



**UNIVERSIDAD DE TALCA
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL DE MINAS**

**DISEÑO DE UNA MINA A CIELO ABIERTO
UTILIZANDO REDES NEURONALES DE BASE RADIAL**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO(A) CIVIL DE MINAS

RONALD MATIAS GONZÁLEZ VALDERRAMA

PROFESOR GUÍA

Dr. Manuel Reyes-Jara

MIEMBROS DE LA COMISIÓN

Mg. Carlos Moraga Cruz

Sr. Kenji Naito Chiang

CURICÓ-CHILE

2021

CONSTANCIA

La Dirección del Sistema de Bibliotecas a través de su encargado Biblioteca Campus Curicó certifica que el autor del siguiente trabajo de titulación ha firmado su autorización para la reproducción en forma total o parcial e ilimitada del mismo.



Two circular official stamps and handwritten signatures in blue ink. The left stamp is from the 'DIRECCIÓN SISTEMA DE BIBLIOTECAS' of the 'UNIVERSIDAD DE TALCA'. The right stamp is from the 'SISTEMA DE BIBLIOTECAS CAMPUS CURICO' of the 'UNIVERSIDAD DE TALCA'.

Curicó, 2022

RESUMEN

La industria minera está en constante modernización en sus diversas áreas, procesamiento, geología, geotecnia, perforación, transporte, etc. Los avances tecnológicos por su parte siempre buscan minimizar el trabajo del ser humano y hacer que las maquinas realicen tareas que requieran mayor tiempo y esfuerzo. En el ámbito del diseño de minas, existen *softwares* que realizan la optimización de los pits, pero estos no son operativizados en lo que muchas veces altera el cálculo del beneficio minero, ya que al integrar elementos como rampas y bermas en algunas ocasiones cambian la geometría de la envolvente.

La presente memoria busca integrar estos elementos y ofrecer una alternativa a la ejecución de diseños operativos de minas, integrando la transformación digital y la necesidad de opciones en este ámbito, es por esto por lo que el desarrollo de diseños de minas a cielo abierto utilizando redes neuronales de base radial resulta más que motivador y un desafío a la vez, este trabajo apunta a la modernización de la minería y tratar de impulsar un cambio en el diseño de minas a cielo abierto.

Palabras claves: Diseño - Rampa - Inteligencia Artificial - Base radial - Predicción - Error

ABSTRACT

The mining industry is constantly modernizing in its various areas, processing, geology, geotechnics, drilling, transportation, etc. Technological advances for their part always seek to minimize human work and make machines perform tasks that require more time and effort. In the field of mine design, there are software that perform pit optimization, but these are not operationalized, which often alters the calculation of the mining benefit, since when integrating elements such as ramps and berms, the geometry sometimes changes. of the envelope.

This report seeks to integrate these elements and offer an alternative to the execution of operational mine designs, integrating the digital transformation and the need for options in this area, which is why the development of open pit mine designs using networks Radial-based neurons is more than motivating and challenging at the same time, this work aims at modernizing mining and trying to promote a change in the design of open pit mines.

ÍNDICE

1. INTRODUCCIÓN.....	1
1.1. Objetivo general.....	2
1.2. Objetivos Específicos.....	2
1.3. Alcances.....	2
2. MARCO TEORICO	4
2.1. Elementos básicos en el diseño de una mina a cielo abierto	4
2.1.1. Banco.....	4
2.1.2. Angulo global del talud.....	5
2.1.3. Angulo interrampa	5
2.1.4. Angulo cara de banco.....	5
2.1.5. Ancho de berma	5
2.1.6. Altura de Banco.....	5
2.2. Rampa.....	5
2.2.1. Ancho de rampa	6
2.2.2. Sentido del camino.....	7
2.2.3. Switchback	7
2.3. Algoritmo de Lerchs & Grossman.....	7
2.3.1. Pit Final y Beneficio Económico	8
2.3.2. Valor Actual Neto (VAN).....	8
2.4. Maching Learning	8
2.5. Redes neuronales artificiales	9
2.6. Redes Neuronales de Base Radial	11
2.7. Arreglo Ortogonal	13
2.7.1. Diseño ortogonal.....	14
2.8. Medición del error de pronóstico.....	14
2.8.1. Error absoluto.....	14
2.8.2. MAPE.....	15
2.8.3. RMSE.....	15
3. METODOLOGÍA.....	16
3.1. Procedimientos.....	16

3.2. Recursos utilizados	17
3.2.1. Maptex Vulcan	17
3.2.2. IBM SPSS Statistics	18
4. RESULTADOS Y DISCUSIÓN	19
4.1. Base de Datos	19
4.2. Diseño Ortogonal	21
4.3. Diseño de escenarios	24
4.4. Modelo de Red Neuronal de Base Radial	29
4.4.1. Variables de entrenamiento	30
4.4.2. Entrenamiento 36 Casos	31
4.4.3. Entrenamiento 72 Casos	33
4.4.4. Entrenamiento 108 Casos	36
4.5. Modelo de predicción de diseño	38
4.6. Validación de Modelos	41
4.7. Evaluación método predictivo de mejor y peor caso	44
4.8. Logros del modelo	45
5. CONCLUSIONES Y RECOMENDACIONES	47
5.1. Conclusiones	47
5.2. Recomendaciones	48
REFERENCIAS	49

ÍNDICE DE FIGURAS

Figura 1: Componentes geométricos del talud minero.....	4
Figura 2: Elementos de una rampa.....	6
Figura 3 Esquema de las Redes Neuronales.....	10
Figura 4 Esquema de una Red Neuronal de Base Radial.....	11
Figura 5 Representación de las neuronas ocultas en la red RBF	12
Figura 6 Vista en planta del pit optimo	20
Ilustración 7 Vista isométrica del caso número 12 del plan ortogonal	25
Figura 8 Comparación entre los diseños del pit 21 (rojo) y 28 (verde)	28
Figura 9 Grafico beneficio vs tonelaje	29
Figura 10 Casos reservados de la variable beneficio, diferencia entre casos reales y predichos, y error respectivo.	32
Figura 11 Grafico de barras de la cantidad de casos por respectivo error	34
Figura 12 Casos reservados de la variable beneficio, diferencia entre casos reales y predichos, y error respectivo	35
Figura 13 Grafico de dispersión de los errores absolutos para las 3 variables estudiadas... ..	35
Figura 14 Casos reservados de la variable beneficio, diferencia entre casos reales y predichos, y error respectivo.	38
Figura 15 Vista en planta del mejor y peor modelos de Marvin.....	41
Figura 16 Grafico de dispersión variable beneficio.	42
Figura 17 Grafico de dispersión variable finos de Cu.....	43

ÍNDICE DE TABLAS

Tabla 1 Parámetros Pit Optimiser de Vulcan	19
Tabla 2 Recursos pit óptimos	20
Tabla 3 Resumen de los factores que inciden en el diseño ortogonal.....	22
Tabla 4 Diseño ortogonal	23
Tabla 5 Parámetros de diseño.....	24
Tabla 6 Resultados de 36 diseños realizados	25
Tabla 7 Selección de casos con mayor y menor beneficio.....	27
Tabla 8 Resumen variables afectan el entrenamiento de la red neuronal	30
Tabla 9 Partición de casos para entrenamiento de red neuronal	31
Tabla 10 Resumen modelo 36 casos	31
Tabla 11 Partición de casos para entrenamiento de red neuronal	33
Tabla 12 Resumen modelo 72 casos	34
Tabla 13 Partición de datos para el entrenamiento de la red neuronal.....	36
Tabla 14 Resumen modelo 108 casos	36
Tabla 15 Configuración de diseño para el mejor escenario..	39
Tabla 16 Configuración de diseño para el escenario.....	39
Tabla 17 Resumen del modelo de predicción para mejor y peor escenario.....	40
Tabla 18 Comparación modelos.....	42
Tabla 19 Cinco peores escenarios del modelo predictivo.	44
Tabla 20 Importancia variables independientes	45

1. INTRODUCCIÓN

La minería a cielo abierto es ampliamente utilizada en los yacimientos a lo largo del mundo, más aún en Chile donde es la principal forma de extracción de minerales. Junto a ello el diseño de este tipo de minas permite una extracción masiva, donde se alcanzan las mayores tasas extracción de roca. Para alcanzar altos niveles de producción es necesario movilizar gran cantidad de maquinarias en donde se incluyen camiones, perforadoras, palas, etc. Lo cual trae consigo costos asociados que para que el negocio minero sea fructífero deben ser siempre disminuidos.

La generación de nuevos avances tecnológicos en la industria surge como una necesidad para mantenerse vigente como país en el mercado minero mundial, estos avances apuntan a la automatización, optimización de procesos y operaciones mineras, que siempre han seguido los lineamientos tradicionales, pero con las nuevas herramientas tecnológicas y computacionales pueden llegar a ser una alternativa real en la minería a cielo abierto.

Las redes neuronales son una herramienta nueva para la predicción de diferentes eventos ligados a la ciencia, intentando emular el comportamiento del cerebro humano de pensar, recordar y resolver problemas, en la actualidad son utilizadas en muchos campos, los que destacan el reconocimiento de imágenes y clasificación de datos en campos como la medicina e ingeniería, siendo este tipo de tecnología un pilar fundamental para la industria 4.0.

Es por esto, que el proyecto tiene como finalidad el desarrollo de una red neuronal de base radial que permita el cálculo del valor económico de diseños de mina a cielo abierto sin la necesidad de diseñarlos, para obtener el máximo beneficio y los parámetros ideales logrando disminuir considerablemente los tiempos de ejecución de los diseños generado por un humano, permitiendo bajar los recursos utilizados y aportando una opción real a la industria.

1.1. Objetivo general

Desarrollar una metodología de generación de diseños para una mina a cielo abierto, mediante la utilización de redes neuronales de base radial.

1.2. Objetivos Específicos

1. Hacer un plan ortogonal con variables de diseño de mina a cielo abierto que permitan verificar como afectan estas el valor económico del *pit*.
2. Diseñar un conjunto de casos de diseño de mina a cielo abierto que permitan entrenar, probar y evaluar distintos escenarios.
3. Establecer una comparación entre un diseño manual de una mina a cielo abierto y una realizada por el método de redes neuronales de base radial, que proporcione la calidad del modelo tomando en consideración su geometría y valor económico.
4. Desarrollar una predicción para miles de casos aleatorios de diseños de minas, y obtener mejores y peores escenarios.

1.3. Alcances

- Se utilizará una base de datos proporcionada, donde está calculado previamente el valor económico del cada bloque.
- Para efectos del diseño de los *pits* para entrenar la red neuronal, no se considerarán problemas o fallas geotécnicas.
- Los diseños escogidos para probar el modelo están dados por un plan ortogonal ejecutado por el *software* IBM SPSS Statistics.
- El algoritmo de *pit* final se calculará por medio de las herramientas del *software* Vulcan.
- Se realizarán diseños de rajas tanto para entrenar, probar y evaluar la red neuronal de base radial

- El entrenamiento de la red neuronal para los diferentes modelos se realizará con la herramienta función de base radial del *software* IBM SPSS Statistics.

2. MARCO TEORICO

2.1. Elementos básicos en el diseño de una mina a cielo abierto

Son varios los elementos que determinan el diseño de un pit, entre ellos destacan: parámetros geológicos como la geología, ubicación de la mineralización, etc. Parámetros geométricos como el tamaño, talud, altura de banco, inclinación de caminos, rampas, entre otros.

2.1.1. Banco

Son los elementos principales en el talud y cruciales en una operación ya que acomodan las áreas activas de perforación y tronadura. Los bancos se pueden dividir en bancos de trabajo e inactivos. Los bancos de trabajo están en proceso de extracción de material, mientras que los bancos inactivos, son los restos de los bancos de trabajo dejados en su lugar para mantener la estabilidad de la pendiente del rajo.

En la figura 1 siguiente muestra los elementos de un talud minero, que son los parámetros que afectan directamente el diseño de un pit.

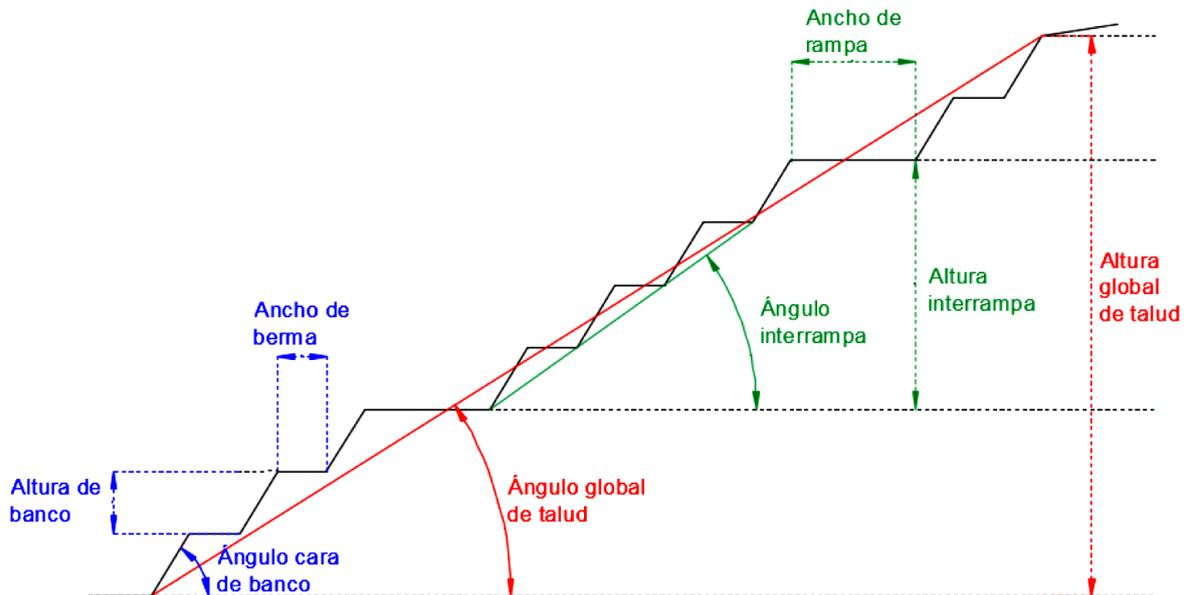


Figura 1: Componentes geométricos del talud minero (Pizarro, 2017)

2.1.2. Angulo global del talud

Corresponde al ángulo formado por la recta tangente a la pata del banco más profundo y la cresta del banco que interseca la superficie. Su valor dependerá del ángulo interrampa del diseño, el número de *catch-berms* utilizado y el sistema de rampas, el valor típico de este parámetro oscila entre 37° y 48°. (Moreno, 2019)

2.1.3. Angulo interrampa

Está definido por el ángulo formado entre la pata del banco inferior y superior, para el grupo de bancos existentes entre rampas. (Pizarro, 2017).

2.1.4. Angulo cara de banco

Es el ángulo formado entre la horizontal y la pared del banco.

2.1.5. Ancho de berma

Corresponde a la distancia horizontal medida entre la cresta de un banco y la pata del banco superior. Este elemento cumple con una función de seguridad, el cual permite la contención de material que se desprende o caídas de rocas de bancos superiores (Reti, 2015).

2.1.6. Altura de Banco

Este parámetro se escoge en función de los equipos de carguío y transporte que se ocuparan dentro de la mina. La altura de trabajo máximo es un factor determinante a la hora de elegir una altura de bancos (Cortés, 2009).

2.2. Rampa

Números son los parámetros que inciden en el diseño y cálculo de los elementos de una rampa, entre estos se encuentran la pendiente, el ancho y radios de curvatura los cuales deben ser calculados de tal forma que los equipos de transporte y operación de mina circulen por

estos caminos alcanzando su máximo rendimiento, respetando la seguridad de la operación y minimizando los deterioros en su funcionamiento (Pizarro, 2017).

La rampa es la ruta de transporte de camiones u operadores cuyo fin es llevar el material desde las zonas de excavación activa hasta el borde superior del rajo.

2.2.1. Ancho de rampa

El cálculo del ancho de rampa está determinado por el vehículo más ancho que transitara por la rampa, se deben considerar bermas de seguridad, zanjas y una distancia de seguridad entre camiones, generalmente el diseño recomendado es de al menos 3.5 veces el ancho del camión más grande de la operación en camino recto y 4 veces el ancho del camión en curvas (Moreno, 2019). En la ilustración 2 se observan los componentes que determinan el ancho de una

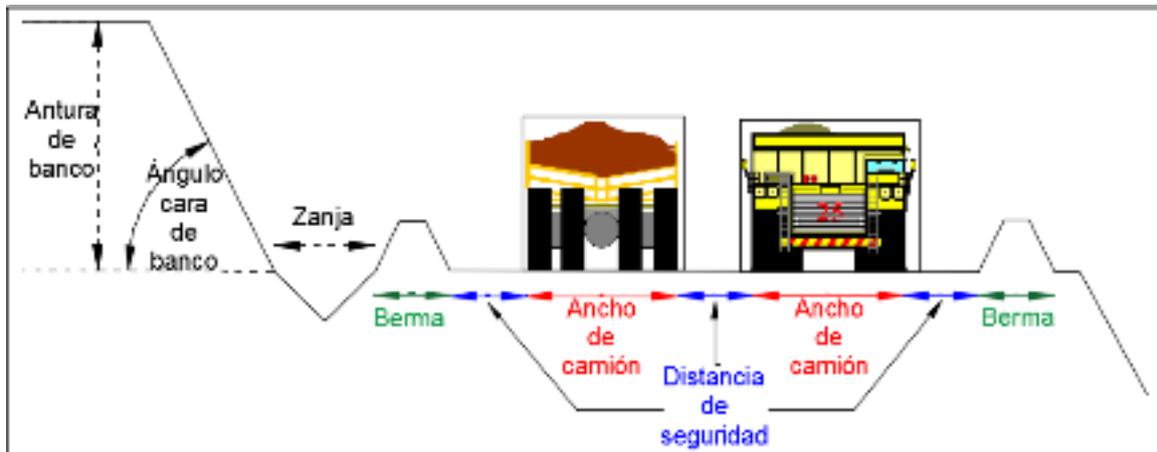


Figura 2: Elementos de una rampa (Pizarro, 2017)

rampa.

