

Universidad Católica de Santa María

Facultad de Ciencias e Ingenierías Físicas y Formales

Escuela Profesional de Ingeniería de Minas



ELABORACIÓN DE UN MODELO DE REDES NEURONALES RECURRENTE PARA LA PREDICCIÓN DE LA ALIMENTACIÓN A UNA CHANCADORA PRIMARIA

Tesis presentada por el bachiller:

Gallegos Cornejo, Yanirasut del Carmen

Para optar el Título Profesional de:

Ingeniero de Minas

Asesor:

Mg. Esquicha Tejada, José David

Arequipa – Perú

2022

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE MINAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 20 de Junio del 2022

Dictamen: 004077-C-EPIM-2022

Visto el borrador del expediente 004077, presentado por:

2014800912 - GALLEGOS CORNEJO YANIRASUT DEL CARMEN

Titulado:

**ELABORACIÓN DE UN MODELO DE REDES NEURONALES RECURRENTE PARA LA PREDICCIÓN
DE LA ALIMENTACIÓN A UNA CHANCADORA PRIMARIA**

Nuestro dictamen es:

APROBADO

**1635 - SULLA TORRES JOSE ALFREDO
DICTAMINADOR**



**1748 - CALDERON RUIZ GUILLERMO ENRIQUE
DICTAMINADOR**



**2872 - LOPEZ CASAPERALTA PATRICIA YANETH
DICTAMINADOR**



Presentación

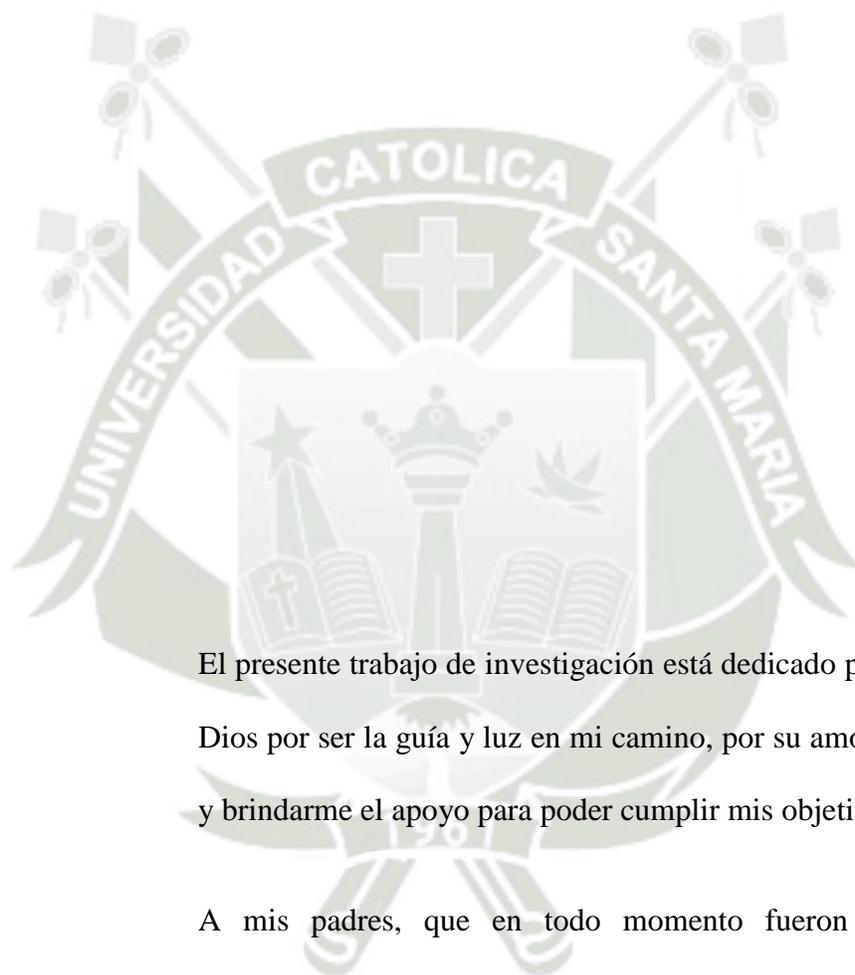
Señor Decano de la Facultad de Ciencias e Ingenierías Físicas y Formales.

Señora Directora de la Escuela Profesional de Ingeniería de Minas.

Señores Miembros del Jurado Dictaminador de la Tesis.

De conformidad con las disposiciones del Reglamento de Grados y Títulos de la Escuela Profesional de Ingeniería de Minas, me complace presentar el trabajo de investigación titulado: **“ELABORACIÓN DE UN MODELO DE REDES NEURONALES RECURRENTE PARA LA PREDICCIÓN DE LA ALIMENTACIÓN A UNA CHANCADORA PRIMARIA”**, con el propósito de optar el título profesional de Ingeniera de Minas.

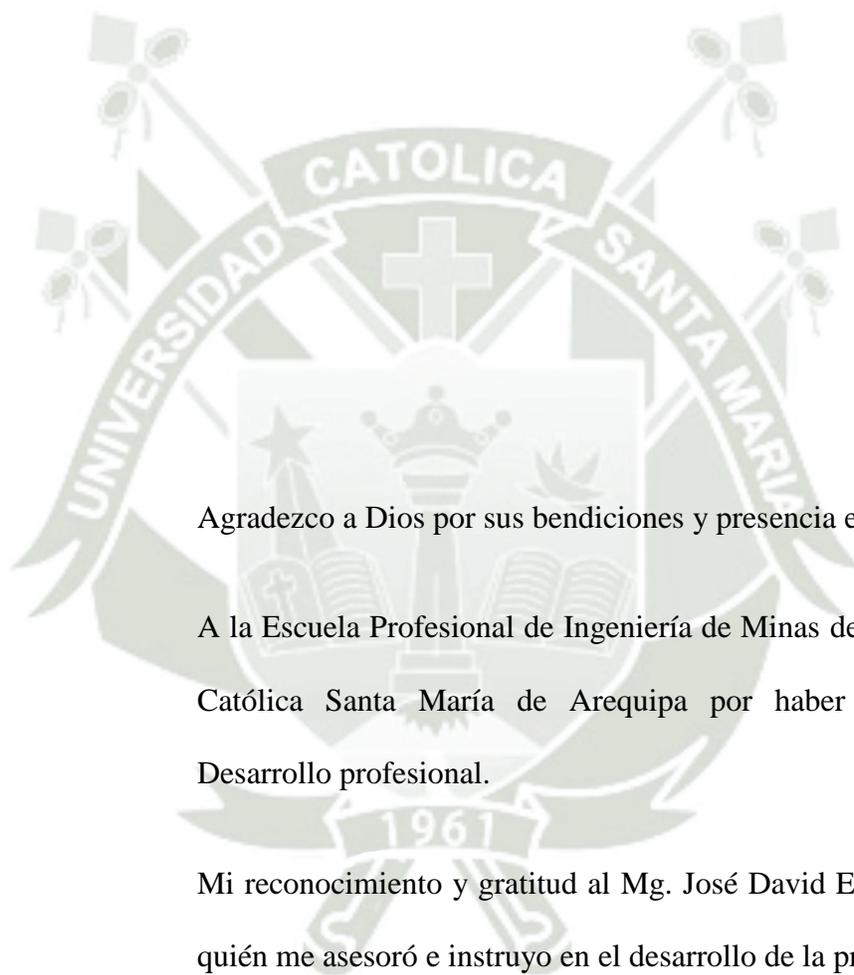
Dedicatoria



El presente trabajo de investigación está dedicado principalmente a Dios por ser la guía y luz en mi camino, por su amor incondicional y brindarme el apoyo para poder cumplir mis objetivos.

A mis padres, que en todo momento fueron mi soporte y motivación.

Agradecimientos

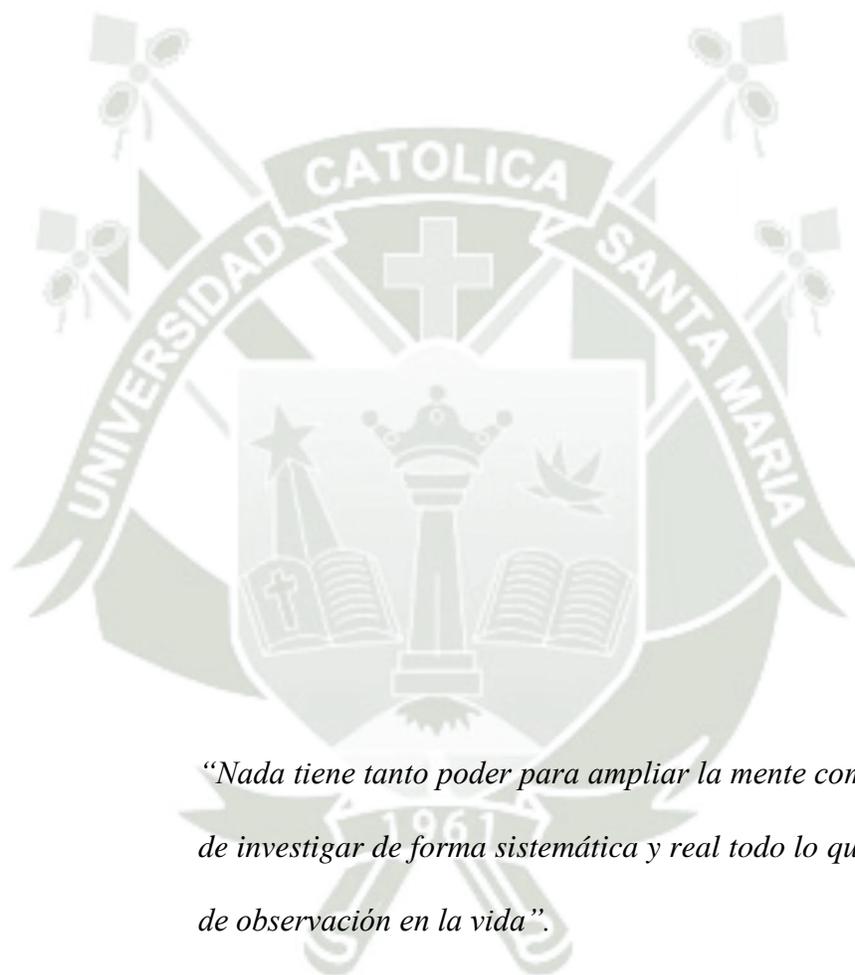


Agradezco a Dios por sus bendiciones y presencia en mi vida.

A la Escuela Profesional de Ingeniería de Minas de la Universidad Católica Santa María de Arequipa por haber impulsado mi Desarrollo profesional.

Mi reconocimiento y gratitud al Mg. José David Esquicha Tejada, quién me asesoró e instruyó en el desarrollo de la presente tesis.

Epígrafe



“Nada tiene tanto poder para ampliar la mente como la capacidad de investigar de forma sistemática y real todo lo que es susceptible de observación en la vida”.

Marco Aurelio

RESUMEN

La presente tesis tiene como objetivo obtener un modelo de redes neuronales recurrentes para la predicción de la alimentación de una chancadora primaria, utilizando redes del tipo LSTM desarrolladas con Tensorflow.

Para esto se utilizaron datos históricos recolectados sobre la alimentación de una chancadora primaria durante el 2018 a finales del 2019, en dicha base de datos también se encuentran otras variables tales como: Leyes de cabeza de mineral, tipo de mineral, disponibilidad y utilización de la chancadora, de las palas y camiones, entre otras más.

Los datos históricos fueron evaluados y analizados, para posteriormente con estos datos entrenar diferentes modelos para obtener un modelo más eficiente. Dentro de todos los modelos se utilizaron como métrica el Error cuadrático medio (RMSE), ya que, con esta métrica se conserva la naturaleza de la variable (toneladas). Como resultado se obtuvo un modelo que tuvo como RMSE 26844.85 TN, dicho modelo consta de una arquitectura de una capa densa de entrada de 32 neuronas, una capa de filtro Dropout del 25%, una capa LSTM de 64 neuronas, obteniéndose una mejora del 13% en comparación del modelo preliminar.

Este modelo fue entrenado correctamente mediante la separación de datos de entrenamiento y validación, 80 y 20% respectivamente, esta separación permitió poder hacer la comparación de los datos predichos con datos reales, demostrándose que la aplicación de estas nuevas tecnologías tiene un potencial uso dentro del campo de la minería, ya que se pudo llegar a reducir el error de predicción del plan de producción en el planeamiento minado en un 56.0% para el 2018 y 55.7% para el 2019, y por ende la cantidad de remanejo de mineral.

Palabras Clave: Chancadora primaria, mineral, remanejo, Redes neuronales, tensorflow.

ABSTRACT

The objective of this thesis is to obtain a model of recurrent neural networks for the prediction of the feeding of a primary crusher, using LSTM-type networks developed with Tensorflow.

For this, historical data collected on the feeding of a primary crusher during 2018 at the end of 2019 were used, in said database there are also other variables such as: ore head grades, type of ore, availability and use of the crusher, shovels and trucks, among others. The historical data was evaluated and analyzed, to subsequently train different models with these data to obtain a more efficient model. Within all the models, the Mean Squared Error (RMSE) was used as a metric, since, with this metric, the nature of the variable (tons) is preserved.

As a result, a model was obtained that had as RMSE 26844.85 TN, said model consists of an architecture of a dense input layer of 32 neurons, a dropout filter layer of 25%, an LSTM layer of 64 neurons, obtaining an improvement of 13%. compared to the preliminary model.

This model was trained correctly through the separation of training and validation data, 80 and 20% respectively, this separation allowed to compare the predicted data with real data, demonstrating that the application of these new technologies has a potential use within the mining field, since it was possible to reduce the prediction error of the production plan in the mined planning by 56.0% for 2018 and 55.7% for 2019, and therefore the amount of ore rehandling.

Keywords: Primary crusher, ore, re-handling, neural networks, tensorflow.

ACRÓNIMOS

- **LSTM:** Memoria de largo a corto plazo
- **TN:** Tonelada
- **TN/hr:** Toneladas por hora
- **NORMA ASARCO:** Marco de referencia utilizado para la definición de conceptos y distribución de los tiempos en que el equipo, máquina, o instalación incurren durante la operación.
- **ML:** Aprendizaje de máquina
- **DL:** Aprendizaje profundo
- **RNN:** Red neuronal recurrente
- **RMSE:** Error cuadrático medio
- **KNN:** K vecinos más cercanos, es un algoritmo de Machine Learning que pertenece a los algoritmos de aprendizaje supervisado
- **HG:** Mineral de alta ley
- **Cu:** Cobre
- **Zn:** Zinc

GLOSARIO

Ley de Cabeza: Contenido de finos en el mineral que entra al proceso de concentración.

Remanejo: Cantidad de mineral que se envía a los stocks y que no entra al proceso productivo.

Redes neuronales recurrentes: Es una clase de redes neuronales que se basa en procesar y analizar datos que se encuentran registrados de manera secuencial.

Stockpile: Acopios de mineral donde el material se sustenta sobre sí mismo.

Mine to mill: Estrategia de integración entre la mina y la planta.

Carguío y Acarreo: Etapas que suponen la ejecución conjunta de cargar, con equipos de gran tamaño, el material en el sistema de transporte y transportarlo al lugar de destino correspondiente

Dispatch: Herramienta en tecnología minera de gestión cuyo objetivo es incrementar la asignación de equipos, maximizando la utilización del tiempo y minimizando las pérdidas, en tiempo real.

Aprendizaje máquina: Es aquella tecnología por la cual se utilizan algoritmos computacionales para el reconocimiento de patrones.

Imputación: Reemplazo de valores registrados que fueron nulos o no tuvieron un valor.

Batch: Es el proceso el cual se realiza de manera finita.

Internet de las cosas (IoT): Es aquel sistema en donde se orquestan todos los sensores y dispositivos físicos los cuales realizan el envío y recepción de datos.

ÍNDICE GENERAL

Presentación.....	iii
Dedicatoria.....	iv
Agradecimientos.....	v
Epígrafe.....	vi
RESUMEN.....	vii
ABSTRACT.....	viii
ÍNDICE GENERAL	xi
ÍNDICE DE FIGURAS.....	xiv
ÍNDICE DE TABLAS.....	xvi
INTRODUCCIÓN	1
CAPÍTULO I.....	3
1. Planteamiento de la investigación.....	3
1.1. Planteamiento del problema.....	3
1.2. Objetivos.....	4
1.2.1. Objetivo general.....	4
1.2.2. Objetivos específicos	4
1.3. Preguntas de investigación.....	5
1.3.1. Pregunta general.....	5
1.3.2. Preguntas específicas	5
1.4. Línea de Investigación	5
1.5. Palabras Clave.....	6
1.6. Aporte del desarrollo de Tesis	6
CAPÍTULO II	6
2. Fundamentos Teóricos	6

2.1.	Antecedentes de la Investigación.....	6
2.2.	Bases Teóricas	12
2.2.1.	Proceso de producción minero.....	12
2.2.2.	Planeamiento Estratégico.....	18
2.2.3.	Planeamiento Corto Plazo.....	20
2.2.4.	Distribución de tiempos ASARCO (American Smelting and Refining Company)..	23
2.2.5.	Aprendizaje Máquina (Machine Learning) aplicado a las minas	25
2.2.6.	Tecnología de información y comunicaciones en minería	28
2.3.	Marco conceptual.....	33
2.4.	Hipótesis	35
2.5.	Variables	35
2.5.1.	Variable dependientes:.....	35
2.5.2.	Variable independiente:	35
CAPÍTULO III.....		37
3.	Marco Metodológico.....	37
3.1.	Alcances y Limitaciones.....	37
3.1.1.	Alcance	37
3.1.2.	Limitaciones.....	37
3.2.	Tipo y Nivel de la Investigación.....	37
3.3.	Población y Muestra	38
3.3.1.	Población.....	38
3.3.2.	Muestra	39
3.4.	Método, Técnicas e Instrumentos de Recolección de Datos.....	39
3.4.1.	Instrumentos para la recolección de datos	39
3.4.2.	Técnicas para la recolección de datos.....	40
3.5.	Análisis Estadístico.....	44
CAPÍTULO IV		46

4.	Modelo Propuesto	46
4.1.	Análisis e Interpretación de Resultados	46
4.1.1.	Análisis exploratorio de datos.....	46
a)	Variables Categóricas	47
b)	Variables de Fecha.....	48
c)	Variables Numéricas.....	48
4.1.2.	Preprocesamiento e imputación de datos	48
a)	Variables Categóricas preprocesadas.....	51
b)	Variables numéricas preprocesadas	54
4.1.3.	Descripción de Variables utilizadas.....	60
4.2.	Desarrollo del Modelo de Redes Neuronales LSTM.....	63
CAPÍTULO V.....		71
5.	Resultados	71
5.1.	Resultados del modelo preliminar	71
5.3.	Evaluación de los resultados predichos	76
CONCLUSIONES.....		83
RECOMENDACIONES		85
REFERENCIAS BIBLIOGRÁFICAS.....		86

ÍNDICE DE FIGURAS

Figura 1. <i>Etapas del proceso de producción minero</i>	12
Figura 2. <i>Diagrama de flujo del chancado primario y secundario</i>	15
Figura 3. <i>Escala de tiempos de acuerdo a la Norma ASARCO</i>	23
Figura 4. <i>Diagrama de Inteligencia Artificial, Aprendizaje de Maquina y Aprendizaje Profundo</i>	27
Figura 5. <i>Estructura de una red neuronal LSTM</i>	31
Figura 6. <i>Plataforma de TensorFlow</i>	33
Figura 7. <i>Ejemplo de la transformación la función series_to_supervised</i>	43
Figura 8. <i>Resultados descriptivos de la base de datos</i>	46
Figura 9. <i>Resultados descriptivos de los datos imputados</i>	50
Figura 10. <i>Frecuencia de los niveles de las variables categóricas</i>	51
Figura 11. <i>Frecuencia de cada material</i>	52
Figura 12. <i>Frecuencia del tipo de Material según la fase de origen</i>	53
Figura 13. <i>Frecuencia de envíos por inoperatividad de la chancadora primaria</i>	54
Figura 14. <i>Series de tiempo para la ley de cobre y zinc entre el año 2018 y 2019</i>	55
Figura 15. <i>Correlación de Pearson para la ley de cobre y zinc</i>	56
Figura 16. <i>Serie de tiempo para la disponibilidad y utilización de la chancadora</i>	57
Figura 17. <i>Serie de tiempo para la disponibilidad y utilización de la pala</i>	58
Figura 18. <i>Serie de tiempo para la disponibilidad y utilización de camiones</i>	59
Figura 19. <i>Serie de tiempo para la cantidad de toneladas enviadas ("tn_enviado")</i>	60
Figura 20. <i>Estructura del modelo de predicción multivariado</i>	64
Figura 21. <i>Estructura y características del modelo de redes neuronales</i>	65
Figura 22. <i>Código en python para el desarrollo del modelo preliminar</i>	65
Figura 23. <i>Resultados las diferentes iteraciones con la librería Hplot</i>	67
Figura 24. <i>Ejemplos de dinámicas de las curvas de aprendizaje</i>	69
Figura 25. <i>Mejor resultado de la optimización de parámetros</i>	70
Figura 26. <i>Curvas de aprendizaje del modelo preliminar</i>	71
Figura 27. <i>Predicciones con el modelo preliminar del conjunto de datos de prueba</i>	72
Figura 28. <i>Predicciones con el modelo preliminar sobre el conjunto de datos de prueba</i>	73
Figura 29. <i>Curvas de aprendizaje para el modelo con hiperparámetros optimizados</i>	74

Figura 30. <i>Predicciones del modelo optimizado para el conjunto de datos de prueba.....</i>	75
Figura 31. <i>Resultados de la función de perdida para un modelo LSTM univariado.....</i>	77
Figura 32. <i>Remanejo promedio de mineral de los años 2018 y 2019 por inoperatividad de chancadora.....</i>	78
Figura 33. <i>Comparación de costos de Remanejo promedio</i>	81



ÍNDICE DE TABLAS

Tabla 1. <i>Costo de Carguío por hora</i>	79
Tabla 2. <i>Costo de Acarreo por hora</i>	80
Tabla 3. <i>Cálculo de Costos de Carguío por Toneladas</i>	80
Tabla 4. <i>Cálculo de Costos de Acarreo por Toneladas</i>	81



INTRODUCCIÓN

La industria minera busca recurrentemente la mejora y optimización de sus procesos con el fin de obtener una mayor productividad a costos menores, es por ello que se han implementado planificaciones a fin de asegurar el resultado económico; sin embargo, tan solo con implementar la planificación no obtienen los resultados esperados; razón por la cual se busca mejoras por operación unitaria.

