5	8.7	9.5	0.17	67	72	25.52	3825_26	97.0	6	6.5	0.51	48	55	68.85
3855_41	96.6	6	9.5	0.31	79	82	30.77	3750_09	102.5	6	7	0.48	52	56	80.04
3855_53	93.9	9	9.5	0.14	60	60	30.75	3765_27	97.0	6	6.6	0.34	50	50	88.26
3855_57	101.5	9.5	9.5	0.15	57	62	30.73	3825_29	98.9	6	6.5	0.52	65	70	57.33
3840_24	66.0	5.2	6.5	0.25	57	60	61.29	3825_28	102.3	6	7	0.51	50	54	85.97
3785_26	91.9	8.7	9	0.16	60	65	30.50	3840_45	96.2	6	6.5	0.50	67	70	54.94
3855_59	97.2	8.7	8.3	0.19	75	81	23.43	3840_46	100.4	6	6.6	0.52	65	72	55.74
3840_42	83.2	8.7	8.8	0.15	55	58	34.62	3840_44	98.6	5.2	6.5	0.60	65	67	69.40
3840_43	105.7	9.6	9.5	0.15	48	49	44.35	3840_44	98.2	6	6.5	0.56	65	71	56.90
3855_63	96.3	9.5	9	0.14	65	60	28.87	3750_09	96.6	6	6.5	0.50	50	50	99.82
3825_26	103.4	9.5	10	0.14	54	60	31.88	3825_32	97.2	8.2	6.5	0.38	64	70	41.09
3825_28	94.0	8.7	9.5	0.15	60	65	29.73	3825_30	97.6	6	6.5	0.50	65	70	56.59
3840_47	92.4	9.2	9	0.17	57	52	37.73	3840_49	97.3	6	6.5	0.51	67	71	54.70
3840_42	108.3	9.6	10	0.14	63	65	26.93	3825_31	98.6	5.5	6.5	0.62	67	73	59.78
3840_35	93.9	8.7	9	0.18	52	50	44.60	3840_51	101.8	6	7	0.49	63	65	60.35
3825_41	94.3	8.7	9.5	0.16	68	70	25.51	3825_33	100.7	6	7	0.50	49	50	92.63
3840_37	97.2	8.2	9.5	0.19	65	65	30.90	3840_50	103.1	6	6	0.57	50	55	95.16
3825_41	111.4	9.5	9.2	0.19	65	60	31.79	3840_48	103.6	6	6.5	0.54	48	50	101.16
3840_52	96.5	9.2	9.5	0.16	60	55	33.56	3750_11	96.9	5.5	6.5	0.55	50	48	107.19
3825_25	94.9	6	10	0.32	61	65	44.67	3840_51	102.6	6	6.5	0.53	60	63	68.47
3825_42	102.6	6	10	0.37	70	70	40.01	3825_33	94.6	5.5	6.5	0.60	45	45	113.08
3825_47	91.9	8.7	9.5	0.16	62	68	27.76	3750_12	102.0	6	6.5	0.59	47	50	103.29
3825_44	96.7	8.7	9.5	0.19	58	65	31.78	3840_56	97.4	6.2	6.5	0.49	67	70	53.53
3840_67	101.1	8	9.8	0.21	55	60	39.16	3840_58	98.4	5.2	6.5	0.65	75	78	54.73
3825_35	96.4	8.5	9.5	0.16	60	65	31.05	3750_13	105.7	6	6.5	0.56	51	55	89.84
3840_70	102.8	6	9.5	0.35	78	83	32.32	3750_15	96.5	5.2	6.5	0.58	48	55	103.27
3840_82	88.1	8.7	8.5	0.16	65	68	28.13	3750_12	103.4	5.2	6.5	0.63	55	47	112.95
3735_01	99.2	6	7	0.46	49	50	90.87	3840_53	99.0	6	6.6	0.51	72	74	49.87
3735_01	87.9	6	6.5	0.44	46	49	95.25	3750_16	95.2	6.2	6.5	0.49	59	65	62.26
3825_68	84.3	8.7	8.3	0.17	55	60	35.88	3825_47	101.7	6	6.5	0.60	65	63	65.48
3825_63	138.8	7.8	9	0.40	57	55	57.62	3825_48	113.5	6	7.3	0.56	57	60	72.10
3825_72	90.9	8.2	8.5	0.21	52	55	44.96	3750_13	89.1	6.5	6.5	0.44	50	55	75.02
3825_72	113.4	9.6	9.5	0.19	55	58	36.39	3825_39	96.2	6	6.5	0.52	51	50	92.81
3825_71	99.4	8.2	9	0.19	52	55	44.95	3750_18	95.7	5.2	6.6	0.59	48	55	101.88
3825_73	121.7	8.7	9.8	0.20	55	52	45.24	3825_49	97.5	6	6.5	0.54	70	75	50.76
3825_70	113.3	8.7	9.5	0.21	50	55	46.02	3825_48	107.6	6.5	6.7	0.50	55	60	70.82
3825_24	96.4	8.7	8.6	0.19	63	60	84.31	3750_16	94.1	6	6.5	0.47	55	60	72.08
3785_34	94.9	6	6.5	0.50	48	50	95.92	3825_39	94.5	5.5	6.5	0.54	50	50	101.72
3785_35	89.8	5.5	6.5	0.61	47	55	101.82	3750_20	97.9	6	6.5	0.52	48	45	107.88
3780_26	103.0	6	6.5	0.60	48	50	107.51	3825_51	97.4	6	6.5	0.53	67	70	55.75
3780_37	91.1	6	6.5	0.49	55	62	69.25	3825_52	101.0	6	7	0.46	55	62	68.96
3870_71	97.6	6	6.5	0.47	62	65	62.35	3750_22	94.8	6	7	0.48	49	55	81.83
3855_21	101.6	5.2	6.5	0.66	79	83	50.54	3840_62	96.7	6	6.5	0.50	65	69	57.16
3855_22	97.9	5.2	6.5	0.66	65	68	69.23	3825_50	95.2	6	6.5	0.46	50	55	84.22
3795_35	104.7	6	7	0.32	66	70	55.59	3750_21	96.6	6	6.5	0.52	47	50	98.73
3870_84	102.0	6.2	6.5	0.50	70	75	49.85	3825_56	98.4	6	6.5	0.53	70	74	51.48
3855_40	97.4	6.5	6.5	0.43	68	73	47.71	3825_54	104.7	6	7	0.50	78	75	45.78
3855_43	95.9	5.2	6.5	0.54	62	64	72.98	3750_23	105.2	5.2	7	0.61	53	50	105.05
3840_23	98.2	6.4	6.5	0.45	57	62	65.09	3825_57	100.3	6	6.5	0.52	72	78	49.58
3840_20	100.1	6	6.5	0.51	57	62	71.09	3825_51	95.8	6	6.5	0.51	65	72	54.79
3840_21	97.8	6	6.5	0.51	55	52	84.90	3750_21	99.0	6	7	0.47	51	55	81.06
3840_21	97.5	6	6.7	0.48	50	55	83.98	3825_59	104.5	6	6.5	0.55	65	68	61.09
3785_23	101.1	6	7	0.50	51	55	82.45	3825_60	103.1	5.2	7	0.61	64	66	69.64
3855_44	103.1	5.5	7	0.37	66	68	62.22	3785_02	88.0	6.5	6.5	0.49	52	55	72.16
3840_25	95.3	6.4	6.5	0.43	63	65	56.59	3840_70	95.4	5.2	6.5	0.57	75	82	50.50
3840_26	96.8	6.5	6.5	0.46	62	65	57.46	3735_03	95.1	6	6.5	0.52	48	50	96.47
3855_50	105.3	6	7	0.52	49	45	105.29	3825_64	100.2	6	6.7	0.52	65	62	63.42
3840_26	97.0	6	6.5	0.50	59	57	73.46	3825_58	98.9	6	6.5	0.52	77	80	44.58
3840_27	101.1	6	7	0.50	55	52	82.15	3825_41	100.8	8.7	8.5	0.21	62	65	33.83
3750_01	116.9	6	7	0.58	40	40	146.37	3840_82	98.9	6	6.6	0.50	54	59	76.07
3785_26	97.4	6	6.5	0.51	65	70	56.68	3825_68	98.5	6	6.5	0.52	42	45	119.76
3840_29	98.5	6	6.5	0.50	77	83	42.80	3825_64	98.4	6	6.5	0.52	67	70	55.87
3840_28	94.7	5.2	6.5	0.57	65	68	66.69	3825_65	97.2	6	6.5	0.49	68	73	52.37
3855_54	93.8	6	6.5	0.50	60	65	63.17	3825_70	94.1	6.5	6.5	0.46	50	55	77.75
3750_02	93.7	6	6.5	0.50	55	58	74.78	3735_03	94.1	6	6.5	0.48	50	55	84.07
3840_28	95.9	6	6.5	0.50	54	60	74.58	3825_40	98.3	6.5	6.5	0.52	62	65	58.78
3840_20	96.8	6	6.5	0.57	64	68	59.75	3825_71	95.6	6	6.5	0.51	64	70	56.85
3840_23	93.1	6	6	0.50	40	35	159.65	3825_71	98.2	6	6.6	0.37	54	60	71.41
3840_21	100.5	6	6.5	0.37	75	82	45.43	3735_05	98.0	6.2	6.5	0.54	50	55	84.81
3840_31	102.7	6	6.8	0.51	75	81	44.34	3735_04	96.4	6	6.5	0.55	50	45	104.62
3840_34	90.4	6	6.5	0.47	57	61	67.75	3825_78	95.7	7	7	0.41	50	45	82.77

Fuente: Cálculo de datos en Excel.

memoricen literalmente y busquen más iteraciones con las demás neuronas de entrada.

- k) *Kinovea*. Es un software de análisis de vídeo, que sirve para observar, analizar, hacer mediciones de movimientos y trayectorias.
- l) *Matlab*. Mathworks, (1994); Se trata de un lenguaje de computación técnica de alto nivel y un entorno interactivo para desarrollo de algoritmos, visualización de datos, análisis de datos y cálculo numérico.
- m) *Minimizar el ruido*. Se refiere a los valores nulos y a los valores con formato inconsistente que se puedan presentar durante la prueba.
- n) *Momento*. Determina cómo los cambios pasados de los pesos afectan a los actuales cambios en los pesos.
- o) *Red neuronal artificial (RNA)*. Las redes neuronales artificiales son técnicas de aprendizaje y procesamiento automático inspirada en el funcionamiento del cerebro humano.
- p) *Rifting*. Insuficiente longitud de taco y/o material de taco inapropiado pueden producir Flyrock del material del taco y de la roca suelta en el collar.
- q) *Overfitting*. Se da cuando la red tan solo aprende puntos individuales en vez de generales.

CAPÍTULO III

HIPÓTESIS

3.1 HIPÓTESIS DE LA INVESTIGACIÓN.

3.1.1 Hipótesis general.

- La determinación de las distancias, cubiertas por el flyrock, usando las redes neuronales artificiales del Matlab en el tajo Ferrobamba, proyecto minero las Bambas.

3.1.2 Hipótesis específico.

- Se conoce el comportamiento de las variables de proyección de roca para el tajo Ferrobamba, mediante el análisis de sensibilidad.
- Existe un alto grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección.
- Establecer los parámetros de voladura y datos Geotécnicos para la predicción de la distancia cubierta por el flyrock, en el Tajo Ferrobamba del proyecto minero las Bambas.
- Las redes neuronales del Matlab son una potente herramienta de predicción a diferencia de otros métodos tradicionales de predicción de flyrock.

3.2 VARIABLES.

OPERACIONALIZACIÓN DE VARIABLES	
DEPENDIENTE	UNIDADES
Predicción de la distancia	m. (metros)
INDEPENDIENTE	UNIDADES
Aplicación de las redes neuronales del Matlab	<ul style="list-style-type: none"> • Concentración de carga lineal (Kg/m) • Burden (m) • Taco (m) • Espaciamiento (m) • Factor de carga (Kg/ton) • RMR (Mpa) • RQD (%)

Fuente: matriz de consistencia.

CAPÍTULO IV

METODOLOGÍA DE LA INVESTIGACIÓN

4.1 TIPO Y ALCANCE DE LA INVESTIGACIÓN.

Según Hernández, R. (2010). El tipo de la investigación es, Cuasiexperimental, y tiene un alcance Correlacional, por que intentaremos predecir el valor aproximado de la variable de la distancia cubierta por los proyectiles de roca y/o flyrock, a partir del valor que poseen las variables de los parámetros de voladura, en artificial neural network.

4.2 MÉTODO Y DISEÑO DE INVESTIGACIÓN.

4.2.1 Método.

El método planteado para este trabajo es del tipo “Inductivo”, por otro lado también “Estadístico” en lo que se pretende sacar estadísticas mediante gráficos y correlaciones, y “analítico” para poder hacer un adecuado análisis de los resultados obtenidos.

4.2.2 Métodos de predicción.

TABLA 17. Métodos de predicción.

Nº	PASOS	DESCRIPCIÓN
1	Identificar el horizonte temporal	Es decir el corto, mediano y largo plazo.
2	Observar los hechos.	Identificar las variables a predecir y sus dependencias
3	Seleccionar una Técnica.	Seleccionar las técnicas que más se ajustan al tipo de problemas presentado.
4	Aplicar Técnicas Seleccionadas	Implementar la predicción con la técnica seleccionada.

FUENTE: (Bowerman, 2007)

- Método de diseño de modelos de predicciones con redes neuronales artificiales.

4.2.3 Diseño de la investigación.

Del libro de Hernández, R.(2010), pág.152, se obtiene, que el diseño de investigación para el presente trabajo, es el diseño Cuasi-experimental, en la clasificación de los “Diseños transeccionales exploratorios”, ya que el propósito es comenzar a conocer el comportamiento de una variable, por lo que se aplica a problemas poco conocidos.

4.3 POBLACIÓN Y MUESTRA.

4.3.1 Población.

El presente trabajo de investigación se realizara en el proyecto minero las Bambas, la población para este estudio han sido los bancos: 3735, 3750, 3765, 3780, 3795, 3825, 3840, 3855, 3870, 3885 y 3900 del tajo Ferrobamba en donde han cumplido las condiciones para las muestras.

4.3.2 Muestra.

Las muestras que se han tomado para el presente estudio son los fragmentos con tamaños mayores a 10 centímetros, obteniendo un total 152 datos de registros de voladura entre mineral y desmonte.

4.4 METODOS, TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

4.4.1 Metodología.

Las metodologías consideradas para el siguiente trabajo son: la metodología para la generación de datos, pronósticos y la implementación de las redes neuronales artificiales.

4.4.1.1 Metodología usada en la generación de datos.

4.4.1.1.1 Sobre datos de distancia observada.

Se identificó las máximas distancias proyectadas por fragmentos mayores a 10 cm, mediante el uso de GPS y winchado a partir de la pila del material volado llevando, el registro por bancos, niveles y proyectos de voladura como se muestra en la TABLA.18.

FIGURA 41. Medición de fragmentos después de la voladura con GPS.



Fuente: Fotografía de campo.

TABLA 18. Registro de distancias observadas.