2.2.1.1.1. **Zanja [Z]:** es una alcantarilla de drenaje construida con el fin de capear las condiciones climáticas e hidrogeológicas que existen en la mina, cumple la función de seguridad que evita accidentes por presencia de líquidos en vía. (Pizarro, 2017)

2.2.1.1.2. **Berma [B]:** es un elemento de seguridad también conocido como pretil que lo diferencia de las bermas del talud, su finalidad es detener los equipos de transporte en los extremos, evitando así posibles caídas, y evitar accidentes. El diseño de la berma debe

considerar por lo menos la mitad de la rueda del camión más grande de la flota. (Pizarro, 2017)

2.2.1.3. **Distancia de Seguridad [D]:** es la longitud mínima requerida para evitar colisiones frontales entre los equipos de transporte y permitir así un paso holgado entre los camiones. (Pizarro, 2017)

2.2.2. Sentido del camino

En la medida de lo posible cuando el camino asciende del fondo se debe respetar el sentido horario, esto ya que produce menos esfuerzo en la pared del talud cuando los camiones ascienden cargados por la rampa. Lo anterior permite disminuir riesgos, ya que transitar por el borde del talud con el camión cargado, lo hace más inseguro, puesto que al poseer carga aumenta la probabilidad de falla en ejes o frenos. También por disposición del camión permite ubicar la cabina en el centro de la calzada lo que le permite al operador tener mayor visibilidad del camino ante posibles alteraciones de este. (Ault, 2011)

2.2.3. Switchback

Este parámetro en español significa cambio de sentido, en donde aquí se encuentran los radios de giro más pronunciado dentro del camino, por lo general el switchback es mínimo 1.5 veces el ancho de la rampa en rectas y así evitar colisiones. Además, mientras mayor sea el radio de curvatura, este cambio de sentido se vuelve más eficientes y pudiendo así disminuir el tiempo de ciclo. (Ault, 2011)

2.3. Algoritmo de Lerchs & Grossman

Es una metodología que permite diseñar la geometría del *pit* y donde alcanza su máxima utilidad neta, permite crear una serie de *pit* anidados variando el precio del metal en el cual se trabaja, es decir, un *pit* pequeño tiene asociado un precio bajo, por el contrario, a medida que aumenta el *pit* se le asocia un más alto valor, esto hasta que haya una constante el cual determina el *pit* final.

Este algoritmo trabaja sobre un modelo de bloques valorizado, determinando que bloques son posiblemente extraídos, arrojando la envolvente más óptima dependiendo de los parámetros de diseño. El algoritmo utiliza el criterio que, si un bloque se explota, también se explotan los tres bloques superiores, resultando una estructura con forma cónica de 45° respecto a los bloques de arriba. *Lerchs & Grossman* soluciona el problema de maximizar el valor económico de un conjunto de bloques contenidos en un volumen (Cortés, 2009)

2.3.1. Pit Final y Beneficio Económico

Se define como la envolvente que es económicamente explotable de un depósito (Dagdelen, 2001; McCarthy, 2002), el cual pasa a ser el límite de un rajo. Para ello, se debe tener previamente un modelo de bloques son valorizados, asumiendo precios y costos fijos. A través de *Lerch y Grossman* antes mencionado se comprueba el valor económico de un bloque y si este es explotado o no, luego se calcula el beneficio neto de cada bloque, considerando costos y precios, por consiguiente, se tiene un beneficio total de los bloques contenidos en la envolvente.

2.3.2. Valor Actual Neto (VAN)

El Valor Actual Neto o Valor del Presente Neto (VPN) tiene como definición medir la generación de riqueza cuando se realiza una inversión, el VAN tiene como finalidad poder medir el valor de un proyecto en una extensión de tiempo, también es un indicador de rentabilidad al analizar inversiones donde su enfoque es netamente económico. (Valencia, 2011).

2.4. Maching Learning

El Machine Learning es un área de la inteligencia artificial que engloba un conjunto de técnicas que hacen posible el aprendizaje automático a través del entrenamiento de grandes volúmenes de datos. El aprendizaje automático permite que un sistema aprenda a partir de datos en lugar de programación explícita, utiliza una variedad de algoritmos que iterativamente aprenden de los datos para mejorar, describir y predecir resultados. A medida

que los algoritmos ingieren datos de entrenamiento, es posible producir modelos más precisos basados en esos datos.

En este contexto existen tres grupos de algoritmos de Machine Learning: Algoritmos supervisados, que utilizan un conjunto de datos de entrenamiento preclasificados, buscando corregir errores en los mismos datos alcanzando un nivel de precisión deseado; Algoritmos semi-supervisados, combinan datos etiquetados como no etiquetados, este tipo modelo busca organizar datos y realizar predicciones; Algoritmos no supervisados, los datos no se encuentran etiquetados y se desconoce el resultado. (Russo, 2016)

2.5. Redes neuronales artificiales

La definición aceptada universalmente sobre una red neuronal artificial no existe, pero varios autores coinciden en que una red neuronal funciona como un sistema de procesamiento de información formado por un conjunto de procesadores simples organizados en paralelo, los cuales cada uno posee una pequeña cantidad de memoria. Muchas de estas redes neuronales artificiales tienen la regla de aprendizaje a partir de datos del exterior. (Pastor, 1998)

Como no hay una unificación de definiciones a continuación se dejan dos presentadas por distintos autores:

“Una red neuronal es un circuito inspirado neuralmente que está compuesto por un gran número de elementos de procesamiento simples. Cada elemento opera sólo con información local. Además, cada elemento opera asincrónicamente, es decir no hay un temporizador global del sistema” (Nigrin, 1993)

“Las redes neuronales están compuestas por capas de conexiones que relacionan inputs con outputs. Las redes neuronales en la toma de decisiones funcionan como el cerebro, ya que imitan las características de adaptación e inferencia de los sistemas biológicos” (Pastor, 1998)

El diseño de una red neuronal posee características comunes entre todas ellas, estos elementos principales de las redes neuronales artificiales son, la capa de entrada, la cual se encarga de recibir la información externa, la capa oculta en la que se procesa la información a través de neuronas, y la capa de salida, la cual decodifica la información entregada por la capa oculta obteniéndose el resultado. Dentro de estos elementos generales se encuentran otros más específicos los pesos sinápticos, funciones de activación de la neurona, entre otras.

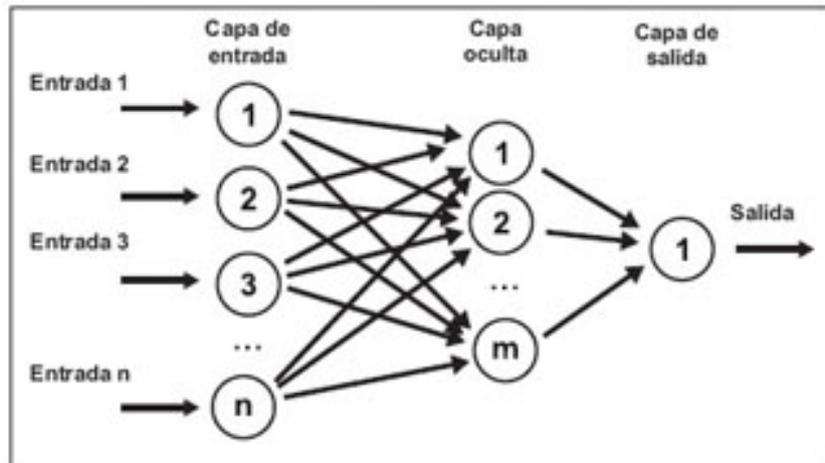


Figura 3 Esquema de las Redes Neuronales

Para la clasificar las redes neuronales normalmente se hace por el mecanismo de aprendizaje que estas ocupan, en la cual se distinguen dos, aprendizaje supervisado y no supervisado. Las más destacada son:

- Red neuronal Convolutiva (CNN): son un tipo de redes neuronales artificiales que son utilizadas, entre otras cosas, para el análisis y reconocimiento de imágenes. Su parte más importante radica en las capas convolucionales que participan como un grupo de filtros que, al ingresar una entrada, generan con esta un mapa de características que forma parte de la salida, en el caso por ejemplo de las imágenes, se aplican filtros a una parte tomando sus características, luego a otro sector de la imagen, y así sucesivamente hasta obtener los patrones que hacen más fácil el procesamiento. (Prieto, 2019)

- Red neuronal de perceptrón multicapa (MLP): son un tipo de red neuronal cuya característica principal es el aprendizaje por retro propagación del error o propagación del error hacia atrás (*backpropagation*), donde el modelo que relaciona las entradas con las salidas es determinado por los propios datos y no con un modelo estadístico. (Pastor, 1998)
- Red Neuronal de base radial (RBF): son un tipo de red neuronal artificial que se caracterizan por ser una red multicapa con propagación hacia adelante, cuya salida varía en función del cálculo de las distancias de un punto denominado centro. Las neuronas de la capa oculta por su parte se activan en función de la distancia que separa cada patrón de entrada con respecto al centro. En la siguiente sección se ampliará el estudio de este tipo de red neuronal. (Longoni, 2010)

2.6. Redes Neuronales de Base Radial

Las redes neuronales de base radial o también llamadas RBF (*radial basis function*) tienen tres capas de conexión hacia adelante: la capa de entrada, capa intermedia u oculta y capa de salida. Las neuronas de la capa de entrada solo tienen la función de transmitir la información a la capa oculta. Las neuronas de la capa intermedia por su parte se activan en función de la distancia que separa cada patrón de entrada con respecto al centro (o centroide) que cada neurona oculta almacena, estas neuronas se le aplica una función radial con forma de campana de Gauss. La capa de salida solamente calcula la suma ponderada de las salidas de la capa oculta. (Lucay, 2018) (Longoni, 2010). En la ilustración 4 se muestra el esquema general de una red neuronal de base radial con función gaussiana, donde c_j y σ_j son el centro y ancho y w el factor de peso en la salida de la función.

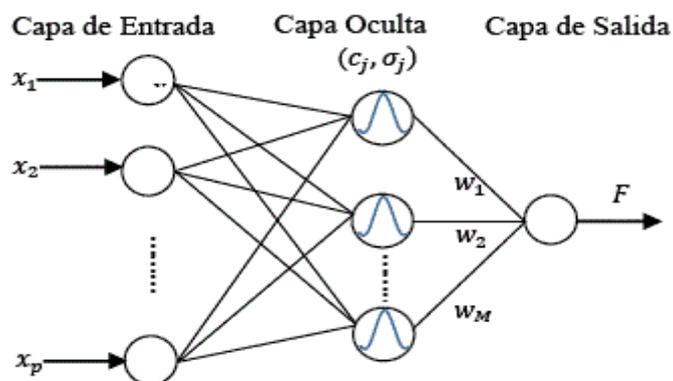


Figura 4 Esquema de una Red Neuronal de Base Radial. (Lucay, 2018)

Esta red se considera de tipo híbrido ya que incorpora aprendizaje supervisado y no supervisado. En las neuronas ocultas de la RBF la respuesta es localizada, es decir, solo responden con una intensidad apreciable cuando el espacio de entradas presentado y los pesos sinápticos de la neurona (también conocidos como centros) pertenecen a una zona próxima. Cada neurona oculta se ocupa de una zona del espacio de entradas y el conjunto de neuronas debe cubrir totalmente la zona de interés, pero debe hacerse suavemente, controlando el número de neuronas de la capa oculta y el ancho de cada una, para evitar aumentos innecesarios en la cantidad de neuronas (Egly Barrero Vicedo, 2014). En la imagen siguiente se muestra una representación de los centros con los datos de entrada:

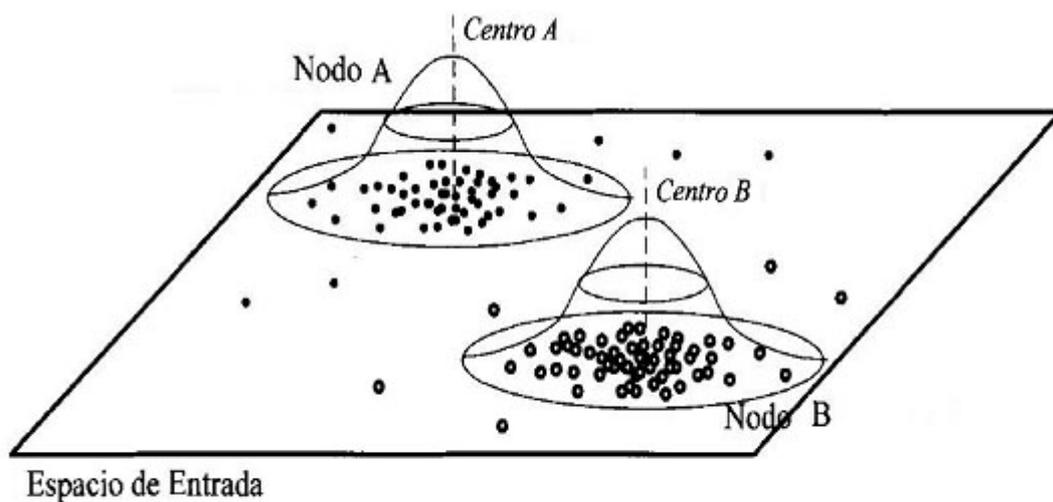


Figura 5 Representación de las neuronas ocultas en la red RBF. Fuente: (Egly Barrero Vicedo, 2014)

Cuando el espacio de entrada se encuentra en una región cercana al centro de una neurona la respuesta de esta tiende a uno, lo que significa que está activa, indicando que reconoce el patrón de entrada; por el contrario, si el patrón de entrada es muy diferente del centro la respuesta tiende a cero, indicando que la neurona está inactiva.

El aprendizaje de las redes neuronales de base radial se realiza en dos etapas, primero se realiza un entrenamiento no supervisado de esta forma se determina el valor de los centros, para esta etapa generalmente se utiliza el algoritmo de clúster de k- medias, mientras que para la parte supervisada se utiliza el método de la matriz pseudo – inversa, la finalidad de este tipo de aprendizaje híbrido es acelerar el proceso de aprendizaje el cual es notablemente más rápido que otros. No existe aún un método que estipule la cantidad de neuronas ocultas

precisas para cada modelo, pero la solución clásica a este problema radica en comparar varios modelos con diferentes números de unidades cada uno, seleccionando el que posee menor error de predicción.

Para el entrenamiento de la red se utilizan variables denominadas de partición, las cuales se encargan en dividir los casos de entrada para entrenamiento, pruebas y reservas.

- Entrenamiento: la muestra de entrenamiento comprende los registros de datos utilizados para entrenar la red neuronal; cierto porcentaje de casos del conjunto de datos debe asignarse a la muestra de entrenamiento para poder obtener un modelo. (IBM Corporation, 2020)
- Pruebas: para el caso de las muestras de prueba estas son un conjunto independiente de registros de datos que se utiliza para realizar un seguimiento de los errores durante el entrenamiento, con el fin de evitar un exceso de entrenamiento. Es muy recomendable crear una muestra de prueba y el entrenamiento de la red generalmente será más eficiente si la muestra de prueba es más pequeña que la muestra de entrenamiento. (IBM Corporation, 2020)
- Reserva: la muestra reservada es otro conjunto independiente de registros de datos que se utiliza para evaluar la red neuronal final; el error de la muestra reservada ofrece una estimación "sincera" de la capacidad predictora del modelo, ya que los casos reservados no se utilizan para crear el modelo. (IBM Corporation, 2020)

2.7. Arreglo Ortogonal

Es una selección de un determinado número de casos o muestras que son representativas de la población total, de forma tal que los resultados permiten que los factores del experimento sean evaluados separadamente. (Fernandez, 1996)

El cálculo del arreglo ortogonal sigue la siguiente formula:

$$L_A(B^C) \tag{1}$$

Donde:

$A = \text{número necesario de experimentos}$

$B = \text{número de nivel de cada factor}$

$C = \text{número de factores}$

Los arreglos pueden tener factores con varios niveles, aunque los factores con dos o tres niveles son los más comunes. (Fernandez, 1996)

2.7.1. Diseño ortogonal

Hacer un diseño ortogonal consiste en ordenar de forma matricial los posibles experimentos que se generan de los factores y niveles escogidos. La matriz esta dado por filas y columnas, donde las filas representan un posible escenario y en las columnas los factores que intervienen en el arreglo. Se debe cumplir la única condición en que los escenarios no pueden repetirse y deben es representados todos los niveles de los factores. Esto permitirá tener muestras representativas en pequeña escala, que sean representativos de la totalidad de casos reales. (Fernandez, 1996)

2.8. Medición del error de pronóstico

Para poder evaluar el desempeño de los modelos y cada predicción echa por la red neuronal de base radial, es que se emplearán distintas medidas de cálculo de error, estas se pasarán a detallar a continuación.