La planta de chancado primario busca reducir el tamaño de partícula del material enriquecido proveniente del tajo, teniendo como objetivo procesar el mineral que viene de la mina para su traslado a la planta concentradora (Zela, 2017). Esta operación unitaria debe manejar correctamente sus variables de operaciones para evitar problemas con otros procesos que se puede ver reflejado en un mayor costo de producción. Actualmente las empresas mineras tienen un plan estimado de disponibilidad, utilización y tonelaje de alimentación por día de la chancadora primaria, que se elabora en función del promedio de los datos de meses o años anteriores. (Rojas, 2010)

Sin embargo debido a que su planificación está basado solo en datos de años anteriores es muy inexacto ya que no toma en cuenta las variables operativas como; tipo de material, leyes de cabeza, minerales contaminantes presentes que afectan la dureza, disponibilidad mecánica, utilización de la chancadora primaria y equipos de carguío y acarreo, fase y banco de minado, entre otras variables de operación; causando una sobreestimación o subestimación del material chancado, y como consecuencia el incumplimiento con los planes de minado a corto plazo y resultando un mayor costo en el acarreo por el remanejo de material que no pudo ser enviado a chancadora.

Es por ello que se propone la aplicación de la inteligencia artificial y sus técnicas (redes neuronales) como soporte de esta operación y así optimizar el proceso (Bardales y Zamora, 2019). Las redes neuronales recurrentes (LSTM) buscan predecir y optimizar un determinado proceso ya que tiene la posibilidad de almacenar una representación de los acontecimientos recientes de una secuencia (Pérez, 2002), por lo que aplicando este modelo predictivo multivariado junto con las variables operacionales reales, se podrá realizar un planeamiento estratégico y de integración siguiendo el concepto de Mina a Molino, que nos permitirá enviar solo la cantidad necesaria de mineral que chancadora podrá recibir.

Por lo cual el presente trabajo planteará la utilización de esta tecnológica herramienta de aprendizaje automático como lo son las redes neuronales recurrentes LSTM, con la cual se predecirá la cantidad más exacta de mineral a chancar para disminuir la cantidad del remanejo del mineral, lográndose obtener una mejor gestión y un menor costo productivo.

CAPÍTULO I

1. Planteamiento de la investigación

1.1. Planteamiento del problema

Para el proceso de chancado primario usualmente, se tiene un plan estimado de disponibilidad, utilización y tonelaje de alimentación por día de la chancadora primaria, que se elabora en función del promedio de los datos de meses o años anteriores, lo que representa en una inexactitud en la planificación. (Rojas, 2010)

Esto se debe dado a que no se consideran más variables como el tipo de material, leyes de cabeza, minerales contaminantes presentes que afectan la dureza, disponibilidad mecánica, utilización y utilización operativa de la chancadora primaria, fase y banco de minado, entre otras variables de operación.

Reflejando este error en que no se llegue a cumplir con el plan estimado. Si dicha disponibilidad y utilización no se llegase a cumplir puede llevar a que el equipo entre en inoperatividad y disminuirá la capacidad de recibir más material, de igual manera como no se hace una diferencia entre las TN/hr que puede chancar por diferentes tipos de material y ley que ingresan habremos sobreestimado la capacidad de chancado y tolva de la chancadora primaria, haciendo que el material que se esperaba chancar sea redirigido y almacenado en los stockpiles, que luego representará en un remanejo del material, aumentando los costos operativos.

Por lo tanto, se continuará sobrestimando y subestimando la cantidad de material que se chanca, haciendo que los planes de minado de corto plazo y distribución de acarreo de los camiones termine en no cumplirse o resultar en un mayor costo por el remanejo de material.

Por este motivo, lo que se quiere lograr en el presente trabajo de investigación es poder utilizar las nuevas herramientas y tecnologías de aprendizaje de maquina (Machine Learning) como las redes neuronales recurrentes como la LSTM, para desarrollar un modelo predictivo que logré estimar la cantidad precisa de mineral que se va a procesar en la chancadora primaria para reducir la cantidad de remanejo de mineral mediante un plan de minado confiable que a su vez influirá en la correcta gestión del carguío y acarreo.

1.2. Objetivos

1.2.1. Objetivo general

Obtener un modelo de redes neuronales recurrentes para la predicción de la alimentación a una chancadora primaria.

1.2.2. Objetivos específicos

- A. Analizar de los datos históricos que se utilizarán para entrenar el modelo.
- B. Determinar las variables a utilizar en el modelo redes neuronales recurrentes.
- C. Diseñar y entrenar una red neuronal recurrente multivariada para predecir los datos históricos tratados.
- D. Comparar los resultados obtenidos de los modelos de redes neuronales recurrentes para seleccionar el modelo más eficiente.
- E. Evaluar la predicción del modelo de redes neuronales recurrentes obtenido en comparación con la predicción del plan de producción en el planeamiento de minado.

1.3. Preguntas de investigación

1.3.1. Pregunta general

¿Se podrá desarrollar un modelo de redes neuronales recurrentes para la predicción de la alimentación a una chancadora primaria?

1.3.2. Preguntas específicas

- A. ¿Qué estructura y características presentará la base de datos históricos que servirán para el entrenamiento de la red neuronal recurrente?
- B. ¿Cuáles serán las variables a utilizar en el modelo de redes neuronales recurrentes?
- C. ¿Cuál será el diseño y entrenamiento de la red neuronal recurrente multivariada para predecir los datos históricos tratados?
- D. ¿Cuál es el modelo de redes neuronales recurrentes obtenido más eficiente?
- E. ¿Se tendrá una mejor predicción de alimentación a la chancadora primaria con el modelo de redes neuronales recurrentes en comparación con la predicción del plan de producción en el planeamiento de minado?

1.4. Línea de Investigación

El presente trabajo tiene como línea de investigación: la Optimización de Procesos Mineros, ya que mediante la elaboración de modelo predictivo multivariable utilizando redes neuronales recurrentes para obtener las toneladas diarias de alimentación a chancadora primaria para su uso como plan de producción de planeamiento de minado de corto plazo, se podrá realizar un planeamiento estratégico y de integración siguiendo el concepto de Mine to Mill que permita enviar solo la cantidad necesaria de mineral

que chancadora podrá recibir en el día evaluando diferentes variables como tipo de mineral, leyes, disponibilidad y utilización de la chancadora que cambian todos los días. Para evitar subestimar o sobreestimar la capacidad de alimentación diría, logrando reducir el remanejo de material causado por la sobreestimación de TM/día. Lo que representa la reducción del costo en carguío y acarreo.

1.5. Palabras Clave

Las palabras claves que representan el presente trabajo podrían ser: Chancadora primaria, mineral, remanejo, Redes neuronales, tensorflow.

1.6. Aporte del desarrollo de Tesis

La presente investigación brindara un valioso aporte a el planeamiento estratégico de minado y producción, mediante la aplicación de redes neuronales recurrentes como la inteligencia artificial, que nos permitirá desarrollar un modelo predictivo multivariable que logré estimar la cantidad precisa de mineral que se va a chancar en la chancadora primaria en base a variables operativas, y así poder reducir el error de predicción del plan de producción en el planeamiento de minado actual y por ende la cantidad de remanejo de mineral favoreciendo a la empresa por la disminución del costo en el carguío y acarreo del mineral remanejado y ayudara a tener una mejor gestión de minado.

CAPÍTULO II

2. Fundamentos Teóricos

2.1. Antecedentes de la Investigación

Fu y Aldrich (2020) con su artículo titulado **“Deep Learning in Mining and Mineral Processing Operations: A Review”**, buscaron demostrar el gran impacto que tiene la aplicaciones del aprendizaje profundo (Deep Learning) en la industria minera, ya que dichas herramientas, como las redes neuronales tienen un alto grado de aplicación para el análisis y toma de decisiones a partir de los datos extraídos de los diferentes sensores, especialmente por su aplicación en la visión de computadora, logrando obtener una mayor automatización y optimizando los tiempos en las operaciones. Como resultado de dicha investigación bibliográfica, es que actualmente muchas y más empresas están comenzando a buscar la utilización de estas nuevas herramientas tecnológicas para optimizar sus operaciones, por medio del acceso a la gran cantidad datos industriales, que al final significara como un buen y solido punto de referencia para la toma de decisiones.

Así mismo, Ouanan y Abdelwahed (2019) con su trabajo titulado **“Image processing and machine learning application in mining industry: Mine 4.0”**, en donde se busca poder establecer un estado del arte sobre la aplicación del aprendizaje automático (ML) y el procesamiento de imágenes dentro la industria minera, así como también una aplicación a tiempo real para el análisis de imágenes de espuma de flotación dentro del procesamiento de minerales. Dicha investigación dio como resultado que la utilización de ML y DL pueden ser aplicadas en diferentes áreas dentro de las operaciones mineras, logrando un alto potencial prospectivo.

Por otro lado, en Sudamérica, Contreras (2018) con su trabajo titulado **“Diseño de modelo predictivo multivariable para la molienda en la Compañía Minera Doña Inés de Collahuasi”**, en dónde se buscó desarrollar un modelo que pueda predecir el comportamiento no lineal de la potencia que tienen los molinos SAG de la Compañía Minera Doña Inés de Collahuasi, mediante la utilización de las variables mineralógicas, variables utilizadas por el operador y teniendo como variable respuesta la potencia del molino. Para esto se propone la utilización de un modelo de redes neuronales y un modelo de bosques aleatorios y compararlos como el modelo establecido por Austin. Se obtuvo como resultado el modelo de bosques aleatorios presentó un error de 0.76% mientras que el error de las redes neuronales fue de 1.40%, siendo estos errores mucho menores a los obtenidos por el modelo establecido por Austin (clásico) que fue de 3.04%, llegando finalmente a la conclusión que los nuevos modelos de Machine Learning logran predecir y adaptarse mejor a los datos que los modelos clásicos.

En el estudio de Franco-Sepúlveda, Del Rio-Cuervo y Pachón-Hernández (2019) en su artículo titulado **“State of the art about metaheuristics and artificial neural networks applied to open pit mining”**, realizó una búsqueda bibliográfica con relación a las principales técnicas metaheurísticas y las redes neuronales artificiales para la optimización de las operaciones mineras, tales como las voladuras, transporte y procesamiento de los minerales. En este estudio se mostraron las propuestas de desarrollo en la optimización global en todos los complejos mineros existentes en una planta, describiendo así, la aplicación de estas técnicas para optimizar las variables en la

planificación minera, siendo implementada en varias minas del mundo, ya que estas alternativas propuestas tiene el fin de lograr alcanzar los objetivos para procesos reales mediante la aplicación de diferentes técnicas como el modelado estadístico y el aprendizaje automático; dando una oportunidad de encontrar diferentes opciones de soluciones frente a los problemas tradicionales que se encuentran en las operaciones mineras.

Otro estudio realizado por Ramesh et al. (2018) en su artículo titulado **“Rock Fragmentation Prediction through a New Hybrid Model Based on Imperial Competitive Algorithm and Neural Network”**, describe un nuevo algoritmo híbrido (ICA) - red neuronal artificial (ANN) para la estimación de la fragmentación de la roca en las operaciones de voladura, el cual permite resolver las deficiencias de la propia ANN en las predicciones de la fragmentación de rocas tomando en cuenta el patrón de explosión y las características del macizo rocoso. Todos los modelos fueron realizados a partir de 8 entradas y una salida que es la fragmentación de la roca, donde se estudió la influencia de ICA en los resultados de ANN. Los resultados mostraron que el mejor modelo de predicción fue el desarrollo híbrido ICA-ANN. El estudio concluyó que el modelo propuesto ICA-ANN puede ser implementado en el mejoramiento de rendimiento para la estampación de rocas.

Dindarloo y Siami-Irdemoosa, (2017), en su artículo titulado **“Data mining in mining engineering: results of classification and clustering of shovels failures data”**, en donde se resalta que existe un alto costo en el mantenimiento de los equipos de minería, además que, estos mantenimientos significan un tiempo de inactividad costosos y que

deberían evitarse con una correcta planificación inteligente y eficiente. Así mismo, se reconoce que actualmente las minas modernas manejan un gran volumen de datos sobre el rendimiento y la confiabilidad del equipo, así como también datos de planeamiento de mantenimiento antiguos. Es por esto por lo que el artículo busca extraer una aplicación de clasificación y agrupamiento (clustering) para el reconcomiendo de los patrones y así poder realizar el pronóstico de las fallas que pueden suceder en las palas mineras. Para esto se utilizaron datos históricos de fallas y el tiempo que tomó su reparación mediante un modelo de Support Vector Machine (SVM), lográndose identificar que dicha técnica tuvo un 75% de éxito de predicción, y esto solo fue en el primer intento dejando abierta la posibilidad de que se pueda alcanzar a un mayor grado de pronóstico. Por esto, la aplicación de dichas herramientas son un aporte muy valioso para la toma de decisión durante el planeamiento y programación del mantenimiento preventivo.

Sotelo (2016), con su trabajo que lleva como título **“Desarrollo de una librería Neuronal en Control Builder 5.1 para controlar el nivel de mineral al interior de un molino de bolas”**, tuvo como objetivo elaborar y diseñar un sistema de control neuronal que pueda ser capaz de determinar cuál es el nivel de carga instantáneo en un molino de bolas, utilizando los datos y experiencia del operador de la sala de control, para esto se utilizaron las variables: Presión, Velocidad de Impacto y Tonelaje; dichas variables fueron introducidas en un algoritmo neuronal supervisado, como datos de entrenamiento. Los resultados demostraron que la predicción de la carga del molino tuvo un error máximo del 4.22%.

Linares (2018), con su trabajo **“Un enfoque predictivo de la fragmentación en la voladura de Rocas”**, en donde presentó la importancia de la utilización de modelos revolucionarios como Redes Neuronales Artificiales (ANN), técnicas de Análisis Multivalente y el modelo clásico KUZ-RAM. Logrando obtener una optimización en las operaciones mineras, ya que, al entregar una óptima fragmentación a los procesos de molienda, se reducen los tiempos y se maximiza la productividad. Los resultados mostraron que el modelo de ANN logró un ajuste lineal de aproximadamente el 99.03% mientras que los demás modelos como el MVR obtuvo un coeficiente de ajuste lineal del 65% y el modelo KUZ-RAM de 0.65%, lo que significa que las redes neuronales lograron adaptarse de manera muy significativa a los datos utilizados para el entrenamiento.

Bardales y Zamora (2019), en su trabajo **“Estimación de las característica geomecánicas del macizo rocoso mediante la inteligencia artificial”**, tuvo como objetivo obtener una revisión bibliográfica significativa para poder estimar el poder de la aplicación de redes neuronales o inteligencia artificial dentro de la industria minera, en específico, para caracterizar las características geomecánicas de los macizos rocosos, en donde se logró obtener que existe evidencia desde el 2008 al 2018 de diferentes autores que buscan la aplicación de dichas nuevas tecnologías para la caracterización de los macizos rocosos, y que además son sumamente eficientes logrando aprovechar al máximo su aplicación en las operaciones mineras.

Carrion (2018) con su trabajo titulado **“Aplicación de Redes Neuronales Artificiales para la predicción de la recuperación de Planta Concentradora en MINSUR S.A. – Unidad San Rafael”**, que tuvo como objetivo el desarrollo y aplicación de la inteligencia artificial, para la predicción de la recuperación dentro de la Planta Concentradora y luego comparar estos resultados predichos con los obtenidos realmente, para luego establecer los entornos para su aplicación. Para esto se utilizó el software NeuralTools, en donde se aplicaron las Redes Neuronales Probabilísticas y una Red Neuronal de Regresión Generalizada. Los resultados obtenidos presentan que al utilizar una regresión lineal clásica se obtiene un error que no es aceptable, mientras que, el modelo de red neuronal logra adaptarse mucho mejor a los datos logrando tener un alto grado de precisión en las predicciones.

De los antecedentes mencionados se observa que, en los estudios e investigaciones realizadas, se obtuvo muy buenos resultados del uso de inteligencia artificial y redes neuronales aplicado en el campo de ingeniería de minas, logrando obtener predicciones que mejoran los procesos mineros.

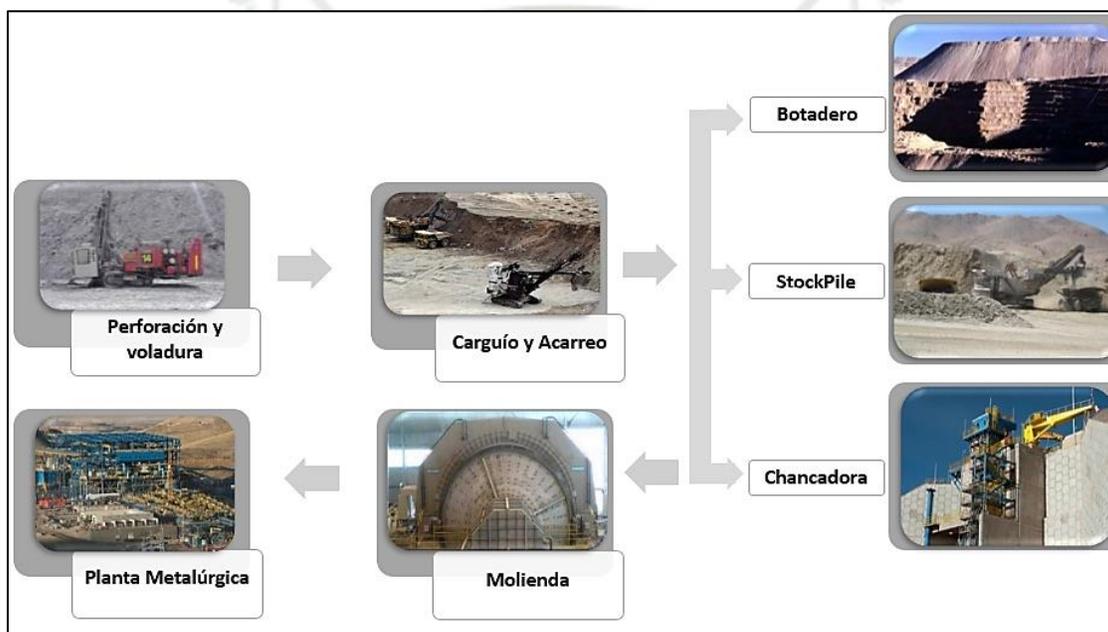
2.2. Bases Teóricas

2.2.1. Proceso de producción minero

El proceso de producción minera consta de varias etapas tales como la perforación y voladura, carguío y acarreo, chancado, molienda, y procesos metalúrgicos como se presenta en la Figura 1.

Figura 1.

Etapas del proceso de producción minero



Fuente: Iquiapaza (2018), Barreto (2017), Camus (2009), Barrios (2015), Consejo Minero (2002)

I. Perforación y voladura

a. Perforación

Es la primera etapa de todas las operaciones mineras donde se aplican una serie de acciones que consiste en la preparación de la voladura y la ejecución de esta, además, se deben tomar en cuenta que las perforaciones deben ser realizadas de manera ordenada y adecuada para la obtención de una mayor eficiencia en las siguientes etapas como el carguío y por ende en la producción de la mina.

Asimismo, se debe tomar en cuenta respecto a la profundidad, paralelismo, perpendicularidad y exactitud de las coordenadas, así como también las características estructurales y geomecánicas de los macizos rocosos (Iquiapaza, 2018).

b. Voladura

Es una de las etapas más importantes de todas las actividades realizadas en el ciclo de minado. En esta etapa se realizan tres tipos de voladura como de producción, buffer y precorte, siendo ésta última donde se aplican el carguío del explosivo en proporción menor que la anterior voladura con el motivo de no generar daños en las paredes del tajo. Además, de se debe considerar factores para obtener buenos resultados en la voladura tales como la distribución y secuenciación de iniciación, las propiedades de los explosivos, las propiedades del macizo rocoso y la geometría del disparo (Iquiapaza, 2018).