DISTANCIAS OBSERVADAS DEN CAMPO		DISTANCIAS OBSERVADAS DEN CAMPO		DISTANCIAS OBSERVADAS DEN CAMPO	
Proyecto	Distancia Real (m)	Proyecto	Distancia Real (m)	Proyecto	Distancia Real (m)
3885_56	24	3855_40	45	3750_12	94
3900_55	32	3855_42	75	3840_56	51
3870_75	27	3840_23	58	3840_58	58
3870_67	30	3840_20	67	3750_13	79
3870_79	44	3840_22	81	3750_15	104
3870_83	23	3840_21	80	3750_12	111
3855_41	33	3765_23	74	3840_53	54
3855_53	25	3855_44	58	3750_16	58
3855_57	27	3840_25	54	3825_47	58
3840_24	72	3840_26	52	3825_48	63
3765_26	30	3855_50	89	3750_13	77
3855_59	35	3840_26	68	3825_39	89
3840_42	33	3840_27	76	3750_18	92
3840_43	37	3750_01	123	3825_49	54
3855_63	24	3765_26	50	3825_48	60
3825_26	26	3840_29	41	3750_16	68
3825_28	27	3840_28	76	3825_39	98
3840_47	33	3855_54	56	3750_20	97
3840_42	19	3750_02	79	3825_51	51
3840_55	34	3840_28	69	3825_52	62
3825_41	22	3840_30	54	3750_22	82
3840_57	25	3840_33	150	3840_62	52
3825_41	23	3840_31	44	3825_50	82
3840_52	31	3840_31	42	3750_21	97
3825_35	34	3840_34	72	3825_56	50
3825_42	35	3750_04	94	3825_54	44
3825_47	29	3840_41	53	3750_23	98
3825_44	28	3765_26	56	3825_57	46
3840_67	35	3855_63	56	3825_51	53
3825_55	28	3825_27	58	3750_21	74
3840_70	33	3825_26	86	3825_59	54
3840_82	30	3750_09	69	3825_60	77
3735_01	80	3765_27	75	3735_02	74
3735_01	87	3825_29	51	3840_70	53
3825_68	37	3825_28	83	3735_03	93
3825_63	34	3840_45	51	3825_64	57
3825_72	42	3840_46	51	3825_58	44
3825_72	26	3840_44	71	3825_41	31
3825_72	36	3840_44	57	3840_82	71
3825_73	37	3750_09	87	3825_68	110
3825_70	35	3825_32	37	3825_64	51
3825_74	28	3825_30	54	3825_65	47
3765_14	91	3840_49	52	3825_70	78
3765_15	99	3825_31	63	3735_03	81
3780_36	93	3840_51	60	3825_40	54
3780_37	66	3825_33	88	3825_71	55
3870_71	57	3840_50	90	3825_71	68
3855_33	53	3840_48	93	3735_05	79
3855_32	68	3750_11	108	3735_04	105
3795_35	58	3840_51	68	3825_78	76
3870_84	49	3825_33	106		

Fuente: Obtenido de datos de campo.

4.4.1.1.2 Sobre datos geotécnicos.

El RQD y RMR han sido generados a partir de ensayos ya realizados en el tajo Ferrobamba, el área de geotecnia se ha encargado de determinar estos valores para diferentes niveles durante la perforación diamantina practicada en la exploración, estos resultados fueron integrados al software minesigh 3D, los valores generados para cada nivel y taladro fueron a partir del contraste entre la información del levantamiento topográfico de los taladros a cargar y la información cargada al software, los datos obtenidos se muestran en la siguiente tabla.

TABLA 19. Datos geotécnicos generados desde el Minesigth 3D.

DATOS GEOLÓGICOS DEL TAJO FERROBAMBA			DATOS GEOLÓGICOS DEL TAJO FERROBAMBA			DATOS GEOLÓGICOS DEL TAJO FERROBAMBA		
Proyecto	RMR (Mpa)	RQD(%)	Proyecto	RMR (Mpa)	RQD(%)	Proyecto	RMR (Mpa)	RQD(%)
3885_56	71	72	3855_40	68	73	3750_12	47	50
3900_55	60	55	3855_42	62	64	3840_56	67	70
3870_75	65	70	3840_23	57	62	3840_58	75	78
3870_67	55	60	3840_20	57	62	3750_13	51	55
3870_79	50	45	3840_22	55	52	3750_15	48	55
3870_83	67	72	3840_21	50	55	3750_12	55	47
3855_41	79	82	3765_23	51	55	3840_53	72	74
3855_53	60	60	3855_44	66	68	3750_16	59	65
3855_57	57	62	3840_25	63	65	3825_47	65	63
3840_24	57	60	3840_26	62	65	3825_48	57	60
3765_26	60	65	3855_50	49	45	3750_13	50	55
3855_59	75	81	3840_26	59	57	3825_39	51	50
3840_42	55	58	3840_27	55	52	3750_18	48	55
3840_43	48	49	3750_01	40	40	3825_49	70	75
3855_63	65	60	3765_26	65	70	3825_48	55	60
3825_26	54	60	3840_29	77	83	3750_16	55	60
3825_28	60	65	3840_28	65	68	3825_39	50	50
3840_47	57	52	3855_54	60	65	3750_20	48	45
3840_42	63	65	3750_02	55	58	3825_51	67	70
3840_55	52	50	3840_28	54	60	3825_52	55	62
3825_41	68	70	3840_30	64	68	3750_22	49	55
3840_57	65	65	3840_33	40	35	3840_62	65	69
3825_41	65	60	3840_31	75	82	3825_50	50	55
3840_52	60	55	3840_31	75	81	3750_21	47	50
3825_35	61	65	3840_34	57	61	3825_56	70	74
3825_42	70	70	3750_04	47	50	3825_54	78	75
3825_47	62	68	3840_41	66	70	3750_23	53	50
3825_44	58	65	3765_26	67	72	3825_57	72	76
3840_67	55	60	3855_63	65	70	3825_51	65	72
3825_55	60	65	3825_27	65	71	3750_21	51	55
3840_70	78	83	3825_26	48	55	3825_59	65	68
3840_82	65	68	3750_09	52	56	3825_60	64	66
3735_01	49	50	3765_27	50	50	3735_02	52	55
3735_01	46	49	3825_29	65	70	3840_70	75	82
3825_68	55	60	3825_28	50	54	3735_03	48	50
3825_63	57	55	3840_45	67	70	3825_64	65	62
3825_72	52	55	3840_46	65	72	3825_58	77	80
3825_72	55	58	3840_44	65	67	3825_41	62	65
3825_72	52	55	3840_44	65	71	3840_82	54	59
3825_73	55	52	3750_09	50	50	3825_68	42	45
3825_70	50	55	3825_32	64	70	3825_64	67	70
3825_74	63	60	3825_30	65	70	3825_65	68	73
3765_14	48	50	3840_49	67	71	3825_70	50	55
3765_15	47	55	3825_31	67	73	3735_03	50	55
3780_36	48	50	3840_51	63	65	3825_40	62	65
3780_37	55	62	3825_33	49	50	3825_71	64	70
3870_71	62	65	3840_50	50	55	3825_71	54	60
3855_33	79	83	3840_48	48	50	3735_05	50	55
3855_32	65	68	3750_11	50	48	3735_04	50	45
3795_35	66	70	3840_51	60	63	3825_78	50	45
3870_84	70	75	3825_33	45	45			

Fuente: Registro de datos planeamiento mina.

4.4.1.4 Métodos de pronóstico.

TABLA 20. Método General de Diseño de Pronóstico.

	Pasos	Descripción
1	Temporal	Es decir el corto, mediano y largo plazo.
2	Observar los Hechos	Identificar las variables a predecir y sus dependencias
3	Seleccionar una Técnica	Seleccionar las técnicas que más se ajustan al tipo de problemas presentado.
4	Aplicar Técnicas	Implementar el pronóstico con la técnica seleccionada.

Fuente: Método de diseño de modelos de pronósticos con redes neuronales artificiales.

4.4.1.5 Metodología para la implementación de las redes neuronales.

La metodología para la implementación de Redes Neuronales en la predicción del flyrock, se basa en el trabajo de Kaastra y Boyd 1996.

El cual está compuesto por 8 pasos:

- 1.- Selección de la Variable.
- 2.- Recolección de Datos.
- 3.- Pre-procesamiento de Datos.
- 4.- Definición de Conjunto de Entrenamiento, Validación y Prueba.
 - a) Conjunto de Entrenamiento.
 - b) Conjunto de Validación.
 - c) Conjunto de Prueba.
- 5.- Selección de la Arquitectura de Redes Neuronales.
 - a) Número de Neuronas de Entrada.
 - b) Número de Capaz Ocultas.
 - c) Número de Neuronas Ocultas.
 - d) Número de Neuronas de Salida.

e) Función de Transferencia.

6.- Criterios de Evaluación.

7.- Entrenamiento de la Red Neuronal.

a) Número de Iteraciones.

b) Tasa de Aprendizaje y Momentum.

8.- Implementación del Modelo de Redes Neuronales Artificiales.

4.4.2 Técnicas a utilizar.

- Análisis de videos
- Redes neuronales artificiales.
- Regresión multivariable.

4.4.3 Herramientas.

- MATLAB 8.5.0
- MATLAB Neural Network Toolbox, KINOVEA
- Microsoft Excel 2013, GPS, wincha.
- CAMARA FOTOGRAFICA (61 frames for second)

4.4.4 Fuente.

Los datos geológicos y geotécnicos a emplear fueron proporcionados por el área de planeamiento mina.

4.5 ANÁLISIS E INTERPRETACIÓN DE DATOS

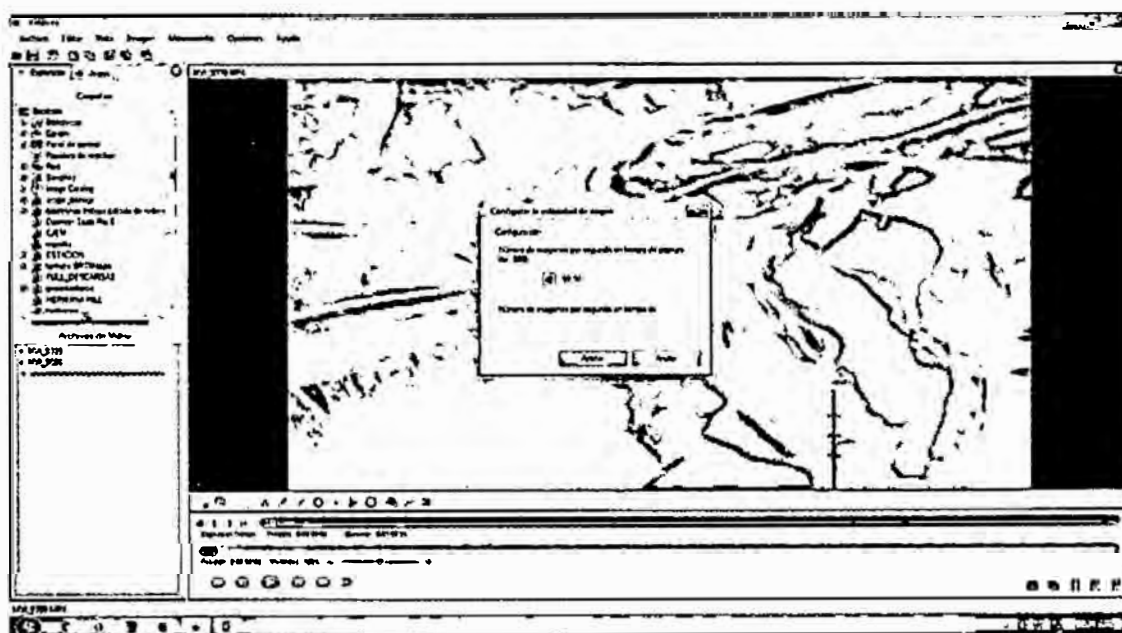
4.5.1 Predicción de flyrock por el KINOVEA.

Las voladuras se registraron en los diferentes proyectos, mediante la cámara fotográfica, asegurándose de que esta coincida con el plano horizontal de la malla, y de que se pueda escalar correctamente mediante los patrones de burden-espaciamento.

Estos registros han sido descargados a la computadora en formato .mp4, archivo soportado por el software KINOVEA, para realizar el análisis de movimiento lento. Dicho análisis se realizó calibrando la escala con el burden, espaciamiento y altura de banco como se muestra en la Figura. 45.

Para un correcto análisis con el software KINOVEA hay que conocer la velocidad de grabado de la cámara, el mismo que es de vital importancia para el trabajo, ya que el cálculo de la velocidad se da en base a los cuadros por segundo grabados por la cámara, la calibración de la velocidad se realiza en la pestaña Opciones<preferencia<general, (ver Figura.43), además en esta pestaña se configura el formato del tiempo, la velocidad de la cámara utilizada es de 59.94 frames for second.

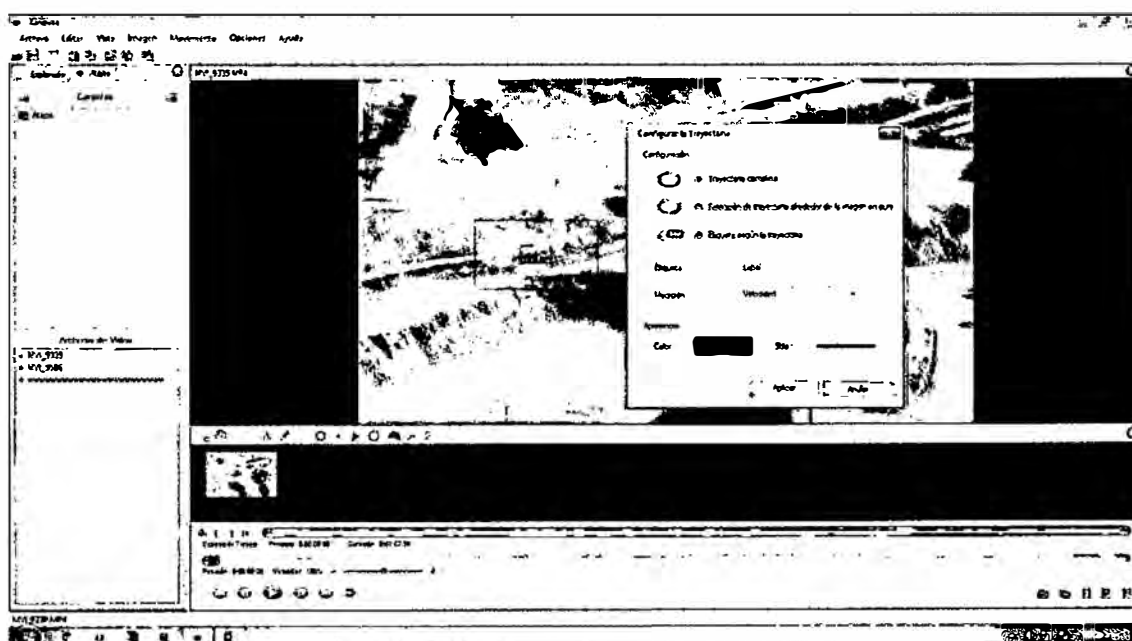
FIGURA 43. Configuración de los cuadros por segundo.