2.8.1. Error absoluto

Representa una medida de cuanto se subestimo o sobreestimo un pronóstico, permitiendo observar de forma simple según el rango de magnitud de los datos, cuan exacto fue el pronóstico. (Hanke, 2010)

$$Error = |Y - \hat{Y}| \quad (2)$$

Donde:

$Y = \text{Valor real}$

$\hat{Y} = \text{Valor pronosticado}$

2.8.2. MAPE

Corresponde al error porcentual absoluto medio o MAPE (*Mean Absolute Percentage Error*), se calcula obteniendo el error absoluto, dividido en el valor real observado y promediando la sumatoria de estos errores absolutos, luego se multiplica por 100 para obtener el porcentaje, esta es una medida de evaluación de exactitud del pronóstico, y es especialmente útil cuando los valores de Y son muy grandes, este error no posee unidades de medida. (Hanke, 2010)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y - \hat{Y}|}{|Y|} \times 100 \quad (3)$$

Donde:

$Y = \text{Valor real}$

$\hat{Y} = \text{Valor pronosticado}$

$n = \text{número de casos}$

2.8.3. RMSE

La raíz del error cuadrático medio (RMSE, *Root mean squared error*) se utiliza para evaluar pronósticos, este calcula la diferencia al cuadrado del pronóstico y el valor real, este tipo de error sanciona errores grandes, de modo que su magnitud se interpreta con mayor facilidad, posee las mismas unidades que el valor de pronóstico. (Hanke, 2010)

$$RMSE = \sqrt{\frac{\sum_t^n (Y - \hat{Y})^2}{n}} \quad (4)$$

Donde:

$Y = \text{Valor real}$

$\hat{Y} = \text{Valor pronosticado}$

$n = \text{número de casos}$

3. METODOLOGÍA

3.1. Procedimientos

Para realizar esta memoria se proporcionó por el profesor guía el modelo de bloques Marvin, cuyos bloques estaban estandarizados en 30 x 30 x 30 metros, estos bloques se encontraban valorizados por medio de su concentración de mineral y lo que implica en costos removerlo, a partir de esto se calculó por medio de la herramienta *pit optimiser* del *software* Vulcan un *pit* óptimo considerando el precio del mineral, los costos asociados a la operación y los elementos geométricos del *pit*.

Luego se procedió a la asignación de variables que fueron rescatadas de la memoria de (Moreno, 2019) con la finalidad de utilizar sus resultados de los diseños para obtener más precisión en el entrenamiento de la red neuronal, con estas variables ya identificadas se realizó un plan ortogonal en el software IBM SPSS Statistics, el cual asignó casos de muestras para realizar los diseños.

Con las muestras ya obtenidas del plan ortogonal se procedió al diseño operativo de los *pits* de prueba en el *software* Vulcan, los diseños se realizaron en base a un *pit* óptimo con parámetros establecidos de rampas, bermas y bancos. En esa línea se calcularon sus tonelajes, volúmenes, valor económico, finos de cobre y oro, todo esto por medio de cubitaciones de los *pits* obtenidos.

Se construyó una base de datos para 36, 72 y 108 casos, estos provistos en colaboración con Rodrigo Gajardo y Ricardo Moreno, se continuó con el entrenamiento de la red neuronal para los tres modelos, obteniendo sus respectivos errores de predicción y realizando una comparación entre los pronósticos y los casos reales. Finalmente se puso a prueba la red neuronal con mayor calidad de predicción la que se evaluó su desempeño para un gran número de pruebas donde se extrajo el mejor y peor caso, los que se diseñaron nuevamente en el software Vulcan para conocer sus características geométricas y valor económico.

3.2. Recursos utilizados

Esta memoria se llevó a cabo a través *softwares*, estos fueron Maptek Vulcan, cuya finalidad fue el diseño y cálculo de recursos mineros para los casos de prueba, también se utilizó IBM SPSS Statistics *software* en el cual se realizó el plan ortogonal y el entrenamiento de redes neuronales de base radial. También se dispuso de dos bases de datos complementarias de diseño, una proporcionada por Ricardo Moreno, Ingeniero Civil de Minas y Rodrigo Gajardo, estudiante de la misma carrera, esto con la finalidad de poseer más modelos y conseguir un mejor ajuste de la red neuronal.

3.2.1. Maptek Vulcan

Es software que proporciona información espacial 3D avanzada, visualización, modelamiento y análisis en la industria minera. Permite trabajar desde la exploración, pasando por el diseño y la planificación minera, hasta la rehabilitación de la mina. (Maptek, 2020).

En la exploración y evaluación de recursos Vulcan proporciona un ambiente interactivo de visualización y modelado en 3D para crear y validar los modelos de exploración. Gestiona y valida datos de sondajes, geofísicos, litológicos y analíticos. En cuanto al diseño y desarrollo minero las herramientas de diseño de minas de Vulcan permiten considerar la geología de un sitio y diseñar un plan óptimo de la mina que garantice fases rentables de producción. Pronostica el uso de la maquinaria, genera diseños de carretera y analiza escenarios de productividad antes de que comiencen las operaciones. (Maptek, 2020)

Las herramientas de programación de Vulcan cuentan con una interfaz fácil de usar para simplificar el ajuste y configuración de los programas. Las opciones de visualización previa, animación y reportes le permiten presentar planes y justificar sus resultados claramente. (Maptek, 2020)

3.2.2. IBM SPSS Statistics

El software es un sistema global para el análisis de datos. SPSS Statistics puede adquirir datos de casi cualquier tipo de archivo y utilizarlos para generar informes tabulares, gráficos y diagramas de distribuciones y tendencias, estadísticos descriptivos y análisis estadísticos complejos. (Statistics, 2010)

Puede conseguir que el análisis estadístico sea accesible para el principiante y muy práctico para el usuario experto. Las selecciones de menú y los cuadros de diálogo permiten realizar análisis complejos sin necesidad de generar sintaxis de programación. El Editor de datos le ofrece una herramienta simple y eficaz con un diseño del tipo de hoja de cálculo, que le permitirá introducir datos y examinar el archivo de datos de trabajo. (Statistics, 2010)

Este software es de código abierto por lo que se puede utilizar R y Python para mejorar la Sintaxis de SPSS por medio de extensiones especializadas. Existen más de 130 extensiones, además se puede crear la propia y compartirla para crear una solución personalizada. (Statistics, 2010)

4. RESULTADOS Y DISCUSIÓN

4.1. Base de Datos

Para desarrollar esta memoria se utilizó la base de datos *Marvin* cuya característica principal es que se utilizan bloques de 30 x 30 x 30 metros y con un número de bloques de 53.270, dentro de sus variables se encuentra la ubicación indicando la posición en el eje x, y, z, también variables propias de las características del modelo como el volumen, densidad, tonelaje, contenido de cobre y oro, finalmente el valor asociado a cada bloque. Estas variables permiten cargar el modelo de bloques correctamente el *software* Vulcan, una vez definido previamente los límites del modelo se procede a ejecutar la herramienta *pit optimiser* para calcular el *pit* que mejor se ajuste en la relación tonelaje/beneficio, los parámetros para ejecutar esta herramienta se basan principalmente en elementos financieros y de optimización, los que se detallan en la tabla 1.

Tabla 1 Parámetros Pit Optimiser de Vulcan

Precio del cobre	2.8 US\$/lb
Costo de Procesamiento	10 US\$/ton
Costo de Mina	3 US\$/ton
Costo de Venta	0.16 US\$/lb
Recuperación	90%
Ángulo de Talud	45°

El *pit* final calculado por Vulcan se realiza en base al algoritmo de *Lerchs & Grossmann*, el cual considera todos los bloques que deben ser extraídos para maximizar el beneficio económico, y es este *pit* el que se ocupará como base para realizar los diseños operativizados.

Cabe mencionar que la operativización consiste en añadir parámetros de bancos, bermas, rampas, switchback, etc. El modelo entregado en bruto por el *pit optimiser* carece de estos parámetros que son fundamentales en el diseño y puesta en marcha de una mina, esto trae como consecuencia muchas veces aumento de tonelaje y disminución del beneficio de la mina. A continuación, se muestra el diseño del modelo óptimo entregado por el *pit optimiser*:

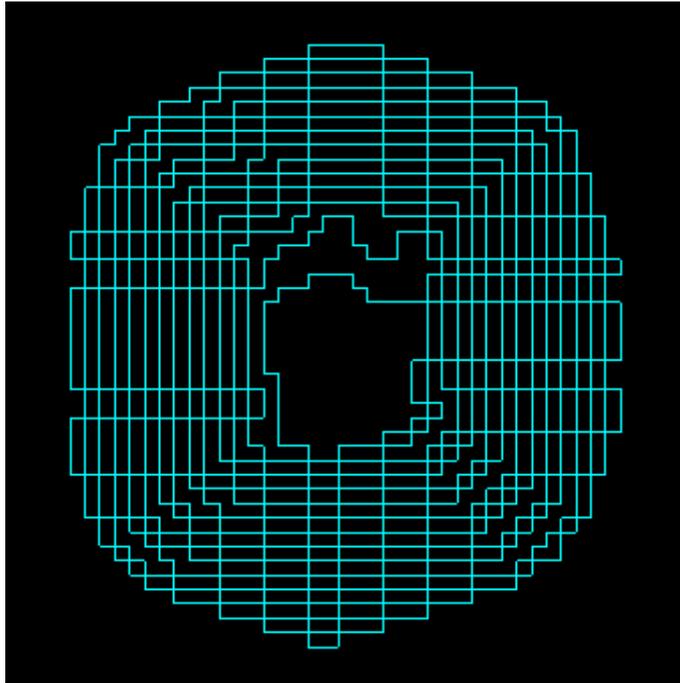


Figura 6 Vista en planta del pit optimo (Fuente: Elaboración Propia)

En la tabla siguiente se detallan los recursos que posee el *pit* óptimo, estos fueron calculados a partir de un cruce con una topografía creada en base a la densidad de los bloques, se consideraron bloques de aire hasta 2.1 g/cm^3 , lo cual indica el límite entre la roca y el aire.

Tabla 2 Recursos pit óptimos (Fuente: Elaboración Propia)

Pit óptimo	
Volumen	238,984,875 m ³
Tonelaje	595,950,662 toneladas
Finos de Cu	1,894,019 toneladas
Finos de Au	180.61 toneladas
Beneficio	1,414,237,835 USD
Cantidad de Bloques	1,540 bloques

4.2. Diseño Ortogonal

Los arreglos ortogonales ofrecen una muestra representativa, considerando todos los parámetros a evaluar, esto balancea y pondera equitativamente cada factor, haciendo que el resultado sea lo más consistente posible. Para efecto de esta memoria se utilizaron parámetros como la presencia o no de *switchback* en un respectivo nivel del *pit*, la posición de inicio de la rampa para cada punto cardinal (norte, oeste, sur, este), además del sentido en el cual ascendería la rampa.

Estos parámetros se escogieron en base a lo realizado por Ricardo Moreno (Moreno, 2019), para efectos de conseguir modelos que tuvieron los mismos factores y así acumular la cantidad necesaria para poder entrenar de manera correcta una red neuronal de base radial.

Se debe considerar que los *switchback* influyen decididamente en el diseño operacional de *pit*, ya que estos cambian el sentido de los caminos en ciento ochenta grados, por lo cual el diseño deja de ser el mismo con la presencia de uno o más, para este trabajo la posibilidad de insertar *switchbacks* estará dado por el avance de cada nivel, esto quiere decir, cada 30 metros y en 12 ocasiones, lo cual por si sola genera miles de posibilidades. Sumado a esto también se considera el inicio de la rampa un factor relevante a considerar y que pudiera afectar los recursos del diseño, como existen múltiples sectores donde pueden iniciar las rapas, para poder cuantificar y tener exactitud a la hora de diseñar se resumieron en 4 áreas dentro del *pit*, estas se definieron según los puntos cardinales, en el cual la rampa puede iniciar en el Norte, Oeste, Sur o Este. Finalmente, cabe mencionar que, para efectos de la realización de los diseños, estos se ejecutaran desde el fondo del *pit* hacia arriba, esto para mantener un orden y concordancia en los niveles del *pit*, para este caso se planteó dos posibilidades, la primera un giro en el inicio de la rampa en sentido horario, y el segundo antihorario, esto es relevante ya que el solo cambio de sentido puede ubicar segmentos de rampa o *switchbacks* en la pared contraria del *pit*. En resumen, se tienen 3 variables de las cuales para los *switchback* se pueden disponer en doce niveles sin importar el nivel anterior, para la posición de inicio cuatro posibilidades y para el sentido otras dos posibles combinaciones, en la tabla siguiente resume las variables que inciden en el diseño de los *pit* operacionales.

Tabla 3 Resumen de los factores que inciden en el diseño ortogonal (Fuente: elaboración propia)

Niveles 1-12	Sin switchback
	Con switchback
Sentido	Horario
	Antihorario
Inicio	Norte
	Oeste
	Sur
	Este

En relación con las variables descritas anteriormente se calculó el número total de posibles casos que pueden estar en el arreglo ortogonal, esto se realizó con la fórmula 5 descrita en el marco teórico.

$$2[\textit{switchback}]^{12[\textit{número de niveles}]} \times 2[\textit{sentido de inicio}] \times 4[\textit{posición de inicio}] \quad (5)$$

La fórmula anterior describe a posibilidad de ocurrencia de los diferentes casos, el cual en primera instancia el número 2 de *switchbacks* representa la opción de que allá o no un cambio de sentido en un respectivo nivel, esto está elevado a 12 que son los niveles que existen en el *pit*, luego estas posibilidades se multiplican por 2 que son las opciones que al inicio la rampa tenga un sentido horario o antihorario y finalmente se vuelve a multiplicar por 4 por la posibilidad de que la rampa inicie en el norte, oeste, sur o este. Realizando este cálculo matemático, se crean 32.768 posibles combinaciones de estas variables.

Luego de definir y calcular las posibles combinaciones, se generó mediante el software IBM SPSS Statistics, el diseño ortogonal con 36 casos. La nomenclatura utilizada para representar las variables se basa principalmente en ceros y unos, con excepción de la variable de inicio de la rampa, ya que esta posee más de dos posibles casos, de esta forma en los distintos niveles, la variable “sin *switchback*” queda identificada con 0 y “con *switchback*” con 1, de la misma manera el sentido de inicio, la variable “horario” queda establecida con 0 y “antihorario” con 1, finalmente la posición de inicio de la rampa queda “norte” con 1, “oeste” con 2, “sur” con 3 y “este” con 4. A continuación, se muestra en la tabla (4) se muestra el diseño arrojado por el software.

Tabla 4 Diseño ortogonal (Fuente: elaboración propia)

Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio
1	0	0	1	1	1	0	1	0	1	1	1	0	1	2
2	0	1	1	1	0	1	1	0	0	1	0	1	0	1
3	1	0	0	1	0	1	1	0	1	0	0	1	0	3
4	0	1	0	0	1	1	0	0	1	0	1	1	1	2
5	0	0	0	1	1	1	0	0	0	1	0	1	1	3
6	1	1	1	0	0	0	0	0	1	1	0	0	0	3
7	1	1	1	1	1	1	0	0	1	0	0	1	1	1
8	0	0	0	0	0	1	0	1	1	1	0	0	1	2
9	1	0	1	0	1	1	0	0	0	1	1	1	1	4
10	0	0	1	1	1	1	1	1	0	0	1	0	0	1
11	1	0	1	0	1	0	0	1	1	0	1	1	0	3
12	1	0	1	1	0	0	0	0	0	0	1	0	0	2
13	0	0	1	0	0	1	1	0	1	0	1	1	0	4
14	1	0	1	1	0	1	0	1	1	1	1	0	1	1
15	1	1	0	0	0	0	1	1	1	0	1	1	1	1
16	0	1	1	0	1	0	1	0	0	0	0	0	1	3
17	1	0	0	0	1	1	1	1	0	0	0	0	0	2
18	1	0	0	0	1	0	1	0	1	1	0	0	1	1
19	1	1	1	0	0	1	0	1	0	0	0	0	1	4
20	0	0	0	0	0	0	0	0	0	0	0	0	0	1
21	1	0	0	1	0	0	1	1	0	1	0	1	1	4
22	0	1	1	0	1	1	1	1	1	1	0	0	0	4
23	0	0	0	1	1	0	0	1	1	0	0	1	0	4
24	1	1	0	0	0	1	1	0	0	1	1	1	0	2
25	0	1	0	1	0	1	0	1	0	0	1	0	1	3
26	1	1	1	1	1	0	0	1	0	1	0	1	0	2
27	1	1	0	1	1	0	1	0	0	0	1	0	1	4
28	0	1	0	0	1	0	0	1	0	1	1	1	0	1
29	1	1	0	1	1	1	1	1	1	1	1	0	0	3
30	0	1	1	1	0	0	1	1	1	0	0	1	1	2
31	0	0	1	0	0	0	1	1	0	1	1	1	1	3
32	0	1	0	1	0	0	0	0	1	1	1	0	0	4
33	0	0	1	0	0	0	0	0	1	1	0	0	0	2
34	1	0	0	1	0	0	1	0	1	1	0	1	1	2
35	0	1	0	0	1	1	0	0	1	1	0	0	1	3
36	1	0	1	0	0	1	0	1	1	0	1	0	0	1

4.3. Diseño de escenarios

En primera instancia, para comenzar a realizar los diseños en el *software* Vulcan, se desarrolló un polígono inicial lo más uniforme posible, logrando que las curvas no fueran tan pronunciadas para así respetar los elementos de seguridad para el tránsito de camiones, también este polígono debía estar lo más apegado al *pit* resultante del *optimiser* para no incluir bloques que tuvieran bajo beneficio económico.