II. Carguío y acarreo

a. Carguío

La operación del carguío se refiere a la carga del mineral fragmentado extraído del yacimiento minero o del material estéril de la mina para luego llevarlo a posibles destinos como la planta de beneficio, el stock del mineral, o botaderos de estéril; asimismo, la operación del carguío consiste en una serie de funciones que aseguran el desarrollo del proceso de manera normal y eficiente. En esta puede definirse los sectores de carga, el destino de los materiales en función a las leyes minerales a los tonelajes definidos y a las direcciones del carguío (posiciones de

equipos de carguío, frentes de carga y niveles de pisos de carguío). (Barreto, 2017)

b. Acarreo

Por otro lado, la etapa del acarreo consiste en el transporte del mineral o material estéril desde un punto de partida (yacimiento minero) hasta los posibles destinos (planta beneficio, stocks y botaderos), donde involucra una serie de funciones como las rutas de transporte, el destino del material de acuerdo con las leyes y a los tonelajes definidos. (Barreto, 2017)

III. Chancado

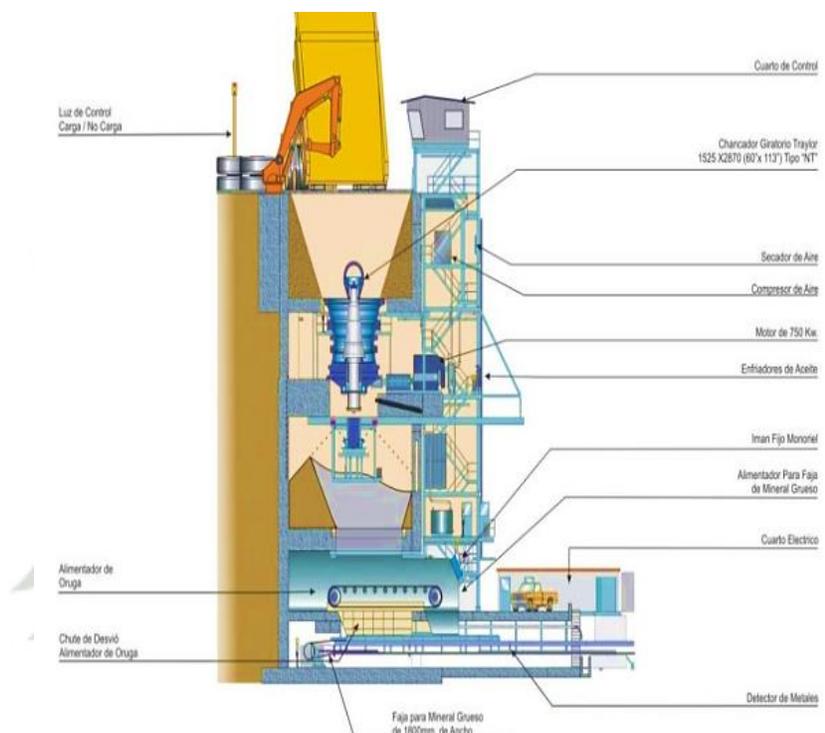
El chancado es la primera etapa de procesamiento de los minerales dentro de la planta de beneficio, el cual consiste en la aplicación de una fuerza mecánica capaz de romper y reducir los trozos de rocas de interés a un tamaño que generalmente puede variar de acuerdo con el procesamiento; estas fuerzas mecánicas involucran la fuerza de fricción, fuerza de cizallamiento y fuerza de flexión. Además, las chancadoras realizan normalmente a una velocidad media o baja de trayectoria fija para la reducción del mineral, de modo que puede ejercer presiones inmensas debido a la baja velocidad en que se opera la máquina siendo caracterizadas por sus elementos trituradores al no tocarse entre sí durante la trituración, no obstante, cabe destacar que el factor influyente para las condiciones de operación se debe principalmente a las características del mineral. (Chavez, 2019)

Por otro lado, las chancadoras deben diseñarse de modo que sean capaces de reducir los trozos del mineral, sin embargo, estos equipos pueden producir toda una gama de tamaños incluidos una cierta cantidad fragmentos finos; ya que un

aumento del consumo de energía por equipos en gran medida ocasionará una disminución del tamaño del mineral en la producción de finos. En el caso de una chancadora primaria se utilizan equipos como chancadora de quijadas o giratorias.

Figura 2.

Diagrama de flujo del chancado primario y secundario



Fuente: Escobedo (2014)



a. Chancadora primaria

Así mismo, Zela (2017) menciona que esta operación pertenece a la primera etapa de preparación mecánica durante el proceso de conminación, que como ya se indicó, tiene como objetivo la reducción de grandes trozos a pequeños fragmentos, y así empezar con la liberación de los minerales importante, mediante el uso de fuerzas de compresión, además de que es un proceso que se lleva a cabo en seco. Dicha operación se realiza en máquinas resistentes, robustas y pesadas que se denominan chancadoras o trituradoras, que se mueven en una trayectoria fija y ejercen grandes presiones a bajas velocidades (Zela, 2017).

En la etapa del chancado primario entra el mineral extraído de los yacimientos mineros de explotación, donde los equipos denominados como chancadoras de quijadas o giratorias trituran rocas de 60" hasta 8" - 6" de tamaño de mineral. En el caso de las chancadoras de quijadas, estas operan por aplastamiento de las rocas mediante el movimiento oscilatorio de dos mandíbulas, una fija y la otra móvil. Existen varios tipos de trituradoras mandíbulas de las cuales pueden ser la Universal, Dodge y el Blake. El mecanismo de la trituración comienza con el trozo del mineral que entra por la abertura mayor del equipo el cual es quebrado y triturado hasta descender por debajo de la abertura entre estas mandíbulas, de modo que, pasa a un SET de descarga de chancadora para la continuación del circuito de trituración del mineral. Asimismo, las chancadoras giratorias tienden a triturar a través de la compresión de dos paredes troncocónicas siendo una fija de forma cóncava y la otra móvil con forma de un tronco, el efecto de la parte móvil permite la oscilación del alejamiento y acercamiento del tronco a la pared cóncava

de forma alternada, de manera que permita aplastar el mineral reduciéndose y cayendo a otro nivel por gravedad para ser nuevamente triturado. A diferencia de la chancadora de quijadas, la chancadora giratoria realiza la trituración durante todo el ciclo y su capacidad es mucho mayor y continua de modo que es mayormente escogida por las plantas debido a su mayor producción y rendimiento. (Chavez, 2019)

b. Molienda

Es la última etapa de las operaciones de conminación del mineral, donde la reducción se debe principalmente a la combinación entre la abrasión y el impacto del proceso ya sea en pulpa o en seco del material. El propósito de la molienda se debe al control del tamaño de las partículas que se quiere obtener ya que normalmente esta etapa es la clave para la una mayor recuperación de la especie interesada, siendo destacado como la operación con mayor requerimiento de energía en el procesamiento del mineral. (Barrios, 2015)

c. Procesos metalúrgicos

Son aquellas etapas de procesamiento del mineral que consiste en la extracción de la especie interesada el cual contiene otras especies de menos interés y ganga dentro de la composición del mineral. Generalmente para el procesamiento del mineral, primero son sometidos a las operaciones previas de separación el cual consiste en el chancado y molienda del mineral, para luego pasar a los procesos metalúrgicos (gravimetría, disociación magnética o flotación, electrodeposición). Asimismo, se debe tomar en cuenta los factores tanto de las etapas anteriores como de las etapas durante la extracción metalúrgica de la especie, tales como el

tamaño óptimo de partícula, la composición química del mineral, el tipo de proceso de extracción de la especie; de modo que puede ser reflejado al final del proceso en el rendimiento de extracción de la especie interesada.

2.2.2. Planeamiento Estratégico

El planeamiento estratégico se refiere a la elaboración y diseño de los objetivos y metas para luego establecerlo y alinearlos bajo estrategias adecuadas, ya que es una herramienta de gestión donde comprende diversas fases de planificación tales como el establecimiento de objetivos y metas para todo el proceso de planificación, desarrollo de supuestos para la toma de decisiones y la planificación a través de la retroalimentación y la evaluación del desempeño.

La planeación estratégica es una forma de actitud donde es necesario realizar un enfoque profundo con base en la observación hacia el futuro y determinación para la continuidad sistemática hacia una misma dirección, asimismo, el planeamiento estratégico es una labor permanente con un desarrollo ordenado donde permite la identificación de los posibles resultados futuros en función a las decisiones tomadas en el presente.

De modo que se puede inferir que el planeamiento estratégico es aquel proceso donde los miembros de la organización prevén el futuro desarrollando procedimientos necesarios para lograr alcanzar todos los objetivos y metas propuestas en el presente (Sevilla, 2011).

Para que las empresas mineras puedan ejecutar la explotación de un yacimiento minero, es necesario presentar a la administración un plan de proyecto estratégico, con el objeto de conseguir préstamos, justificar las inversiones, y en caso de una

empresa que cotizan la bolsa, tiene una incidencia directa sobre el valor de las acciones. De tal modo que, surge una disciplina denominada como planificación minera (Vargas, 2011). El ciclo de planificación estratégica permite alinear el plan acorde a las normativas de la empresa, generando un proceso de control del riesgo y maximizando los resultados establecidos (Torres, 2018). Su correcta planificación en las etapas de minado garantizará que los objetivos planteados en el proyecto se cumplan a lo largo de todo el ciclo de vida de la mina (Leiva, 2019). El proceso de planificación minera presenta como punto de partida en el modelo de bloques, ya que, de esta manera, pueda trabajarse sobre una buena base lo que permitirá lograr un buen planeamiento de minado del proyecto (Herrera y Jorge, 2019).

Vargas (2011), menciona que planeamiento estratégico puede dividirse en función a la escala espacial y el nivel de precisión de datos, de las cuales constituyen:

- Planificación a largo plazo: Se refiere a la relación existente entre la planificación económica y las reservas mineras disponibles, de esta manera se puede desarrollar el plan de minado, debido a que se establece el tamaño de la mina, la capacidad de producción, el método, los perfiles de leyes de corte y la secuencia de explotación. Asimismo, también se deben incorporar variables generales en promedio, por el motivo del mayor tamaño del problema a resolver no permitiendo considerar en nivel de detalle, sino de las heurísticas usadas en el presente.
- Planificación a mediano plazo: Por lo general abarca una escala de tiempo trianual y anual, donde se realización planes para la obtención de objetivos en

el corto plazo, además de asegurar el presupuesto en la planificación a largo plazo.

- **Planificación a corto plazo:** Su tiempo de planificación puede ser de forma diaria, semanal, mensual hasta trimestral, el cual se analizan las operaciones de la mina con la utilización de los recursos, así también de recoger toda la información de producción para llevar a la planificación a mediano plazo como una retroalimentación de las operaciones ejecutadas.

2.2.3. Planeamiento Corto Plazo

El planeamiento a corto plazo presenta el aspecto a detalle de las operaciones mineras, el cual su desarrollo es diario, semanal y mensual, para diferentes campos, tales como: desarrollo primario, exploraciones, minado y diseños en general.

Para poder cumplir con los objetivos a corto plazo, es necesario realizar un seguimiento a todas las operaciones programadas (Ampuero, 2010).

A. Campañas de mineral

Se realiza en períodos mensuales, con información obtenida a partir del modelo de bloques que se definen como volúmenes geométricos; estos sólidos se adecuan a la calidad del mineral, así tenemos: el tonelaje, ley del mineral y el tonelaje de desmonte. El planeamiento a corto plazo tiene como objeto conseguir la máxima rentabilidad en mínimo costo de recursos de la empresa, por lo que actualmente pasan por análisis de multi opciones de extracción del mineral hasta lograr una secuencia de extracción que permita

cumplir con la producción mensual y con las condiciones de operación minera. (Cruz, 2016)

B. Plan diario

Este tipo de planificación es diario, y sus acciones de operación son concretas, ya que pasa por jefes de turno, y tiene como objetivo gestionar todas las operaciones mineras y recopilar la información al proceso productivo, tomando decisiones inmediatas y retroalimentando la planificación de mediano plazo. (Vargas, 2011; Galdames, 2015)

La planificación a corto plazo aplica polígonos de minado donde se puede ver mucho más detallado y clasificado el yacimiento, siendo la forma en que se decida extraer la cantidad de tonelaje por cada polígono y cual equipo utilizar para su extracción. Además, el planeamiento a corto plazo también tiene la función de las operaciones de las plantas con la maximización del rendimiento tomando en cuenta las leyes de los minerales y las características geológicas del mineral. Ya que a partir de la planificación a largo plazo se obtienen resultados que son convertidos en parámetros y metas de las cuales son cumplidos por la planificación a corto plazo. Carpio (2018), indica que el proceso de planificación se puede dividir en diferentes etapas:

- **Diseño:** Es la primera etapa donde se diseñan los polígonos de minado, se determinan las ubicaciones de las rampas, las rutas, y los puntos de explotación de cada uno de los bancos.
- **Secuenciamiento:** Se evalúa cual polígono se extraerá, en qué periodo, en que orden y con qué tipos de equipos; además de la determinación de

equipos que utilizará por fase también se asignarán sus mantenimientos según lo establecido en sus requerimientos, presentándose extracciones por fase y estableciendo ritmos por banco de periodo a periodo.

- Programación de planta: Se determina que material extraído del polígono minado se procesará y en qué tiempo hacerlo; asimismo, se define el blending o mezcla del mineral que será llevado al proceso. Siendo un factor importante las características geológicas de cada polígono y los requerimientos establecidos en el largo plazo (capacidad, leyes de los minerales, llenado de plana y cantidad de contaminantes).
- Valorización: La planta presenta varias operaciones de procesamiento de las cuales llevan consigo a costos de los recursos de insumos y mano de obra; de modo que, estos costos ya sea directos o indirectos, deben ser determinados y cuantificados para establecer el beneficio final de manera más detallada y precisa en comparación con el planeamiento a largo plazo.

Para la planificación a corto plazo se utilizan herramientas el cual permiten digitalizar los polígonos mineros creando macro-bloques de reservas, además de que pueden ser modificados y replanificados con el fin de asociarle algún valor importante al tonelaje del mineral en particular. Asimismo, estas herramientas tecnológicas pueden ser capaces de considerar mezclas de minerales con propiedades geológicas diferentes, de modo que puedan generar soluciones razonables en tiempos de plazo corto, ya que permiten definir las programaciones

en periodos cortos que progresen en el futuro con periodos largos bajo un horizonte temporal establecido. (Vargas, 2011)

2.2.4. Distribución de tiempos ASARCO (American Smelting and Refining Company)

Dentro del sector minero generalmente existe una forma de evaluación y control sobre la gestión de los estatus operacionales en que se hallan los equipos en función un periodo determinado de evaluación, de modo que, puede ser desglosado y distribuido en distintos tiempos de Índices Operacionales de los equipos con el fin de realizar la evaluación requerida. Es por ello por lo que, la minería utiliza las escalas de tiempos de acuerdo con la Norma ASARCO, el cual se basa en la operación y del sistema Dispatch®, clasificando y describiendo a detalle cada una de las operaciones de los equipos en un periodo de tiempo determinado. (Bonzi, 2016)

Figura 3.

Escala de tiempos de acuerdo a la Norma ASARCO

Tiempo Nominal			
Tiempo Disponible			Fuera de servicio
			Programada
Tiempo Operativo			Reserva
Tiempo Efectivo	Pérdidas Operacionales	Demoras	
		Programada	No Programada

Fuente: Morales y Jélvez (2019)

Las características mostradas en la Figura 2, son clasificadas según el periodo de tiempo determinado:

- Nominal: Se refiere al tiempo en que el equipo se encuentra en plena faena de operación, siendo denominada el tiempo total de un periodo.
- Disponible: Es aquel tiempo donde el equipo está en buenas condiciones y habilitado para ser operado, además de descontarse de las mantenciones.
- No Disponible: Son aquellos tiempos fijados para las reparaciones electromecánicas y mantenciones programadas.
- Operativo: Es el tiempo el cual el equipo esta plena operación de la faena junto con el operador.
- Reserva: Tiempo donde los equipos están en condiciones de operación, no obstante, estos no son utilizados en las labores de operaciones.
- Efectivo: Es aquel tiempo utilizado para lo que realmente se invirtió, siendo denominadas las operaciones puras de la faena sin colas.
- Demoras Programadas: Son aquellos tiempos en donde el equipo presenta detención programada.
- Demoras No Programadas: Es aquel tiempo el cual no fue prevista ni programada de modo que, tampoco se sabe cuánto durará.
- Pérdidas Operacionales: Es denominado como aquel tiempo donde el equipo se encontraba en estado de espera.

Cabe destacar que, cada empresa minera tiene su propio sistema en relación de la distribución de tiempos sobre la Norma ASARCO; según Orellana, Morales y Jélves (2019) detallan estos indicadores de tiempo de la siguiente manera:

- Disponibilidad: Es el aquel porcentaje de las horas nominales en donde el equipo estaba en condiciones de ser operado, ya que sirve para poder establecer la capacidad de mantención y el marco de referencia funcional de la operación.
- Utilización (base nominal): Es denominado aquel porcentaje sobre las horas nominales en que el equipo realiza las tareas efectivas (Formula 1).

$$UBN(\%) = \frac{T. Efectivo}{T. Nominal} * 100\% \quad (1)$$

- Utilización efectiva (base disponible): Es aquel porcentaje sobre las horas disponibles en que el equipo opera las tareas efectivas (Formula 2).

$$UEBD (\%) = \frac{T. efectivo}{T. disponible} * 100\% \quad (2)$$

- Utilización operativa: Es aquel porcentaje sobre las horas disponibles en que el equipo se halla operativo.
- Factor de utilización: Se define como aquel porcentaje sobre las horas operativas en que el equipo efectúa las tareas efectivas.

2.2.5. Aprendizaje Máquina (Machine Learning) aplicado a las minas

La inteligencia artificial es la ingeniería y la ciencia donde se desarrollan programas informáticos inteligentes, siendo relacionado con las actividades que realizan las computadoras para comprender la inteligencia humana. La inteligencia artificial es una rama de la informática capaz de analizar datos sumamente complejos demostrando el potencial para explorar de forma más precisa las relaciones de un conjunto de datos en diferentes escenarios reales (McCarthy, 2007; Ramesh et al., 2004).

Por otro lado, el Aprendizaje de Máquina (Machine Learning) es un subconjunto de inteligencia artificial que incluye técnicas estadísticas abstrusas que permiten a las máquinas mejorar en tareas con experiencia. De modo que, gracias a la capacidad de pensar de los seres humanos, estos pueden aprender de la vida diaria mediante los recuerdos y pensamientos, pero, por otro lado si las máquinas utilizan algoritmos, esto se le denomina Aprendizaje de Máquina (Machine Learning), en donde las computadoras buscan simular el aprendizaje humano, sin embargo, estas, pueden contar con una mayor capacidad de procesamiento, logrando que puedan identificar patrones y adquirir conocimientos que provienen del mundo real, mejorando el desempeño de ciertas tareas basadas en la información que recién se logró adquirir. (Jung y Choi, 2021)

Así mismo, Mitchell, Michalski, y Carbonell, (2013) mencionan que ML puede definirse como, aquel programa de computadora que logra aprender de la información adquirida de la experiencia de cualquier clase de tareas y pudiendo mejorar su desempeño con forme se va adquiriendo la experiencia.

Por este motivo, dicho aprendizaje de maquina puede emplearse en diferentes áreas como informática, salud, energía, ingeniería, entre otros (Portugal, Alencar, y Cowan, 2018).

Actualmente existen varios sectores de la industria que están pasando a una revolución industrial el cual se refiere a las implementaciones de las nuevas tecnologías como los sistemas de aprendizaje automático, redes de alto rendimiento, inteligencia artificial, entre otros; siendo principalmente estudiado Machine Learning el cual se presenta como una oportunidad para la industria

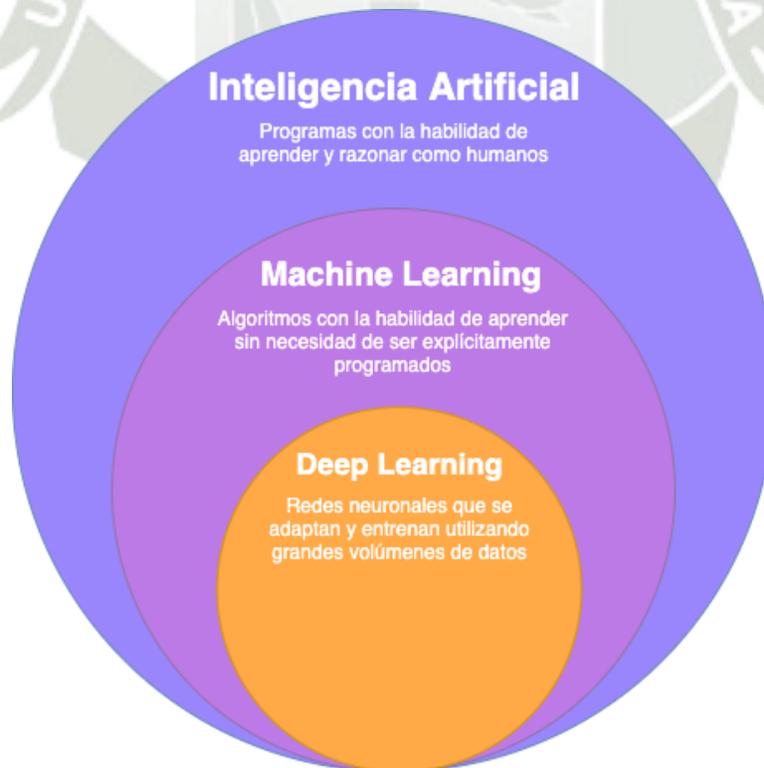
minera lo que proporciona un enfoque innovador como el impacto significativo en las decisiones sobre la planificación y optimización de los procesos. (Torres et al., 2021)

La aplicación de dichos algoritmos no solo tiene una aplicación informática, ya que se puede tomar en consideración la minería inteligente dentro de la industria minera (Jung y Choi, 2021).