Fuente: Captura en pantalla del software Kinovea.

En el análisis de la trayectoria se determinó los fragmentos a analizar utilizando el marcador en la pantalla principal, este marcador tiene propiedades que se ingresan presionando el anticlic del mouse, sobre el macador antes mencionado, en él se configura las etiquetas de velocidad del proyectil (ver Figura .44).


FIGURA 44. Configuración de la trayectoria.



Fuente: captura en pantalla en el software Kinovea.

Seguidamente se procedió a analizar las proyecciones de los fragmentos con mayores alcances, siguiendo la trayectoria del movimiento, para calcular el ángulo inicial con que este sale proyectado y la velocidad a la cual viaja (Ver. Figura.45).

FIGURA 45. Análisis de movimiento lento en el KINOVEA.



Fuente: Fotografía extraída del entorno KINOVEA.

Las distancias del flyrock han sido calculados por la formula física del alcance máximo.

$$Dk = \frac{Vo^2 \text{sen}(2\theta o)}{g} (24)$$

Donde:

Dk: Distancia calculada por el software Kinovea (m)

Vo: Velocidad inicial del con que sale el flyrock (m/s)

θo : Angulo inicial con que sale el flyrock

g: gravedad (m/s)

En total se ha realizado el análisis para 152 voladuras obteniéndose los siguientes resultados como se muestra en la TABLA .21.

TABLA 21. Registro de ángulos y velocidades, y cálculo de distancias "Dk (m)".

Proyecto	Vo	Bo	g	Dk
3885_56	28.5	79	9.8	31.1
3900_55	29.4	77	9.8	38.7
3765_14	34.0	58	9.8	106.2
3765_15	35.3	56	9.8	118.3
3780_36	33.8	59	9.8	103.1
3780_37	31.0	68	9.8	68.2
3870_71	31.7	69	9.8	68.7
3855_33	30.8	71	9.8	59.7
3855_32	32.1	66	9.8	78.3
3870_75	28.9	79	9.8	32.0
3795_35	31.6	70	9.8	65.6
3870_67	30.1	76	9.8	43.4
3870_79	31.3	72	9.8	58.9
3870_83	29.5	79	9.8	33.3
3870_84	30.9	74	9.8	51.8
3855_41	29.0	78	9.8	35.0
3855_40	31.1	73	9.8	55.2
3855_42	32.0	64	9.8	82.5
3840_23	31.6	69	9.8	68.3
3840_20	32.3	68	9.8	74.1
3840_22	32.8	62	9.8	91.2
3840_21	33.1	62	9.8	92.6
3765_23	32.5	65	9.8	82.7
3855_44	31.0	70	9.8	63.1
3840_25	29.2	70	9.8	56.0
3840_26	31.4	71	9.8	62.0
3855_50	34.0	57	9.8	107.9
3840_26	32.3	66	9.8	79.3
3840_27	32.2	65	9.8	80.9
3750_01	38.5	43	9.8	150.8
3765_26	30.8	71	9.8	59.7
3855_53	29.3	79	9.8	32.9
3855_57	29.3	78	9.8	35.8
3840_24	32.4	67	9.8	77.2
3840_29	30.0	75	9.8	46.1
3840_28	32.2	65	9.8	81.0
3855_54	31.5	69	9.8	67.9
3750_02	32.3	66	9.8	79.3
3840_28	32.3	64	9.8	84.0
3840_30	30.3	68	9.8	65.2
3840_33	39.0	45	9.8	155.6
3840_31	30.2	73	9.8	52.1
3840_31	30.8	74	9.8	51.3
3840_34	32.7	68	9.8	75.9
3765_26	29.4	78	9.8	35.9
3750_04	33.8	59	9.8	103.1
3855_59	28.7	78	9.8	34.2
3840_41	31.0	71	9.8	60.5
3765_26	31.1	72	9.8	58.1
3855_63	31.4	70	9.8	64.8
3840_42	29.7	80	9.8	30.8
3840_43	31.0	77	9.8	43.1
3825_27	31.1	70	9.8	63.6
3825_26	33.1	63	9.8	90.6
3855_63	28.3	78	9.8	33.2
3825_26	28.4	78	9.8	33.6
3825_28	28.4	78	9.8	33.6
3750_09	32.3	64	9.8	84.0
3765_27	33.0	62	9.8	92.3
3825_29	31.3	71	9.8	61.7
3825_28	33.1	62	9.8	92.8
3840_45	31.1	73	9.8	55.1
3840_46	31.1	74	9.8	52.5
3840_44	32.0	67	9.8	75.3
3840_47	29.1	77	9.8	37.8
3840_44	30.7	70	9.8	61.9
3750_09	33.5	62	9.8	95.1
3840_42	28.9	79	9.8	32.0
3825_32	30.1	76	9.8	43.5
3825_30	30.8	70	9.8	62.3
3840_49	31.0	70	9.8	63.1
3825_31	31.4	69	9.8	67.4
3840_51	31.2	69	9.8	66.6
3825_33	33.2	62	9.8	93.4
3840_50	33.7	60	9.8	100.5
3840_48	34.2	58	9.8	107.1
3750_11	35.0	56	9.8	116.1
3840_55	30.1	75	9.8	46.2
3840_51	31.6	67	9.8	73.4
3825_33	37.5	57	9.8	131.5
3750_12	34.1	57	9.8	108.6
3840_56	31.1	72	9.8	58.1
3840_58	31.3	71	9.8	61.7
3825_41	28.5	79	9.8	31.1
3750_13	32.7	61	9.8	92.7
3750_15	34.2	59	9.8	105.3
3750_12	36.4	57	9.8	123.9
3840_57	29.2	80	9.8	29.8
3825_41	29.3	78	9.8	35.8
3840_52	29.2	78	9.8	35.4
3840_53	30.5	75	9.8	47.5
3750_16	32.0	69	9.8	70.2
3825_35	30.7	75	9.8	48.2
3825_42	29.0	74	9.8	45.6
3825_47	31.2	69	9.8	66.6
3825_48	32.2	67	9.8	76.2
3750_13	32.1	66	9.8	78.3
3825_39	33.6	61	9.8	97.9
3750_18	34.1	59	9.8	104.9
3825_47	29.2	79	9.8	32.6
3825_44	29.0	78	9.8	35.0
3825_49	31.1	72	9.8	58.1
3825_48	31.3	69	9.8	67.0
3750_16	32.0	65	9.8	80.2
3825_39	34.1	58	9.8	106.5
3750_20	34.2	55	9.8	112.3
3825_51	32.3	72	9.8	62.7
3840_67	30.1	76	9.8	43.4
3825_52	32.1	68	9.8	73.2
3750_22	32.7	63	9.8	88.4
3840_62	31.0	70	9.8	63.1
3825_50	32.4	64	9.8	84.6
3750_21	34.0	57	9.8	107.9
3825_56	31.0	73	9.8	55.0
3825_55	29.4	79	9.8	33.1
3825_54	31.0	74	9.8	52.1
3750_23	34.4	55	9.8	113.7
3840_70	29.4	78	9.8	35.8
3825_57	30.5	72	9.8	55.9
3825_51	31.1	70	9.8	63.6
3840_82	29.2	78	9.8	35.3
3735_01	34.1	59	9.8	104.9
3750_21	32.5	64	9.8	85.1
3825_59	31.8	69	9.8	69.2
3735_01	33.6	61	9.8	97.9
3825_60	31.6	66	9.8	75.9
3735_02	32.5	66	9.8	80.2
3840_70	31.7	73	9.8	57.4
3735_03	33.8	60	9.8	101.1
3825_64	32.3	69	9.8	71.4
3825_58	31.0	73	9.8	54.9
3825_68	29.4	78	9.8	35.9
3825_41	28.9	77	9.8	37.3
3840_82	32.3	67	9.8	76.7
3825_68	37.3	58	9.8	127.8
3825_64	30.6	70	9.8	61.5
3825_63	30.5	69	9.8	63.6
3825_65	31.0	72	9.8	57.7
3825_72	30.8	75	9.8	48.5
3825_70	32.2	65	9.8	81.2
3825_72	29.4	79	9.8	33.1
3735_03	32.5	61	9.8	91.6
3825_40	31.3	72	9.8	58.9
3825_72	30.0	78	9.8	37.4
3825_73	31.1	74	9.8	52.4
3825_70	31.3	73	9.8	56.0
3825_71	31.0	69	9.8	65.7
3825_71	31.9	65	9.8	79.7
3735_05	33.0	63	9.8	90.1
3735_04	34.3	56	9.8	111.5
3825_74	28.3	78	9.8	33.3
3825_78	32.0	66	9.8	77.8

Fuente: Resultado de cálculos de distancias en el KINOVEA.

4.5.2 Predicción de flyrock por el análisis de la regresión multivariable MVRA.

Las relaciones entre las variables pueden ser calculadas usando el método de los mínimos cuadrados y el análisis de la regresión multivariable, la regresión de las matrices resuelven las ecuaciones así creadas. Para el cálculo mediante la regresión multivariable, se utilizó los mismos valores de entrada que se utilizó para el cálculo con las redes neuronales; la ecuación para la predicción del flyrock mediante este método es el siguiente:

$$D_{rm} = \frac{10^{5.1} q_1^{0.51} q^{0.14}}{B^{0.93} S^{0.64} RMR^{0.75} RQD^{0.93}} \quad (25)$$

Donde:

D_{rm} : Distancia calculada por la regresión multivariable (m)

q_1 : Concentración de carga lineal (kg/m)

q : Factor de carga (Kg/ton).

B : Burden (m)

S : Stemming o taco (m)

RMR : Clasificación de bienaski (Mpa)

RQD : Índice de calidad de la roca (%).

Los cálculos realizados para hallar la distancia por la regresión multivariable se muestran en la TABLA.23 y fueron calculados en una hoja Excel, los datos son los mismos parámetros de entrada que se utilizan en el cálculo de la distancia predecida por las redes neuronales artificiales.

TABLA 22. Registro de parámetros y cálculo de distancias “D_{rm} (m)”.