Al empezar a diseñar, hay que escoger una serie de parámetros relacionado con la rampa, bancos y bermas, estos serán los elementos fundamentales en la operatividad del *pit* diseñado. Para la estimación del ancho de rampa se utilizó el camión minero CAT 797F, uno de los camiones con mayor tonelaje en la industria y cuyo ancho es de 9,76 metros, junto a esto, con el estudio de (Ault, 2011) que establece que el ancho mínimo de seguridad en operación es de 3,5 veces el vehículo más grande que transite por el camino, el cual es el camión antes mencionado. Además, para la construcción de los *switchbacks*, se consideró que estos debiesen ser 1,5 veces el ancho de la rampa en un tramo recto, es decir, el ancho mínimo de los *switchbacks* es de 53 metros. La altura del banco se consideró igual que la altura del bloque, para que cada nivel avanzara de acuerdo con los bloques. Con esto los parámetros para la construcción de los caminos quedan de la siguiente manera resumidos en la tabla 5:

Tabla 5 Parámetros de diseño

Ancho de rampa	35 metros
Pendiente	10%
Altura de banco	30 metros
Ancho del switchback	53 metros
Berma	19.8
Ángulo <i>pit</i> global	45°
Ángulo banco-berma	70°

Bajo estas condiciones, se diseñaron los 36 casos indicados por el plan ortogonal, luego de las respectivas triangulaciones y posterior cubicación de los diseños, se procedió a estimación de sus reservas, considerando como elemento de mayor importancia el beneficio de cada diseño, también los finos de cobre, finos de oro, y tonelaje de cada diseño. En la imagen siguiente se ve uno de los diseños triangulados por el software Vulcan:



Figura 7 Vista isométrica del caso número 12 del plan ortogonal (Fuente: Elaboración Propia)

A continuación, en la tabla 6 se muestran los 36 casos diseñados, con sus respectivos valores de tonelaje, beneficio (USD), cantidad de finos de cobre y finos de oro.

Tabla 6 Resultados de 36 diseños realizados (Fuente: elaboración propia)

Caso	Tonelaje	Beneficio (USD)	Finos de Cu (ton)	Finos de Au (ton)
1	766,609,939	1,273,746,897	1,930,746	182.78
2	744,664,778	1,290,614,668	1,918,011	182.34
3	776,313,762	1,267,676,245	1,928,867	183.01
4	777,520,293	1,268,075,359	1,934,772	183.27
5	759,268,302	1,283,304,332	1,931,514	183.27
6	775,483,003	1,267,898,087	1,926,846	182.97
7	750,895,049	1,288,906,056	1,927,775	182.92
8	768,054,162	1,273,862,248	1,932,240	182.93
9	767,330,441	1,273,952,252	1,926,326	182.83
10	727,623,699	1,279,468,562	1,879,499	179.84

11	791,033,208	1,251,026,632	1,924,004	182.52
12	767,516,185	1,272,432,865	1,923,592	182.68
13	769,086,267	1,275,571,059	1,933,617	183.28
14	722,276,096	1,295,101,137	1,896,564	180.44
15	748,101,399	1,287,440,904	1,919,093	182.35
16	760,280,518	1,280,612,641	1,929,014	183.11
17	764,093,252	1,276,178,896	1,925,561	182.74
18	757,740,499	1,280,027,047	1,924,138	182.67
19	768,206,776	1,272,736,788	1,924,962	182.74
20	726,760,839	1,311,167,528	1,928,179	182.95
21	780,743,560	1,258,299,803	1,921,222	182.29
22	767,834,944	1,277,229,957	1,932,734	183.26
23	755,450,101	1,286,882,693	1,930,687	183.07
24	761,222,349	1,281,867,050	1,935,242	183.38
25	751,365,379	1,289,812,173	1,931,350	183.22
26	789,773,368	1,254,726,618	1,925,783	182.90
27	772,190,776	1,269,077,503	1,924,377	182.69
28	737,176,944	1,299,326,336	1,924,489	182.67
29	779,407,781	1,263,439,998	1,926,136	182.87
30	765,860,150	1,277,530,715	1,931,570	183.07
31	743,157,911	1,297,162,968	1,929,702	183.14
32	763,519,159	1,280,061,591	1,930,201	183.10
33	736,698,939	1,302,018,161	1,926,366	182.90
34	768,048,487	1,272,521,459	1,924,857	182.74
35	759,209,928	1,282,113,483	1,930,216	183.16
36	744,307,707	1,295,966,796	1,930,934	183.13

De forma general la cantidad tonelaje obtenido en los 36 diseños fue superior al entregado por el pit optimiser, ya que los diseños se realizaron por fuera del contorno del pit, además al operativizar se incluyen parámetros como bancos y bermas lo que hace ampliar el *pit*, si esto lo sumamos al ancho de la rampa y al número de switchbacks se explica la cantidad de aumento del tonelaje en los diseños. También beneficio fue inferior, por lo que se entiende que los bloques exteriores que se incluyeron al operativizar poseían gran cantidad de estéril en relación con su contenido de cobre y oro lo cual mermaba la ley de cobre y por consecuencia el beneficio total de los diferentes pit. En cuanto a los finos de cobre y oro estos

en todos los casos aumentaron su cantidad, esto se explica, debido a como se mencionaba anteriormente el ampliar el contorno del pit, trajo consigo un pequeño aumento en las concentraciones de finos de los diferentes metales considerando los bloques aledaños.

Al extraer algunos de los casos y hacer un análisis más detallado de estos, se encuentra varios elementos que se pueden destacar, en la siguiente tabla 7 se extraen el 10% de los casos con mayor y menor beneficio.

Tabla 7 Selección de casos con mayor y menor beneficio (Fuente: Elaboración Propia)

Caso	Beneficio	Tonelaje	Finos Au	Finos Cu
26	1,254,726,618	789,773,368	182.90	1,925,783
21	1,258,299,803	780,743,560	182.29	1,921,222
11	1,251,026,632	791,033,208	182.52	1,924,004
20	1,311,167,528	726,760,839	182.95	1,928,179
28	1,299,326,336	737,176,944	182.67	1,924,489
33	1,302,018,161	736,698,939	182.90	1,926,366

La tabla anterior hace una comparación de los casos con mayor y menor beneficio que arrojo el plan ortogonal donde en rojo se encuentran los casos con menor valor económico y en verde con mayor, haciendo un análisis más detallado de sus especificaciones se puede destacar que los que obtuvieron un mejor desempeño responde varios factores. En primer lugar, la cantidad de *switchbacks* influye de manera notoria, ya que el caso 20 no posee ningún *switchback* en su diseño, resultando el que obtuvo el mejor valor económico, por el contrario, el caso 26 posee ocho *switchbacks* en su diseño, lo cual hace extender el contorno del *pit* extrayendo más tonelaje. El segundo punto para evaluar es hacia que dirección el *pit* se extiende, ya que la distribución del mineral no es uniforme y se concentra en ciertos lugares del modelo de bloques, siguiendo esta línea y al comparar los casos 28 y 21 que en la tabla se muestran, se tiene que ambos poseen la misma cantidad de *switchbacks* en su diseño, pero difieren en el sentido e inicio de la rampa lo cual hace que estos tengan resultados visiblemente distintos posicionándose el 28 como uno de los mejores desempeños y el 21 como uno de los peores. En la figura 8 se muestran los 2 *pit* el caso 21 en rojo y el caso 28

en verde, en la cual queda en evidencia hacia donde se amplía cada uno, también se puede inferir que hacia el lado oeste del modelo de bloques concentra mayor cantidad de estéril lo cual influiría en el cálculo del beneficio del pit, por el contrario, en lado noreste posee mayor concentración de mineral en sus bloques.

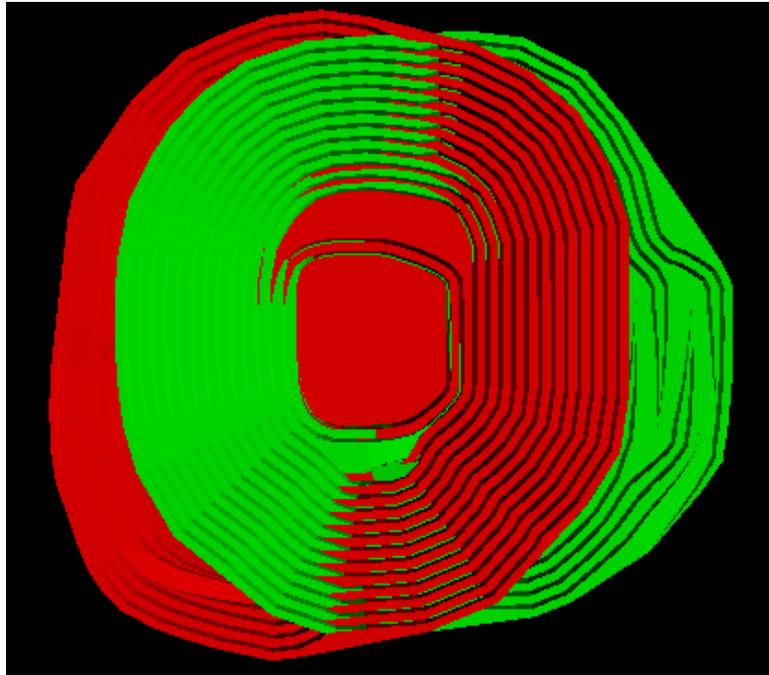


Figura 8 Comparación entre los diseños del pit 21 (rojo) y 28 (verde). Fuente: Elaboración propia

La tercera arista y más importante es la relación tonelaje / beneficio, ya que al comparar los seis casos (los tres peores y tres mejores), se ve como factor clave la gran cantidad de tonelaje que se debe extraer al operativizar los diseños en rojo, esto puede tener su explicación en la cantidad de estéril de los bloques cercanos al límite del *pit*. En la siguiente ilustración se puede ver de manera gráfica esta diferencia, donde por lado en las barras esta el valor económico y por la línea, el tonelaje asociado a cada caso expuesto.

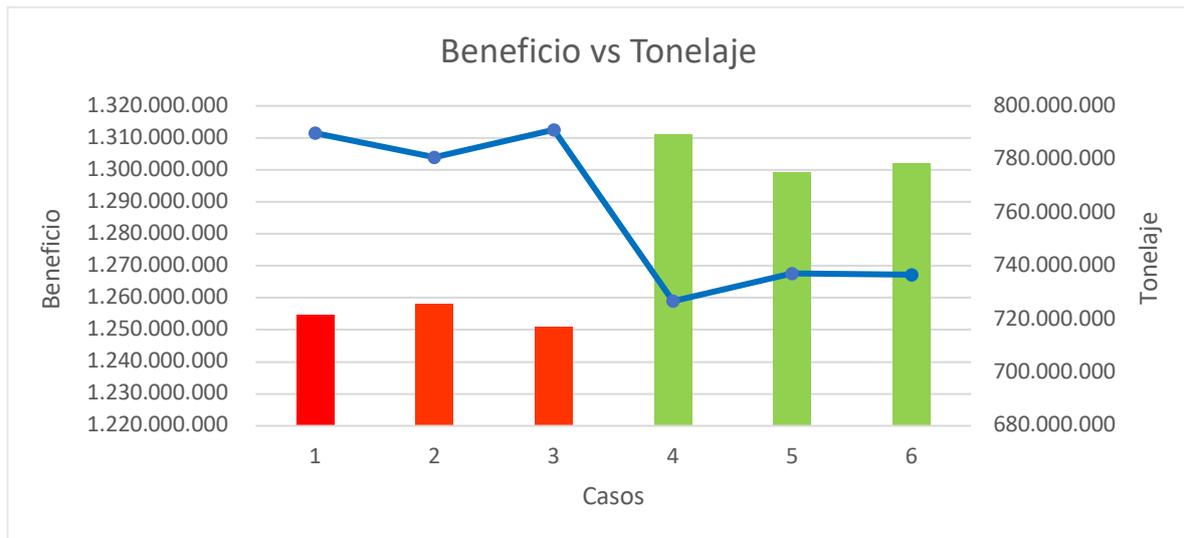


Figura 9 Grafico beneficio vs tonelaje (Fuente: Elaboración Propia)

4.4. Modelo de Red Neuronal de Base Radial

El entrenamiento de la red neuronal de Base Radial (RBF) se realizó en base a los resultados obtenidos de los diseños anteriormente descritos, además se proporcionaron para este estudio, otros 72 resultados de diseños con sus respectivas variables de beneficio, finos de cobre y finos de oro, para ejecutar el entrenamiento de la red RBF, de los 72 diseños suministrados 36 corresponden a (Moreno, 2019) y los 36 restantes fueron en colaboración con un estudiante de la carrera de ingeniería civil de minas de la Universidad de Talca, Rodrigo Gajardo Amaro. Esta cooperación se realizó con el fin de tener una cantidad de modelos adecuados para hacer el entrenamiento, pruebas y reservas de la red neuronal de base radial.

Como se mencionó en el capítulo bibliográfico, las redes de base radial o RBF son un tipo de red neuronal artificial, cuya característica principal es que calcula su salida en función del cálculo de las distancias de un punto denominado centro, está red posee dos fases en su capa oculta una no supervisada y otra supervisada. Es en este marco en que este estudio se desarrolla, ocupando los casos antes descritos se entrenaran 3 redes neuronales para tres, el primero con 36 casos de prueba diseñados en esta memoria. El segundo se entrenará con 72 casos, y finalmente se realizará el mismo procedimiento, pero con la totalidad de los casos que ascienden a 108 posibles situaciones dentro de un *pit*. Cabe mencionar que el

entrenamiento de todos los casos se realizó en el software IBM SPSS Statistics y con la herramienta redes neuronales – función de base radial.

4.4.1. Variables de entrenamiento

Para el entrenamiento de la red neuronal utilizaron 18 variables, 14 de ellas son factores con los cuales la red analiza cómo influyen en las variables dependientes, estos factores son: los niveles numerados del 1 al 12, el inicio de la rampa y el sentido que tiene la rampa en su inicio, estas son las mismas entregadas por el plan ortogonal que en secciones pasadas se describían. Por otro lado, se tienen las variables establecidas como dependientes, estas son las resultantes de los diseños que se generaron, en las que están el beneficio, finos de cobre y finos de oro, además se creó una nueva variable llamada de partición, la cual tiene la misión de hacer un seguimiento a los casos identificándolos como de entrenamiento definida con 1, prueba con 0 y reservados con -1. En la tabla 10 se muestra un resumen con las variables que se utilizaron para este procedimiento.

Tabla 8 Resumen variables afectan el entrenamiento de la red neuronal. (Fuente: elaboración propia)

Factores	Niveles 1 - 12
	Sentido de rampa
	Inicio de rampa
Variables dependientes	Beneficio
	Finos de Cu
	Finos de Au
Variable de partición	Entrenamiento
	Prueba
	Reserva

4.4.2. Entrenamiento 36 Casos

Se ejecutó el entrenamiento de la red neuronal de base radial para los primeros 36 casos entregados por el plan ortogonal, se definió la partición de los casos los cuales se describen en la tabla 8:

Tabla 9 Partición de casos para entrenamiento de red neuronal

	Nº Casos	Porcentaje
Entrenamiento	21	58%
Pruebas	11	31%
Reserva	4	11%

Como se mencionó la revisión bibliográfica, para conocer la evaluación real de red neuronal que se deja una pequeña parte para casos de reserva, los cuales el error de esta muestra ofrece una estimación sincera de la capacidad predictora, ya que estos no se ocupan para crear ni probar el modelo, por lo cual los resultados se basaran en la evaluación del error absoluto porcentual medio (MAPE) que es útil en este caso ya que los valores variable son muy altos, además se evaluara la raíz del error cuadrático medio (RMSE) para los casos reservados del modelo.

La configuración de la red se basó en una función de activación ordinaria, que ocupa una curva de Gauss en la unidad oculta. Además, el número de unidades ocultas se determinó automáticamente, el cual es el que produce menor error en los datos de prueba.

El modelo entrenado arrojó los siguientes resultados los cuales se presentan en la tabla 10.