Asimismo, Sharma, Sharma y Jindal (2021) mencionan que dentro de la categoría de Machine Learning se incluye el campo del Aprendizaje Profundo (Deep Learning) siendo un subconjunto de este, pero que trabajan con una gran cantidad de datos (Figura 4).

Figura 4.

Diagrama de Inteligencia Artificial, Aprendizaje de Maquina y Aprendizaje Profundo



Fuente: Infaimon (2019)

2.2.6. Tecnología de información y comunicaciones en minería

La minería inteligente hace uso de tecnologías de información y comunicación como el Internet de las cosas big data, sensores y dispositivos móviles, inteligencia artificial (IA), realidad aumentada entre otros, todo esto aplicado en el campo de desarrollo de recursos minerales. (Choi y Lee, 2020)

Las industrias manufactureras han ido pasando por un proceso de digitalización con un crecimiento considerable, a la que se le puede denominar la cuarta revolución industrial o Industria 4.0, por lo que, la industria minera no es la excepción (Fu y Aldrich, 2020).

Por otro lado, Ouanan y Abdelwahed (2019), menciona que las empresas que se dedican a la exploración e inversión minera tienen un gran desafío que afrontar, y este es, la cantidad de datos e información tanto administrativos como geocientíficos.

Por lo tanto, es sumamente necesario poder tener una correcta gestión de los datos que se tienen disponibles, para esto es necesario que la industria evolucione, aplicando nuevas tecnologías, a esta transformación se le puede denominar “Mina 4.0” donde se llegan a implementar tecnologías que mejoran el desempeño de los procesos metalúrgicos en todas las áreas de producción tanto desde la producción hasta el medio ambiental y la seguridad. (Torres et al., 2021)

Deloitte (2018) menciona que los beneficios que se pueden obtener de aplicar dichas tecnologías dentro de la industria minera pueden ser:

- Toma de decisiones rápidas con gran precisión;
- Mejoras en los sistemas de seguridad y salud ocupacional;

- Aumento de la eficiencia por medio de la eliminación de errores y;
- Una baja huella de carbono para el ambiente.

Por este motivo, es necesario poder presentar algunas definiciones fundamentales sobre dichas herramientas o tecnologías de Machine Learning.

A. Deep Learning (DL)

En los últimos años se han logrado avances significativos dentro del campo del sistema informático, siendo precisamente en el aprendizaje profundo (Deep Learning), ya que tienen una gran variedad de aplicaciones en diferentes aplicaciones industriales (Krizhevsky et al., 2012; Silver et al., 2017). Donde las características y patrones han permitido obtener un modelo capaz de capturar comportamientos sumamente complejos (Fu y Aldrich, 2020). El aprendizaje profundo (Deep Learning) es un subconjunto que forma parte de la categoría del aprendizaje automático, siendo precisamente una red neuronal de tres a más capas, de los cuales tienen la capacidad de simular el comportamiento del cerebro humano, permitiendo así la facultad del "aprender" de grandes cantidades de datos adquiridos. (IBM, 2020)

B. Redes Neuronales Recurrentes

Las redes neuronales son parte de la Deep Learning y algunas de las herramientas o técnicas que se utilizan para la aplicación de DL son, las redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN) y las redes de creencias profundas (DBN), en donde, las CNN se utilizan con mayor frecuencia en la tareas de visión por computadoras como reconocimiento de imágenes; las RNN, en donde están incluidas las redes de memoria a largo plazo a corto plazo

(LSTM) son técnicas que logran modelar una secuencia o serie de tiempo, donde la red utiliza información pasada y la combina con información nueva para lograr obtener predicciones. (Fu y Aldrich, 2020)

C. LSTM

Es una RNN simple, en donde se tiene la memoria a largo plazo a corto plazo (LSTM por sus siglas en inglés de Long Short Term Memory). Esta técnica es una versión modificada de las RNN, en donde se utilizan datos históricos, logrando generar modelo que pueden “recordar” datos pasados dentro de la memoria, las LSTM son adecuadas para clasificar, procesar y predecir series de tiempo de acuerdo una cantidad de retrasos de duración desconocida. (Mittal, 2019)

La estructura de esta red neuronal se presenta en la Figura 5.

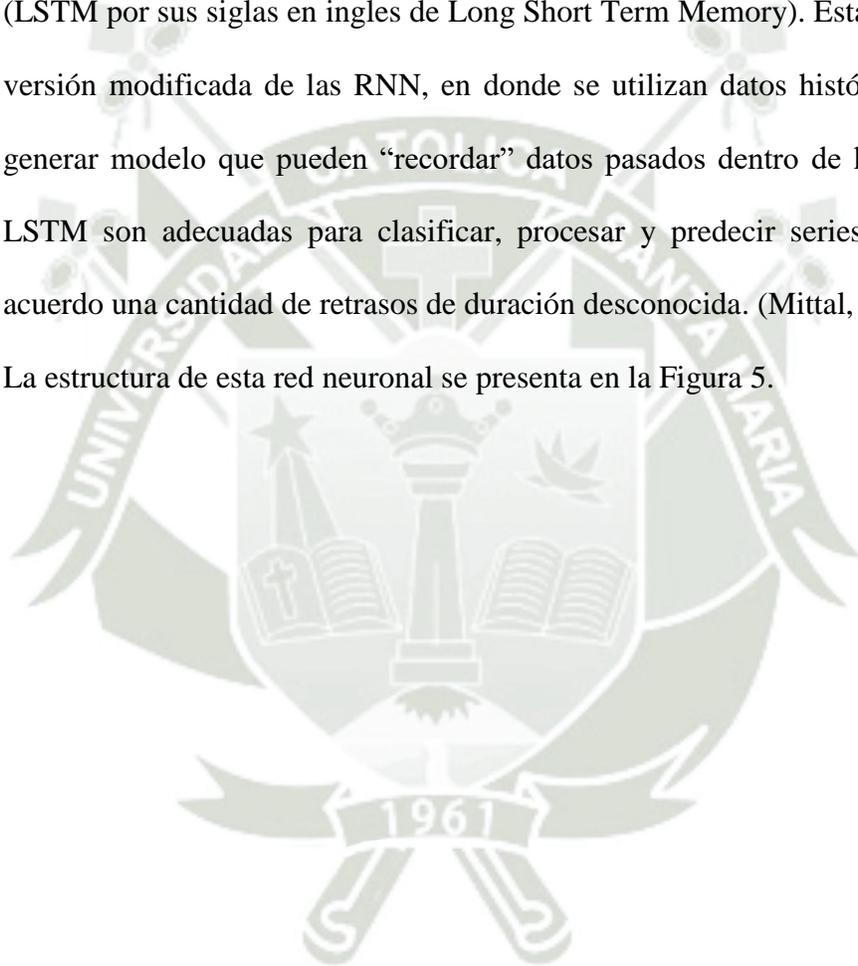
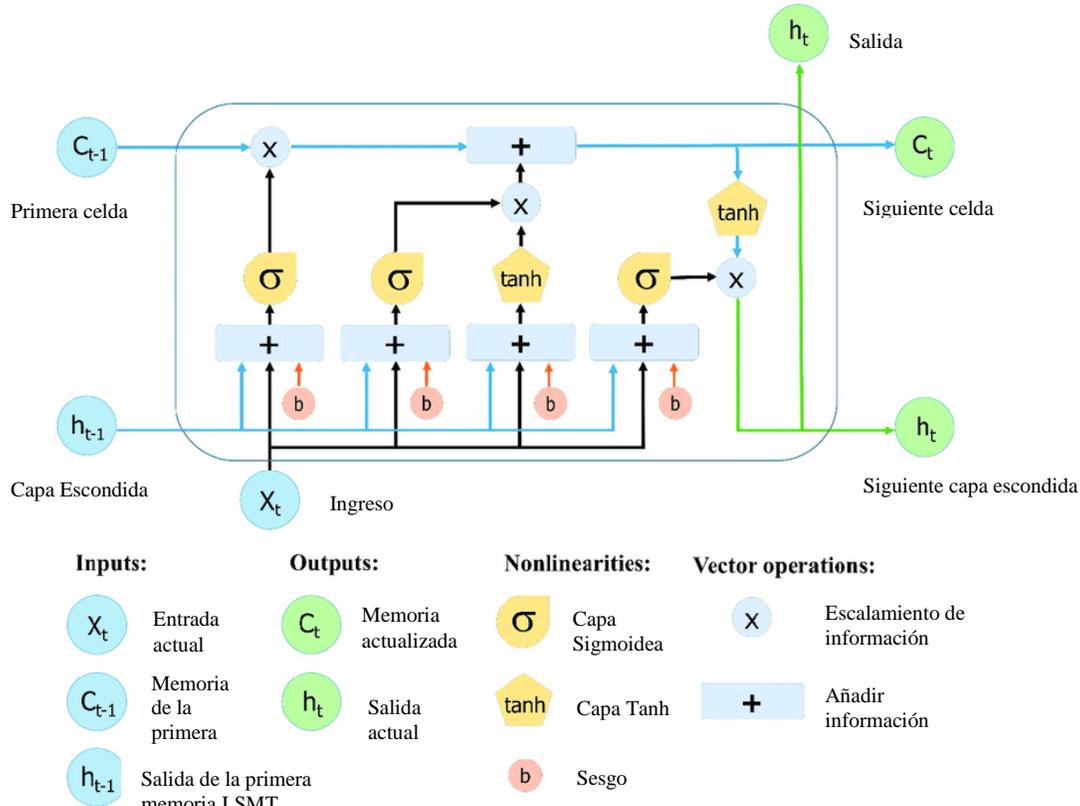


Figura 5.

Estructura de una red neuronal LSTM



Fuente: Le, Ho, Lee, y Jung (2019)

D. Python y Keras

Para la aplicación de dichas redes neuronales a diferentes campos, existen diferentes lenguajes entre ellos se encuentra Python. Python fue creado por Guido van Rossum a inicios de los años 90; este lenguaje tiene una sintaxis limpia y favorece a tener un código legible, así mismo, se trata de un lenguaje de script, dinámico, multiplataforma y orientado a objetos; es decir, que se ejecuta utilizando un programa de por medio al que se le denomina interprete en vez de ejecutar el script directamente en una computadora. (Gonzales, 2014)

Para la utilización de Python para el desarrollo de los modelos de redes neuronales se tienen que utilizar librerías especializadas que brindan todas las herramientas para obtener y diseñar las redes neuronales, una de ellas es Keras.

Keras es una librería que se basa en bloques de construcción de alto nivel para obtener modelos de DL, se basa en una biblioteca de tensores especializada y bien optimizada, actualmente cuenta con tres implementaciones que son TensorFlow, Theano y Microsoft Cognitive Toolkit. (Chollet, 2018)

Keras proporciona una forma muy conveniente de desarrollar y entrenar casi cualquier tipo de modelo de DL, ya que, sus inicios fueron garantizar la experimentación rápida, Keras es distribuido bajo una licencia permisiva del Massachusetts Institute of Technology (MIT), es decir, es una librería gratis y libre para todos los que deseen utilizarla, así mismo, actualmente grandes empresas utilizan dicha herramienta para generar sus modelos, empresas como Google, Netflix, Uber, CERN, Yelp y cientos más, que tienen una amplia gama de problemas. (Chollet, 2018)

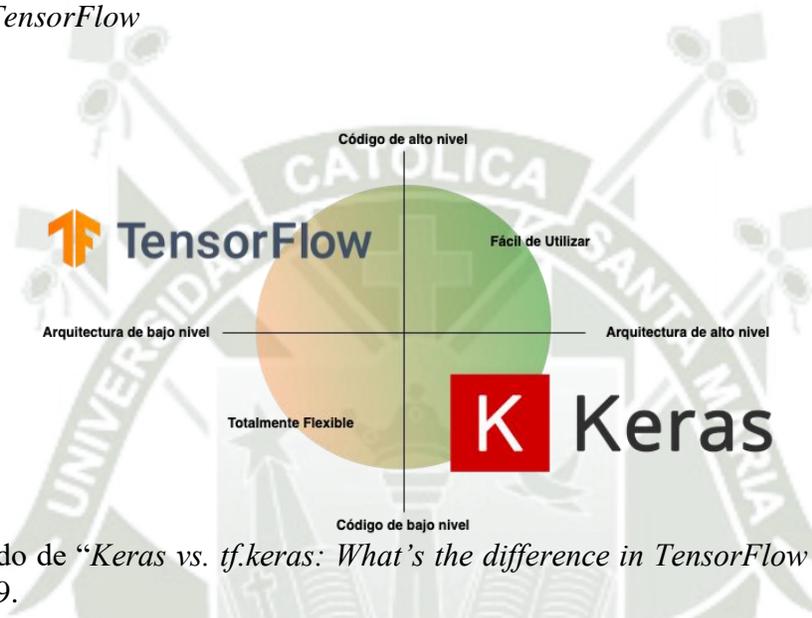
E. Tensorflow

Es una librería con una plataforma de código abierto desarrollado de extremo a extremo para un alto rendimiento en computación numérica, el cual consiste en poseer una arquitectura flexible permitiendo un desarrollo rápido para plataformas TPUs, GPUs o CPUs, de modo que, tiene la facilidad funcionar desde equipos hasta clústers de servidores. Esta biblioteca ofrece un fuerte soporte para Deep Learning y Machine Learning, así como también es muy aplicado en muchos otros estudios de investigación; debido a su alta flexibilidad en su desarrollo y a los

diferentes niveles de abstracción permite la creación y el entrenamiento de las redes neuronales mediante la API de nivel de Keras, siendo capaces de descifrar, correlacionar e identificar patrones análogos al razonamiento humano. (TensorFlow, 2021)

Figura 6.

Plataforma de TensorFlow



Fuente: Adaptado de “Keras vs. tf.keras: What’s the difference in TensorFlow 2.0?” por Adrian Rosebrock, 2019.

Dado que el problema de investigación abarca temas que son relativamente nuevos para la industria minera, los antecedentes investigativos serán en su mayoría de artículos científicos internacionales junto con algunas tesis realizadas.

2.3. Marco conceptual

- *Aprendizaje supervisado*: Son aquellos modelos que se entrenan con una cantidad de datos, de los cuales se les conoce el valor de respuesta o de salida, es decir, se conoce la variable “y” (dependiente), de un conjunto de variables “x” (independientes), y se puede generar una función predictora, siendo la clasificación y regresión, modelos de aprendizaje supervisado. (Roman, 2019)

- *Aprendizaje no supervisado*: A diferencia del aprendizaje supervisado, en este tipo de modelos no se cuenta con la variable “y”, es decir, son datos que no cuentan etiquetado, por lo tanto, lo que buscan este tipo de modelos es obtener la mayor cantidad de información sin tener conocimiento de la variable respuesta. Siendo los modelos de agrupación o clustering y reducción dimensional, tipos de aprendizaje no supervisado. (Roman, 2019)
- *Observaciones*: Es simplemente el valor que toma la medida de cualquier cosa, como, el peso de una persona, el tamaño de un lápiz, etc.
- *Features o Característica*: Dentro de los términos utilizados en machine Learning, se entiende que features o características, son las variables independientes que se encuentran e interactúan dentro de un sistema dado (Brown, 2019).
- *Serie de tiempo*: Es el conjunto de observaciones que toma una variable cuantitativa en el transcurso del tiempo, representando dichos datos de forma estructurada (Brown, 2019).
- *Función de pérdida*: Las funciones de pérdida miden qué tan lejos está un valor estimado de su valor real, por este motivo, dichas funciones juegan un papel importante al momento de desarrollar un modelo, ya que permite evaluar el rendimiento del modelo y sus parámetros aprendidos, ya que se busca minimizar la función de pérdida. (Prashanth, 2021)
- *Imputación de datos*: Se utiliza esta técnica para el tratamiento de datos faltantes o nulos dentro de una base de datos, es así que, se pueden reemplazar dichos valores por nuevos valores según sea el método (Muñoz y Álvarez, 2009).

2.4. Hipótesis

Es de esperar que el diseño de una red neuronal recurrente multivariada logrará obtener una mejor predicción de los datos que el modelo del Plan de producción estimado actual de corto plazo, ya que utilizará la mayor cantidad de variables operativas para realizar la predicción, lo que se reflejará en una reducción de remanaje de materia.

2.5. Variables

2.5.1. Variable dependiente:

Cantidad de mineral de alimentación a la chancadora primaria en toneladas métricas húmedas.

2.5.2. Variable independiente:

Las redes neuronales recurrentes LSTM.

CAPÍTULO III

3. Marco Metodológico

3.1. Alcances y Limitaciones

3.1.1. Alcance

La utilización de datos históricos reales de Dispatch, planeamiento y planta permitirá diseñar y entrenar un modelo que puede generalizar de manera precisa, siendo su punto de objetivo lograr una correspondencia entre las TN de alimentación a chancadora primaria y el planeamiento de minado de una operación de gran minería.

3.1.2. Limitaciones

La estructura y distribución de los datos que se obtengan será una limitación, ya que se podrán observar que las variables estarán en una magnitud diferente entre sí, así como también el formato en la que se encuentre para poder transportarlas en una hoja de cálculo para luego ser utilizados como “.csv”.

Por otro lado, por motivos de confidencialidad de datos de la empresa, no se cuenta con el permiso para la divulgación de la información, por lo tanto, no se mencionará el nombre de la entidad.

3.2. Tipo y Nivel de la Investigación

El tipo de investigación es correccional ya que se utilizará variables, siendo la variable independiente la causa y la variable dependiente la consecuencia o resultado.

El nivel de investigación es aplicada ya que se busca aplicar la utilización de las redes neuronales para la elaboración de un modelo de predicción que sea capaz de estimar la cantidad de material que puede procesar la chancadora primaria.

3.3. Población y Muestra

3.3.1. Población

Los Datos históricos de los años 2018 y 2019, siendo un total de 1321 registros y 19 variables (también se especifica el nombre de la columna correspondiente a cada variable), siendo:

- Fecha
- Fase de Origen (fase_origen)
- Banco de Origen (banco_origen)
- Destino (destino)
- Material: MA, MB, MC; los remanejo MA, remanejo MB, remanejo MC, es lo mismo solo que es material sacado de los stocks y no directamente del tajo (material)
- TN enviada a stock por inoperatividad de chancadora: Las TN enviadas a stock por inoperatividad de chancadora primaria se da cuando la chancadora no está operativa por alguna falla mecánica o por demoras operativas (tn_inop)
- Envío o no envío de material a la chancadora (envio_inop)
- Ley de cobre (cu_ley)
- Ley de zinc (zn_ley)
- Arsénico, que es un contaminante (arsénico)
- Hierro, que es un contaminante (hierro)
- Disponibilidad de chancadora (disp_chan)
- Utilización de chancadora (util_chan)

- Disponibilidad de palas (disp_pala)
- Utilización de palas (util_pala)
- Disponibilidad de camiones (disp_cami)
- Utilización de camiones (util_cami)
- TN chancadas por la chancadora primaria (tn_chanc)

Y la variable respuesta:

- TN por día enviado a chancadora primaria (tn_enviado)

3.3.2. Muestra

En este caso en específico lo que se busca es poder utilizar toda la data posible para poder entrenar de manera eficiente el modelo de LSTM, por lo que se utilizarán las 1321 observaciones o datos registrados junto con todas las variables.

3.4. Método, Técnicas e Instrumentos de Recolección de Datos

3.4.1. Instrumentos para la recolección de datos

Los datos serán recolectados de la base de datos histórica de la empresa, en donde se extraerán las variables mencionadas anteriormente, dicha base de datos se trasladará a un nuevo archivo de Excel que será guardado con la extensión “.csv”, para su utilización dentro del entrenamiento del modelo de LSTM.

Después de haber limpiado los datos de datos nulos o “N.A.” se procederá a entrenar los modelos de LSTM, los resultados de las predicciones serán guardados en otro archivo “.csv” para su análisis exploratorio.

Así mismo, para realizar el diseño y entrenamiento de dicho modelo se utilizará el lenguaje Python con la librería Keras TensorFlow, dentro de la herramienta

que presenta Google que se llama “Google Collaborative”, que es una plataforma virtual que permite el uso de potenciadores de procesamiento como el GPU (Unidad de Procesamiento Gráfico) o TPU (Unidad de Procesamiento de Tensores) de forma gratuita, para poder disminuir los tiempo de procesamiento. En esta plataforma se crearon los diferentes notebooks donde se encontrarán los scripts de Python con el diseño de las redes neuronales.