DATOS PARA CALCULOS DE LA REGRESIÓN MULTIVARIABLE								DATOS PARA CALCULOS DE LA REGRESIÓN MULTIVARIABLE							
Proyecto	Concentración de carga (kg/m²)	Burden	Stemming	Factor de carga	RMR	RQD	D _{rm}	Proyecto	Concentración de carga (kg/m²)	Burden	Stemming	Factor de carga	RMR	RQD	D _{rm}
	kg/m²	kg/m²	kg/m²	kg/m²	Mpa	%	m		kg/m²	kg/m²	kg/m²	kg/m²	Mpa	%	m
3885_56	97.2	8.7	9	0.17	71	72	25.40	3750_04	96.9	6	6.5	0.51	47	50	98.69
3900_35	109.2	9.5	9.5	0.16	60	55	34.65	3840_41	92.7	6	6.5	0.53	56	70	53.01
3870_75	103.3	9	9.5	0.17	65	70	26.90	3765_26	101.8	6	7	0.50	67	72	52.57
3870_67	99.0	8.7	9.5	0.16	55	60	35.35	3855_63	99.0	6	6.5	0.54	65	70	57.62
3870_78	87.3	8	8.5	0.19	50	45	55.95	3825_27	98.0	6.2	6.5	0.50	65	71	54.24
3870_83	96.5	8.7	9.5	0.17	67	72	25.52	3825_26	97.0	6	6.5	0.51	48	55	88.85
3855_41	96.6	6	9.5	0.31	79	82	30.77	3750_09	102.5	6	7	0.48	52	56	80.04
3855_53	93.9	9	9.5	0.14	60	60	30.75	3765_27	97.0	6	6.6	0.34	50	50	88.26
3826_57	101.5	9.5	9.5	0.15	57	62	30.73	3825_29	98.9	6	6.5	0.52	65	70	57.33
3840_24	66.0	5.2	6.5	0.25	57	60	61.29	3825_28	102.3	6	7	0.51	50	54	85.97
3705_26	91.9	8.7	9	0.16	60	65	30.50	3840_45	96.2	6	6.5	0.50	67	70	54.94
3855_59	97.2	8.7	8.5	0.19	75	81	23.43	3840_46	100.4	6	6.6	0.52	65	72	55.74
3840_42	83.2	8.7	8.8	0.15	55	58	34.62	3840_44	98.6	5.2	6.5	0.60	65	67	69.40
3840_43	105.7	9.6	9.5	0.15	48	49	44.35	3840_44	98.2	6	6.5	0.56	65	71	56.90
3855_63	96.3	9.5	9	0.14	65	60	28.87	3750_09	96.6	6	6.5	0.50	50	50	93.82
3845_26	109.4	9.5	10	0.14	54	80	31.88	3825_32	97.2	8.2	6.5	0.38	64	70	41.09
3825_28	94.0	8.7	9.5	0.15	60	65	29.73	3825_30	97.6	6	6.5	0.50	65	70	56.59
3840_47	92.4	9.2	9	0.17	57	52	37.73	3840_49	97.3	6	6.5	0.51	67	71	54.70
3840_42	108.3	9.6	10	0.14	63	65	26.93	3825_31	98.6	5.5	6.5	0.62	67	73	59.78
3840_55	93.9	8.7	9	0.18	52	50	44.60	3840_51	101.8	6	7	0.49	63	65	60.35
3825_41	94.3	8.7	9.5	0.16	68	70	25.51	3825_33	100.7	6	7	0.50	49	50	92.63
3840_57	97.2	8.2	9.5	0.19	65	65	30.90	3840_50	103.1	6	6	0.57	50	55	95.16
3825_41	111.4	9.5	9.2	0.19	65	60	31.79	3840_48	103.6	6	6.5	0.54	48	50	101.16
3840_52	96.5	9.2	9.5	0.16	60	55	33.56	3750_11	96.9	5.5	6.5	0.55	50	48	107.19
3825_25	94.9	5	10	0.32	61	65	44.67	3840_51	102.6	6	6.5	0.53	60	63	68.47
3825_42	102.6	6	10	0.37	70	70	40.01	3825_33	94.6	5.5	6.5	0.60	45	45	123.08
3825_47	91.9	8.7	9.5	0.16	62	68	27.76	3750_12	102.0	6	6.5	0.59	47	50	103.29
3825_64	96.7	8.7	9.5	0.19	58	65	31.78	3840_36	97.4	6.2	6.5	0.49	67	70	53.53
3840_67	101.1	8	9.8	0.21	55	60	39.16	3840_58	98.4	5.2	6.5	0.65	75	78	54.73
3825_25	96.4	8.5	9.5	0.16	60	65	31.05	3750_13	105.7	6	6.5	0.56	51	55	89.84
3840_70	102.8	6	9.5	0.35	78	83	32.32	3750_15	96.5	5.2	6.5	0.58	48	55	103.27
3840_82	88.1	8.7	8.5	0.16	65	68	28.13	3750_12	103.4	5.2	6.5	0.63	55	47	112.95
3735_01	93.2	6	7	0.46	49	50	90.87	3840_53	99.0	6	6.6	0.51	72	74	49.87
3735_01	87.9	6	6.5	0.44	46	49	95.25	3750_16	95.2	6.2	6.5	0.49	59	65	62.26
3825_68	84.3	8.7	8.3	0.17	55	60	35.88	3825_47	101.7	6	6.5	0.60	65	63	65.48
3825_63	138.8	7.8	9	0.40	57	55	57.62	3825_48	113.5	6	7.5	0.56	57	60	72.10
3825_71	90.9	8.2	8.5	0.21	52	55	44.96	3750_13	89.1	6.5	6.5	0.44	50	55	75.02
3825_71	113.4	9.6	9.5	0.19	55	58	36.39	3825_39	96.2	6	6.5	0.52	51	50	92.81
3825_71	99.4	8.2	9	0.19	52	55	44.95	3750_18	95.7	5.2	6.6	0.59	48	55	101.88
3825_71	121.7	8.7	9.8	0.20	55	52	45.24	3825_49	97.5	6	6.5	0.54	70	75	50.76
3825_70	118.3	8.7	9.5	0.22	50	55	46.02	3825_48	107.6	6.5	6.7	0.50	55	60	70.82
3825_74	96.4	8.7	8.6	0.19	63	60	34.31	3750_16	94.1	6	6.5	0.47	55	60	72.08
3705_15	99.8	5.5	6.5	0.61	47	55	101.82	3825_39	94.5	5.5	6.5	0.54	50	50	101.72
3780_36	103.0	6	6.5	0.60	48	50	102.51	3750_20	97.9	6	6.5	0.52	48	45	107.88
3780_37	91.1	6	6.5	0.49	55	62	69.25	3825_31	97.4	6	6.5	0.53	67	70	55.75
3870_71	97.6	6	6.5	0.47	62	65	62.35	3825_52	101.0	6	7	0.46	55	62	68.96
3855_31	101.6	5.2	6.5	0.66	79	83	50.54	3750_22	94.8	6	7	0.48	49	55	81.83
3855_31	97.9	5.2	6.5	0.66	65	68	69.23	3840_62	96.7	6	6.5	0.50	65	69	57.16
3795_25	104.7	6	7	0.52	66	70	55.59	3825_50	95.2	6	6.5	0.46	50	55	84.22
3870_84	102.0	6.2	6.5	0.50	70	75	49.85	3750_21	96.6	6	6.5	0.52	47	50	98.73
3855_60	97.4	6.5	6.5	0.43	68	73	47.71	3825_36	98.4	6	6.5	0.53	70	74	51.48
3825_42	95.9	5.2	6.5	0.54	62	64	72.98	3825_54	104.7	6	7	0.50	78	75	45.78
3840_23	98.2	6.4	6.5	0.45	57	62	65.09	3750_23	105.2	5.2	7	0.61	53	50	105.05
3840_20	100.1	6	6.5	0.51	57	62	71.09	3825_57	100.3	6	6.5	0.52	72	76	49.58
3840_22	97.8	6	6.5	0.51	55	52	84.90	3825_51	95.8	6	6.5	0.51	65	72	54.79
3840_21	97.5	6	6.7	0.48	50	55	83.98	3750_21	99.0	6	7	0.47	51	55	81.06
3785_23	101.1	6	7	0.50	51	55	82.45	3825_59	104.5	6	6.5	0.55	65	68	61.09
3855_44	103.1	5.9	7	0.57	66	68	62.22	3825_60	103.1	5.2	7	0.61	64	66	69.84
3840_25	95.8	6.4	6.5	0.43	63	65	56.59	3755_02	88.0	6.5	6.5	0.43	52	55	72.16
3840_26	96.8	6.5	6.5	0.46	62	65	57.46	3840_70	95.4	5.2	6.5	0.57	75	82	50.50
3826_50	105.3	6	7	0.52	49	45	105.29	3735_03	95.1	6	6.5	0.52	48	50	96.47
3840_26	97.0	6	6.5	0.50	59	57	73.46	3825_64	100.2	6	6.7	0.52	65	62	63.42
3840_27	101.1	6	7	0.50	55	52	82.15	3825_58	98.9	6	6.5	0.52	77	80	44.58
3750_01	116.9	6	7	0.58	40	40	146.37	3825_41	100.8	8.7	8.5	0.21	62	65	33.83
3765_26	97.4	6	6.5	0.51	65	70	56.68	3840_82	98.9	6	6.6	0.50	54	59	76.07
3840_29	98.5	6	6.5	0.50	77	83	42.80	3825_68	98.5	6	6.5	0.52	42	45	119.76
3840_28	94.7	5.2	6.5	0.57	65	68	66.69	3825_64	98.4	6	6.5	0.52	67	70	55.87
3825_54	93.8	6	6.5	0.50	60	65	63.17	3825_65	97.2	6	6.5	0.49	68	73	52.37
3750_00	93.7	6	6.5	0.50	55	58	74.78	3825_70	94.1	6.5	6.5	0.46	50	55	77.75
3840_28	95.9	6	6.5	0.50	54	60	74.38	3735_03	94.1	6	6.5	0.48	50	55	84.07
3840_20	96.8	6	6.5	0.57	64	68	59.75	3825_40	98.3	6.5	6.5	0.52	62	65	58.78
3840_23	93.1	6	6	0.50	40	35	159.65	3825_71	95.6	6	6.5	0.51	64	70	56.85
3840_31	100.5	6	6.5	0.57	75	82	45.43	3825_71	98.2	6	6.6	0.37	54	60	71.41
3840_31	102.7	6	6.8	0.51	75	81	44.34	3735_05	98.0	6.2	6.5	0.54	50	55	84.81
3840_34	90.4	6	6.5	0.47	57	61	67.75	3735_04	96.4	6	6.5	0.55	50	45	104.82
								3825_78	95.7	7	7	0.41	50	45	82.77

Fuente: Cálculo de datos en Excel.



CAPÍTULO V

ANÁLISIS Y DISCUSIÓN DE RESULTADOS

5.1 METODOLOGÍA PARA LAS REDES NEURONALES

5.1.1 Diseñar modelo de RNA.

5.1.1.1 Selección de la Variable.

- a) Determinar las variables de entrada para las redes neuronales fue un asunto crítico para el entrenamiento ya que aparentemente todos tenían alguna relación sin embargo las variables que más influyen en la proyección de rocas fueron los siguientes: carga lineal, burden, stemming, factor de carga, RMR y el RQD.
- b) Carga lineal: Se determinó como el mejor indicador para conocer la cantidad de explosivo por metro lineal, ya que no se tiene un taladro uniforme donde se ingrese la carga total del diseño y nos ayuda a interpretar la geología.
- c) Burden: Se consideró el burden ya que la primera cara libre que se genera es a este lado, la presión busca el lado más débil y el burden es una de ellas, varia su longitud efectiva en las crestas, por el minado o sobrerotura, por lo que es un parámetro crítico.
- d) Stemming: Es un indicar clave para entender las proyecciones verticales y craterizacion, ya que a tacos cortos hay mayor probabilidad de tener flytrock.
- e) Factor de carga: se consideró este parámetro ya que relaciona el burden, espaciamiento, altura del taladro y la carga que se requiere para romper este volumen, este parámetro indica claramente como es

el comportamiento del volumen tronado en función al carguío realizado por taladro.

- f) RMR: se consideró este parámetro geológico ya que nos ayuda a entender el comportamiento de la compresión sobre la cual la roca se fractura, es muy importante ya que interpretaremos la carga requerida por zonas.
- g) RQD: El índice de la calidad de la roca también es un parámetro geológico crítico a considerar ya que nos ayuda a entender el comportamiento del macizo rocoso en función a la calidad del mismo.

Variable a Predecir: Distancia cubierta por el flyrock en el tajo Ferrobamba.

Tipo de Variable: Cuantitativa. Unidad. Es el metro lineal (m).

5.1.1.2 Recolección de datos.

Los datos geológicos y geotécnicos fueron proporcionados por el área de planeamiento mina como se muestra en la TABLA 19.

Los datos de burden, stemming, profundidad del taladro, y la carga, fueron recopilados y registrados en el campo como se muestra en la TABLA 23, con mediciones reales de estos parámetros además de la comparación con los diseños de los parámetros establecidos por minera.

TABLA 23. Registro de datos tomados en campo.

REGISTRO DE DATOS TOMADOS DE CAMPO							REGISTRO DE DATOS TOMADOS DE CAMPO						
Proyecto	Burden	Espaldamie nto	Stemming	Prof. Taladro	Carga	Diametro	Proyecto	Burden	Espaldamie nto	Stemming	Prof. Taladro	Carga	Diametro
	B (m)	E (m)	St (m)	L (m)	Q (Kg)	D (Cm)		B (m)	E (m)	St (m)	L (m)	Q (Kg)	D (Cm)
3885_56	8.7	10	9	15.1	593	31.5	3750_04	6	7	6.5	16.2	941	31.5
3900_55	9.5	10	9.5	15.0	605	31.5	3840_41	6	6.4	6.5	16.1	850	31.5
3870_75	9	10.5	9.5	16.2	695	31.5	3765_26	6	7	7	15.9	907	31.5
3870_67	8.7	10	9.5	15.4	584	31.5	3855_63	6	7	6.5	16.9	1030	31.5
3870_79	8	10	8.5	16.2	669	31.5	3825_27	6.2	7	6.5	16.0	929	31.5
3870_83	8.7	10	9.5	16.0	629	31.5	3825_26	6	7	6.5	16.1	926	31.5
3855_41	6	7	9.5	14.9	517	31.5	3750_09	6	7.2	7	15.4	857	31.5
3855_53	9	11	9.5	16.1	619	31.5	3765_27	6	10	6.6	15.4	853	31.5
3855_57	9.5	10.5	9.5	15.5	611	31.5	3825_29	6	7	6.5	16.2	959	31.5
3840_24	5.2	11	6.5	15.9	617	31.5	3825_28	6	7	7	16.2	937	31.5
3765_26	8.7	10.5	9	15.5	599	31.5	3840_45	6	7	6.5	15.8	895	31.5
3855_59	8.7	10	8.3	15.4	690	31.5	3840_46	6	7	6.6	16.1	949	31.5
3840_42	8.7	11	8.8	16.2	616	31.5	3840_44	5.2	7	6.9	16.0	936	31.5
3840_43	9.6	11	9.5	16.3	720	31.5	3840_44	6	6.4	6.5	15.6	915	31.5
3855_63	9.5	11	9	15.5	630	31.5	3750_09	6	7	6.5	15.9	905	31.5
3825_26	9.5	11	10	15.8	603	31.5	3825_32	8.2	7	6.5	16.3	950	31.5
3825_28	8.7	10.5	9.5	15.9	599	31.5	3825_30	6	7	6.5	15.5	878	31.5
3840_47	9.2	9	9	15.6	610	31.5	3840_49	6	7	6.5	16.1	934	31.5
3840_42	9.6	11	10	16.0	653	31.5	3825_31	5.5	6.4	6.5	16.2	955	31.5
3840_55	8.7	10	9	16.2	674	31.5	3840_51	6	7	7	15.5	853	31.5
3825_41	8.7	10	9.5	16.0	611	31.5	3825_33	6	7	7	15.9	896	31.5
3840_57	8.2	9.5	9.5	15.9	620	31.5	3840_50	6	7	6	16.2	1050	31.5
3825_41	9.5	10	9.2	16.1	789	31.5	3840_48	6	7	6.5	15.8	961	31.5
3840_52	9.2	10	9.5	16.0	631	31.5	3750_11	5.5	7	6.5	15.9	908	31.5
3825_35	6	7	10	16.1	580	31.5	3840_51	6	7	8.3	15.5	923	31.5
3825_42	6	7	10	17.0	718	31.5	3825_33	5.5	6.4	6.5	16.2	919	31.5
3825_47	8.7	10	9.5	16.4	632	31.5	3750_12	6	6.4	6.5	16.2	990	31.5
3825_44	8.7	10	9.5	17.3	756	31.5	3840_56	6.2	7	6.5	16.1	930	31.5
3840_67	8	9	9.8	16.2	645	31.5	3840_58	5.2	6.4	6.5	16.0	933	31.5
3825_55	8.5	10	9.5	15.6	585	31.5	3750_13	6	7	6.5	16.1	1013	31.5
3840_70	6	7	9.5	15.5	620	31.5	3750_15	5.2	7	6.5	16.1	923	31.5
3840_82	8.7	11	8.5	16.3	684	31.5	3750_12	5.2	7	6.5	16.2	1005	31.5
3735_01	6	7	7	14.7	760	31.5	3840_53	6	7	6.6	16.1	936	31.5
3735_01	6	7	6.5	15.1	756	31.5	3750_16	6.2	7	6.5	16.3	933	31.5
3825_68	8.7	10	8.3	16.1	659	31.5	3825_47	6	6.4	6.5	16.9	1057	31.5
3825_63	7.8	6.4	9	14.7	784	31.5	3825_48	6	7	7.5	16.9	1062	31.5
3825_72	8.2	9.5	8.5	16.3	709	31.5	3750_13	6.5	7	6.5	16.4	882	31.5
3825_72	9.6	9.5	9.5	15.9	727	31.5	3825_39	6	7	6.5	17.1	1015	31.5
3825_72	8.2	10	9	15.8	678	31.5	3750_18	5.2	7	6.6	16.6	960	31.5
3825_73	8.7	10	9.8	15.9	736	31.5	3825_49	6	7	6.5	17.5	1073	31.5
3825_70	8.7	9	9.5	16.0	740	31.5	3825_48	6.5	7	6.7	15.5	950	31.5
3825_74	8.7	10	8.6	15.9	703	31.5	3750_16	6	7	6.5	15.0	800	31.5
3765_14	6	7	6.5	16.4	935	31.5	3825_39	5.5	7	6.5	16.2	920	31.5
3765_15	5.5	6.4	6.5	15.5	893	31.5	3750_20	6	7	6.5	16.2	950	31.5
3780_36	6	6.4	6.5	16.5	1030	31.5	3825_51	6	7	6.5	17.1	1030	31.5
3780_37	6	7	6.5	16.9	950	31.5	3825_52	6	7.5	7	15.8	885	31.5
3870_71	6	7.5	6.5	15.8	906	31.5	3750_22	6	7	7	16.5	903	31.5
3855_33	5.2	6.4	6.5	15.5	910	31.5	3840_62	6	7	6.5	15.9	906	31.5
3855_32	5.2	6.4	6.3	16.6	990	31.5	3825_50	6	7.5	6.5	15.9	890	31.5
3795_35	6	7	7	16.0	937	31.5	3750_21	6	7	6.5	16.7	965	31.5
3870_84	6.2	7	6.5	15.5	900	31.5	3825_56	6	7	6.5	16.7	1001	31.5
3855_40	6.5	7.5	6.5	15.3	857	31.5	3825_54	6	7	7	15.3	866	31.5
3855_42	5.2	7.5	6.5	16.0	913	31.5	3750_23	5.2	6.4	7	14.7	805	31.5
3840_23	6.4	7.5	6.5	16.0	930	31.5	3825_57	6	7	6.5	18.0	948	31.5
3840_20	6	7	6.5	15.5	900	31.5	3825_51	6	7	6.5	16.5	953	31.5
3840_22	6	7	6.5	15.9	919	31.5	3750_21	6	7	7	15.3	826	31.5
3840_21	6	7.5	6.7	16.4	950	31.5	3825_59	6	7	6.5	16.3	1024	31.5
3765_23	6	7	7	15.8	889	31.5	3825_60	5.2	7	7	16.6	990	31.5
3855_44	5.5	7	7	16.3	960	31.5	3735_02	6.5	7	6.5	16.1	846	31.5
3840_25	6.4	7.5	6.5	15.8	885	31.5	3840_70	5.2	7	6.5	15.8	890	31.5
3840_26	6.5	7	6.5	15.7	890	31.5	3735_03	6	6.4	6.5	15.1	815	31.5
3855_50	6	7	7	16.0	950	31.5	3825_64	6	7	6.7	16.5	980	31.5
3840_26	6	7	6.5	15.7	891	31.5	3825_58	6	7	6.5	16.2	956	31.5
3840_27	6	7	7	15.9	903	31.5	3825_41	8.7	10	8.5	17.0	857	31.5
3790_01	6	7	7	16.0	1050	31.5	3840_82	6	7	6.6	15.6	885	31.5
3765_26	6	7	6.5	16.0	921	31.5	3825_68	6	7	6.9	16.3	969	31.5
3840_28	6	7	6.5	15.4	880	31.5	3825_64	6	7	6.5	16.3	960	31.5
3840_28	5.2	7	6.5	16.0	901	31.5	3825_65	6	7	6.5	15.1	840	31.5
3855_54	6	7	6.5	16.6	950	31.5	3825_70	6.5	7	6.5	16.3	938	31.5
3750_02	6	7	6.5	16.2	912	31.5	3735_03	6	7	6.5	15.2	839	31.5
3840_28	6	7	6.5	15.8	893	31.5	3825_40	6.5	6.4	6.5	15.8	914	31.5
3840_30	6	6.4	6.5	16.9	1005	31.5	3825_71	6	7	6.5	16.5	958	31.5
3840_33	6	7	6	15.5	887	31.5	3825_71	6	9.5	6.6	15.5	874	31.5
3840_31	6	6.4	6.5	16.0	990	31.5	3735_05	6.2	6.4	6.5	16.0	931	31.5
3840_31	6	7	6.8	15.5	889	31.5	3735_04	6	6.4	6.5	15.8	894	31.5
3840_34	6	7	6.5	15.9	852	31.5	3825_78	7	7	16.3	888	31.5	