Tabla 10 Resumen modelo 36 casos. (Fuente: Elaboración Propia)

	MAPE	RMSE
Beneficio	0.88%	15,017,176 USD
Finos Au	0.09%	0.261 ton
Finos Cu	0.15%	3,662 ton

En términos de beneficio, el modelo arrojó un error porcentual bastante bajo, esto se puede explicar ya que los valores de beneficio están distribuidos de forma cercana, por lo tanto, la predicción en base a la distancia de los centros es muy baja, esto hace que la predicción sea bien certera para los casos reservados, en cuanto al error cuadrático medio, este asciende a aproximadamente 15 millones de dólares, lo cual si se compara con los valores de los *pits*, es muy inferior lo que recalca la capacidad predictiva del modelo. De igual forma para los finos de cobre y oro el MAPE es incluso aún menor que el del beneficio, esto hace que el modelo se comporte de muy buena manera para los casos diseñados en esta memoria, ya que el RMSE para el caso de los finos de oro, ni si quiera alcanza una tonelada. En la tabla A del apéndice se muestran los valores predichos para los casos de entrenamiento y prueba además de sus errores asociados estimados por el modelo de red neuronal de base radial. En la figura 10 se muestra un gráfico combinado que resume cada caso reservado de forma individual:

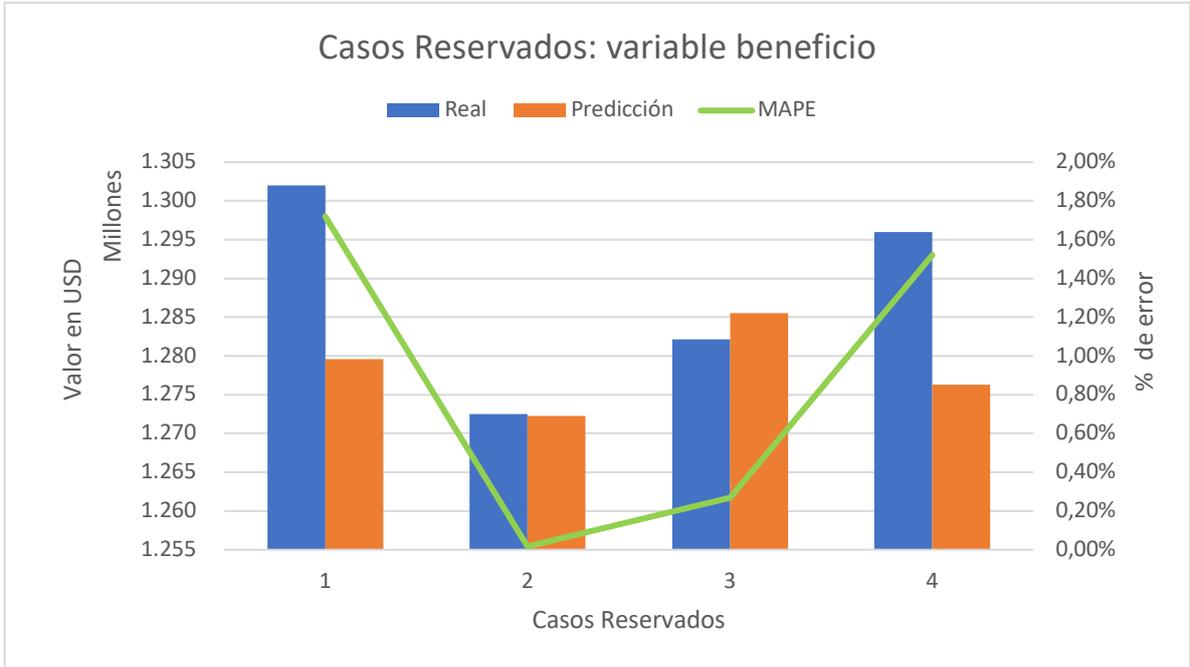


Figura 10 Casos reservados de la variable beneficio, diferencia entre casos reales, predichos y error respectivo (Fuente: elaboración propia)

El gráfico anterior indica los 4 casos reservados, en el cual se muestra en eje Y primario el beneficio en millones, donde las barras en azul muestran el beneficio real obtenido del diseño realizado en el *software* Vulcan y en naranja el valor predicho por la red neuronal, en tanto

el eje Y secundario muestra el error absoluto porcentual medio asociado a cada caso expuesto. De esta forma se puede ver que los valores reales más altos fueron los que tuvieron mayor error de predicción entre 1.5 y 1.7 %, esto responde a que la distancia hacia los centros calculados por la red de base radial en estos casos es mayor, por lo que el modelo tiene a ajustarlos más cercanos a los centros, por el contrario, el caso número 2 obtiene un error ínfimo, lo cual indica que el modelo predijo de manera casi exacta el valor del beneficio real, variando este en solo 216,036 USD. Dentro de los escenarios expuesto el 1, 4 y 2 fueron subestimados, aunque este último muy escasamente, en cambio el escenario 3 fue sobre estimado por el modelo. En cuanto a patrones notorios en los variables independientes o factores no se encontraron diferencias significativas para formular una hipótesis valida en este entrenamiento.

4.4.3. Entrenamiento 72 Casos

El segundo modelo de entrenamiento contempló 72 casos, de los cuales 36 son los diseñados en esta memoria y 36 extras proporcionados por (Moreno, 2019). Para el entrenamiento de la red neuronal se seguirán los mismos lineamientos que para el modelo anterior, solo que este caso la cantidad de caso se reserva será mayor, con lo que la evaluación del modelo será más ajustada. En la tabla 11 se muestra la distribución de partición para el modelo de red neuronal RBF:

Tabla 11 Partición de casos para entrenamiento de red neuronal

	Casos	Porcentaje
Entrenamiento	43	59.7%
Pruebas	22	30.6%
Reserva	7	9.7%

En este modelo se utilizó de igual forma que el anterior la función de activación ordinaria, basada en la campana de Gauss, y las neuronas en la capa oculta fueron calculadas automáticamente. Los resultados entregados para este modelo se muestras en la tabla 11:

Tabla 12 Resumen modelo 72 casos (Fuente: elaboración propia)

	MAPE	RMSE
Beneficio	0.74%	15,433,602 USD
Finos Cu	4.85%	91,598 ton
Finos Au	3.91%	7.05 ton

Para el caso del modelo de 72 casos, este fue aún más certero que el anterior en la predicción de los escenarios, pero no obstante esta diferencia entre los errores de los dos modelos es muy pequeña está es 0.14%, por el contrario tanto los finos de cobre y oro la predicción obtuvo un error significativo, en especial para las toneladas de cobre, donde su RMSE asciende a poco más de 91,500 toneladas de cobre fino, además para el oro este fue de 7 toneladas pero en este caso como se tiene un numero bajo de finos de oro su porcentaje de error es también alto, en la tabla B del apéndice se encuentran todos los resultados de la predicciones realizadas por este modelo. A continuación, se muestra una ilustración que agrupa el error de predicción para los casos de entrenamiento, prueba y reserva de la variable beneficio.

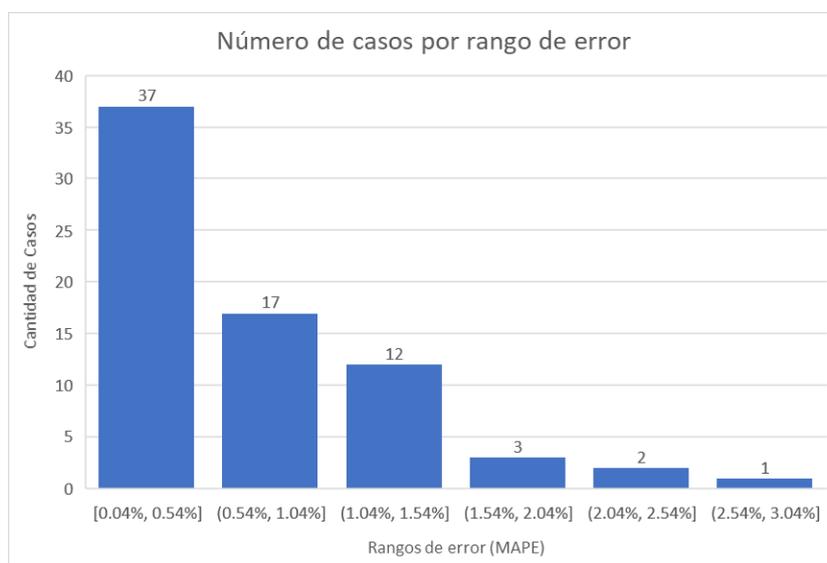


Figura 11 Grafico de barras de la cantidad de casos por respectivo error. (Fuente: elaboración propia)

Los pronósticos hechos por el modelo se evidencian de mejor forma en el gráfico de barras anterior donde solo un 25% de los casos supero el 1% de error absoluto, mientras que el 75% de los casos este error fue menor al 1%, e incluso el 50% de las predicciones fueron menores al 0.5% de MAPE, lo cual demuestra la capacidad predictora de modelo de base radial para 72 casos. En la ilustración 12 se muestran los 7 casos reservados con su error respectivo y la diferencia entre el caso real y el predicho por el modelo.

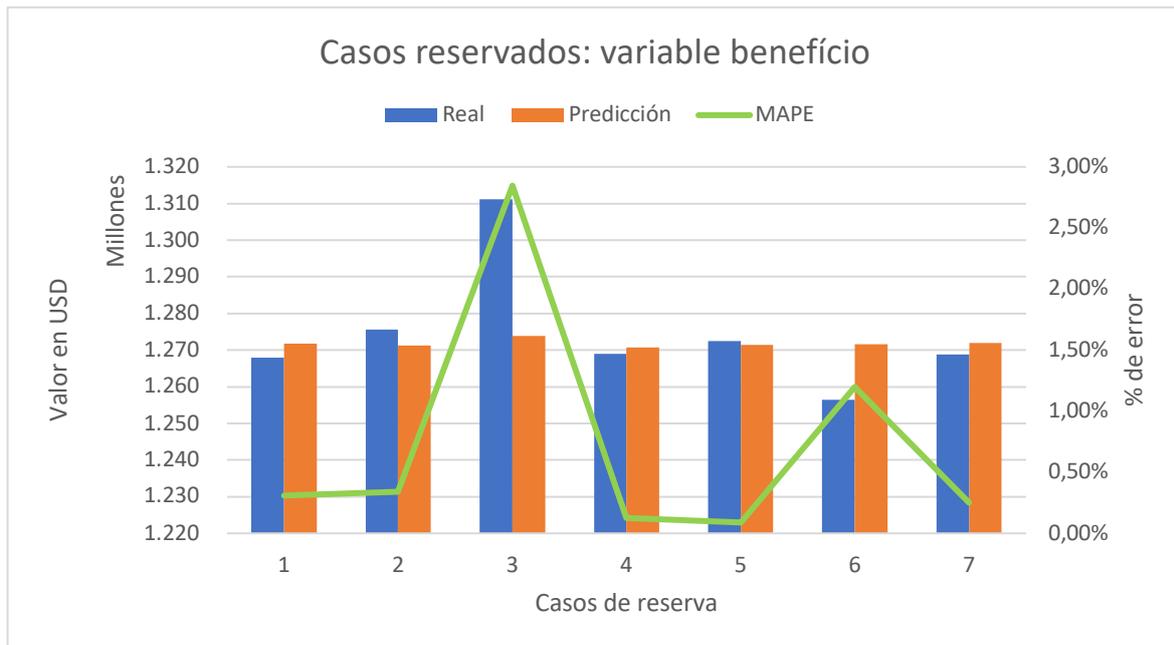


Figura 12 Casos reservados de la variable beneficio, diferencia entre casos reales y predichos, y error respectivo. (Fuente: elaboración propia)

El gráfico anterior muestra en el eje de las ordenadas el valor del beneficio en dólares y en el eje de las abscisas los 7 casos de reserva de la red neuronal, además en el eje secundario se muestra el error MAPE asociado a cada caso. De esta gráfica se puede desprender que los errores asociados responden a la misma lógica del modelo anterior, mientras más al extremo están los datos de su distribución el modelo predictivo los tiene a llevar al centro, un ejemplo es el escenario 3, que es el que posee mayor beneficio de toda la muestra de los casos, esto lo hace un excelente caso para evaluación, ya que es el que está más al extremo de la distribución de muestras; el error asociado a este caso es de 2.85% siendo el más alto encontrado en todos los datos independiente de su condición, lo que nos permite poner un techo del máximo error de la predicción del modelo en este caso. Los demás escenarios

mantienen un error bajo y el caso 6 nuevamente se encuentra un valor sobre 1%, pero en este escenario la estimación es sobreestimada.

4.4.4. Entrenamiento 108 Casos

A los 72 casos anteriores se sumaron 36 nuevos los cuales fueron facilitados en cooperación con Rodrigo Gajardo, con estos 108 casos se realizó el nuevo modelo de predicción de redes neuronales de base radial, siguiendo los mismos estándares de los entrenamientos anteriores, la distribución de los casos de entrenamiento, prueba y reserva se ven en la tabla 12:

Tabla 13 Partición de datos para el entrenamiento de la red neuronal

	Casos	Porcentaje
Entrenamiento	66	61.1%
Pruebas	30	27.8%
Reserva	12	11.1%

Se considero la misma proporción de casos de los modelos anteriores para poder tener una comparación justa de los tres modelos, las unidades de capa oculta para este modelo se asignaron automáticamente, además la función de activación fue exponencial, en la tabla siguiente se muestran los resultados asociados al entrenamiento de los 108 casos.

Tabla 14 Resumen modelo 108 casos. (Fuente: elaboración propia)

	MAPE	RMSE
Beneficio	2.208%	32,596,208 USD
Finos Cu	3.525%	70,661 ton
Finos Au	2.764%	5.39 ton

Los resultados obtenidos indican un error porcentual absoluto de un poco más de 2% para la variable beneficio, mientras que el error cuadrático medio es de aproximadamente 32,5 millones de dólares, si bien es el peor error de los 3 modelos, este no es exageradamente alto. Para las demás variables el error es más bajo que en el modelo anterior bajando en un punto porcentual aproximadamente, donde su RMSE para los finos de cobre es 70 mil toneladas aprox. y solo 5 para el oro. En la tabla C del apéndice se encuentran todos los pronósticos de

realizados por la red neuronal con sus respectivos errores, en la ilustración 12 se muestra un gráfico de dispersión que indican como se vinculan los errores de las 3 variables estudiadas.

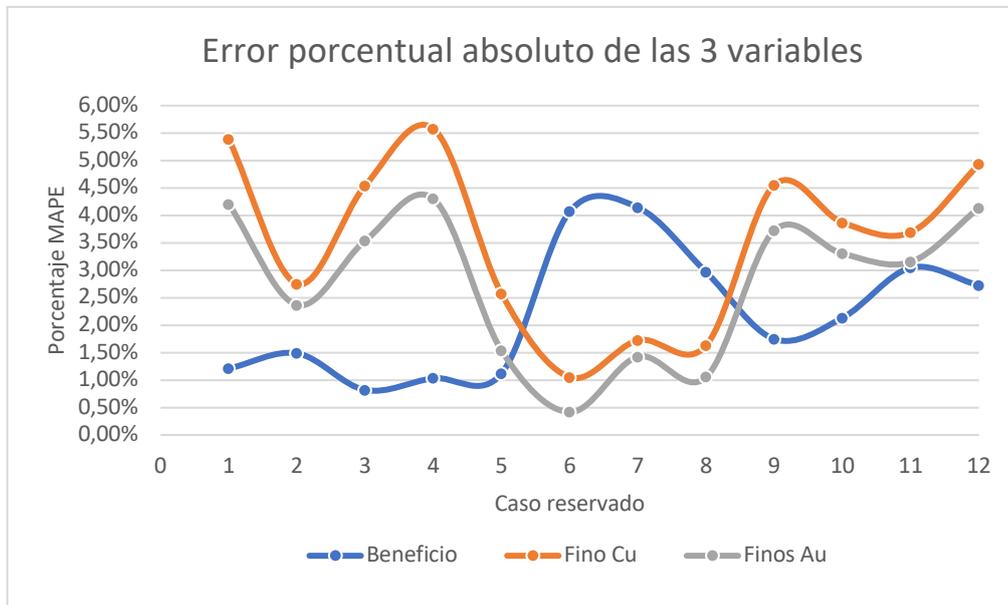


Figura 13 Grafico de dispersión de los errores absolutos para las 3 variables estudiadas. (Fuente: elaboración propia)

En el grafico observan los errores de cada caso de reserva de la red neuronal para las 3 variables estudiadas, en azul la variable beneficio, en naranja los finos de cobre y en gris los finos de oro y que relación tienen estas entre sí. En el eje de las abscisas se encuentran enumerados los 12 casos de reserva y en el eje de las ordenadas se encuentra el porcentaje de error absoluto de cada escenario. Si se mira, se puede obtener que en la mayoría de los casos la predicción hecha para los finos de cobre es la que obtiene el mayor error y tiene una clara relación con los finos de oro, porque se puede deducir que la red neuronal predijo la relación que tiene las variables entre sí, también se observa una relación indirecta entre la cantidad de finos de ambos minerales con la variable beneficio, ya que casi en la totalidad de los casos cuando el MAPE de beneficio es bajo el de los finos es alto y viceversa. Además, en el beneficio, casi el 60% de los datos están bajo la media y existen 2 casos en el cual el error absoluto es superior al 4% el cual afecta directamente el promedio de los casos.

A continuación, se muestra la ilustración 13 la que indica un resumen de los 12 casos reservados para la variable beneficio con su error respectivo y las diferencias entre los valores reales y pronosticados.

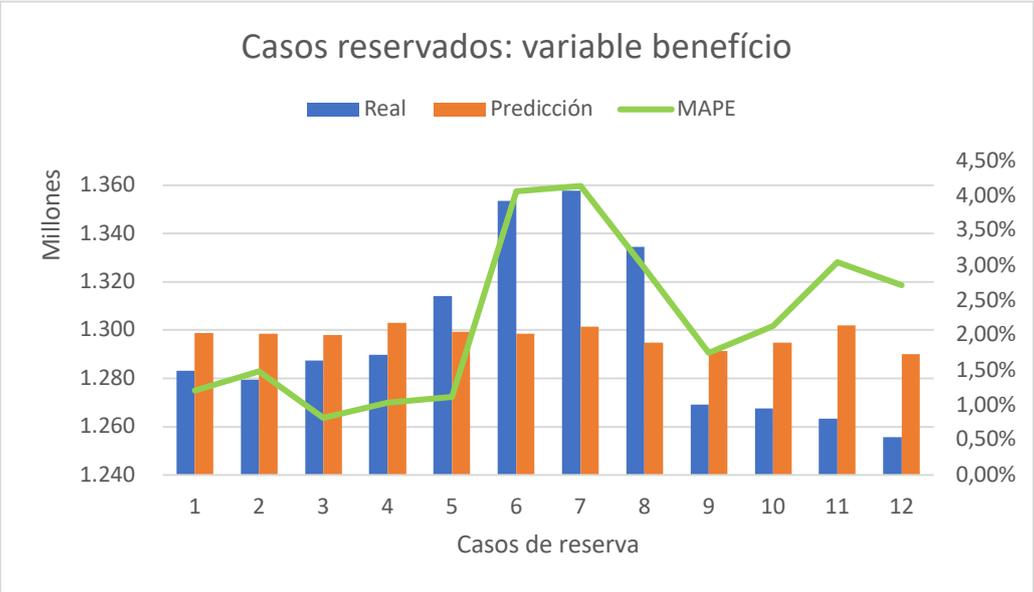


Figura 14 Casos reservados de la variable beneficio, diferencia entre casos reales y predichos, y error respectivo. (Fuente: elaboración propia)

Del gráfico anterior se puede desprender que 8 de los 12 casos fueron sobrestimado y que solo 4 fueron subestimado, también se muestra que los casos 5, 6, 7 y 8 poseen un beneficio real muy superior a los demás casos, estos fueron los últimos agregados al modelo y correspondientes a los proporcionados por Rodrigo Gajardo, en estos se observa un error absoluto muy superior a los demás casos que supera el 3%, la diferencia en cuanto a millones de dólares en su mayoría no supera los 20 millones, un número que si compara con valor económico del *pit*, es muy inferior.