3.4.2. Técnicas para la recolección de datos

a) *Entorno de Python*

Se utilizará un entorno de Python superior a la versión 3.0, con la librería Keras 2.0 o superior, y esta a su vez con TensorFlow 2.2 o superior. Así mismo, como algunas librerías útiles para la manipulación de los datos como Pandas, NumPy, scikit-learn y Matplotlib.

b) *Análisis Exploratorio y Preparación de los Datos*

Con los datos extraídos se realizará un análisis exploratorio para poder identificar qué características tienen las variables estudiadas, así como encontrar algunas inconsistencias y valores que sean nulos o que no pertenezcan a la base de datos. También se analizará de manera preliminar cual es la evolución en el tiempo de la variable respuesta.

Los datos se deberán consolidar según la fecha, para esto se utilizará la librería Pandas. Así mismo se verificará si se encuentran valores nulos y se eliminaran dichas celdas, así como también posibles datos que no pertenezcan a la variable, es decir si la variable es numérica se eliminaran

los datos sean categóricos (señales o indicaciones). Para esto se seguirán los siguientes pasos:

- i. El primer paso es la recolección de todos los datos con su fecha, que luego fueron establecidos como el índice de los datos.
- ii. Se evaluaron la presencia de valores nulos o NA, para poder luego hacer alguna imputación por medio de una técnica de imputación de datos como el método de agrupación de Kmeans, que es comúnmente utilizada para el reemplazo de datos.
- iii. Luego se extraen gráficas y estadísticos que describieron los datos de manera general.

c) *Desarrollo del modelo LSTM y las predicciones*

Primero se prepara la base de datos, que se limpió anteriormente, para el entrenamiento de la LSTM. Para esto se convertirá dichos datos como si fuera un problema de aprendizaje supervisado y luego se normalizarán las variables independientes, ya que podemos estar ante variables de diferente magnitud.

Con los datos ya listos para su entrenamiento se realizará el diseño de la red neuronal (LSMT), para esto se dividirán los datos tanto para entrenamiento como para prueba, luego estos datos de entrenamiento serán convertidos en un vector de 3 dimensiones (no desde el punto de vista geométrico) por medio de una transformación algebraica.

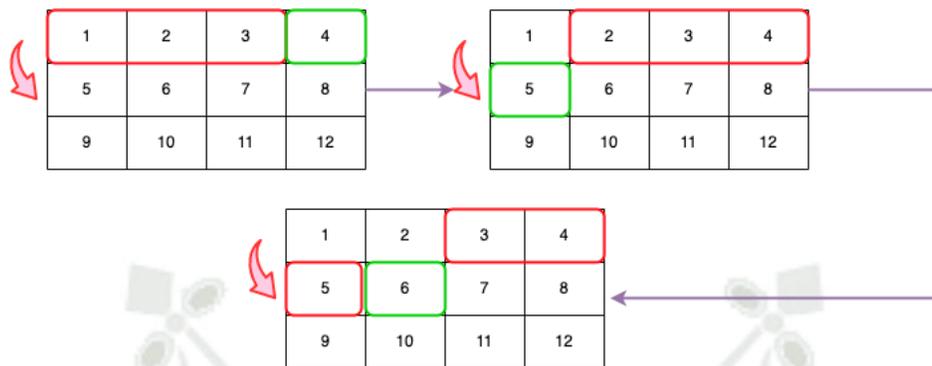
Se utilizará un LSTM de 120 neuronas en la primera capa y 1 una sola neurona de salida, que representa a que solo se predecirá la cantidad de

material TN que va a la chancadora (Brownlee, 2017). Asimismo, como otro parámetro de interés que se tiene que manejar dentro del diseño de redes neuronales, se debe establecer como función de pérdida al promedio error cuadrático medio (RMSE) y como optimizador de la gradiente se utilizará Adam. Finalmente, se hizo un seguimiento de la pérdida de durante el entrenamiento estableciendo el parámetro “*validation_data*” en la función “*fit()*”, al final se graficaron los resultados de pérdida o error tanto para el entrenamiento como para la prueba (Brownlee, 2017). Para esto se debieron hacer los siguientes pasos:

- i. Se consideró el presente problema como un problema de aprendizaje supervisado.
- ii. Para esto se desarrolló una nueva función de python llamada `series_to_supervised()`, para hacer la transformación correspondiente a un problema supervisado, esta función se desarrolló dentro del notebook de entrenamiento en Google Colaboratory. Es decir, se convierten los datos de tal manera, que el dato anterior permite el aprendizaje del siguiente dato, como se muestra en la figura 7:

Figura 7.

Ejemplo de la transformación la función series_to_supervised



Fuente: Elaboración propia

- iii. Se carga el conjunto de datos del archivo con extensión “csv”, y luego se aplicó la función anteriormente desarrollada.
 - iv. Podemos ver las 19 variables de entrada (serie de entrada) y la 1 variable de salida.
- **Definir y ajustar el modelo**
 - i. Con estos pasos se buscó establecer un modelo de LSTM para la serie o datos utilizados para esta tesis.
 - ii. Se separaron los datos en dos conjuntos, uno de entrenamiento y otro de prueba.
 - iii. Finalmente, las entradas (X) se reformularon en un vector de 3 dimensiones, no geoméricamente sino matricialmente, esperado por los LSTMs, es decir, [muestras, pasos de tiempo, características].
 - iv. Luego se construyó de forma preliminar la red neuronal con 60 neuronas en la capa dense de inicio y una LSTM con 120 neuronas

como primera capa y finalmente 1 sola neurona en la capa de salida para predecir las toneladas enviadas (“tn_enviado”).

- v. Se utilizó el error cuadrático medio (RMSE) como función de pérdida y como optimizador de gradiente Adam.
- vi. El modelo fue entrenado con 40 épocas o iteraciones de entrenamiento con un tamaño de batch de 70, es decir, realiza un muestreo de los datos cada 70 filas de manera aleatoria, dichos son utilizados para cada iteración de entrenamiento.

3.5. Análisis Estadístico

Primero se realizará un análisis descriptivo para poder conocer cuál es el comportamiento de los datos en general, para esto se extraerán algunos parámetros descriptivos como el promedio, media, rango, varianza entre otros, así como también se realizarán diferentes graficas que apoyen para el análisis preliminar de los datos.

Una vez obtenido el modelo, se podrá generar pronósticos, de estos valores se les extraerá el error que tengan en comparación de los datos reales en su escala real, para esto se utilizará el error cuadrático medio (RMSE) que da el error en las mismas unidades de la propia variable. (Brownlee, 2017)

También se calcularán algunas otros parámetros de desempeño del modelo como: el error cuadrático medio o RMSE por sus siglas en inglés (Root Mean Square Error), ya que con esta métrica se pudo evaluar la diferencia entre los datos originales y los datos que son predichos con el modelo, buscándose el menor valor de error posible.

Muharemi et al. (2019) define las siguientes métricas como:

- **Raíz del error cuadrático medio (RMSE):** es la tasa de error por la raíz cuadrada del error cuadrático medio o MSE; el RMSE es una métrica más fácil de interpretar estadísticamente, ya que mantiene las mismas unidades que la cantidad medida en el eje y, debido a que compara el valor predicho con el valor original de la serie. El RMSE se puede interpretar directamente en términos de unidades de medida y, por lo tanto, es una mejor medida de ajuste que un coeficiente de correlación (Formula 3).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \dots\dots\dots (3)$$

CAPÍTULO IV

4. Modelo Propuesto

4.1. Análisis e Interpretación de Resultados

4.1.1. Análisis exploratorio de datos

Antes de haber iniciado el desarrollo del modelo de Redes Neuronales (LSTM), se realizó un análisis exploratorio de los datos, con el objetivo de poder identificar cual es el tipo de datos de cada una de las variables, asimismo, identificar la distribución que cuentan los datos.

Figura 8.

Resultados descriptivos de la base de datos

```

--- Data Summary ---
Name                Values
Number of rows      1321
Number of columns    19

-----
Column type frequency:
character            5
numeric              14

-----
Group variables      None

--- Variable type: character ---
skim_variable  n_missing  complete_rate  min  max  empty  n_unique  whitespace
1 fecha        0           1      7   8     0       730        0
2 fase_origen  0           1      1   7     0         4        0
3 banco_origen 0           1      1  11     0        39        0
4 destino      0           1     19  19     0         1        0
5 material     0           1      1  18     0         7        0

--- Variable type: numeric ---
skim_variable  n_missing  complete_rate  mean  sd  p0  p25  p50  p75  p100  hist
1 tn_enviada   0           1  62243.  43011.  0  20919  70530  99341  132099
2 tn_inop     1157        0.124  15467.  17789.  231  303  1772  31997.  63674
3 enviado_inop 0           1      0.124  0.330  0  0  0  0  1
4 cu_ley      0           1      0.856  0.196  0  0.76  0.82  1.02  1.16
5 zn_ley      10          0.992  0.466  0.521  0  0  0  1.04  2.1
6 arsenico    0           1      34.0  19.7  0  15  36  50  74
7 hierro      2           0.998  10.3  4.10  0  8  10  12  25
8 disp_chan   0           1      0.952  0.104  0  0.96  0.98  0.99  1
9 util_chan   0           1      0.854  0.109  0  0.86  0.89  0.9  1
10 disp_pala  0           1      0.832  0.0842  0.49  0.77  0.83  0.9  0.97
11 util_pala  0           1      0.816  0.0568  0.63  0.78  0.82  0.86  0.91
12 disp_cami  0           1      0.902  0.0451  0.77  0.87  0.91  0.94  0.97
13 util_cami  0           1      0.821  0.0548  0.6  0.78  0.82  0.87  0.93
14 tn_chanc   14          0.989  5951.  111.  5700  6000  6000  6000  6000
    
```

Fuente: Elaboración Propia

Como se puede observar en la figura 8 los resultados obtenidos con RStudio y el paquete skimR, la base de datos cuenta con 1321 observaciones que se encuentran registrados según la fecha, que no necesariamente son datos únicos registrados en un día, ya que en un solo día se pueden registrar más de una operación; asimismo, también la base de datos extraída cuenta con un total de 19 variables.

Por otro lado, en cuanto al tipo de datos, se puede observar que 5 de las variables son de tipo “carácter”, 13 de tipo “numérica” y 1 de tipo “fecha”.

a) Variables Categóricas

Para los datos tipo carácter se cuenta con las siguientes variables:

- fase_origen
- banco_origen
- destino
- material
- tn_enviado

Todas estas variables no cuentan con valores nulos o N.A., por otro lado, se puede observar que existe una incongruencia con la variable “tn_enviado”, ya que se espera que esta variable sea de tipo numérica y no tipo carácter, y esto se debe a que dentro de esta columna existen caracteres especiales como guiones (“ - “), en reemplazo de valores nulos. Estos valores nulos se deben a que existen días en los que no se realizan operaciones por motivos de mantenimiento de las diferentes unidades en la mina. Estas observaciones en donde se encuentran los guiones deben ser

reemplazados por “0”, ya que esta es la variable respuesta para generar el modelo.

b) Variables de Fecha

En cuanto a la única variable tipo fecha (fecha), se puede encontrar que no existen valores nulos, y va desde el 01 de enero de 2018 hasta el 31 de diciembre de 2019. Sin embargo, los valores registrados se pueden realizar en un mismo día, por este motivo, en la figura 7 se observa que solo existen 730 fechas únicas y no 1321.

c) Variables Numéricas

En cuanto a las 13 variables numéricas en la figura 7 se puede observar que, si existe una gran cantidad de valores nulos dentro de la base de datos, especialmente en las variables, “tn_inop” con 1157 datos nulos, “zn_ley” con 10 datos nulos, “hierro” con 2 datos nulos y “tn_chanc” con 14 datos nulos, esto se debe a que al igual que en las variables categóricas, existieron días en los que no se registraron datos.

Por otro lado, según la columna “hist” de la figura 7 muestra que la gran mayoría de las variables numéricas no cuentan con una distribución normal, por lo que demuestra que hacer un análisis con técnicas tradicionales de estadística multivariado significaría aumentar la complejidad matemática del modelo.

4.1.2. Preprocesamiento e imputación de datos

El preprocesamiento de los datos se aplicó tanto en las variables numéricas como categóricas, en donde se realizaron las siguientes operaciones:

- *Para la variable “fase_origen”*: se hizo una imputación o sustitución de datos en donde se cambió aquellas observaciones en donde se encontraron guiones por el carácter “No proceso”, ya que no se realizó ningún proceso, debido a mantenimientos o paradas programadas.
- *Para la variable “banco_origen”*: se hizo el cambio de todas las observaciones que fueron guiones por el carácter “No proceso”.
- *Para la variable “material”*: También se hizo el cambio de aquellas observaciones que tienen guiones por “No proceso”.
- *Para la variable “tn_inop”*: se hizo una imputación sencilla, colocando 0 en aquellos registros que fueron nulos, y esto se hizo dado que existen fechas en las cuales no se envió material a la chancadora por inoperatividad.
- *Para la variable “zn_ley”*: en esta variable se cambiaron los valores nulos por 0 dado que existen tipos de material que no tienen zinc dentro de su composición.
- *Para la variable “tn_chanc”*: dado que existen fechas en las cuales no se realizaron operaciones con la chancadora, se imputaron aquellos valores nulos con 0.
- *Para la variable “cu_ley”*: dado a que existieron fechas en las cuales no hubo operaciones mineras, se cambiaron todos los guiones por 0.
- *Para la variable “zn_ley”*: además de los valores nulos también se cambiaron las observaciones con guiones por 0.

- Para la variable “arsenico”: también se hizo el cambio de guiones por cero.
- Para la variable “hierro”: en esta variable se hicieron dos imputaciones, una primera imputación simple para cambiar los guiones por cero, y una segunda imputación por medio de KNN, dado que son tan solo 2 registros nulos y según el contexto en el cual se encuentran estos valores, no pueden ser 0, por lo que la técnica KNN permite hacer una correcta imputación.
- Para la variable “tn_enviado”: por último, para esta variable se hizo el reemplazo de guiones por 0, dado que, en la columna existe estos guiones hace que el tipo de variable se reconozca erróneamente.

Como resultado de las imputaciones, se obtuvo lo que se muestra en la figura 9.

Figura 9.

Resultados descriptivos de los datos imputados

```

--- Data Summary ---
Name                Values
df.imputed          1321
Number of rows      1321
Number of columns   19

-----
Column type frequency:
character           5
numeric            14

-----
Group variables     None

--- Variable type: character ---
skim_variable n_missing complete_rate min max empty n_unique whitespace
1 fecha        0          1 7 8 0 730 0
2 fase_origen  0          1 7 10 0 4 0
3 banco_origen 0          1 4 11 0 39 0
4 destino      0          1 19 19 0 1 0
5 material     0          1 9 18 0 7 0

--- Variable type: numeric ---
skim_variable n_missing complete_rate mean sd p0 p25 p50 p75 p100 hist
1 tn_enviado  0          1 62243. 43011. 0 20919 70530 99341 132099
2 tn_inop    0          1 1920. 8069. 0 0 0 0 63674
3 send_inop  0          1 0.124 0.330 0 0 0 0 1
4 cu_ley     0          1 0.856 0.196 0 0.76 0.82 1.02 1.16
5 zn_ley     0          1 0.463 0.521 0 0 0 1.04 2.1
6 arsenico   0          1 34.0 19.7 0 15 36 50 74
7 hierro     0          1 10.3 4.10 0 8 10 12 25
8 disp_chan  0          1 0.952 0.104 0 0.96 0.98 0.99 1
9 util_chan  0          1 0.854 0.109 0 0.86 0.89 0.9 1
10 disp_pala 0          1 0.832 0.0842 0.49 0.77 0.83 0.9 0.97
11 util_pala 0          1 0.816 0.0568 0.63 0.78 0.82 0.86 0.91
12 disp_cami 0          1 0.902 0.0451 0.77 0.87 0.91 0.94 0.97
13 util_cami 0          1 0.821 0.0548 0.6 0.78 0.82 0.87 0.93
14 tn_chanc  0          1 5888. 619. 0 6000 6000 6000 6000
    
```

Fuente: Elaboración Propia

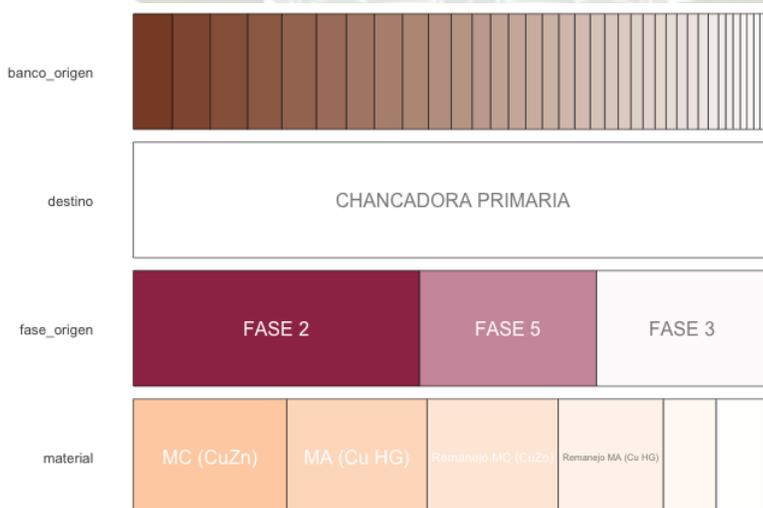
Como se puede observar en la figura 9 ya no existen variables numéricas con datos nulos, y además la variable “tn_enviado” (variable respuesta), se encuentra bien clasificada.

a) Variables Categóricas preprocesadas

Como se puede observar en la figura 10, la variable “banco_origen” que representa el banco de origen del material a chancar, tiene una gran cantidad de niveles o valores unitarios; la variable “destino” solo existe un nivel, la variable “material” presenta 7 niveles, de los cuales los niveles “MC (CuZn)”, “MA (Cu HG)” y “Remanejo MC (CuZn)” son los que tienen mayor frecuencia. Y en cuanto, a la variable “fase_origen”, cuenta con 4 niveles, de los cuales “fase 2” es la fase que presenta mayor frecuencia a comparación de las otras fases.

Figura 10.

Frecuencia de los niveles de las variables categóricas

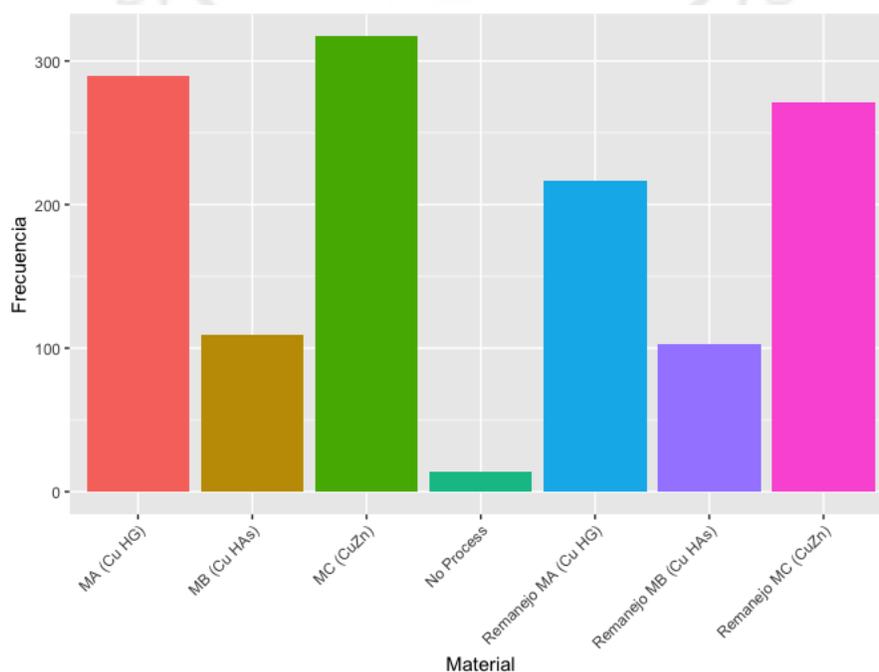


Fuente: Elaboración Propia

Por otro lado, como se puede observar en la figura 11, los materiales que tienen mayor frecuencia son “MC (CuZn)”, “MA (Cu HG)” y “Remanejo MC (CuZn)”, mientras cuando no hubo operaciones (“No proceso”) tienen una muy baja frecuencia, eso significa que existieron pocos eventos de mantenimientos o que estos estuvieron correctamente programados.

Figura 11.