Fuente: Fotografía de campo.

5.1.1.3 Pre-procesamiento de Datos.

El pre-procesamiento de datos consistió en el hecho de analizar y transformar las variables de entrada y salida para minimizar el ruido, se enfatizó relaciones importantes, se detectó las tendencias, y se aplanó la distribución de la variable para ayudar a la red neuronal en el aprendizaje de patrones relevantes.

Se realizó la evaluación previa de las condiciones de terreno insitu, además de verificar que los parámetros de voladura registrados sean los más óptimos posibles y que se esté cumpliendo lo diseñado, para evitar cálculos errados a la hora de hacer la predicción con las redes neuronales, dado que los datos registrados ya se encuentran en formato libre de ruido (no contiene valores nulos ni valores con formato inconsistente), sin embargo, el software de implementación ofrece funciones de pre-procesamiento y post-procesamiento implícitas en las funciones de entrenamiento.

5.1.1.4 Definición del conjunto de entrenamiento, validación y prueba.

5.1.1.4.1 El conjunto de entrenamiento.

Fue el conjunto de datos que le sirve a la red neuronal para aprender los patrones presentes en los datos, es decir la obtención de los pesos de la red. En este caso este conjunto representó un total del 70 % de las 152 muestras disponibles, que fueron un total de 106 muestras para el conjunto de entrenamiento, Ver Figura.47.

5.1.1.4.2 El conjunto de validación.

El conjunto de validación que se ingresó fueron los datos más recientes y contiguas observaciones. Se procuró no usar el conjunto de validación

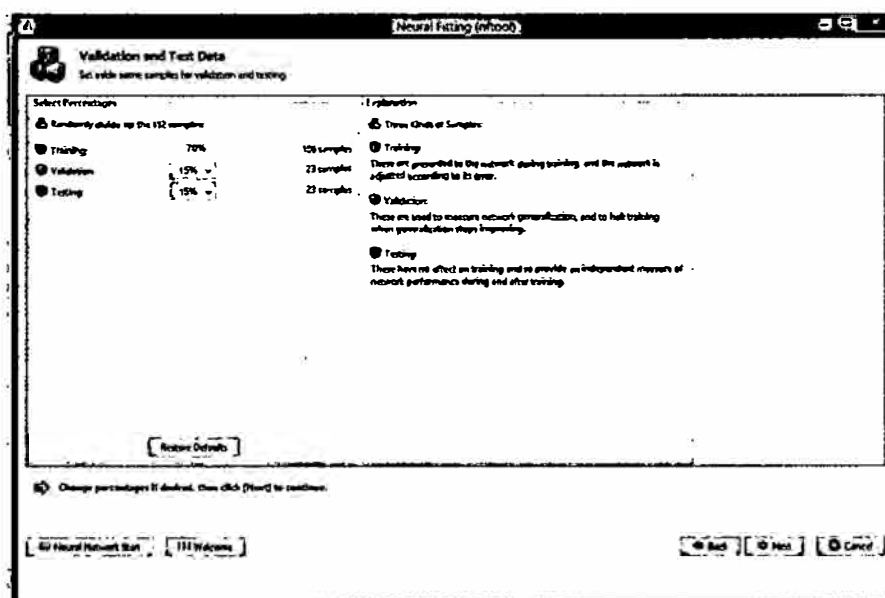
como conjunto de testeo tras ejecutar repetidamente pasos de series de entrenamiento-testeo-validación y adaptar las variables de entrada basadas en la actuación de la red en el conjunto de validación.

Muchas veces ocurre durante el proceso de entrenamiento de la red, un problema llamado overfitting (se da cuando la red tan solo aprende puntos individuales en vez de generales), para evitarlo; fue necesario incluir un conjunto de validación durante el proceso de aprendizaje de la red. En este caso se representó por el 15% de las 152 muestras disponibles haciendo un total de 23 muestras. Ver Figura .47.

5.1.1.4.3 Conjunto de prueba.

Correspondió a los datos restantes, una vez seleccionados los patrones de entrenamiento. Este conjunto de datos se utilizó para evaluar la precisión de la red. Fue compuesto por el 15% de las 152 muestras disponibles, haciendo un total de 23 muestras. Ver Figura .47.

FIGURA 46. Conjunto de entrenamiento, validación y prueba.



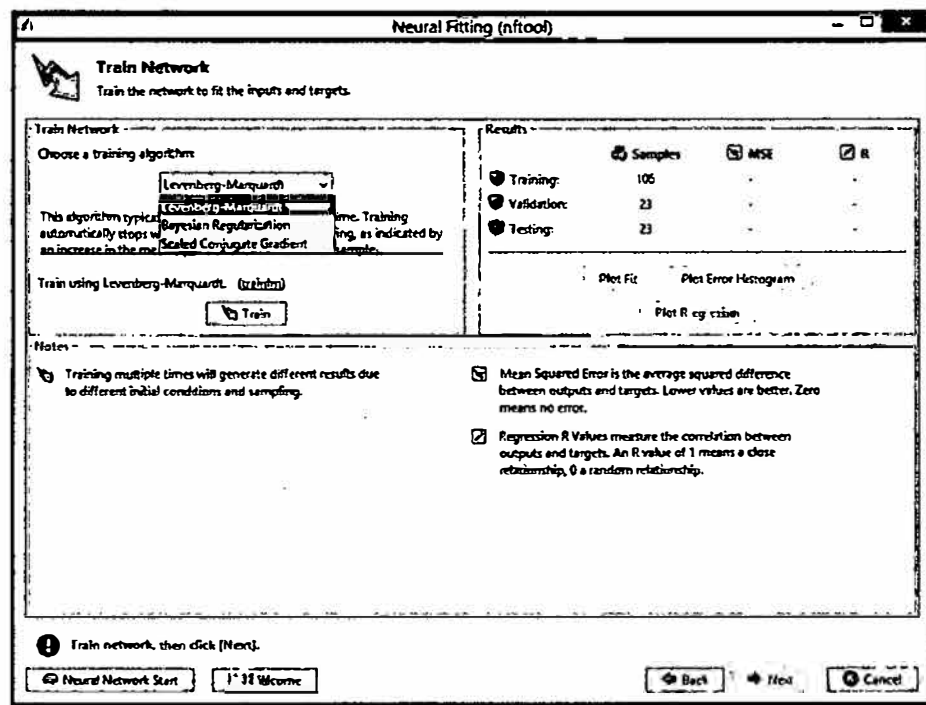
Fuente: Captura de la pantalla de trabajo del entorno MatLab.

5.1.1.5 Selección de la arquitectura de redes neuronales.

Existen diversas formas de determinar la arquitectura a seguir para desarrollar una red neuronal de predicción, cabe destacar que se emplea en la mayoría de los casos redes con algoritmo de entrenamiento Backpropagation.

Neural network integra estos algoritmos por lo que solamente se tiene que seleccionar en el menú desplegable train network>choose a training algorithm>Levenberg-Marquardt como se muestra en la Figura .47.

FIGURA 47. Selección del algoritmo backpropagation.



Fuente: Captura de la pantalla de trabajo del entorno MatLab.

5.1.1.5.1 Número de neuronas de entrada.

Correspondió a las variables independientes para la predicción de flyrock en el tajo Ferrobamba las cuales fueron 6 parámetros de entrada

mencionados como son: Concentración de carga lineal, burden, stemming, factor de carga, RMR y RQD.

5.1.1.5.2 Número de Capas Ocultas.

Las capas ocultas dan a la red la habilidad de generalizar, y en la práctica las redes neuronales con una o dos capas ocultas son las más utilizadas y han tenido un buen desempeño (Kaastra y Boyd 1996). El incremento en el número de capas también incrementa el tiempo de procesamiento y el peligro de sobre ajuste lo que conduce a un pobre desempeño en la predicción fuera de muestra. El sobre ajuste ocurre cuando un modelo de predicción tiene muy pocos grados de libertad. En otras palabras, se tienen relativamente pocas observaciones en relación con sus parámetros y por lo tanto es capaz de memorizar datos

Individuales en lugar de aprender patrones generales. Es por eso que se recomienda que todas las redes neuronales comiencen de preferencia con una o a lo mucho con dos capas.

Para nuestro caso hemos optado por una sola capa oculta la cual es suficiente para asegurar la capacidad de generalización de nuestra red dada la cantidad de datos con los que contamos. Esto nos dió un total de 3 capas, la capa de entrada, la capa oculta y la capa de salida. Ver Figura .48.

5.1.1.5.3 Número de neuronas ocultas.

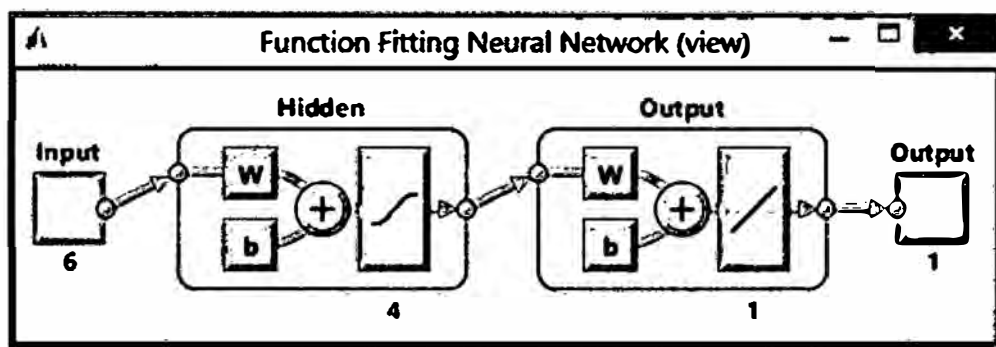
El número de neuronas de nuestra capa oculta será de un 75% del total de entradas (Kaastra y Boyd 1996). El número de neuronas de nuestra capa oculta sería de 4 neuronas ver Figura.48, dado que el número de neuronas de entrada son el total 6 parámetros.

5.1.1.5.4 Número de Neuronas de Salida.

Decidir el número de neuronas de salida es algo más sencillo porque hay muchas razones para emplear sólo una neurona de salida. Las redes neuronales con múltiples salidas, especialmente si éstas salidas están ampliamente espaciadas, producirán resultados inferiores en comparación con una red con una única salida. Lo recomendable es tener una red especializada para cada una de las salidas deseadas en cada predicción.

El número de neuronas de la capa de salida de nuestra red es una, porque tan solo intentamos predecir el valor de la variable de la distancia cubierta por el flyrock en el tajo Ferrobamba, como se muestra en la siguiente figura.

FIGURA 48. Arquitectura de las neuronas.




Fuente: Captura de la pantalla de trabajo.

5.1.1.5.5 Función de Transferencia.

El propósito de esta función es prevenir a las salidas de alcanzar valores muy elevados los cuales pueden paralizar la red y detener el entrenamiento de la misma. Como función de transferencia usaremos la función sigmoide (cuyo rango de salida se encuentra entre -1 y +1) la cual es

preferente para tareas de predicción según (Kaastra y Boyd 1996) y se muestra en la siguiente figura.

FIGURA 49. Función sigmoideal.



Fuente: Figuras de funciones sigmoideales.

5.1.1.6 Criterios de evaluación.

En cuanto a los criterios de evaluación para medir la eficiencia de la red, se ha considerado utilizar el Error Cuadrático Medio (ECM) de la tabla 6. El Error Cuadrático Medio calculado como la diferencia entre la salida de la red y la respuesta deseada. El cual se usa como factor de culminación del entrenamiento. Para esta fase se fijó un parámetro en 300 épocas y el factor de terminación empleado del ECM teniendo como umbral un valor de 0.5.

5.1.1.7 Entrenamiento de la Red Neuronal.

Entrenar una red neuronal para aprender patrones involucra el presentarle ejemplos de manera iterativa de las respuestas correctas. El objetivo del entrenamiento es encontrar un conjunto de pesos entre las neuronas que determinan el mínimo global de la función de error. A menos que el modelo esté sobre-ajustado, el conjunto de pesos debería proporcionar una buena generalización.

El entrenamiento de la red utiliza la técnica del gradiente descendente inmerso en el algoritmo de backpropagation. El entrenamiento se detendrá

básicamente cuando suceda uno de estos 3 motivos: el número de iteraciones excede el número de épocas establecidas, si la función de evaluación (ECM) cae por debajo de la meta establecida, o si el error medio por la función de evaluación se incrementa para un número específico de iteraciones (este último caso requiere de la existencia del conjunto de validación). En cualquier caso los pesos y bias obtenidos son los encontrados en el mínimo error medido por la función de evaluación.