4.5. Modelo de predicción de diseño

La última parte de esta memoria se enfoca en realizar una predicción para cinco mil casos de diseños, buscando en estos el mejor y peor diseño para la mina Marvin. Los cinco mil casos se generaron aleatoriamente entre las 32,768 posibles combinaciones que arrojaba el plan ortogonal, para realizar la predicción del valor económico del *pit* se utilizó la red neuronal de base radial entrenada para 72 casos, la que fue que obtuvo un mejor desempeño de los tres modelos propuestos.

En primera instancia los cinco mil casos fueron obtenidos aleatoriamente a través de Excel, para luego agregar los 72 de entrenamiento a una base de datos que finalmente tuvo 5072 casos, los cinco mil escenarios fueron ingresados al software de entrenamiento como casos reservados en el cual la red neuronal entrenada solo arrojará un resultado para cada configuración de diseño respectiva. Para este modelo de predicción se utilizaron diez neuronas en la capa oculta, para tener una cantidad de centros suficientes para abarcar todos los datos, sin sobre entrenar la red y una función de capa oculta ordinaria en base a curvas de Gauss.

Una vez generada la predicción, los datos se ingresaron nuevamente a Excel para buscar el mejor y peor escenario de diseño para la mina y una vez encontrados diseñarlos en el *software* Vulcan para corroborar la predicción y ver si esta es fidedigna. En las siguientes tablas se muestran la configuración del mejor y peor caso predicho por la red neuronal de base radial, la nomenclatura utilizada es la misma que fue explicada para el plan ortogonal.

Tabla 15 Configuración de diseño para el mejor escenario. (Fuente: elaboración propia).

Mejor caso														
Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio
1136	0	0	1	0	0	1	0	1	0	0	1	0	0	1

Tabla 16 Configuración de diseño para el escenario. (Fuente: elaboración propia).

Peor Caso														
Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio
3753	1	1	0	1	1	0	1	0	1	0	1	0	0	3

En las tablas anteriores se puede apreciar la configuración del diseño para ambos casos, en los que se observan diferencias principalmente en tres aspectos. Lo primero a evaluar es el inicio de la rampa, donde los casos son completamente contrarios, el mejor caso parte por el sur y mejor por el norte, lo cual la red neuronal le da gran importancia a este parámetro, lo segundo es el número de switchback empleados en cada escenario, puesto que para el mejor solo se incluyeron 3 switchback, en cambio para el peor fueron 7, este factor es relevante para el diseño ya que mientras a medida que se agregan *switchbacks* el *pit* tiende a aumentar su contorno, por lo que incrementa su volumen lo cual va en perjuicio del valor económico. Otro elemento que evaluar es hacia donde el *pit* se va ensanchando, esto mezcla por un lado el inicio de la rampa y también la disposición de los *switchbacks* en los diferentes niveles del rajo, es relevante que la red neuronal pueda entender hacia que lado es más conveniente que el *pit* se agrande puesto que dirige la configuración hacia el lado con mayores concentraciones mineral.

Una vez obtenido los escenarios, se procedió a diseñarlos en el *software* Vulcan, esto siguiendo la misma configuración de rampas y parámetros que para los 36 casos diseñados en esta memoria, esto se cubicaron y se obtuvieron los resultados que se muestran en la tabla 17:

Tabla 17 Resumen del modelo de predicción para mejor y peor escenario. (Fuente: elaboración propia).

	Valor Real (USD)	Valor Predicción (USD)	Diferencia (USD)	MAPE
Mejor Caso	1,301,668,640	1,313,864,113	-12,195,473	0.937%
Peor Caso	1,262,513,241	1,257,668,116	4,845,125	0.384%

En el mejor caso el modelo tiene a sobreestimar el valor del *pit* en poco más de 12 millones de dólares, lo cual es una gran cantidad, el error asociado bordea el 1%, por el contrario, en el peor escenario este el modelo lo tiene a subestimar en 4.8 millones de dólares, de todas formas, el modelo permite diferenciar entre los casos que poseen mayor y menor valor económico. Si bien es cierto, es muy complejo encontrar cual es efectivamente el mejor y peor diseño en casi 33 mil posibilidades, el modelo recién presentado puede dar luces de como tendría que ser la configuración para encontrar el mejor y peor escenario. En la tabla D del apéndice se encuentran los 5 mejores y peores escenario escenarios, donde se pueden ver las similitudes que encuentra la red neuronal en ellos, a continuación, se muestran una comparación visual de las triangulaciones de los diseños realizados en el *software* Vulcan:

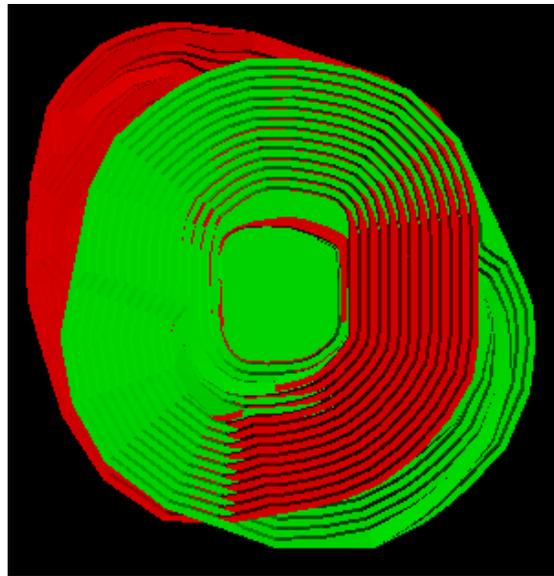


Figura 15 Vista en planta del mejor y peor modelos de Marvin

4.6. Validación de Modelos

Los resultados expuestos en la sección anterior permiten hacer una comparación de los 3 modelos propuestos, la tabla 17 resume el comportamiento de los 3 modelos propuestos.

Tabla 18 Comparación modelos (Fuente: elaboración propia).

	Casos	MAPE	RMSE
Modelo 1	36	0.88%	15,017,176 USD
Modelo 2	72	0.74%	15,433,602 USD
Modelo 3	108	2.208%	32,596,207 USD

La lógica diría que, a mayores casos de entrenamiento de la red neuronal, mayor será la calidad o el acierto de la predicción hecha por ésta, de forma general esto es así, pero hay otros factores que influyen al momento de hacer la predicción como la naturaleza de los datos ingresados y que estos sean realmente concordantes entre ellos. En este caso existen diferencias en la dispersión de los datos para los tres *sets* ingresados, lo que se puede entender en una diferencia en los parámetros de construcción de las rampas o en la elección y cálculo de pit óptimo que se utilizó de base para los cálculos de los diseños en la herramienta *pit optimiser* de Vulcan. En la siguiente ilustración se muestra un gráfico de dispersión de los tres grupos de datos.

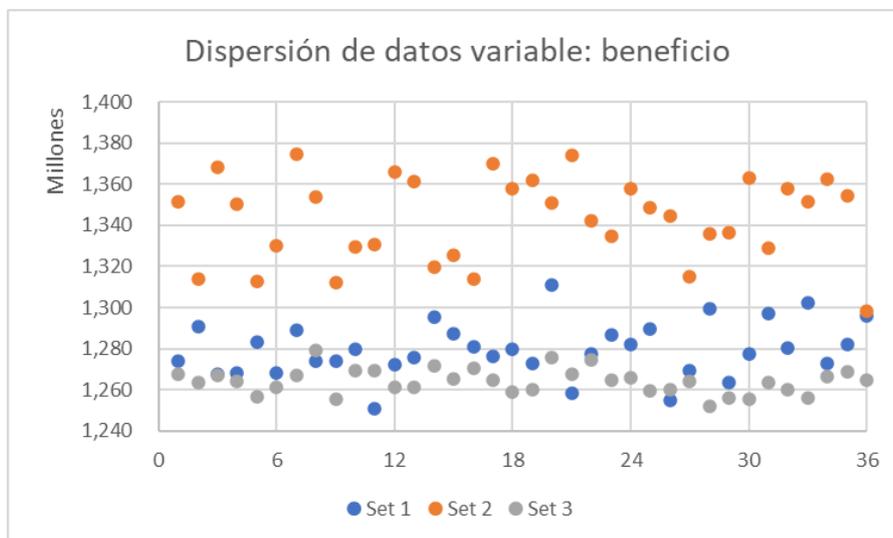


Figura 16 Grafico de dispersión variable beneficio. (Fuente: elaboración propia).

Al analizar el grafico de dispersión que puede notar claramente la diferencia de tendencia que poseen los datos del grupo naranja ya que el peor caso de este grupo se sitúa alrededor de los 1,300 millones a diferencia de los otros sets que su peor valor esta alrededor de 1,250 millones, esto influye claramente en el entrenamiento de la red neuronal ya que aumenta el error y tiene a asimilar de mala forma las variables, esto si bien es cierto se puede minimizar aumentando el número de capas ocultas de la red, ya que permite aumentar el número de centros de los clúster de k-medias, por lo cual los datos tenderán a distribuirse de mejor forma, esto no haría que el error disminuyese considerablemente, ya que la naturaleza de los datos ingresados es en parte discordante. Caso opuesto ocurre con los sets de datos uno y tres que claramente siguen una misma tendencia y se ve reflejado en el error calculado para el modelo de 72 casos, donde se utilizaron estos dos grupos de datos y el error en si disminuyo levemente entre el modelo uno y dos. Una hipótesis que se baraja en la discordancia de los sets de datos es el cálculo del pit optimo el cual sirve de base para el diseño de los demás *pits*, esto ya que cambiar un solo parámetro como el precio del cobre, costos de planta o mina, haría que el precio del beneficio aumente o disminuya considerablemente, además no existía información de los parámetros utilizados para realizar dicho cálculo. Esta diferencia en los grupos de datos se acentúa si se evalúa en los finos de cobre, ya que fue esta variable en los 3 modelos que tuvo mayor error asociado, la figura 17 muestra el grafico de dispersión para la variable finos de cobre.

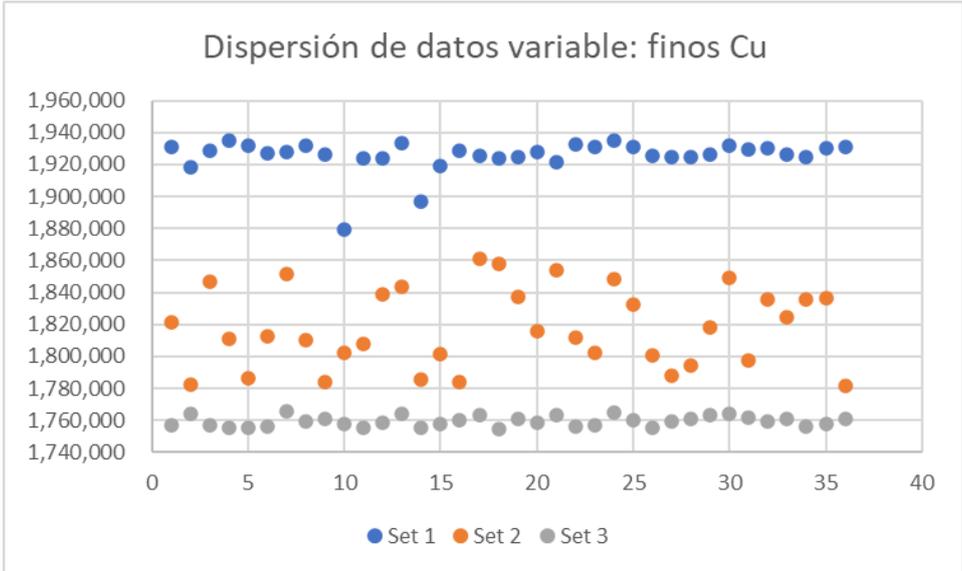


Figura 17 Grafico de dispersión variable finos de Cu. (Fuente: elaboración propia)

Si bien es cierto ningún set de datos se puede catalogar como erróneo o mal calculado, esta distinta concordancia en los datos hace aumentar el error en la predicción de casos de la red neuronal. De todas maneras, el error bordea el 2% lo cual, es un muy buen resultado de predicción, pero se puede perfeccionar aún más si se elimina o disminuye este error sistemático.

4.7. Evaluación método predictivo de mejor y peor caso

En cuanto a la predicción hecha por la red neuronal de base radial, este no acierta del todo, ya que, al comparar los casos predichos como mejores o peores con la base de datos inicial, existían casos que poseían mejor y peor beneficio respectivamente, no obstante los escenarios predichos si estaban dentro de los mejores o peores de la base de datos de 72 casos. De esta forma, el modelo de predicción si entrega parámetros claros de como son los diseños peores y mejores, por ejemplo, el modelo predijo que los peores casos son aquellos que concentran *switchbacks* en los primeros seis niveles, y también los que en general tenían muchos cambios de sentido en la rampa, esto se relaciona con la geometría del rajo, ya que al ensanchar la base del rajo esto genera remoción excesiva de roca. El modelo indica como sus peores escenarios los cuales en su inicio la rampa se ensanche hacia el lado oeste, lo cual queda demostrado en la predicción, a continuación, se muestran los 5 peores escenarios predicho por la red:

Tabla 19 Cinco peores escenarios del modelo predictivo. (Fuente: elaboración propia)

Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio	Beneficio
3753	1	1	0	1	1	1	1	0	1	0	1	0	0	3	1,257,668,116
4821	1	0	1	0	1	1	1	0	1	0	1	1	0	3	1,258,036,141
4837	1	0	1	0	1	1	0	1	1	0	1	1	0	3	1,258,200,777
2721	1	1	0	1	1	1	0	1	1	1	1	0	1	1	1,259,013,962
4239	1	1	0	1	0	1	0	1	1	0	1	0	1	1	1,259,496,940

En la tabla anterior se resaltan los dos criterios mencionados anteriormente, los cuales indican que la presencia o no de *switchback* en los primeros seis niveles si determinan si el pit posee mayor o menor beneficio económico, ya que en todos estos poseen al menos cuatro de seis *switchbacks* posibles. Sumado a esto el inicio y sentido de la rampa para la red neuronal es

fuertemente influyente, debido a que los cinco casos expuestos amplían su primer tramo de rampa hacia el lado oeste, lo cual condice con el modelo de bloques de Marvin en que los bloques con menor ley se ubican hacia ese sector. Considerando la importancia de las variables, a continuación, se muestran la importancia asignada a cada variable en el modelo predictivo de casos.

Tabla 20 Importancia variables independientes. (Fuente: elaboración propia)

Variable	Importancia
Inicio	10.04%
Sentido	9.00%
Nivel 6	8.67%
Nivel 2	8.20%
Nivel 12	7.83%

En la tabla anterior, recalca la importancia que tienen la variable inicio de rampa y sentido de esta, puesto que juntas influyen en casi el 20% de la predicción del beneficio del *pit*, lo cual las hace parámetros relevantes para el diseño, los siguientes son variables de los primeros 6 niveles y como se mencionaba anteriormente influyen en la remoción de roca del rajo, esto por consecuencia puede hacer variar el beneficio. Las demás variables poseen importancia más menos similar que rondan entre el 5,5% y 7,5%, en la tabla E del apéndice se muestra la totalidad de las variables.

4.8. Logros del modelo

El modelo de redes neuronales de base radial predijo de buena manera los casos de reserva de los tres modelos ejecutados, si bien es cierto el porcentaje de error es muy bajo, esto llevado a millones de dólares logra ser un tanto alto para ciertos casos de diseño. Al entrenar los diferentes casos este logra un buen ajuste en escenarios cuyos beneficios son extremos, en donde el modelo logra identificar patrones dentro de las variables las cuales las sabe interpretar como aumento o disminución de valor económico, en casos que están más al centro de la distribución este ajuste es mucho más asertivo teniendo error ínfimos, esto responde a la forma que la red neuronal utiliza para hacer sus predicción ya que como se

mencionó, utiliza clúster para calcular las salidas, lo que hace que valores que se encuentren más céntricos en la distribución, tengan más de un opción de clústeres, lo cual disminuye su error.

En cuanto a la predicción de casos, el modelo no logra del todo dar con los casos mejores o peores, sin embargo, habría que construir los cinco mil escenarios propuestos para corroborar cuales son los mejores o peores, lo cual pierde todo el sentido. Siguiendo en esta línea, muchos son los factores que pueden influir en lograr dar con exactitud el valor de un caso específico, como la base de datos, números de centros asignados, número de casos de entrenamiento, entre otros. De todas formas, la predicción de los casos no supera el 1% de error, lo que hace ser un excelente predictor, sumado a esto el modelo de predicción logra entender cómo funcionan las mejores y peores configuraciones de *pit* para Marvin y cómo se comportan las distintas variables en el cálculo del valor económico final.

5. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

El plan ortogonal desarrollado en la memoria funciono correctamente de acuerdo con los parámetros ingresados, se obtuvo la muestra de modelos de prueba para ejecutar los diseños en el software Vulcan, esto se verifico ya que, había modelos cuyo valor económico era elevado, otros con bajos beneficio por lo que el plan ortogonal logro hacer un barrido de toda la distribución de casos posibles.

En cuanto a los diseños estos se realizaron de acuerdo con los parámetros establecidos inicialmente sin alteraciones y lograron ser una buena cantidad de inicio para la producción del primer modelo, alcanzado una distribución de casos de entrenamiento, prueba y reserva que permitía la ejecución correcta del modelo.