Frecuencia de cada material



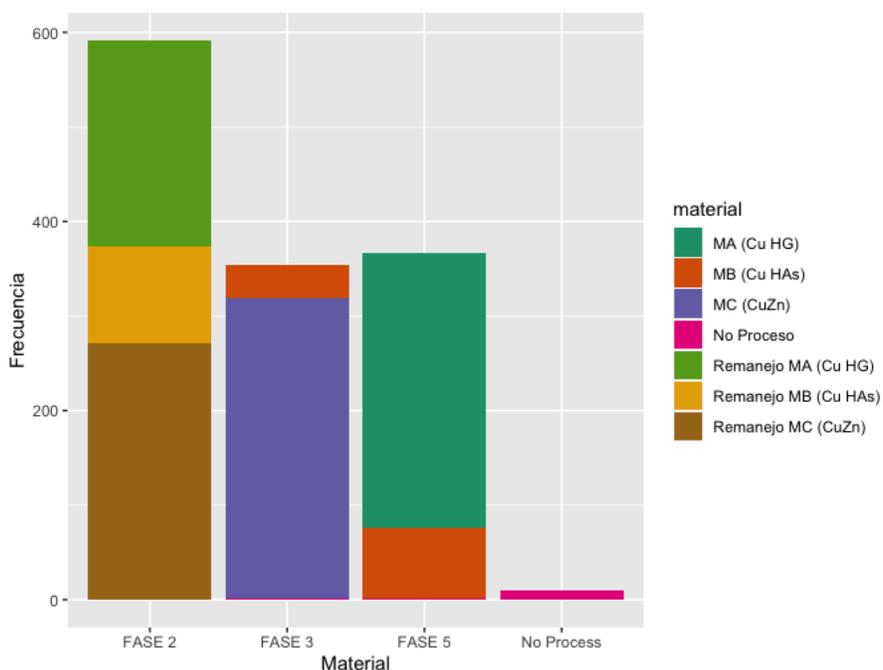
Fuente: Elaboración Propia

Asimismo, en la figura 12 se muestra la frecuencia que tiene cada tipo de material por cada fase de origen de donde proviene; como se puede observar en la “fase 2” se manejan 3 tipos de materiales que son el Remanejo MA (Cu HG), Remanejo MB (Cu Has) y Remanejo MC (CuZn); mientras que en la “fase 3” tan solo se encuentran el material MC (CuZn); mientras que en la “fase 3” tan solo se encuentran el material MC (CuZn) en mayor frecuencia y el MB (Cu HAs) en menor frecuencia; por

último, en la “fase 5”, se tiene que en mayor frecuencia se encuentra el MA (Cu HG) y el MB (Cu HAs).

Figura 12.

Frecuencia del tipo de Material según la fase de origen

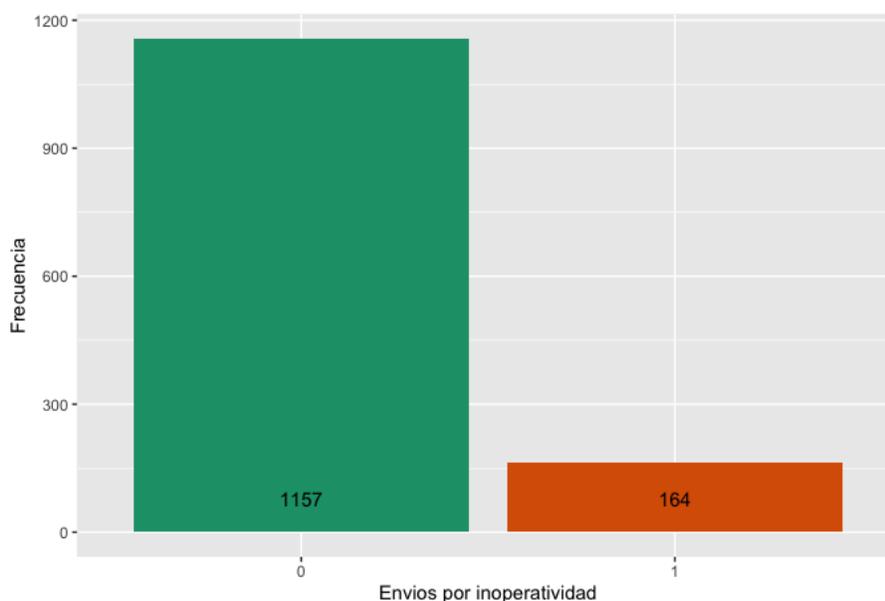


Fuente: Elaboración Propia

Por último, en la figura 13 se muestra cuantos envíos fueron enviados al stock por inoperatividad de la chancadora, siendo tan solo 164 veces que se enviaron por inoperatividad de un total de 1321 registros tomados.

Figura 13.

Frecuencia de envíos por inoperatividad de la chancadora primaria



Fuente: Elaboración Propia

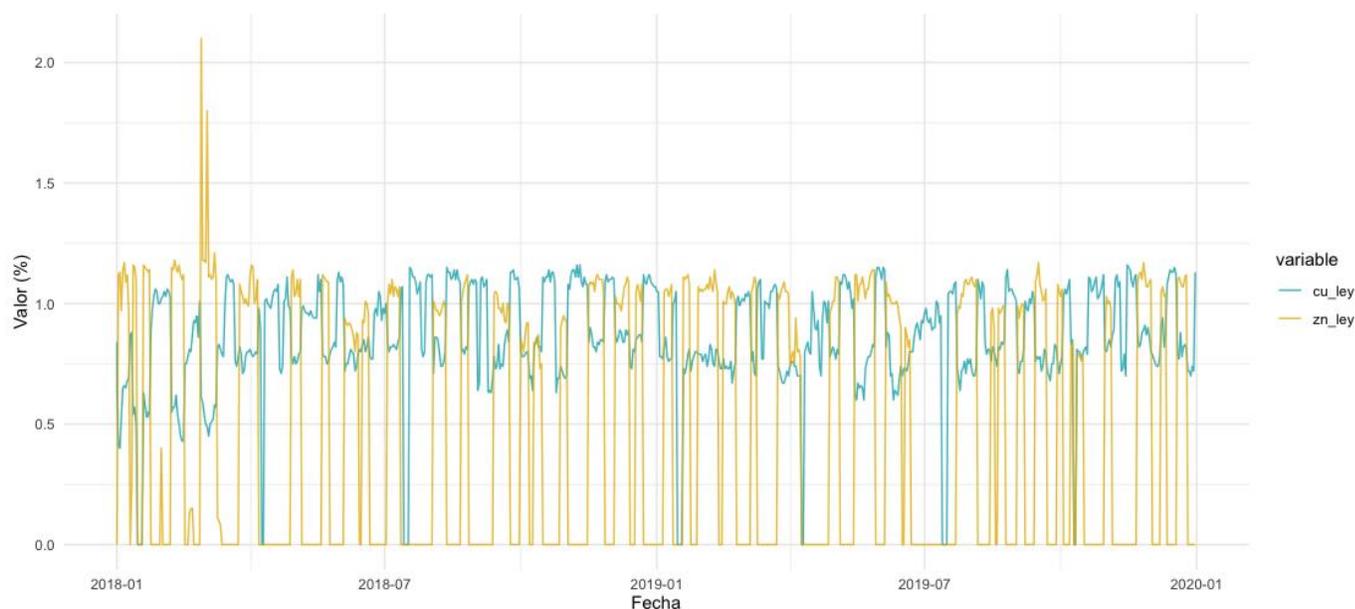
b) Variables numéricas preprocesadas

En cuanto a las variables numéricas, lo que normalmente se puede observar son diferentes series de tiempo que muestran la evolución de un fenómeno en el transcurso de un tiempo que se define en la base de datos.

En la figura 14 se puede observar cómo es el comportamiento en cuanto a la ley de cobre y de zinc, en el tiempo estudiado; como se puede observar, que durante los años 2018 a 2019, que normalmente la ley de cobre es inversamente proporcional con la ley de zinc.

Figura 14.

Series de tiempo para la ley de cobre y zinc entre el año 2018 y 2019

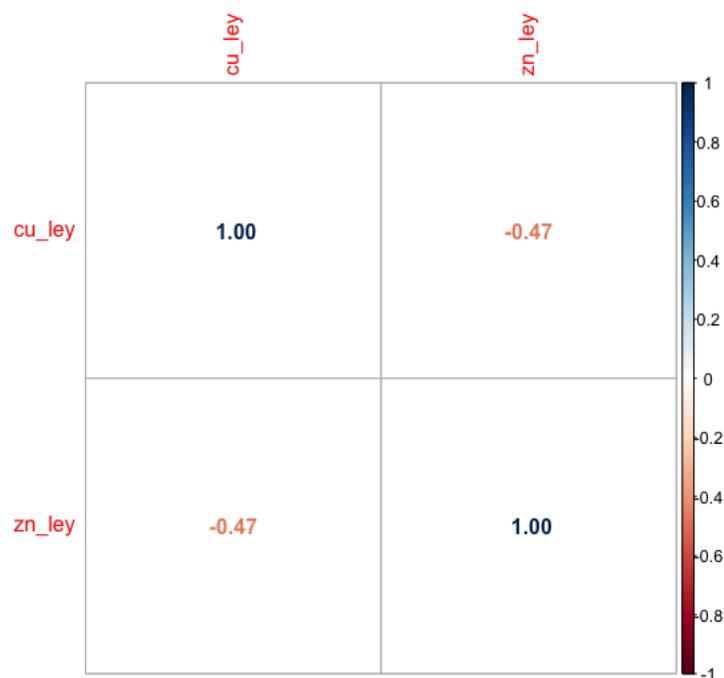


Fuente: Elaboración Propia

Esta correlación se puede observar en la figura 15, en donde se muestra el coeficiente de correlación de Pearson para estas dos variables, en donde de una escala de 1 a -1, estas dos variables tienen una correlación de -0.47, lo que demuestra el comportamiento inverso antes mostrado.

Figura 15.

Correlación de Pearson para la ley de cobre y zinc



Fuente: Elaboración Propia

Por otro lado, en la figura 16, se muestra una comparación entre la disponibilidad y utilización de la chancadora en una serie de tiempo desde el 2018 al 2019, como se puede observar, normalmente la utilización de la chancadora no alcanza el 100% de la disponibilidad, salvo ciertos puntos, en promedio la utilización de la chancadora es del 85%, mientras que la disponibilidad es del 95%. Sin embargo, existieron eventos en donde la utilización de la chancadora alcanzo el 100% de la disponibilidad.

Figura 16.

Serie de tiempo para la disponibilidad y utilización de la chancadora

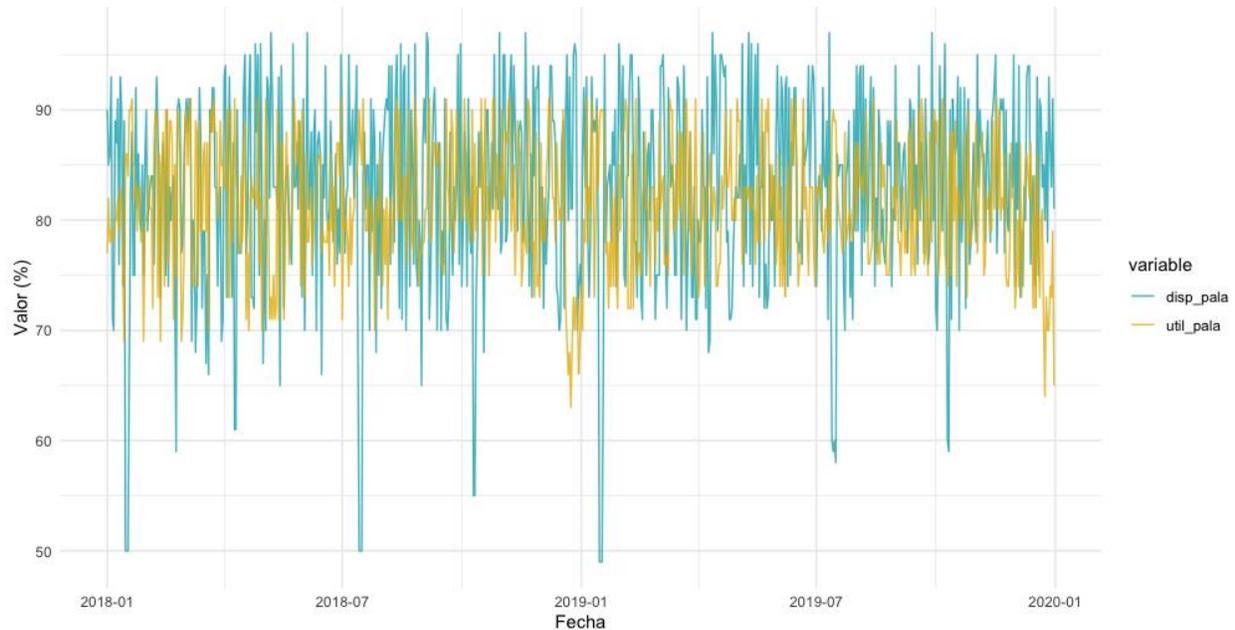


Fuente: Elaboración Propia

No obstante, en cuanto a la comparación de la disponibilidad con la utilización de la pala (figura 17), se puede observar que estas dos variables comparten un mismo comportamiento, sin presentar tendencia a lo largo de la serie de tiempo, pero si una estacionalidad de esta.

Figura 17.

Serie de tiempo para la disponibilidad y utilización de la pala



Fuente: Elaboración Propia

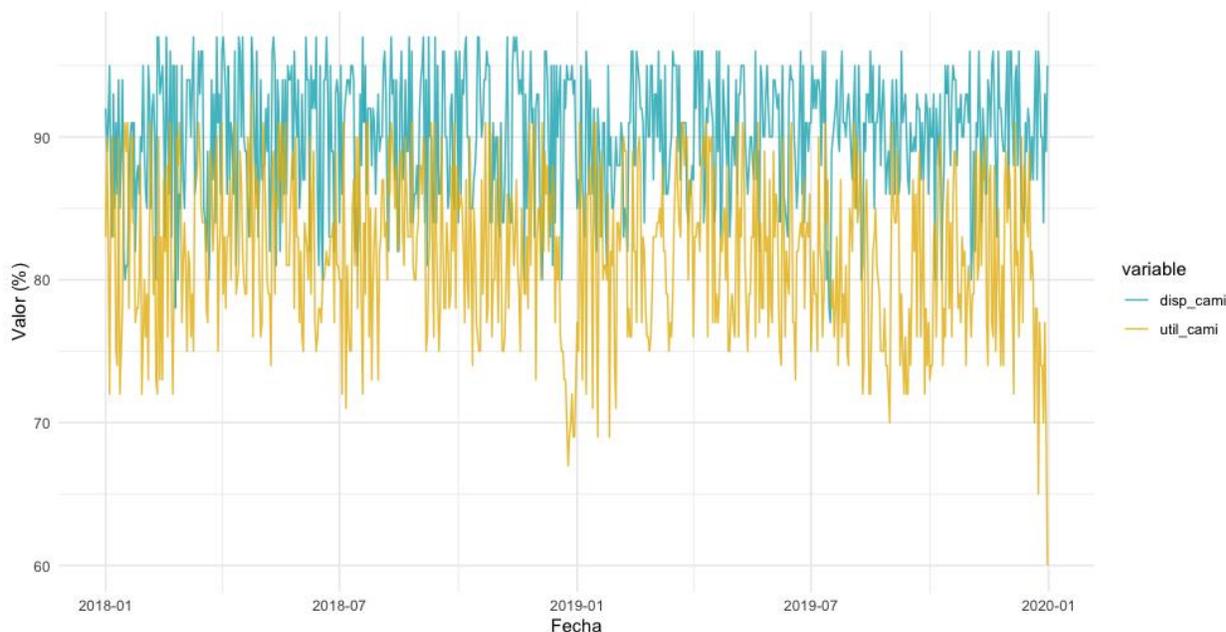
El promedio de la disponibilidad es del 83% y para la utilización es del 81%. Sin embargo, según los datos registrados en la figura 17, a finales del año 2019 se puede observar un descenso en la utilización de la pala muy significativo, separándose de la línea de tiempo de la disponibilidad, lo cual representa una anomalía en dicha serie, debido a que a finales de año se incrementa el ausentismo de los trabajadores considerablemente por fiestas de navidad y año nuevo.

Por otro lado, en la figura 18 se muestra la comparación entre la disponibilidad de los camiones y la utilización de estos entre los años 2018 a 2019, como se puede observar, la utilización de los camiones se encuentra por debajo de la disponibilidad de estos, ya que en promedio se

tiene una disponibilidad de 90% mientras que la utilización en promedio es del 82%.

Figura 18.

Serie de tiempo para la disponibilidad y utilización de camiones



Fuente: Elaboración Propia

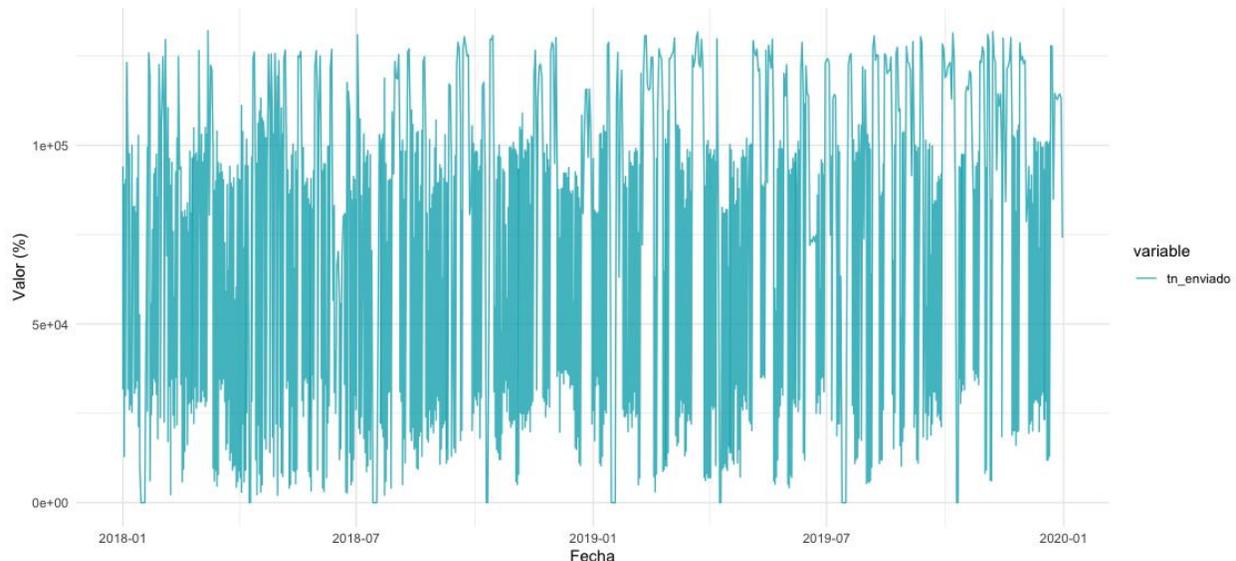
Este comportamiento se puede ver afectado a que, al igual que la utilización de la pala, la utilización de los camiones disminuye considerablemente a finales del 2019, separándose totalmente de la disponibilidad. Este comportamiento a finales 2019 e inicios del 2020, se puede atribuir a la reducción del personal por motivo de las fiestas de fin de año.

En cuanto a la variable respuesta, cantidad de toneladas enviadas a la chancadora (“tn_enviado”), en la figura 19 se muestra el comportamiento que tiene esta variable en una serie de tiempo entre el 2018 al 2019; como

se puede observar, esta variable no presenta tendencia, siendo su evolución homogénea a lo largo del tiempo, tiene estacionalidad, ya que se pueden observar una repetitividad de ciertos picos en fechas similares.

Figura 19.

Serie de tiempo para la cantidad de toneladas enviadas ("tn_enviado")



Fuente: Elaboración Propia

4.1.3. Descripción de Variables utilizadas

Después de haber realizado el análisis exploratorio en la sección anterior, se tomaron algunas decisiones acerca de que variables se pueden utilizar para el desarrollo del modelo, por tal motivo no se tomaron en cuenta las siguientes variables:

- **Destino:** Dado que para este estudio solo se manejó un solo destino (chancadora primaria), no se tomó en cuenta esta variable por ser constante.

- **tn_inop:** Esta variable refleja las toneladas de mineral enviadas a los stocks, sin embargo, para motivos de entrenar el modelo, se puede utilizar una variable dicotómica en lugar de las cantidades, es decir, si se envió o no material al stock; para esto se tiene la variable “envio_inop”.
- **fase_origen:** Esta variable fase_origen: Es la fase de origen en donde existen diferentes fases, sin embargo, esta variable no se encuentra balanceada ya que, en la mayoría de los registros se tiene que la “Fase 2” es la que presenta mayor frecuencia, lo que puede incrementar el error del modelo a entrenar.

Por consiguiente, las siguientes variables son las que se tomaron en cuenta para el entrenamiento del modelo:

1. **Fecha:** Dado que es un análisis de series de tiempo, los datos fueron ordenados de manera progresiva según la fecha de cada registro en la base de datos.
2. **Tipo de material (material):** es el tipo de mineral en donde se engloban todas las características como dureza, cohesión, humedad y otras propiedades que son intrínsecas de la roca. Para este caso se tomó la clasificación que una empresa minera realiza, resultando 3 tipos de materiales. Es una variable categórica.
3. **Leyes de cabeza (“cu_ley”, “zn_ley”):** Las leyes influyen en la dureza del material a alimentar, ya que los minerales tienen una dureza diferente a las rocas que contienen este mineral, por tal motivo a mayor o menor ley

de mineral esto puede aumentar o disminuir la dureza del material a alimentar a la chancadora.