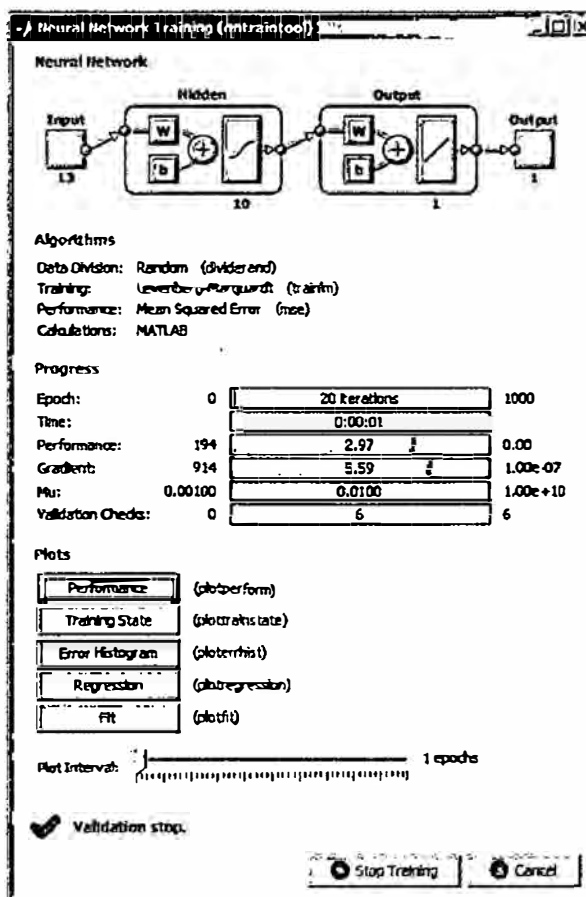
5.1.1.7.1 Número de Iteraciones (Épocas) Entrenamiento.

Muchas veces el procedimiento de agregar un número mayor de iteraciones en el entrenamiento producirá un menor error en el entrenamiento, pero éste a su vez no garantiza que se obtendrá el menor error con el conjunto de prueba. En nuestro caso el número máximo fue de 15 épocas (ver Figura .51), que fue suficiente para conseguir un nivel de error aceptable.

5.1.1.7.2 Tasa de Aprendizaje y Momento.

La tasa de aprendizaje es una constante de proporcionalidad que determina el tamaño del cambio de los pesos. El cambio de los pesos de una neurona es proporcional al impacto del peso de las neuronas sobre el error. Un método de incrementar la tasa de aprendizaje y por lo tanto agilizar el tiempo de entrenamiento sin caer en oscilaciones, es incluir un término de momento en la regla de aprendizaje de BP. El término de momento determina cómo los cambios pasados de los pesos afectan a los actuales cambios en los pesos. Este término suprime oscilaciones lado a lado filtrando variaciones de alta frecuencia. Cada nueva dirección de búsqueda es una suma ponderada de los gradientes actuales y previos.

FIGURA 50. Entrenamiento de backpropagation con las redes neuronales.



Fuente: Captura de la pantalla de trabajo.

5.1.1.8 Implementar modelo de las RNA.

Se llevó a cabo la implementación del modelo haciendo uso de la técnica de Redes Neuronales Artificiales.

Para proceder con la implementación de este modelo, se realizó un resumen de los datos más relevantes del mismo (ver TABLA .24) que nos ayudó a internarnos en el proceso de su implementación en MATLAB.

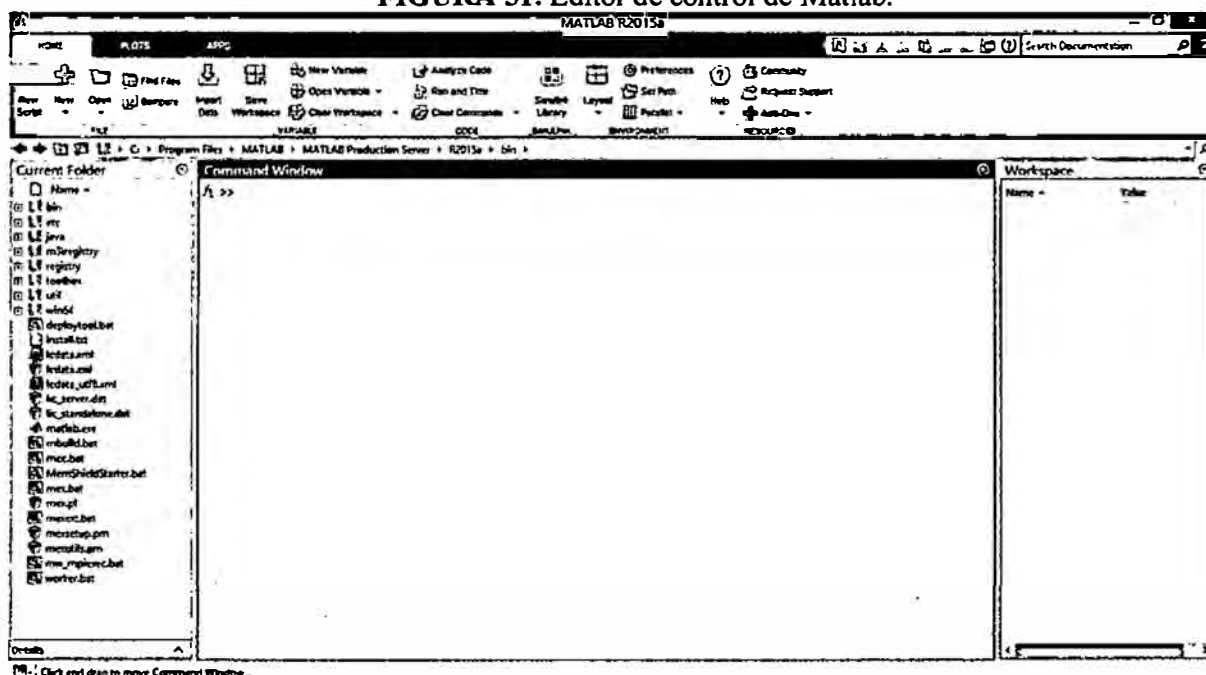
TABLA 24. Resumen de datos de la red neuronal.

RESUMEN DE DATOS DE LA RED NEURONAL	
Data pre-procesada	152
Tipo de variable	Cuantitativa (m)
Numero de epocas	15
Tamaño de conjunto de entrenamiento	106
Tamaño de conjunto de prueba	23
Tamaño de conjunto de validación	23
Numero de neuronas de entrada	6
Número de capas ocultas	3
Número de neuronas ocultas en cada capa	4
Número de neuronas de salida	1
Función de transferencia	Sigmoidal
Función de error	Error cuadrático medio

Fuente: Elaboración de tablas.

Se ha utilizado el software MATLAB versión 8.5.0, para la elaboración de esta tesis, haciendo uso de una de sus herramientas de predicción que es el Neural Network Toolbox, al cual se ingresa desde el entorno principal de Matlab como se muestra en la siguiente figura.

FIGURA 51. Editor de control de Matlab.



Fuente: Captura de la pantalla de trabajo en el entorno MatLab.

El primer paso fue pasar los datos definidos como entradas (parámetros de voladura y datos geotécnicos), y los datos de salida (distancias observadas en campo), a un formato que MATLAB entienda, esto se realiza importando desde un formato Excel con una matriz de $[6 \times 152]$ y $[1 \times 152]$ respectivamente del tipo “double”, para lo cual se definió las variables de entrada “m” y las variables de salida “n” como se muestra en la siguiente figura.

FIGURA 52. Importación de datos en Excel y definición de variables.

The screenshot shows the MATLAB R2015a interface. The 'Import' dialog box is open, showing the 'Import' tab. The 'Range' is set to 'A:LVS' and 'Variable Names Row' is '1'. The 'Import' button is highlighted. The 'Workspace' window on the right shows the following variables:

Name	Value
m	6x152 double
n	1x152 double

Fuente: Captura de la pantalla de trabajo en el entorno del MatLab.

Nótese que los datos ingresados están en forma horizontal, a diferencia de los datos registrados que se encuentran en forma vertical, pero que son los mismos datos para cada campo; se realizó esta modificación solo con fines de dar facilidad al procesamiento de datos por otro lado en la parte superior izquierda se aprecia que las variables ya importadas como “m” y “n”, con su respectiva matriz y el tipo “double”.

Mediante el siguiente orden se definió estas variables como entradas y salidas de la red neuronal.

```
% m - input data. % n - target data.
```

```
x = m; t = n;
```

El siguiente paso es elegir la función de entrenamiento, como se muestra en los comentarios del siguiente script, para mayor información de todas las listas de las funciones de entrenamiento se puede ingresar el comando: **help nntrain**; en nuestro caso la función que se utilizó fue el **trainlm**; en el que se encuentra el algoritmo de backpropagation de Levenberg-Marquardt para el cual se ingresa el siguiente código.

```
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.
```

El siguiente paso es fue crear la red neuronal con la configuración del número de neuronas ocultas, que como se mencionó anteriormente son 4.

```
hiddenLayerSize = 4;
```

```
net = fitnet(hiddenLayerSize,trainFcn);
```

Ahora se define el conjunto de entrenamiento, validación y prueba que fue el 70%, 15% y 15% respectivamente esta división del total se las muestras que son 152 se realiza con el siguiente código.

```
net.divideParam.trainRatio = 70/100;
```

```
net.divideParam.valRatio = 15/100;
```

```
net.divideParam.testRatio = 15/100;
```

Seguidamente se procedió a realizar el entrenamiento de la red con la función “train”, se probó las veces suficientes para minimizar el error, copiando todos los códigos hasta obtener un error aceptable, cabe mencionar que el

preprocesamiento y el post-procesamiento de datos consiste por ejemplo en la anulación de valores nulos, valores repetitivos etc, estos ya están inmersos en la función train, se ingresó entonces el siguiente código.

```
[net,tr] = train(net,x,t);
```

Seguidamente se realizó el testeo de la red neuronal, analizando los errores generados, y el performance de las pruebas realizadas, haciendo una correcta interpretación de los valores y pesos asignados, hay que tener en cuenta la estabilización de la curva en función a los errores obtenidos, para eso se ingresa el siguiente código.

```
y = net(x);
```

```
e = gsubtract(t,y);
```

```
performance = perform(net,t,y)
```

Para ver la red neuronal simplemente se ingresa el siguiente código.

```
view(net)
```

Los siguientes códigos se utilizaron para plotear los gráficos integrados en el neural network, para poder analizar el performance o el error medio cuadrático generado en la época respectiva, el estado del entrenamiento, se puede plotear los histogramas con los bins respectivos, además de plotear la correlación entre los valores reales y predcidos, para la generación de este ploteos se ingresó el siguiente código.

```
plotperform(tr)
```

```
plottrainstate(tr)
```

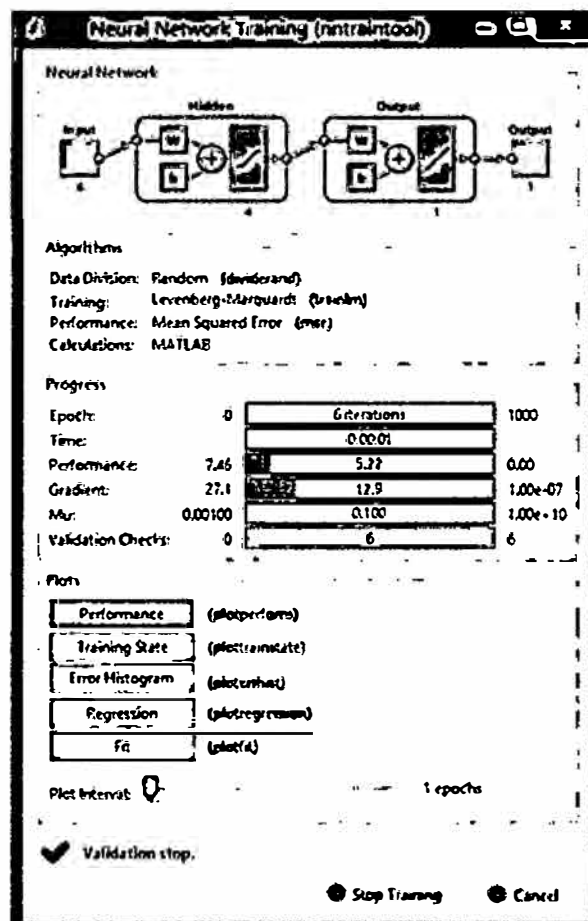
```
ploterrhist(e)
```

```
plotregression(t,y)
```

El código completo puede consultarse en el Anexo I. El resultado del entrenamiento se visualiza a continuación:

En el gráfico se muestra que el entrenamiento finalizó en la época 15, que es el entrenamiento seleccionado por tener un error aceptable, seguidamente se guardó la red ya entrenada para utilizar en el cálculo del nivel de error, y finalmente ya para concluir con la implementación del modelo, se presenta las gráficas que miden la eficiencia de los mismos.

FIGURA 53. Resultados del entrenamiento en modo gráfico.




Fuente: Captura de la pantalla de trabajo.

5.1.1.8.1 Performance de la red neuronal.

El mejor performance fue de 11.15 con un nivel de error medio aceptable que es de 7.63 m, detenido en la época 15 como se puede apreciar en la siguiente figura, de la imagen se puede interpretar que los niveles de error disminuyen para posteriores épocas estabilizándose en las líneas de entrenamiento, validación y el conjunto de prueba en los cuales se determinó el mejor performance.

FIGURA 54. Mejor performance en el entrenamiento de la red.



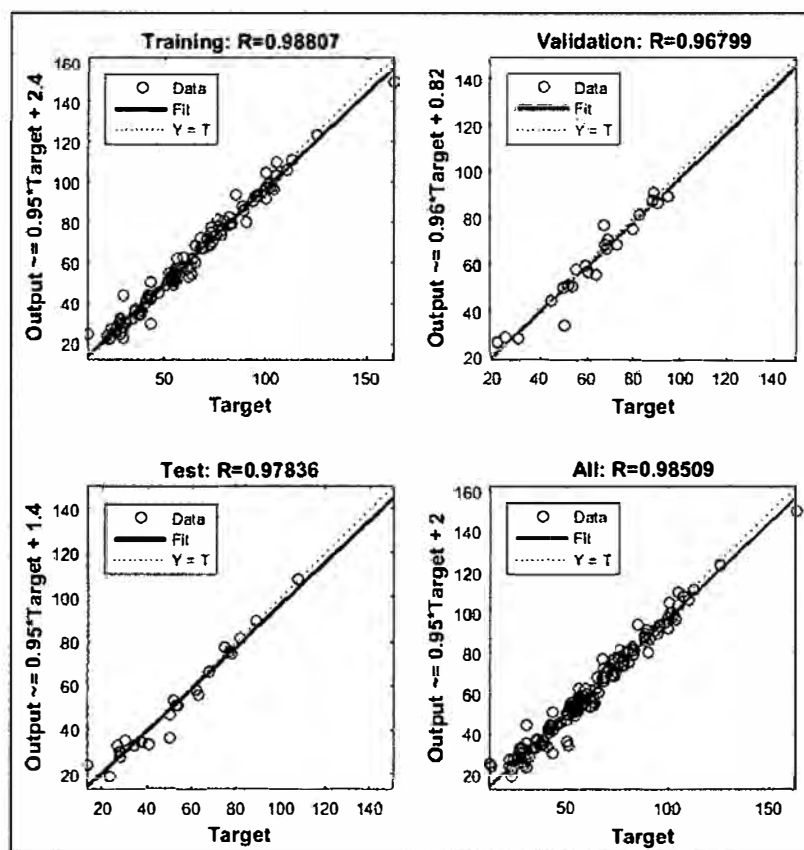
Fuente: Generación de reporte.