Los tres modelos ejecutados fueron altamente precisos en su predicción lo que, valida la metodología utilizada, si bien es cierto en un principio se pensó que la mejor predicción la tendría el modelo con mayores casos, esto no fue así y responde básicamente a la variabilidad que tenía la base de datos de entrada de la red neuronal, de todas formas, la precisión del pronóstico fue acertada con errores muy bajos. Los demás modelos tuvieron el desempeño esperado y fueron los que lograron acercarse más al valor original de los diseños, lo cual hace que la metodología usada sea perfectamente replicable.

La predicción de casos para los mejores y peores escenarios funciono correctamente, sin embargo, se hace imposible la comprobación de cinco mil casos en este estudio, de todas maneras, esta última prueba resulto muy asertiva ya que pronostico como son los casos extremos, que diseño tienen o cuál es su configuración de acuerdo con los parámetros entregados, siendo de gran utilidad.

Finalmente el modelo se comporta como un pie de inicio en la metodología del diseño de minas a cielo abierto utilizando inteligencia artificial, logrando ser una herramienta muy útil para diseñar minas y comprender sus patrones para un modelo de bloques dado, además es perfectamente perfeccionable al agregar variable que puedan hacer los diseños cada vez más

reales, un ejemplo de esto puede ser restricciones geomecánicas en distintos niveles u operacionales, lo cual haría un poco más complejo el modelo, pero aún más pegado a la realidad. De esta forma estimar el beneficio y patrones en diferentes *pits* sin necesidad de diseñarlos garantiza un ahorro de recursos tremendo para la minería en general.

5.2. Recomendaciones

1. Ajustes y evaluaciones más precisas con el entrenamiento de red neuronal se pueden lograr verificando los datos de entradas y que estos sean congruentes entre sí, para que no ocurran errores sistemáticos arrastrados de procesos anteriores.
2. La construcción de un algoritmo de base radial podría conseguir predicciones más cercanas aún a los casos reales, ya que variar parámetros de la red como el ancho de los centros, pesos sinápticos, etc. Conseguiría tener un seguimiento de las diferentes capas de la red neuronal de base radial y así poder realizar pequeños ajustes.
3. Evaluar el mismo modelo, pero con más casos de prueba sería útil, ya que este debiese tender a mejorar los ajustes, además sería relevante encontrar un número de casos mínimos en el cual la curva de error se estandariza.
4. Complejizar el modelo conseguiría hacerlo más realista y estándar para otros modelos de bloques, incluir una mirada geotécnica, conseguiría hacer el modelo más robusto de lo que es actualmente.

REFERENCIAS

- Ault, W. W. (2011). *Design of Surface Mine Haulage Roads - A Manual*. Pittsburgh, PA: National Institute for Occupational Safety and Health.
- Benítez, R. E. (2014). *Inteligencia artificial avanzada*. Editorial UOC.
- Cortés, M. A. (2009). *Efecto de aplicación de leyes de corte en el cálculo de un programa de producción*. Santiago, Chile .
- Egly Barrero Viciedo, B. F. (2014). Propuesta de procedimiento para configurar una red neuronal artificial de Base Radial con aplicaciones en el diagnóstico de fallos. *Ingeniería Electrónica, Automática y Comunicaciones*, 60-75.
- Fernandez, G. S. (1996). *El método taguchi en diseños experimentales*. Veracruz: Universidad de Veracruz.
- Hanke, J. E. (2010). *Pronósticos en los negocios*. México : Pearson educación.
- IBM Corporation. (2020). *IBM* . Retrieved from https://www.ibm.com/docs/es/spss-statistics/27.0.0?topic=function-partitions-radial-basis#idh_idd_rbf_partitions
- Longoni, M. G. (2010). Modelos de Redes Neuronales Perceptrón Multicapa y de Base Radial para la predicción del rendimiento académico de alumnos universitarios. *XVI Congreso Argentino de Ciencias de la Computación*.
- Lucay, F. A. (2018). Aplicación de Redes Neuronales Artificiales de Base Radial y Geoestadística para la Interpolación/Reconstrucción de Base de Datos de Leyes de Cobre. *Revista de Medio Ambiente y Minería*, 44-58.
- Maptek. (2020). *Maptek*. Retrieved from <https://www.maptek.com/>
- Moreno, R. (2019). *Metodología para diseño de rampas en base a análisis conjunto*. Curicó.

- Nigrin, A. (1993). Neural networks for pattern recognition. In A. Nigrin, *Neural networks for pattern recognition* (p. 11). London: A Bradford Book.
- Pastor, J. B. (1998). *Aplicación de redes neuronales artificiales al tratamiento de datos incompletos*. Barcelona: Departament de Psicobiologia i Metodologia de les Ciències de la Salut.
- Pizarro, C. A. (2017). *Planificación minera a cielo abierto considerando diseño óptimo de rampas*. Santiago, Chile.
- Prieto, J. S. (2019). *Redes neuronales convolucionales y redes neuronales recurrentes en la transcripción automática*. Colombia .
- Reti, A. F. (2015). *Planificación minera a cielo abierto utilizando fundamentos geomecánicos*. Santiago, Chile.
- Russo, C. R. (2016). *Tratamiento masivo de datos utilizando técnicas de Machine Learning*. Entre Ríos, Argentina: XVIII Workshop de Investigadores en Ciencias de la Computación.
- Statistics, I. S. (2010). *Guía breve de IBM SPSS Statistics 19*. EEUU: IBM Company.
- Valencia, W. A. (2011). Indicador de Rentabilidad de Proyectos: el Valor Actual Neto (VAN) o el Valor Económico Agregado (EVA). *Industrial data*, 15-18.

Apéndice A

Estimaciones del modelo 1 (36 casos)

Caso	Beneficio Estimado	Finos Cu Estimados	Finos Au Estimados	MAPE beneficio
1	1,275,978,158	1,927,530	182.86	0.29%
2	1,277,309,594	1,927,828	182.89	0.05%
3	1,274,225,214	1,927,188	182.82	0.75%
4	1,285,553,942	1,929,545	183.06	1.08%
5	1,285,553,979	1,929,545	183.06	0.06%
6	1,275,972,061	1,927,552	182.86	0.73%
7	1,277,309,594	1,927,828	182.89	0.73%
8	1,281,379,642	1,928,675	182.97	1.03%
9	1,276,622,533	1,927,685	182.87	1.02%
10	1,289,832,090	1,888,563	180.19	0.78%
11	1,278,803,562	1,928,139	182.92	1.72%
12	1,274,781,571	1,927,281	182.83	1.16%
13	1,276,622,533	1,927,685	182.87	0.59%
14	1,284,733,608	1,887,502	180.09	0.77%
15	1,273,212,128	1,926,978	182.80	2.43%
16	1,280,472,386	1,928,488	182.95	0.60%
17	1,276,622,533	1,927,685	182.87	0.74%
18	1,273,212,128	1,926,978	182.80	1.84%
19	1,276,622,533	1,927,685	182.87	0.40%
20	1,281,379,182	1,928,677	182.97	1.72%
21	1,272,746,220	1,926,881	182.79	0.09%
22	1,279,615,071	1,928,308	182.93	1.15%
23	1,284,421,869	1,929,309	183.03	0.72%
24	1,274,225,176	1,927,189	182.82	1.84%
25	1,283,356,927	1,929,065	183.01	0.74%
26	1,278,803,102	1,928,141	182.92	2.29%
27	1,273,704,620	1,927,080	182.81	0.94%
28	1,285,553,979	1,929,545	183.06	0.53%
29	1,275,363,269	1,927,402	182.84	0.16%
30	1,277,309,134	1,927,830	182.89	1.33%
31	1,277,309,594	1,927,828	182.89	1.04%
32	1,278,803,102	1,928,141	182.92	0.28%
33	1,279,614,611	1,928,309	182.93	2.92%
34	1,272,305,423	1,926,789	182.78	1.24%
35	1,285,553,942	1,929,545	183.06	1.39%
36	1,276,262,487	1,924,175	182.62	2.68%

Apéndice B

Estimaciones del modelo 2 (72 casos)

Casos	Beneficio estimado	Finos de Cu estimado	Finos de Au estimado	MAPE beneficio
1	1,270,841,112	1,830,083	175.42	0.23%
2	1,287,631,156	1,896,908	180.74	0.23%
3	1,266,014,799	1,827,242	175.15	0.13%
4	1,270,671,246	1,839,461	176.13	0.20%
5	1,271,352,840	1,829,353	175.37	0.93%
6	1,271,826,325	1,833,599	175.69	0.31%
7	1,271,259,883	1,828,665	175.32	1.37%
8	1,274,401,389	1,868,412	178.35	0.04%
9	1,269,826,461	1,847,387	176.73	0.32%
10	1,272,711,909	1,853,410	177.21	0.53%
11	1,255,381,573	1,842,017	176.32	0.35%
12	1,271,116,891	1,828,342	175.30	0.10%
13	1,271,234,717	1,830,182	175.44	0.34%
14	1,272,881,777	1,853,328	177.20	1.72%
15	1,270,058,115	1,812,841	174.10	1.35%
16	1,270,207,049	1,845,624	176.58	0.81%
17	1,274,908,481	1,887,081	179.77	0.10%
18	1,270,581,605	1,855,441	177.32	0.74%
19	1,271,618,250	1,837,872	176.02	0.09%
20	1,273,847,771	1,837,686	176.00	2.85%
21	1,270,645,008	1,827,206	175.21	0.98%
22	1,275,235,225	1,888,982	179.92	0.16%
23	1,279,082,727	1,854,560	177.28	0.61%
24	1,271,094,267	1,825,153	175.05	0.84%
25	1,270,632,406	1,821,960	174.80	1.49%
26	1,271,199,145	1,828,383	175.30	1.31%
27	1,270,663,040	1,830,238	175.43	0.12%
28	1,271,707,992	1,830,098	175.43	2.13%
29	1,273,080,815	1,860,147	177.72	0.76%
30	1,270,938,257	1,823,828	174.95	0.52%
31	1,271,399,914	1,822,941	174.88	1.99%
32	1,279,051,569	1,853,546	177.20	0.08%
33	1,274,801,636	1,843,460	176.44	2.09%
34	1,271,389,242	1,828,672	175.32	0.09%
35	1,271,873,395	1,836,161	175.89	0.80%

36	1,276,287,903	1,900,149	180.77	1.52%
37	1,267,891,367	1,769,179	170.70	0.04%
38	1,270,359,501	1,830,531	175.45	0.54%
39	1,271,049,767	1,836,009	175.87	0.30%
40	1,271,080,746	1,828,395	175.30	0.57%
41	1,271,555,644	1,832,707	175.63	1.20%
42	1,271,022,774	1,828,583	175.32	0.79%
43	1,271,042,359	1,853,636	177.19	0.30%
44	1,273,847,771	1,837,686	176.00	0.41%
45	1,270,233,163	1,838,260	176.04	1.17%
46	1,270,511,711	1,813,118	174.12	0.11%
47	1,272,669,987	1,853,784	177.24	0.27%
48	1,271,726,239	1,838,170	176.05	0.83%
49	1,275,217,359	1,886,871	179.76	1.13%
50	1,275,417,466	1,842,973	176.40	0.31%
51	1,272,700,539	1,835,122	175.83	0.59%
52	1,273,761,563	1,835,806	175.86	0.27%
53	1,270,796,155	1,827,850	175.26	0.49%
54	1,271,199,547	1,829,390	175.38	0.99%
55	1,268,486,247	1,784,654	171.93	0.68%
56	1,270,144,796	1,847,877	176.77	0.46%
57	1,266,038,260	1,829,303	175.31	0.13%
58	1,277,293,371	1,769,854	170.78	0.22%
59	1,270,845,901	1,827,802	175.25	0.49%
60	1,270,909,393	1,828,536	175.31	0.40%
61	1,255,381,573	1,842,017	176.32	0.35%
62	1,273,948,702	1,842,184	176.39	1.09%
63	1,274,807,868	1,850,607	176.99	0.83%
64	1,272,018,209	1,856,300	177.41	1.60%
65	1,271,654,643	1,836,526	175.92	1.26%
66	1,270,911,011	1,828,209	175.29	1.25%
67	1,269,174,793	1,830,540	175.44	0.46%
68	1,273,194,412	1,833,967	175.72	1.03%
69	1,270,705,118	1,842,223	176.33	1.19%
70	1,272,697,279	1,849,503	176.91	0.49%
71	1,272,032,161	1,841,676	176.31	0.25%
72	1,271,620,976	1,831,809	175.56	0.56%

Apéndice C

Estimaciones modelo 3 (108 casos)

Caso	Beneficio estimado	Finos de Cu estimado	Finos de Au estimado	MAPE beneficio
1	1,294,739,568	1,833,243	175.95	1.65%
2	1,291,919,852	1,834,304	175.98	0.10%
3	1,292,974,916	1,833,450	175.93	2.00%
4	1,297,009,449	1,828,930	175.64	2.28%
5	1,298,829,890	1,827,403	175.56	1.21%
6	1,293,575,062	1,833,336	175.93	2.03%
7	1,296,041,234	1,830,111	175.72	0.55%
8	1,289,733,267	1,836,715	176.13	1.25%
9	1,300,207,339	1,826,775	175.53	2.06%
10	1,298,501,089	1,827,761	175.58	1.49%
11	1,298,497,273	1,830,845	175.83	3.79%
12	1,297,959,218	1,832,824	175.98	2.01%
13	1,288,774,865	1,837,625	176.18	1.04%
14	1,300,518,618	1,826,219	175.50	0.42%
15	1,297,988,349	1,831,909	175.90	0.82%
16	1,293,341,149	1,833,753	175.96	0.99%
17	1,292,876,727	1,833,952	175.97	1.31%
18	1,291,407,994	1,836,245	176.12	0.89%
19	1,297,622,466	1,828,854	175.65	1.96%
20	1,296,638,631	1,829,855	175.71	1.11%
21	1,291,729,813	1,843,377	176.70	2.66%
22	1,277,418,773	1,849,908	176.94	0.01%
23	1,297,036,312	1,830,602	175.78	0.79%
24	1,298,612,679	1,828,013	175.60	1.31%
25	1,303,139,193	1,823,582	175.34	1.03%
26	1,295,741,975	1,835,917	176.18	3.27%
27	1,294,369,502	1,839,490	176.44	1.99%
28	1,300,617,300	1,828,082	175.65	0.10%
29	1,298,521,159	1,828,395	175.63	2.78%
30	1,294,363,056	1,833,381	175.95	1.32%
31	1,297,763,714	1,832,154	175.92	0.05%
32	1,299,222,368	1,827,965	175.61	1.50%
33	1,296,622,079	1,831,342	175.83	4.07%
34	1,299,287,685	1,828,596	175.66	1.12%
35	1,290,223,093	1,837,331	176.19	5.71%

36	1,293,464,796	1,842,622	176.68	4.22%
37	1,293,900,653	1,836,638	176.20	1.43%
38	1,297,401,546	1,829,248	175.68	2.44%
39	1,297,405,805	1,829,943	175.73	5.59%
40	1,298,524,346	1,829,593	175.73	4.07%
41	1,296,175,512	1,835,445	176.15	1.21%
42	1,298,846,592	1,827,596	175.57	2.29%
43	1,298,421,886	1,831,437	175.87	2.43%
44	1,295,130,791	1,832,545	175.90	5.18%
45	1,293,516,463	1,833,745	175.96	4.96%
46	1,287,281,737	1,839,449	176.30	2.44%
47	1,299,364,593	1,829,901	175.77	1.98%
48	1,294,914,148	1,831,251	175.79	1.46%
49	1,299,106,840	1,827,973	175.61	5.18%
50	1,301,549,163	1,825,556	175.46	4.14%
51	1,294,789,397	1,831,474	175.80	4.94%
52	1,287,567,907	1,838,939	176.26	4.67%
53	1,297,098,398	1,831,146	175.82	5.58%
54	1,292,917,468	1,833,218	175.91	3.67%
55	1,294,857,065	1,831,940	175.84	2.97%
56	1,293,993,682	1,839,899	176.47	4.70%
57	1,294,903,164	1,832,141	175.86	3.97%
58	1,290,830,573	1,835,520	176.05	4.01%
59	1,291,085,835	1,835,064	176.02	1.81%
60	1,298,056,455	1,829,006	175.67	2.81%
61	1,302,731,023	1,823,292	175.30	2.51%
62	1,289,588,475	1,836,973	176.14	5.40%
63	1,299,232,323	1,827,339	175.56	2.21%
64	1,301,157,939	1,826,254	175.51	4.16%
65	1,291,548,357	1,836,321	176.13	1.91%
66	1,294,550,806	1,839,292	176.43	2.46%
67	1,295,264,449	1,831,497	175.82	2.21%
68	1,286,334,396	1,840,259	176.34	1.78%
69	1,299,055,240	1,827,224	175.55	3.39%
70	1,298,685,965	1,830,185	175.78	2.98%
71	1,286,104,261	1,841,550	176.44	1.49%
72	1,296,638,631	1,829,855	175.71	1.38%
73	1,296,445,446	1,829,936	175.71	3.26%
74	1,298,291,947	1,827,660	175.57	2.30%
75	1,291,428,097	1,835,181	176.04	1.75%
76	1,295,000,638	1,831,394	175.80	2.67%