4. **Presencia de contaminantes (“hierro”, “arsénico”):** Esta variable representa la presencia de hierro y arsénico que son contaminantes y también tiene influencia sobre las características del mineral, otorgándoles variaciones en la dureza del mineral, siendo importante dada su presencia según el banco de origen, influenciando en la eficiencia de chancado.
5. **Banco de minado (“banco_origen”):** Esta variable está relacionada con la zonificación del material ayudando a poder entender la clasificación que se le da a los tipos de material junto con sus propiedades.
6. **Disponibilidad y utilización mecánica:** Para esta variable se tomaron en cuenta 3 unidades que son: las palas, la chancadora y los camiones. Esto sirve ya que dependiendo de las horas netas que trabajen estos equipos va a depender la cantidad de material chancado. La utilización de la chancadora está relacionada con la disponibilidad y utilización de la camiones y palas, variables que se están usando en el modelo (“disp_chan”, “util_chan”, “disp_pala”, “util_pala”, “disp_cami” y “util_cami”).
7. **Material enviado a stock (“envio_inop”):** Como se mencionó anteriormente, esta variable se consideró ya que es una variable dicotómica que engloba el hecho de que si se envió o no material al stock.
8. **Toneladas chancadas por hora (“tn_chanc”):** Representa las toneladas que se chancan por hora.

Por lo tanto, para entrenar modelos se utilizaron 14 variables, sin embargo, hay que considerar que se tienen dos variables categóricas (banco_origen y material) las cuales tienen una cantidad de niveles, 38 y 7 respectivamente, que, para entrenar el modelo cada nivel se tiene que separar como una variable independiente dicotómica (1 o 0), por lo que al final de hacer las transformaciones necesarias a la base de datos se obtiene un total de 58 variables.

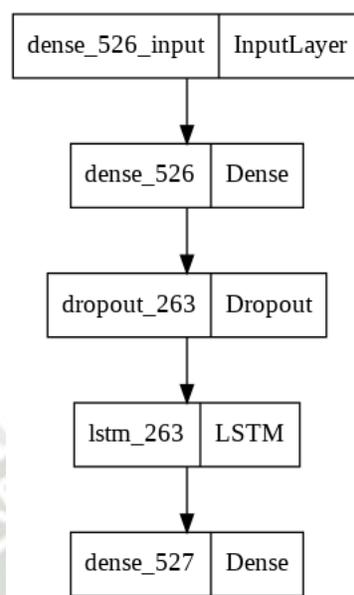
4.2.Desarrollo del Modelo de Redes Neuronales LSTM

A. Modelo Preliminar

Para el desarrollo del modelo de LSTM, primero se realizó un modelo preliminar, como se muestra en la figura 20, asimismo, también se excluyeron las variables “destino”, “tn_inop”, “fase_origen”, dado que estas variables tienen un comportamiento casi constante durante el tiempo.

Figura 20.

Estructura del modelo de predicción multivariado



Fuente: Elaboración Propia

En la figura 20 se muestra la estructura que se utilizó como base para el desarrollo del modelo, según lo recomendado por Brownlee (2017), a dicho modelo se le aplicaron algunas modificaciones como la cantidad de neuronas en la capa densa de entrada. Como se puede observar el modelo sigue un flujo dentro de diferentes capas de redes neuronales que brinda la librería Keras. Todo comienza con una capa densa de entrada, luego pasa por una capa Dropout al 50% o 0.5, para evitar el overfitting o el underfitting, que son términos para evaluar el sobreajuste del modelo según los datos; después se utiliza una capa de LSTM, y por último se cuenta con una capa densa de salida, que devuelve el valor predicho después de que los datos pasan por todo este flujo.

En la figura 21 se muestra la cantidad de neuronas que se establecieron preliminarmente en cada una de las capas del modelo; siendo, para la primera capa densa, 60 neuronas con 3600 parámetros para el entrenamiento, luego la capa

Dropout que contiene la misma cantidad de neuronas que la primera y sin ningún parámetro entrenable, ya que esta capa, es solo un filtro de los datos; luego la capa LSTM con 120 neuronas y 86880 parámetros entrenables, y por último la capa densa con solo una neurona y 121 parámetros entrenables. En total se suman una cantidad de 90601 parámetros entrenables.

Figura 21.

Estructura y características del modelo de redes neuronales

```
Model: "sequential_263"
```

Layer (type)	Output Shape	Param #
dense_526 (Dense)	(None, 1, 60)	3600
dropout_263 (Dropout)	(None, 1, 60)	0
lstm_263 (LSTM)	(None, 120)	86880
dense_527 (Dense)	(None, 1)	121

```

=====
Total params: 90,601
Trainable params: 90,601
Non-trainable params: 0
=====

```

Fuente: Elaboración Propia

Figura 22.

Código en python para el desarrollo del modelo preliminar

```

model = Sequential()
model.add(Dense(60))
model.add(Dropout(0.50))

model.add(LSTM(120, input_shape=(train_X.shape[1], train_X.shape[2])))
model.add(Dense(1))

model.compile(loss='mean_squared_error', optimizer='adam', metrics= RootMeanSquaredError())

with tf.device('/gpu:0'):
    history = model.fit(train_X, train_y, epochs=40, validation_data=(test_X, test_y), verbose=2,
                        shuffle=False)

```

Fuente: Elaboración Propia

En la figura 22, se muestra la porción del código en donde se desarrolla el modelo, en dicho código se muestra que para la ejecución del entrenamiento se utiliza un

acelerador de procesamiento que es el GPU, este es proporcionado gratuitamente por la herramienta dada por Google, Google Colaboratory.

B. Modelo con búsqueda de hiperparámetros óptimos

Después de haber tenido el modelo preliminar para el entrenamiento, se realizó una optimización de los hiperparámetros, que son todos aquellos parámetros que se pueden ajustar, tales como el número de neuronas, la función de activación, las métricas de evaluación, las épocas y la tasa de aprendizaje. (Rendyk, 2021)

Este proceso se basa en realizar iteraciones del entrenamiento con los diferentes parámetros que se desean cambiar y luego evaluar el resultado de estas iteraciones.

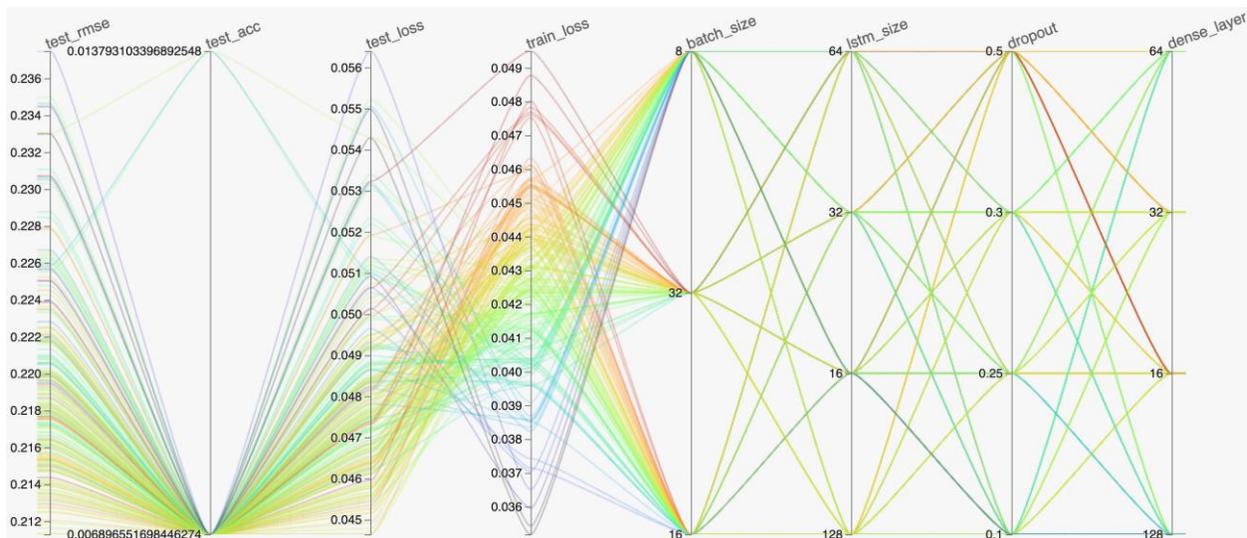
Bronwlee (2017) indica que dentro los parámetros que se pueden buscar hacer el cambio son los siguientes:

- Métricas: “BinaryAccuracy” y “RootMeanSquaredError”
- Cantidad de neuronas en la capa densa de entrada: 16, 32, 64 y 128 neuronas (dense_layer).
- Porcentaje de filtro de la capa Dropout: 10%, 25%, 30% y 50% (Dropout).
- Cantidad de neuronas en la capa LSTM: 16, 32, 64 y 128 neuronas (lstm_size).
- Tamaño del muestreo batch: 8, 16 y 32 muestras por entrenamiento (batch_size).

Las iteraciones se realizaron con el objetivo de poder obtener todas las permutaciones posibles entre todos los parámetros indicados; luego se utilizó la librería “hiplot” para obtener una visualización en donde se muestren los resultados de las métricas de evaluación de desempeño del modelo según cada una de las iteraciones; dicho resultado después del entrenamiento se muestra en la figura 23.

Figura 23.

Resultados las diferentes iteraciones con la librería Hiplot



Fuente: Elaboración Propia

Como se muestra en la figura 23, las cuatro primeras columnas son las métricas resultantes del entrenamiento del modelo como: error para el entrenamiento y la prueba (`train_loss` y `test_loss`) así como también la precisión y el RMSE de la porción de prueba, cabe resaltar que este RMSE no se puede interpretar en esta sección ya que antes de que se ingrese los datos al modelo para el entrenamiento se tuvieron que hacer transformaciones dada la naturaleza de los datos, estas transformaciones son normalizaciones ya que las todas las variables tenían diferentes magnitudes; y las siguientes cuatro columnas son los valores establecidos para cada uno de los parámetros que se buscaron optimizar, “`dense_layer`”, “`Dropout`”, “`lstm_size`” y “`batch_size`”.

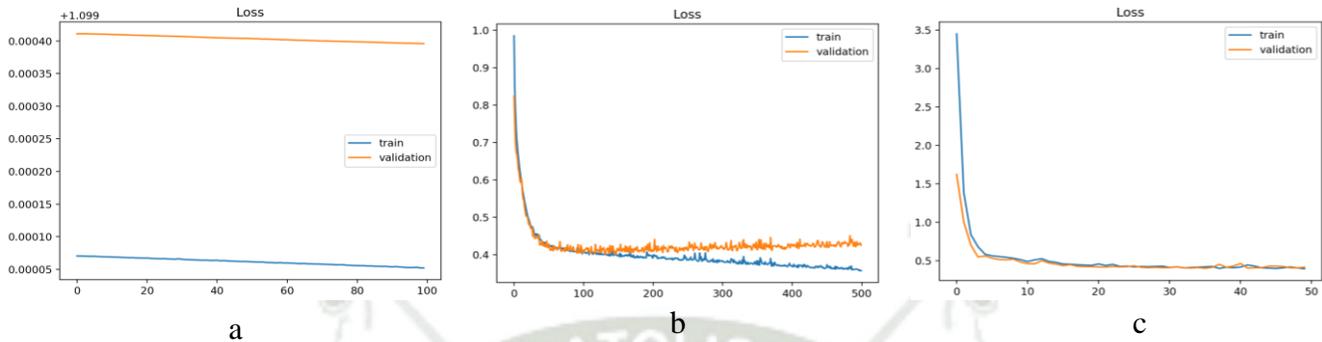
Como se puede observar en la figura 22, existen permutaciones o mezclas que muestran que existe una diferencia significativa entre los resultados del `train_loss` y

test_loss, produciéndose dos situaciones que se tienen que evitar en el desarrollo de un modelo:

- **Underfitting:** Cuando el error del entrenamiento (train_loss) es demasiado diferente con el error de validación o prueba (test_loss), esto se debe a que el modelo no puede obtener un valor bajo de error al usar el conjunto de entrenamiento, lo que significa que la red neuronal no logró aprender ningún patrón de los datos utilizados (Goodfellow, Bengio, y Courville, 2017; Brownlee, 2019) como se visualiza en la figura 24a.
- **Overfitting:** Esta situación sucede cuando el error del conjunto de validación comienza muy similar con el error del conjunto de entrenamiento, sin embargo, conforme se van avanzando con las épocas de entrenamiento el error del conjunto de validación comienza a divergir del de entrenamiento, y esto es indeseable ya que, si bien es cierto el modelo logra aprender de los datos de entrenamiento, pero, no puede generalizar, es decir no realizará buenas predicciones con datos nuevos (James, Witten, Hastie, y Tibshirani, 2013; Brownlee 2019) como se visualiza en la figura 24b.

Figura 24.

Ejemplos de dinámicas de las curvas de aprendizaje



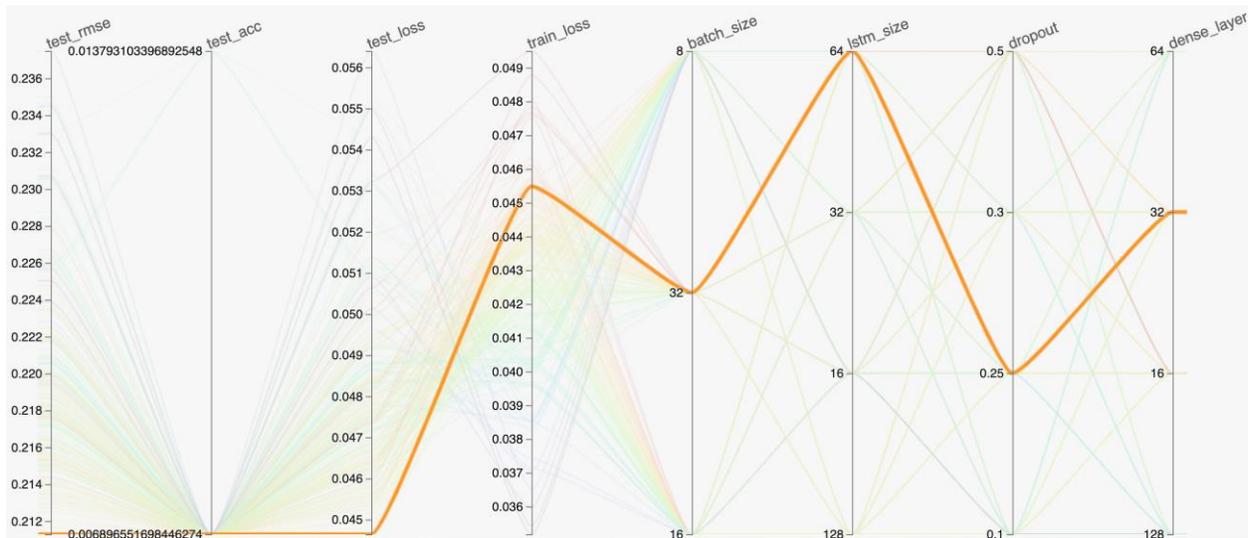
Nota: donde: a) Underfitting b) Overfitting c) Buen aprendizaje; adaptado de Brownlee (2019).

Por este motivo, ya que ambas situaciones son negativas para el modelo, se deberá seleccionar aquella permutación que dé como resultado un error similar tanto para el conjunto de entrenamiento como de validación.

Como resultado de esta evaluación, en la figura 25 se resalta la permutación la cual presenta un test_loss similar al train_loss, 0.0446 y 0.0455 respectivamente; este modelo tendría 32 neuronas en la capa densa de entrada, 25% de filtro en la capa Dropout, 64 neuronas en la capa LSTM y un tamaño de 32 para el batch.

Figura 25.

Mejor resultado de la optimización de parámetros



Fuente: Elaboración Propia



CAPÍTULO V

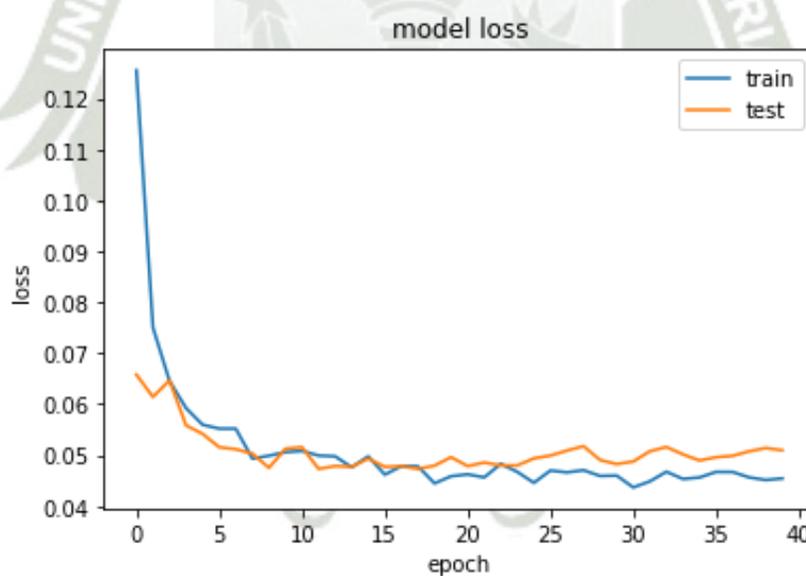
5. Resultados

5.1. Resultados del modelo preliminar

Después de haber realizado el entrenamiento del modelo preliminar, antes especificado, se obtuvo las curvas de aprendizaje como se muestra en la figura 26, en donde se puede observar que tanto el entrenamiento con la prueba (test), tienen un error similar, ya que durante las 40 épocas de entrenamiento ambos se mantienen homogéneas y casi similares, lo que demuestra que el modelo desarrollado preliminarmente según la bibliografía no muestra ni underfitting ni overfitting.

Figura 26.

Curvas de aprendizaje del modelo preliminar



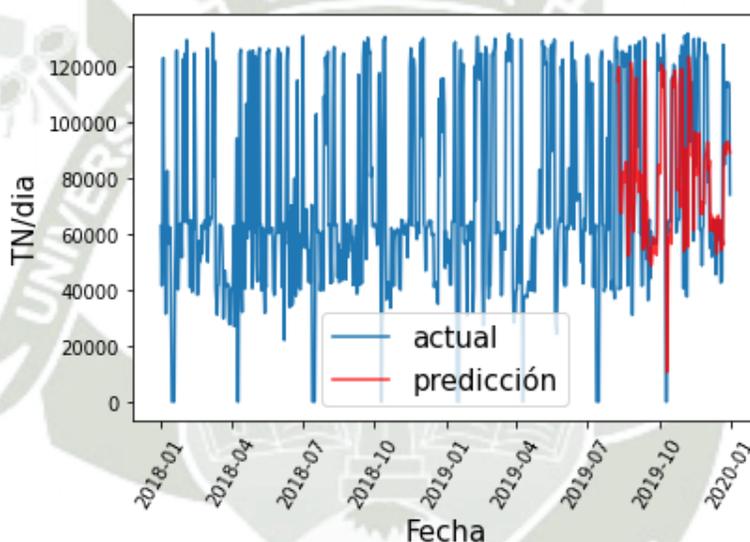
Fuente: Elaboración Propia

Luego de haber sido entrenado el modelo se realizaron predicciones para obtener el RMSE de estas predicciones, esto se calculó para una porción de los datos que es el conjunto de prueba que representa el 20% del total de datos, que representa el intervalo

de tiempo entre diciembre y agosto del 2019. Dado que el RMSE es un error que se puede interpretar bajo las mismas magnitudes estudiadas, el RMSE fue de 29822.36 TN de error promedio para el conjunto de datos de validación que aproximadamente representan 140 registros (4.5 últimos meses de todos los registros utilizados), este error promedio de validación permite generalizar dicha información para predicciones futuras, además que el modelo no tiene underfittin ni overfitting.

Figura 27.

Predicciones con el modelo preliminar del conjunto de datos de prueba

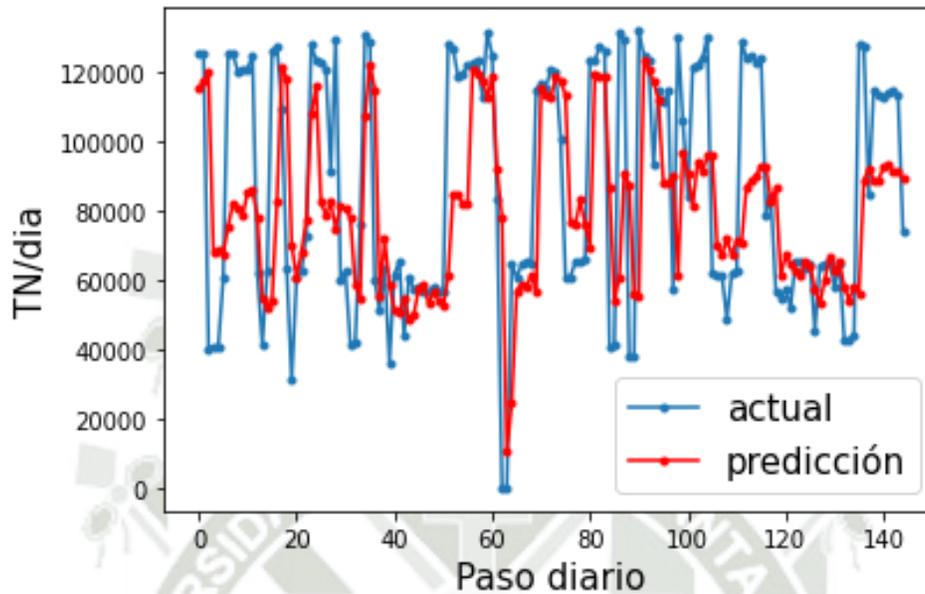


Fuente: Elaboración Propia

En la figura 27 se muestra, de color rojo, las predicciones realizadas con el modelo para los datos de prueba o validación que representa el intervalo de agosto de 2019 a diciembre de 2019, en comparación con los datos originales (de color azul).