5.1.1.8.2 Correlación entre los valores reales y predecidos.

En la figura.55. Se puede observar que el coeficiente de correlación es bastante elevado entre el conjunto de entrenamiento, validación y prueba con un valor de $R=0.98509$ cercano a 1, lo que quiere decir que existe una alta correlación entre los valores reales (abcisas) y los pronósticos (orientados), la

línea azul indica los puntos en los que los valores reales son iguales a los pronósticos pero en un caso ideal.

FIGURA 55. Correlación entre los valores reales y predecidos.



Fuente: Generación de reporte.


5.1.1.8.3 Cálculo del error del modelo de redes neuronales artificial.

El siguiente gráfico de errores se calculó a partir de los valores reales y predecidos, como se puede apreciar en la siguiente figura, se realizó el histograma para 20 bins, la frecuencia en el cual se muestran los diferentes valores de los errores en el conjunto de entrenamiento, validación y prueba. El gráfico presenta una tendencia central de errores con valores menores que indican la efectividad de utilizar las redes neuronales.

El valor del error absoluto medio fue de 3.92 m en caso de la regresión multivariable y 0.25 en caso de las redes neuronales, similarmente el error medio cuadrático de la regresión multivariable fue de 6.5 y en caso de las redes neuronales el error medio cuadrático fue de 2.7.

El coeficiente de determinación (R^2) de la regresión multivariable y las redes neuronales fueron 0.915 y 0.987 respectivamente como se muestran en las figuras

FIGURA 56. Histograma de error.




Fuente: Histograma de errores obtenido del Matlab.

5.1.1.9 Resultados del modelo de la red neuronal.

Se ha realizado el cálculo respectivo para la regresión multivariable, como se observa en el Cuadro.21, estas distancias han sido correlacionadas con las distancias reales de flyrock, teniendo un coeficiente de de $R^2=091$, como se muestra en la figura.57.


FIGURA 57. Correlación entre la distancia real y la predecida por la regresión multivariable.



Fuente: Generación de reporte en el entorno del Matlab.

En la figura.58 se muestra las distancias de flyrock, predecidas por las redes neuronales artificiales y las distancias reales de flyrock, el coeficiente de $R^2= 0.98$, este valor es cercano a 1 y superior a la regresión multivariable mostrado anteriormente. Por lo que se muestra la capacidad predictiva del Matlab, que ajusta mucho más los valores predecidos a los valores reales, además de que nos permite ingresar y manipular más variables.

FIGURA 58. Correlación entre la distancia real y la predecida por RNA.



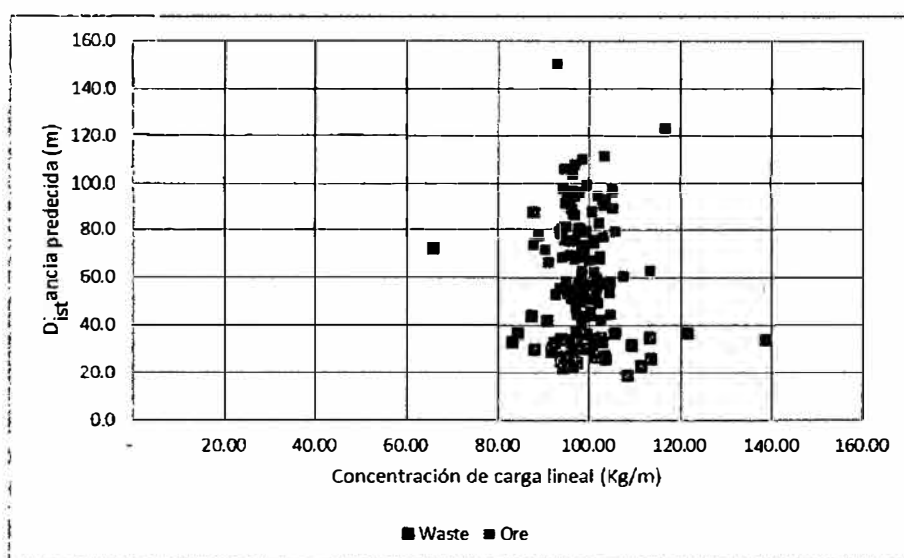
Fuente: Generación de reporte en el entorno del Matlab.

5.1.1.10 Análisis de sensibilidad.

Para evaluar el impacto de las variables independientes en la predicción de la distancia cubierta por el flyrock, tajo Ferrobamba se ha realizado el análisis de sensibilidad respectivo, para la proyección de roca sobre mineral y desmonte, en función de cada una de las variables independientes como son la concentración de la carga lineal, burden, stemming, factor de carga, RQD y RMR, siendo los siguientes resultados:

Como se muestra en la Figura.59, la concentración de carga lineal para mineral y desmote, tiene una correlación positiva (ver la tablas 25 y 26), el coeficiente de Pearson para el desmote y mineral es de 0.350 y 0.103 respectivamente, la razón de que el mineral presente menos correlación indica, que la cantidad de kilos cargados por metro lineal no está influyendo directamente en la proyección de rocas alcanzando distancias distintas y considerables lo que conlleva a hacer un análisis y control en las otras variables que estarían generando estas irregularidades.


FIGURA 59. Efecto de la concentración de carga lineal en la máxima distancia cubierta por el flyrock.



Fuente: Generación de reporte.

Como se muestra en la Figura.60, el efecto que tiene el burden en la distancia cubierta por el flyrock, para mineral y desmonte, tiene una correlación negativa (ver la tablas 25 y 26), el coeficiente de Pearson para el desmonte y mineral es de -0.577 y -0.328 respectivamente, el comportamiento del burden en las mallas de desmonte presentan una distribución normal para longitudes de burden entre 8-10m. la proyecciones no han sido tan significativas, sin embargo el burden en las mallas sobre mineral presentan distancias considerables de flyrock, esta variable presenta un punto crítico, por lo que se debe hacer el control en respetar la configuración de malla, y no sobrecargar en zonas crestas peladas y taladros juntos.


FIGURA 60. Efecto del burden en la máxima distancia cubierta por el flyrock.



Fuente: Generación de reporte.

Como se muestra en la Figura.61, el efecto que tiene el stemming en la distancia cubierta por el flyrock, para mineral y desmote, tiene una correlación negativa (ver la tablas 25 y 26), el coeficiente de Pearson para el desmote y mineral es de -0.694 y -0.163 respectivamente; la mejor correlación se da en el desmote y es lógico que para longitudes de stemming más largos las distancias cubiertas por el flyrock serán menores, en caso de la configuración de stemming para mineral se observa que las longitudes de los tacos no son muy variables pero que estos llegan a alcanzar distancias muy considerables, esta variable requiere de un mayor control en la calidad de tapado, o en todo caso aumentar la longitud de tapado, para evitar alcanzar longitudes excesivas de flyrock.


FIGURA 61. Efecto del stemming en la máxima distancia cubierta por el flyrock



Fuente: Generación de reporte.

Como se muestra en la Figura.62, el efecto que tiene el factor de carga en la distancia cubierta por el flyrock, para mineral y desmote, tiene una correlación positiva (ver la tablas 25 y 26), el coeficiente de Pearson para el desmote y mineral es de 0.353 y 0.522 respectivamente, el comportamiento del factor de carga sobre mineral es crítica, ya que como se observa la imagen a mayores factores de carga se alcanzado mayores longitudes de flyrock, también podemos observar un rango variable del factor de carga, que indica que la configuración del mismo no está muy definido, esto se debe a las condiciones de terreno, en los que se aumenta o disminuye la carga por temas estructurales. Por otro lado el comportamiento del factor de carga sobre el mineral no es muy significativo sin embargo hay puntos en los cuales se ha desconfigurado el diseño por temas estructurales y operativos.


FIGURA 62. Efecto del factor de carga en la máxima distancia cubierta por el flyrock.



Fuente: Generación de reporte.

Como se muestra en la Figura.63, el efecto que tiene el RQD, en la distancia cubierta por el flyrock, para mineral y desmote, tiene una correlación negativa (ver la tablas 25 y 26), el coeficiente de Pearson para el desmote y mineral es de -0.599 y -0.885 respectivamente, el comportamiento del RQD, para las mallas sobre mineral principalmente presentan una correlación negativa muy significativa y que es un punto clave a controlar, ya que como se observa para bajas calidades de roca se han alcanzado distancias de flyrock excesivos, esto es debido a que durante el carguío no se está considerando este parámetro, por desconocimiento y no se cuenta con planos geotécnicos, por lo que como medida de control inmediato se debe integrar esta información y zonificar la malla de carguío, realizar las configuraciones de carga insitu.

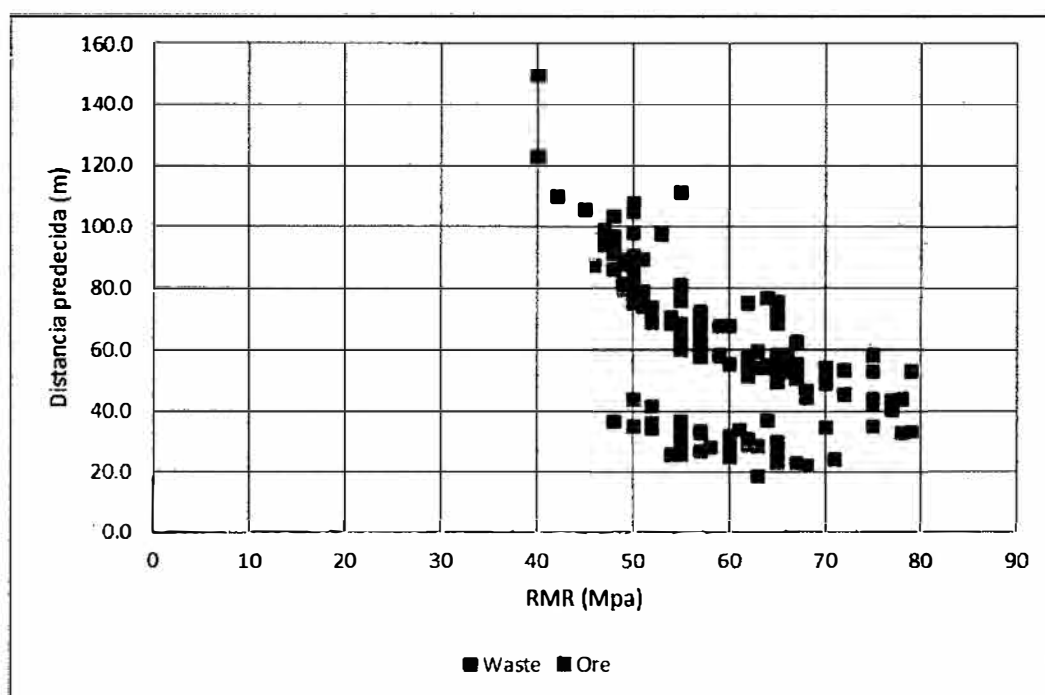
FIGURA 63. Efecto RQD en la máxima distancia cubierta por el flyrock.



Fuente: Generación de reporte.

Como se muestra en la Figura.64, el efecto que tiene el RMR en la distancia cubierta por el flyrock, para mineral y desmante, tiene una correlación negativa (ver la tablas 25 y 26), el coeficiente de Pearson para el desmante y mineral es de -0.613 y -0.850 respectivamente, como se puede observar el comportamiento del RMR en los disparos sobre mineral tiene una correlación negativa muy significativa, se observa que las máximas proyecciones de roca se dan en los valores menores del RMR, la causa de estas variaciones en ambos casos evidencia un pobre control de este parámetro, en función a la resistencia de la roca, ya que actualmente no se está integrando esta información en los diseños de carguío y tener mayor control en los temas netamente operativos.

FIGURA 64. Efecto del RMR en la máxima distancia cubierta por el flyrock.



Fuente: Generación de reporte.

TABLA 25. Coeficiente de correlación Pearson para desmorte.

		Correlación Pearson desmorte						
		Dist. Predecida waste	ROD.waste	RMR.waste	Burden waste	Stemming. Waste	F.carga waste	Conc.carga. lin.waste
Dist Predecida.waste	Correlación de Pearson	1	-.599**	-.613**	-.577**	-.694**	.353**	.350**
	Sig. (bilateral)		.000	.000	.000	.000	.000	.390
	N	42	42	42	42	42	42	42
ROD.waste	Correlación de Pearson	-.599**	1	.906**	-.179	.287	-.015	-.399**
	Sig. (bilateral)	.000		.000	.258	.066	.926	.009
	N	42	42	42	42	42	42	42
RMR.waste	Correlación de Pearson	-.613**	.906**	1	-.126	.302	-.017	-.458**
	Sig. (bilateral)	.000	.000		.428	.052	.914	.002
	N	42	42	42	42	42	42	42
Burden waste	Correlación de Pearson	-.577**	-.179	-.126	1	.448**	-.826**	-.666**
	Sig. (bilateral)	.000	.258	.428		.003	.000	.000
	N	42	42	42	42	42	42	42
Stemming waste	Correlación de Pearson	-.694**	.287	.302	.448**	1	-.415**	-.841**
	Sig. (bilateral)	.000	.066	.052	.003		.006	.000
	N	42	42	42	42	42	42	42
F.carga waste	Correlación de Pearson	.353**	-.015	-.017	-.826**	-.415**	1	.672**
	Sig. (bilateral)	.000	.926	.914	.000	.006		.000
	N	42	42	42	42	42	42	42
Conc.carga lin.waste	Correlación de Pearson	.350**	-.399**	-.458**	-.666**	-.841**	.672**	1
	Sig. (bilateral)	.390	.009	.002	.000	.000	.000	
	N	42	42	42	42	42	42	42

** La correlación es significativa en el nivel 0,01 (bilateral).

Fuente: Reporte generado en el entorno SPSS.

TABLA 26. Coeficiente de correlación Pearson para Mineral.