77	1,293,376,934	1,833,059	175.90	2.57%
78	1,294,903,164	1,832,141	175.86	1.84%
79	1,298,152,091	1,827,909	175.58	2.60%
80	1,300,427,597	1,826,910	175.55	2.37%
81	1,290,922,642	1,846,009	176.90	2.08%
82	1,297,540,160	1,833,959	176.06	3.09%
83	1,297,090,920	1,834,099	176.06	2.95%
84	1,300,736,851	1,825,263	175.42	1.94%
85	1,294,744,228	1,831,851	175.83	2.13%
86	1,297,543,284	1,831,884	175.89	1.80%
87	1,296,943,144	1,830,992	175.81	2.55%
88	1,294,920,003	1,831,538	175.81	2.30%
89	1,298,497,273	1,830,845	175.83	3.08%
90	1,297,509,210	1,828,559	175.62	2.96%
91	1,285,790,799	1,840,773	176.37	1.70%
92	1,298,975,029	1,828,005	175.61	3.76%
93	1,294,407,373	1,832,155	175.85	3.07%
94	1,296,792,265	1,831,479	175.85	3.31%
95	1,301,857,970	1,826,731	175.56	3.05%
96	1,297,148,296	1,831,859	175.88	2.94%
97	1,287,058,819	1,839,847	176.32	1.15%
98	1,294,043,046	1,835,240	176.09	1.69%
99	1,288,241,407	1,838,162	176.21	0.48%
100	1,297,870,868	1,828,166	175.60	0.15%
101	1,297,337,226	1,830,720	175.79	4.01%
102	1,293,778,008	1,841,146	176.57	5.05%
103	1,298,496,930	1,827,534	175.56	4.14%
104	1,299,606,667	1,829,885	175.77	0.11%
105	1,289,981,311	1,847,688	177.02	2.72%
106	1,286,072,637	1,841,172	176.41	1.55%
107	1,286,231,635	1,840,443	176.36	1.37%
108	1,300,736,851	1,825,263	175.42	2.86%

Apéndice D

Peores casos de 5000 posibles

Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio	Beneficio estimado	Finos de Cu estimado	Finos de Au estimado
3753	1	1	0	1	1	0	1	0	1	0	1	0	0	3	1,257,668,116	1,752,522	169.58
4821	1	0	0	0	1	0	0	1	1	0	1	1	0	3	1,258,036,141	1,845,289	176.56
4837	1	0	1	0	1	0	0	1	1	0	1	1	0	3	1,258,200,777	1,846,427	176.65
1012	1	0	1	0	1	0	0	1	1	0	0	1	0	4	1,258,375,007	1,845,711	176.59
1307	0	0	1	0	1	0	0	1	1	0	0	1	0	4	1,259,000,993	1,845,931	176.61
2721	1	1	0	1	1	0	1	1	1	1	1	0	1	1	1,259,013,962	1,755,450	169.66

Mejores casos de 5000 posibles

Caso	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	Nivel 8	Nivel 9	Nivel 10	Nivel 11	Nivel 12	Sentido	Inicio	Beneficio estimado	Finos de Cu estimado	Finos de Au estimado
1136	0	0	1	0	0	0	0	1	0	0	1	0	0	1	1,313,864,113	1,860,320	177.89
1776	0	0	0	0	0	1	0	1	0	0	0	0	0	1	1,313,713,941	1,858,612	177.76
1050	0	0	0	0	0	1	1	0	0	0	0	0	0	2	1,297,997,249	1,745,521	169.04
4406	0	0	1	0	0	1	1	0	0	0	0	0	0	3	1,297,860,605	1,745,052	169.00
2538	0	0	1	0	0	0	1	0	0	0	0	0	0	1	1,297,164,568	1,865,279	178.22

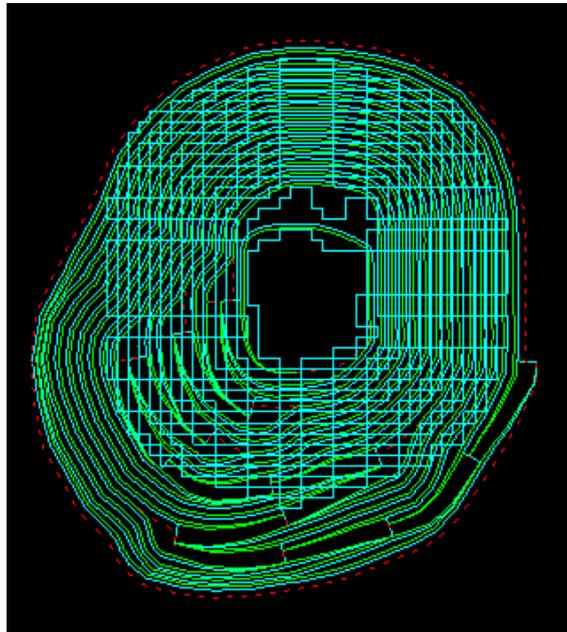
Apéndice E

Importancia de las variables independientes modelo 5000 casos

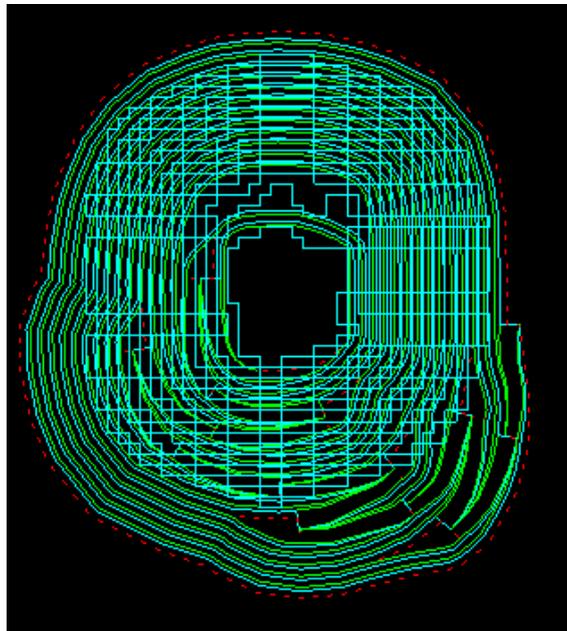
	Importancia
Inicio	10.04%
Sentido	9.00%
Nivel 12	8.67%
Nivel 2	8.20%
Nivel 6	7.83%
Nivel 9	7.52%
Nivel 10	7.25%
Nivel 5	6.93%
Nivel 4	6.89%
Nivel 1	6.82%
Nivel 7	5.88%
Nivel 8	5.77%
Nivel 11	5.54%
Nivel 3	3.66%

Apéndice F

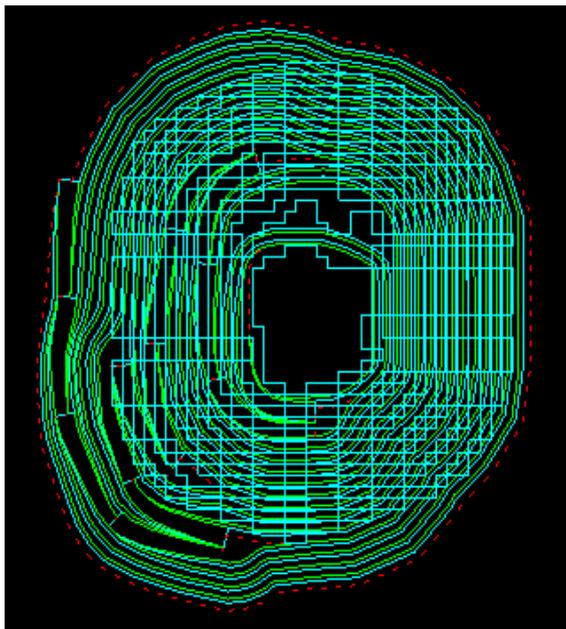
Peores diseños en término de su beneficio



Vista en planta caso 26



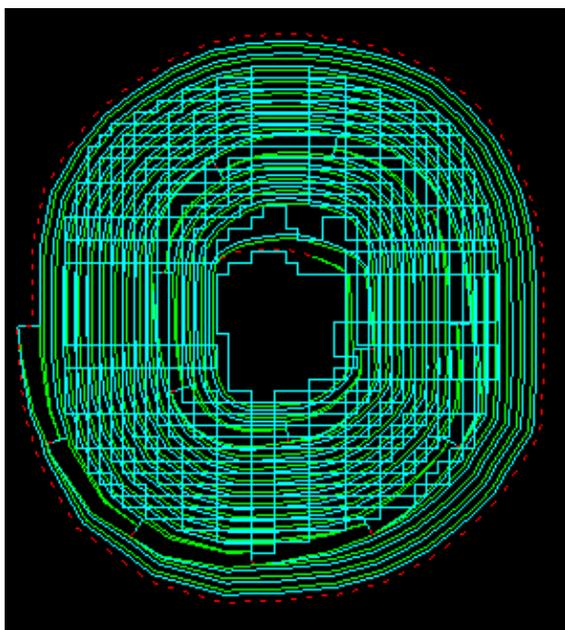
Vista en planta caso 11



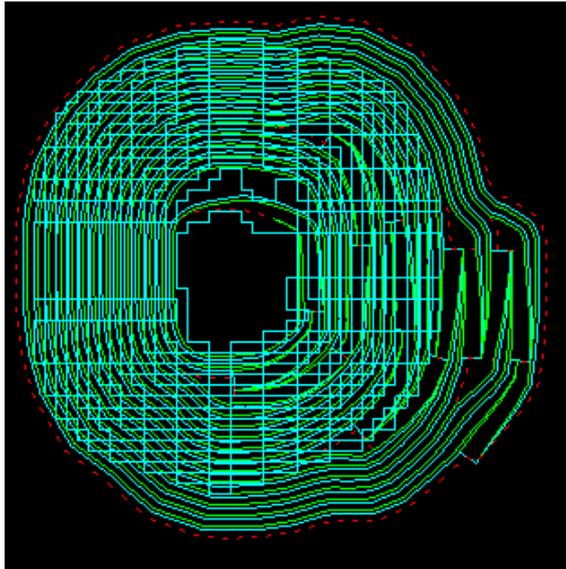
Vista en planta caso 21

Apéndice G

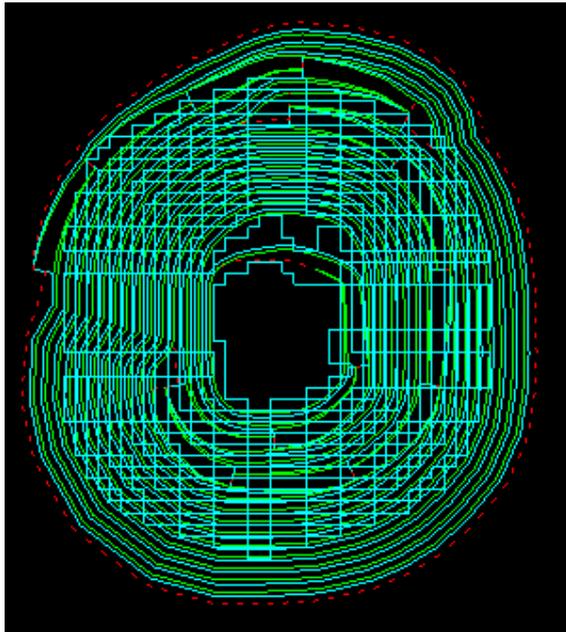
Mejores diseños en término de su beneficio



Vista en planta caso 20



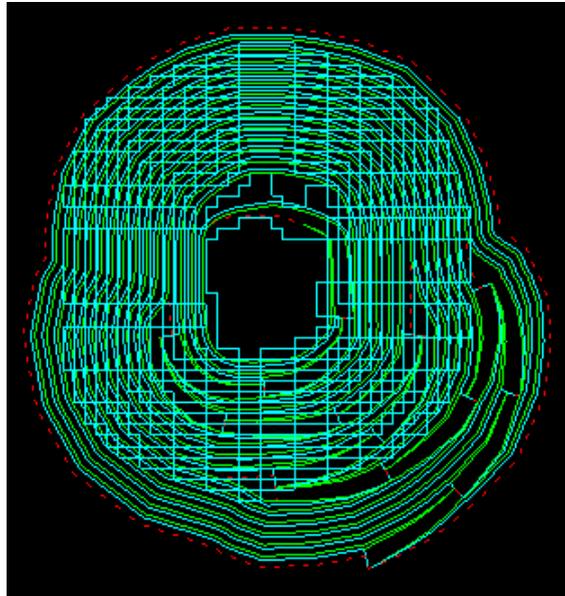
Vista en planta caso 28



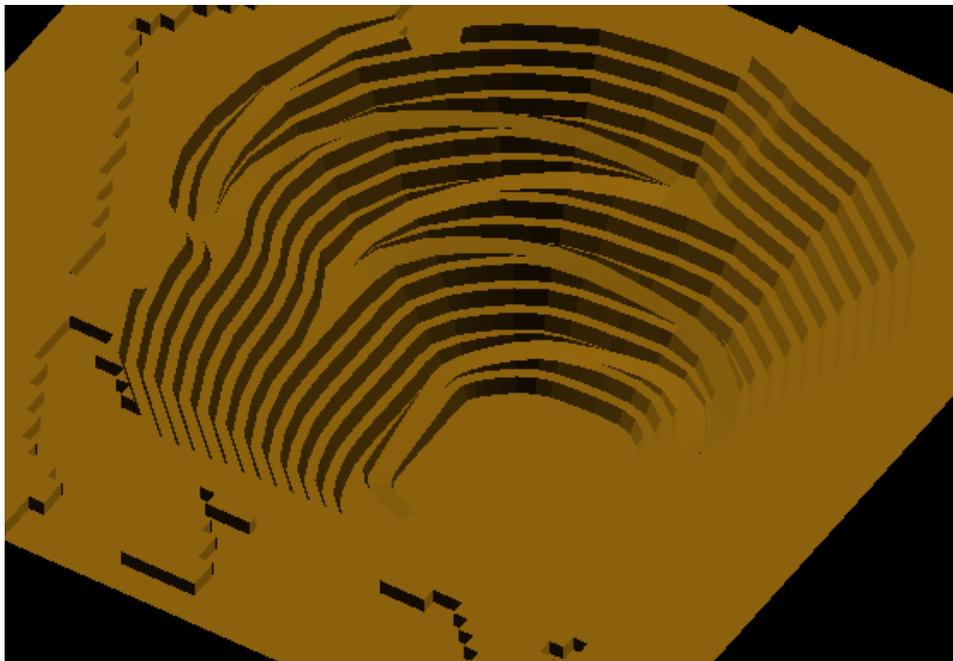
Vista en planta caso 33

Apéndice H

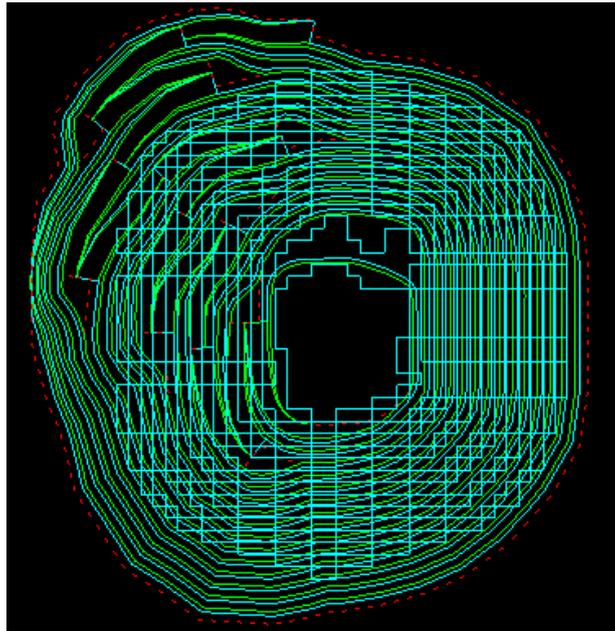
Diseños realizados de la predicción de la red neuronal de base radial



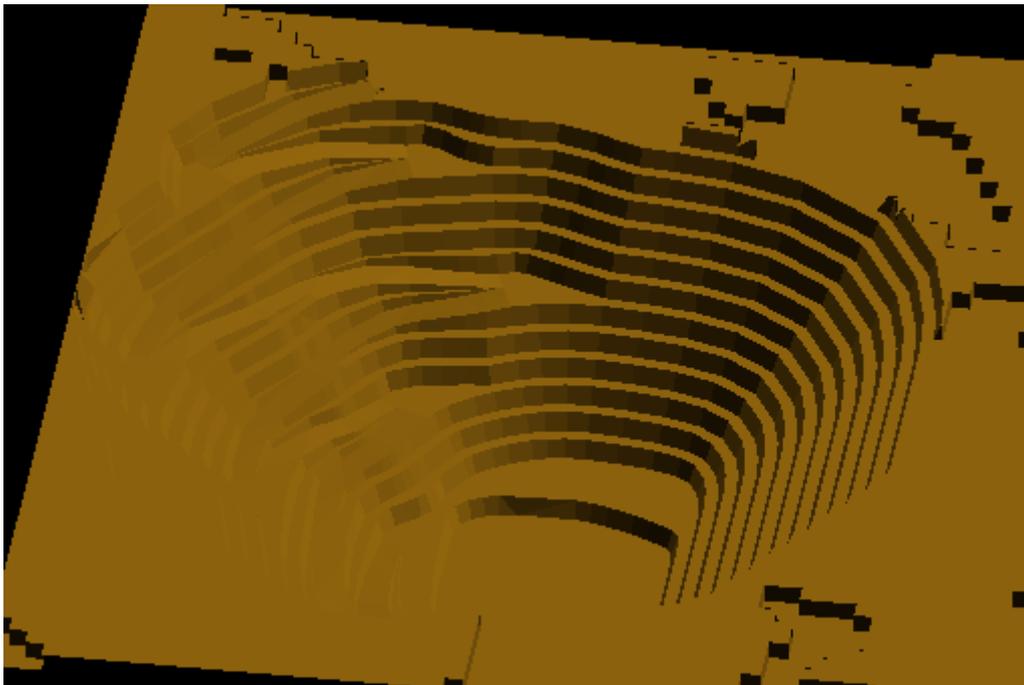
Vista en plata mejor caso predicho



Vista isométrica de la triangulación del mejor caso



Vista en planta peor caso predicho



Vista en isométrica del peor caso predicho