		Correlación Pearson mineral						
		Dist. Predecida.ore	ROD.ore	RMR.ore	Burden ore	Stemming. ore	F.carga.ore	Conc.carga. lin.ore
Dist Predecida.ore	Correlación de Pearson	1	-.885**	-.850**	-.328**	-.163	.522**	.103
	Sig. (bilateral)		.000	.000	.000	.089	.004	.797
	N	110	110	110	110	110	110	110
ROD.ore	Correlación de Pearson	-.885**	1	.956**	-.006	-.037	.058	.004
	Sig. (bilateral)	.000		.000	.954	.702	.546	.966
	N	110	110	110	110	110	110	110
RMR.ore	Correlación de Pearson	-.850**	.956**	1	-.033	-.007	.099	.061
	Sig. (bilateral)	.000	.000		.734	.938	.303	.529
	N	110	110	110	110	110	110	110
Burden.ore	Correlación de Pearson	-.328**	-.006	-.033	1	.341**	-.783**	-.055
	Sig. (bilateral)	.000	.954	.734		.000	.000	.568
	N	110	110	110	110	110	110	110
Stemming.ore	Correlación de Pearson	-.163	-.037	-.007	.341**	1	-.340**	.443**
	Sig. (bilateral)	.089	.702	.938	.000		.000	.000
	N	110	110	110	110	110	110	110
F.carga.ore	Correlación de Pearson	.522**	.058	.099	-.783**	-.340**	1	.282**
	Sig. (bilateral)	.004	.546	.303	.000	.000		.003
	N	110	110	110	110	110	110	110
Conc.carga lin.ore	Correlación de Pearson	.103	.004	.061	-.055	.443**	.282**	1
	Sig. (bilateral)	.797	.966	.529	.568	.000	.003	
	N	110	110	110	110	110	110	110

** La correlación es significativa en el nivel 0,01 (bilateral).

Fuente: Reporte generado en el entorno SPSS.

5.1.1.10.1 Resultados del análisis de sensibilidad.

Bajo los análisis realizados anteriormente se ha obtenido la proporción de cambio por cada variable independiente sobre mineral y estéril, haciendo el análisis de sensibilidad para el valor medio de cada uno de ellos en función a las distancias reales más relevantes siendo estos los resultados como se muestra en la tabla.27. Se observa que las variables RQD, RMR, burden, stemming, tienen una variación de distancia negativa, tanto para mineral y desmonte que indica que para valores mayores de estas variables se obtendrán distancias menores de flyrock, por otro lado el factor de carga y la concentración de carga lineal tienen una variación de distancia positiva, que quiere decir que para valores mayores de estas variables mayores serán las distancias alcanzadas por el flyrock. En caso de la calidad de la roca, nos indica que por cada 1% de RQD la distancia de proyección de roca es de -1.13m y -0.61m. Para mineral y desmonte respectivamente, por cada 1Mpa de RMR la distancia de proyección de roca es de -0.95m y -0.50m, por cada 0.1 m de burden la distancia de proyección de roca es de -1.15m y -0.40m, por cada 0.1m de stemming la distancia de proyección de roca es de -1.05m y -0.37m, por otro lado por cada 0.1 kg/ton de factor de carga la distancia de proyección de roca es de 0.70m y 0.30m, por otro lado por cada 0.1 kg/m de factor de carga la distancia de proyección de roca es de 0.69m y 0.34m. Para mineral y desmonte respectivamente.

TABLA 27. Resultados del análisis de sensibilidad.

RESULTADOS DEL ANÁLISIS DE SENSIBILIDAD		
VARIABLE INDEPENDIENTE	ORE	WASTE
RQD	$\Delta Df / \Delta RQD = (-)1.13$ m por 1%.	$\Delta Df / \Delta RQD = (-)0.61$ m por 1%.
RMR	$\Delta Df / \Delta RMR = (-)0.95$ m por Mpa.	$\Delta Df / \Delta RMR = (-)0.50$ m por Mpa.
BURDEN	$\Delta Df / \Delta B = (-)1.15$ m por 0.1 m.	$\Delta Df / \Delta B = (-)0.40$ m por 0.1 m.
STEMMING	$\Delta Df / \Delta St = (-)1.05$ m por 0.1 m.	$\Delta Df / \Delta St = (-)0.37$ m por 0.1 m.
FACTOR DE CARGA	$\Delta Df / \Delta Fc = 0.70$ m por 0.1 Kg/ton.	$\Delta Df / \Delta Fc = 0.30$ m por 0.1 Kg/ton.
CONCENTRACIÓN DE CARGA LINEAL	$\Delta Df / \Delta CCL = 0.69$ m por 0.1 Kg/m.	$\Delta Df / \Delta CCL = 0.34$ m por 0.1 Kg/m.

Fuente: Análisis de datos con Matlab

CONCLUSIONES

- Se ha podido predecir las distancias cubiertas por el flyrock inducido por la voladura, utilizando las redes neuronales artificiales del Matlab, dando una solución alternativa de predicción de flyrock inducido por la voladura en el tajo Ferrobamba, utilizando las seis variables independientes que se han seleccionado, como son: la concentración de la carga lineal, burden, stemming, factor de carga, RQD y RMR. Las redes neuronales con dos capas ocultas y la función sigmoideal, han sido determinadas como los mejores predictores gracias al algoritmo de retropropagación (backpropagation) hacia atrás, las predicciones han sido satisfactorias ya que se han alcanzado los objetivos esperados.
- El análisis de sensibilidad ha sido realizado para estudiar el comportamiento de las variables en la proyección de rocas del tajo Ferrobamba, es preciso conocer este comportamiento de las variables para poder predecir adecuadamente, del análisis realizado concluimos que el RQD, RMR, burden, stemming, tienen una variación de distancia negativa, tanto para mineral y desmonte que indica que para valores mayores de estas variables se obtendrán distancias menores de flyrock, por otro lado el factor de carga y la concentración de carga lineal tienen una variación de distancia positiva, que quiere decir que para valores mayores de estas variables mayores serán las distancias alcanzadas por el flyrock, enfocando en realizar una correcta zonificación de la malla de voladura y mejorar los controles operativos.
- Las distancias predecidas por las redes neuronales artificiales del Matlab con las distancias reales de proyección mantienen una correlación positiva de $R^2=0.98$, el cual indica que hay un alto nivel de correlación y muestran la eficacia del Matlab.

- Los parámetros de voladura y datos geotécnicos influyen directamente en el cálculo de la predicción de la distancia cubierta por el flyrock, los parámetros como el burden, stemming, factor de carga y concentración de carga lineal son controlables, ya que dependen de temas operativos principalmente, por otro lado el RQD y RMR son variables incontrolables, por lo que muchas veces no se puede hacer un control eficiente y peor aun cuando no se cuenta con esta información durante el carguío de taladros.
- La importancia de la utilización de las redes neuronales del Matlab, como se vio anteriormente, integra muchas variables independientes para un análisis más completo de la predicción de fenómenos incontrolables como es el flyrock, además de ajustar correctamente a las distancias reales. Por otro lado se ha hecho la comparación respectiva entre los errores de cálculo para, el análisis de videos, la regresión multivariable y las redes neuronales artificiales del Matlab siendo este último, un excelente modelo debido a su coeficiente de determinación más alto así como también el MAE y RMSE mínimo, por lo que se muestra que las redes neuronales del Matlab son una herramienta superior de predicción a diferencia de otros métodos tradicionales de predicción de flyrock.

RECOMENDACIONES

- Durante la ejecución de este trabajo de tesis, se observó que el agua también juega un rol importante, ya que hay zonas con mucha presencia de aguas dinámicas, estos taladros en general presentan cráteres, y muchas veces hay sobrecarga de taladros, lo que conlleva a ocasionar proyección de rocas, por lo que sería interesante ver el comportamiento de proyección para esta variable.
- Los datos geológicos y geotécnicos son de vital importancia, ya que como se muestra en el análisis de datos tienen una alta influencia en la proyección de roca, por lo que se recomienda integrar estos datos y zonificarlos en los planos de carguío, ya que muchas veces se utilizan diseños de carga inadecuados para la calidad y dureza de la roca.
- Es necesario que el personal de voladura aplique en el terreno lo que realmente se diseña, cualquier desviación como exceso de carga o mal tapado tiene que ser comunicado para ajustar los radios de evacuación.
- Preferentemente evacuar los equipos en dirección contraria al desplazamiento del material de voladura, y en lo posible moverlo lo más lejos posible.
- En las voladuras donde se use un mayor factor de carga, usar material gravilla para el tapado de taladros, la calidad del taco es fundamental para controlar el flyrock de los disparos.
- Los supervisores de voladura deben asegurar el cumplimiento de los parámetros de diseño de voladura; como diseño de malla, el factor de carga, la secuencia de salida de taladros cargados en cara libre, verificación de longitud del taco y material apropiado del mismo.

BIBLIOGRAFÍA

- 1) Bowerman, K. (2007). *Pronósticos, Series Temporales y Regresión*. MÉXICO: INTERNACIONAL THOMSON.
- 2) EXSA. (2002). *MANUAL PRACTICO DE VOLADURA*. La victoria-LIMA: GRUPO BRESCIA.
- 3) Fernandez, D. R. (10 de julio de 2015). Practica 1. Introducción a MATLAB.
- 4) González .M, C. M. (2005). PREDICCIÓN DE LA DEMANDA ELÉCTRICA HORARIA MEDIANTE REDES NEURONALES ARTIFICIALES. 24.
- 5) *Plata* Hernández, R. (2010). *METODOLOGÍA DE LA INVESTIGACIÓN* (Vol. QUINTA EDICIÓN). *Trinidad* (M. G. HILL, Ed.) MÉXICO, SANTA FÉ, MÉXICO: INTERAMERICANA EDITORES S.A DE C.V.
- 6) Kaastra, L. y. (1999). *DESIGNING A NEURAL NETWORK FOR FORECASTING FINANCIAL AND ECONOMIC TIMES SERIES*. USA: NEUROCOMPUTING.
- 7) Marqués, E. (2004). INTRODUCCIÓN AL ANÁLISIS MULTIVARIABLE. En E. J. Marquez., *INTRODUCCIÓN AL ANÁLISIS MULTIVARIABLE*. (pág. 221).
- 8) MORENO RODRÍGUEZ, A., & GONZÁLEZ FARIAS, I. (10 de Julio de 2013). Desarrollo de una interfaz gráfica de redes. UNIVERSIDAD CARLOS III MADRID, ESPAÑA.
- 9) NAVEROS, H. L. (2009). *FÍSICA I*. LIMA: MOSHERA SRL.
- 10) Rojas, J., & Vásquez, V. (10 de Diciembre de 2012). Predicción mediante Redes Neuronales Artificiales (RNA) de la difusividad, masa, humedad, volumen y sólidos en yacón (*Smallantus sonchifolius*) deshidratado osmóticamente. Trujillo, Trujillo, Perú.
- 11) T. S. Bajpayee, T. R. (2007). BLASTING INJURIES IN SURFACE MINING WITH EMPHASIS ON FLYROCK AND BLAST AREA SECURITY. En T. R. T. S. Bajpayee, *STING INJURIES IN SURFACE MINING WITH EMPHASIS ON FLYROCK AND BLAST AREA SECURITY*. Pittsburgh, PA 15236-0070.

Sitios internet

- 1) D&E Desarrollo y Ecología SAC. (s.f.). Obtenido de <http://www.minem.gob.pe/minem/archivos/file/DGAAM/estudios/lasbambas/>
- 2) GONZALES MARTINEZ, M. (02 de Noviembre de 2012). CIENCIA Y SOCIEDAD. *Redalyc*. Obtenido de www.google.com.
- 3) *INTRODUCCIÓN A LAS REDES REURONALES ARTIFICIALES*. (10 de 06 de 2015). Obtenido de http://magomar.webs.upv.es/rna/tutorial/RNA_marcos.html
- 4) Mathworks. (1994). *Redes neuronales*. Obtenido de <https://es.mathworks.com/discovery/redes-neuronales.html>
- 5) MATLAB CORP. (2005). *www.matlab.com*.



ANEXOS



ANEXO I.- Código fuente de la implementación del modelo de las redes neuronales artificiales en Matlab.




```

% Solve an Input-Output Fitting problem with a Neural Network
% Script generated by Neural Fitting app
% Created 16-Dec-2016 14:07:40
%
% This script assumes these variables are defined:
%
% m - input data.
% n - target data.
x = m;
t = n;
% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. Suitable in low memory situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.
% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);
% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
% Train the Network
[net,tr] = train(net,x,t);
% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)
% View the Network
view(net)
% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotfit(net,x,t)

```

ANEXO II.- Matriz de consistencia.



PROYECTO DE TESIS: "PREDICCIÓN DE LA DISTANCIA CUBIERTA POR EL FLYROCK APLICANDO LAS REDES NEURONALES ARTIFICIALES DEL MATLAB, TAJO FERROBAMBA-PROYECTO MINERO LAS BAMBAS 2015"

INVESTIGADOR: LUIS ALBERTO SANCHEZ SERRANO

MATRIZ DE CONSISTENCIA				
FORMULACIÓN DE PROBLEMAS	FORMULACIÓN DE OBJETIVOS	FORMULACIÓN DE HIPÓTESIS	VARIABLES	DIMENSIONES
PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	DEPENDIENTE	UNIDADES
¿Es posible, predecir la distancia cubierta por el flyrock, inducido por la voladura usando las redes neuronales artificiales del Matlab, aplicado al proyecto minero las Bambas?	Predecir las distancias, cubiertas por el flyrock usando las redes neuronales artificiales del Matlab en el tajo Ferrobamba, proyecto minero las Bambas.	La determinación de las distancias, cubiertas por el flyrock, usando las redes neuronales artificiales del Matlab en el tajo Ferrobamba, proyecto minero las Bambas.	Predicción de la distancia	(metros) m
PROBLEMA ESPECÍFICO	OBJETIVO ESPECÍFICO	HIPOTESIS ESPECÍFICO	INDENDIENTE	UNIDADES
¿Cuál es el comportamiento de las variables, en la proyección de rocas del tajo Ferrobamba?	Determinar cómo es el comportamiento de las variables en la proyección de rocas en el tajo Ferrobamba, mediante el análisis de sensibilidad.	Se conoce el comportamiento de las variables de proyección de roca para el tajo Ferrobamba, mediante el análisis de sensibilidad.		
¿Cuál es el grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección?	Establecer el grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección.	Existe un alto grado de correlación de las distancias predecidas por las redes neuronales del Matlab y las distancias reales de proyección.		
¿Cómo influyen los parámetros de voladura y datos geotécnicos en el cálculo de la predicción de la distancia cubierta por el fryrock en el tajo Ferrobamba?	Determinar los parámetros de voladura y datos geotécnicos para el cálculo de la predicción de la distancia cubierta por el flyrock en el tajo Ferrobamba del proyecto minero las Bambas.	Establecer los parámetros de voladura y datos Geotécnicos para la predicción de la distancia cubierta por el flyrock, en el Tajo Ferrobamba del proyecto minero las Bambas.	Aplicación de las redes neuronales del Matlab	<ul style="list-style-type: none"> • Concentración de carga lineal (Kg/m) • Burden (m) • Taco (m) • Espaciamento (m) • Factor de carga (Kg/ton) • RMR (Mpa) • RQD (%)
¿Cuál es la importancia de utilizar las redes neuronales del Matlab a diferencia de otros métodos	Mostrar que las redes neuronales del Matlab son una herramienta superior de predicción	Las redes neuronales del Matlab son una potente herramienta de predicción a diferencia de otros		



ANEXO III.- Fotos tomadas en el trabajo de campo.



Fotografía 1: Medición de las proyecciones de roca, con el GPS.



Fotografía 1: Medición de los parámetros de voladura.



Fotografía 3: Medición de los tacos y carguío.



Fotografía 4: Flyrock en el tajo Ferrobamba, afectando a perforadoras cercanas.



Fotografía 5: Pala muy próxima al frente de voladura.



Fotografía 6: Pala muy próxima al frente de voladura.