Figura 28.

Predicciones con el modelo preliminar sobre el conjunto de datos de prueba



Fuente: Elaboración Propia

En la figura 28, se muestran de forma más detallada cuales fueron las predicciones del conjunto de validación o prueba, que representan los últimos 140 días (aprox. 4.5 meses) de todos los registros utilizados, como se puede observar, dichas predicciones tienen un buen ajuste, ya que logró predecir de manera correcta cual es la tendencia que se espera a futuro, identificándose correctamente la presencia de algunos picos en cuanto a la cantidad de toneladas que son enviadas a la chancadora al día.

Sin embargo, existen zonas las cuales no logró hacer una predicción precisa, especialmente entre el paso diario 100 al 120.

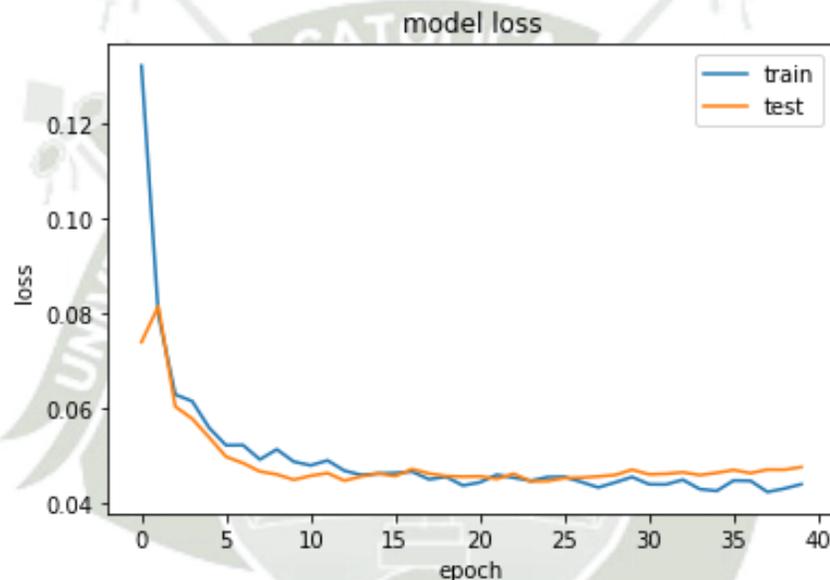
Con la información de este modelo se obtuvo un punto de inicio antes de realizarse la búsqueda de los hiperparámetros óptimos, para luego hacer comparaciones de las métricas y así evaluar qué modelo presenta menor error.

5.2. Resultados del Modelo con búsqueda de hiperparámetros óptimos

Con el modelo obtenido después de la búsqueda de hiperparámetros se obtuvieron las predicciones y las métricas para evaluar al modelo. En la figura 29 se muestra las curvas de aprendizaje para el segundo modelo, es decir, el modelo en el que se intentó optimizar sus hiperparámetros.

Figura 29.

Curvas de aprendizaje para el modelo con hiperparámetros optimizados



Fuente: Elaboración Propia

Como se puede observar, el modelo optimizado muestra que tanto el `train_loss` y el `test_loss` son similares en las 40 épocas de entrenamiento, lo que significa que este modelo no presenta `underfitting` u `overfitting`, eso quiere decir que las variables utilizadas para el entrenamiento no presentan un problema al momento de que el modelo de redes neuronales aprende.

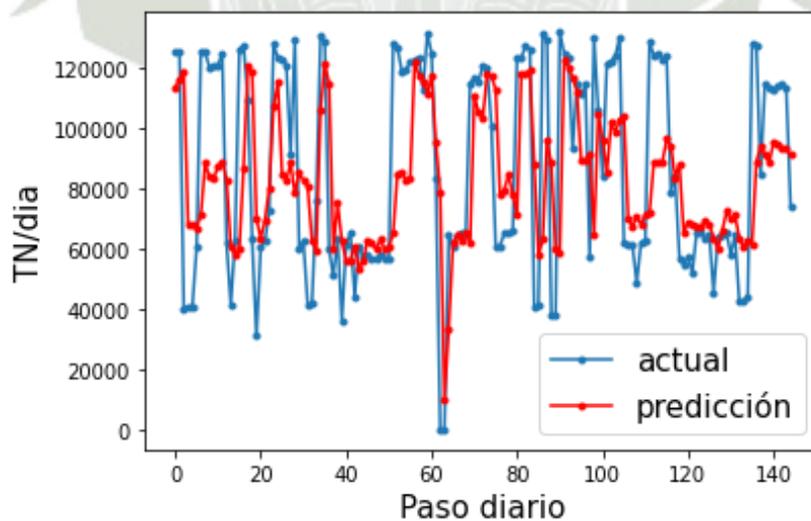
Con el modelo al cual se le realizó una búsqueda de hiperparámetros óptimos, dio un error promedio (RMSE) de 26844.85 TN, siendo este menor al error obtenido por el

modelo preliminar, no obstante, la diferencia entre las características de estos dos modelos no difiere drásticamente.

En la figura 30 se muestran las predicciones obtenidas para el mismo conjunto de datos de prueba (140 últimos días del total de registros utilizados), observándose que el modelo optimizado logra hacer predecir correctamente el comportamiento de la cantidad de toneladas enviadas a la chancadora, obteniendo un error promedio (RSME) de 26844.85 TN, mientras que el error promedio del plan de minado para este periodo, es decir el promedio de cantidad de mineral enviado a stock fue de 48256.00 TN, a pesar de que el error puede ser relativamente alto, este modelo permite tener una predicción lógica de cuál sería el comportamiento de las operaciones en la chancadora primaria.

Figura 30.

Predicciones del modelo optimizado para el conjunto de datos de prueba



Fuente: Elaboración Propia

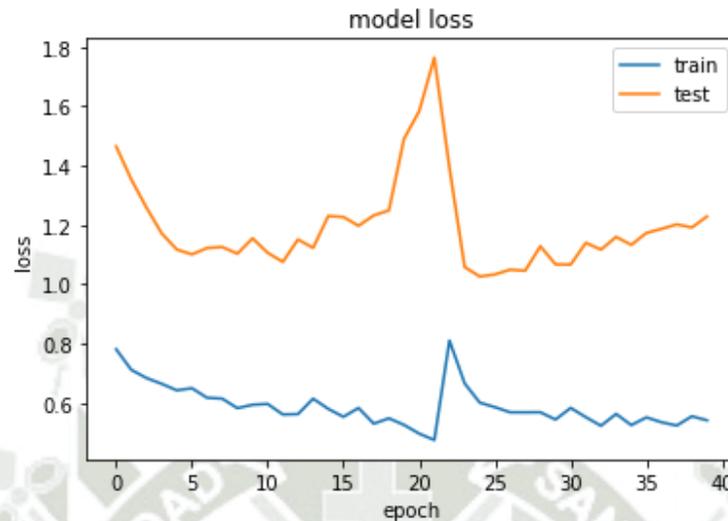
5.3. Evaluación de los resultados predichos

En los puntos anteriores se desarrollaron y mostraron los resultados de un modelo de LSTM multivariado, ya que se utilizaron más de 1 variable independiente para la predicción de las toneladas enviadas a la chancadora primaria (variable dependiente). Estos resultados, tanto como para el modelo preliminar como el modelo optimizado, demostraron ser modelos robustos y con una gran capacidad de generalización, es decir, de que dicho modelo se puede aplicar en datos nuevos y se podrá obtener una respuesta consistente.

Por otro lado, otro tipo de modelo que existe para realizar dichas predicciones es el modelo de LSTM univariado, es decir, un modelo que solo depende de los pasos del tiempo y la variable dependiente o respuesta (toneladas enviadas a la chancadora primaria); este tipo de modelo univariado representa el modelo de plan de producción en el planeamiento de minado ya que para su predicción solo consideran los pasos del tiempo y la variable respuesta, sin embargo, al hacer las pruebas con un modelo univariado, no se obtuvieron los resultados deseados. Como se muestra en la figura 31, después de hacer varios entrenamientos, el test loss y el train loss nunca converge con el train loss, eso quiere decir que el modelo desarrollado está en underfitting, es decir que dicha red neuronal no logró aprender los patrones de los datos, y resulta en un modelo que no puede generalizar, siendo un modelo que no tiene aplicación alguna.

Figura 31.

Resultados de la función de pérdida para un modelo LSTM univariado



Fuente: Elaboración Propia

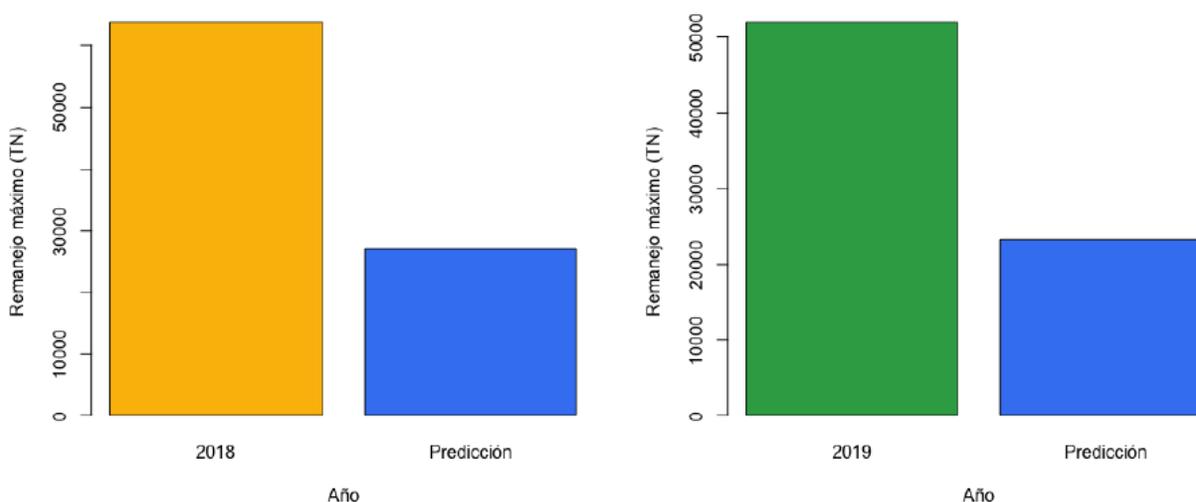
Este resultado del modelo univariado, underfitting, refleja que puede ser necesario la inclusión de más variables para poder hacer la inferencia, esto significa que, hacer un modelo multivariado con las variables operativas consideradas anteriormente es la alternativa más viable y precisa para hacer la predicción y estimación de las toneladas enviadas a la chancadora primaria, como se muestran en los resultados.

Dados los resultados obtenidos con las diferentes experimentaciones realizadas con la arquitectura de un modelo de redes neuronales recurrentes, como son las LSTM, se pudo demostrar que se puede realizar un modelo multivariado que logre predecir de manera concreta el comportamiento sobre la cantidad de toneladas enviadas a la chancadora primaria según la presencia de diferentes variables que van desde la ley de cobre, hierro y zinc hasta, incluso, la disponibilidad y utilización de las unidades mecánicas dentro de la mina. Mientras que, un modelo LSTM univariado justificó la necesidad de utilizar más variables para realizar el modelo, ya que, al utilizar tan solo

una variable no se puede obtener un modelo aplicable con datos nuevos, ya que presenta problemas de underfitting.

Figura 32.

Remanejo promedio de mineral de los años 2018 y 2019 por inoperatividad de chancadora



Nota: Se muestra cantidad promedio de mineral enviado a stock para los años 2018 y 2019 junto con el error promedio de cada año. Elaboración propia.

Según los datos históricos recolectados del 2018 y 2019, el valor promedio enviado a stock por baja disponibilidad y utilización de la chancadora primaria, palas y camiones junto con las demás variables que representan las características del material, fue de 63674 TN y 51899 TN respectivamente. Mientras que el modelo optimizado presenta un error promedio de 28000 TN para el 2018 y 23000 TN para el 2019, este error puede darse dentro del periodo de cada año, por lo tanto, esto representa en una reducción del 56.0% para el 2018 y 55.7% para el 2019, de error de predicción y por ende reducción del remanejo de material ya que se envía menos mineral al stock como se muestra en la figura 32.

Esta reducción de error de predicción, es decir de reducción del remanejo de material, se refleja en la reducción de costos de carguío y acarreo ya que se evita llevar el mineral a stocks, donde posteriormente tendrán que ser trasladados nuevamente a chancadora. Esta reducción de costos se muestra en la Tabla 3, 4 y en la figura 33 donde para el año 2018 el costo promedio de remanejo fue de \$ 16474.04, mientras que con el modelo optimizado se hubiera tenido un costo promedio de remanejo de \$ 7244.29, asimismo, para el año 2019 el costo promedio de remanejo fue de \$ 13427.55, mientras que con el modelo optimizado se hubiera tenido un costo promedio de remanejo de \$ 5950.67. Esto representa una reducción del costo promedio de carguío y acarreo de \$9229.75 y \$7476.89 para el 2018 y 2019 respectivamente.

Tabla 1. Costo de Carguío por hora

Costo de Carguío por hora	
Equipo	Cargador 993K
Tipo de Costo	\$/hr
Costo del equipo	48.73
Combustible	25.17
Repuestos	3.49
Mantenimientos	3.24
Consumibles (neumaticos, aceite, otros)	6.59
EPP's y Seguros	0.8
Costo del Taller	1.12
Costo de operador y personal asociado	8.56
Equipos asociados (limpieza de vías, camión de lubricación)	1.05
COSTO (\$/Hr)	98.75

Tabla 2. Costo de Acarreo por hora

Costo de Acarreo por hora	
Equipo	Camión 793F
Tipo de Costo	\$/hr
Costo del equipo	35.02
Combustible	29.1
Repuestos	4.3
Mantenimientos	2.1
Consumibles (neumaticos, aceite, otros)	9.4
EPP's y Seguros	0.9
Costo del Taller	1.12
Costo de operador y personal asociado	7.24
Equipos asociados (limpieza de vías, camión de lubricación)	0.84
COSTO (\$/Hr)	90.02

Tabla 3. Cálculo de Costos de Carguío por Toneladas

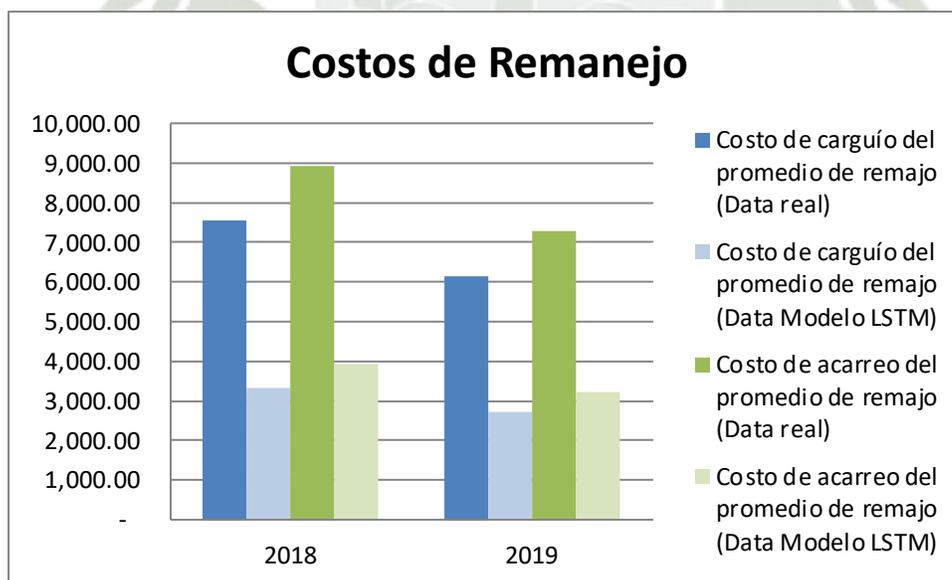
Cálculo de Costos de Carguío por Tn					
Detalle	Data histórica		Data del Modelo LSTM		Uni
	2018	2019	2018	2019	
Capacidad del equipo	20.00	20.00	20.00	20.00	m3
Tiempo de carguío	3.60	3.60	3.60	3.60	min
Remanejo promedio	63,674.00	51,899.00	28,000.00	23,000.00	Tn
Remanejo promedio	25,469.60	20,759.60	11,200.00	9,200.00	m3
Número de veces de carguío	1,273.48	1,037.98	560.00	460.00	-
Tiempo de carguío promedio total	76.41	62.28	33.60	27.60	horas
Costo de carguío	98.75	98.75	98.75	98.75	\$/hr
Costo de carguío del promedio de remajo	7,545.37	6,150.03	3,318.00	2,725.50	\$

Tabla 4. *Cálculo de Costos de Acarreo por Toneladas*

Cálculo de Costos de Acarreo por Tn					
Detalle	Data histórica		Data del Modelo LSTM		Uni
	2018	2019	2018	2019	
Capacidad del equipo	93.00	93.00	93.00	93.00	m3
Tiempo de carga del equipo	3.60	3.60	3.60	3.60	min
Tiempo de acarreo	17.00	17.00	17.00	17.00	min
Tiempo de descarga del equipo	1.13	1.13	1.13	1.13	min
Remanejo promedio	63,674.00	51,899.00	28,000.00	23,000.00	Tn
Remanejo promedio	25,469.60	20,759.60	11,200.00	9,200.00	m3
Número de viajes del camión	273.87	223.22	120.43	98.92	-
Tiempo de carguío promedio total	99.19	80.84	43.62	35.83	horas
Costo de carguío	90.02	90.02	90.02	90.02	\$/hr
Costo de acarreo del promedio de remajo	8,928.67	7,277.52	3,926.29	3,225.17	\$

Figura 33.

Comparación de costos de Remanejo promedio



Fuente: Elaboración Propia

De los resultados obtenidos y presentados en cuanto a cantidad de material de remanejo y costos asociados de carguío y acarreo, se observa que con el modelo de redes neuronales recurrentes se obtiene menor error en la predicción en comparación con la predicción del plan de producción en el planeamiento de minado. Sin embargo, es recomendable poder recolectar una mayor cantidad de datos para que la red neuronal pueda detectar y aprender de manera precisa los patrones presentes en los datos y así reducir considerablemente el valor del RMSE.



CONCLUSIONES

- Mediante una iteración se buscó obtener diferentes modelos de redes neuronales recurrentes, lográndose predecir la alimentación de la chancadora primaria, con un error promedio (RMSE) de 26844.85 TN para el conjunto de datos de prueba o validación y específicamente 28000 TN para el 2018 y 23000 para el 2019.
- Se obtuvo una caracterización de la base de datos donde se demostró que tiene una estructura muy heterogénea con ciertos valores nulos y erróneos dentro de los registros, además, también se encontraron diferentes tipos de datos como: fechas, numéricas y categóricas. Para esto se tuvo que realizar reemplazos e imputaciones de datos para rellenar y reemplazar los posibles valores erróneos.
- Se logró determinar las variables que fueron útiles para el entrenamiento del modelo, eliminándose 3 variables, “destino”, “fase_origen” y “tn_inop”, quedando un total de 14 variables que se pudieron utilizar para el desarrollo y aprendizaje de la red neuronal.
- Se obtuvieron y entrenaron diferentes diseños de modelos de una red neuronal recurrente multivariada, el cual tiene la siguiente estructura: modelo tendría 32 neuronas en la capa densa de entrada, 25% de filtro en la capa Dropout, 64 neuronas en la capa LSTM y un tamaño de 32 para el batch.
- Se hizo la comparación con los resultados obtenidos, siendo que, para el modelo preliminar se obtuvo un RMSE (error) de aproximadamente 30000 TN en comparación a los datos originales, mientras que para el modelo optimizado se logró reducir el RMSE a 26844.85 TN de los datos de prueba lo que representa en una mejora del 13%, estos resultados se pueden mejorar aumentando la cantidad de datos entrenables.

- Con el modelo seleccionado se redujo el error de predicción de alimentación a la chancadora primaria en un 56.0% para el 2018 y 55.7% para el 2019, esto en comparación con la predicción del plan de producción en el planeamiento de minado; demostrando que el modelo de redes neuronales recurrentes presenta una mejor predicción y representa una gran herramienta para la planificación; ya que considera las variables operativas, como disponibilidad, utilización de la chancadora primaria, palas y camiones, entre otras.



RECOMENDACIONES

- Para la mejora del modelo, es decir, para la reducción del error (RMSE) y por ende mejorar la precisión del modelo, se recomienda poder recolectar una mayor cantidad de datos, siendo necesario aumentar los años de evaluación a más de 5 años atrás.
- Con los resultados expuestos en la presente tesis, sirve como antecedente para realizar un estudio más profundo acerca de cómo poner en producción dicho modelo en un servicio de cloud computing o nube, para poder generalizarlo a nivel nacional e incluso internacional como un modelo de inteligencia artificial.
- Se recomienda la utilización de servicios en la nube para poder hacer un escalamiento del modelo para que pueda desarrollarse una aplicación y pueda utilizarse en diferentes empresas mineras.
- Se recomienda optimizar el modelo desarrollado en la presente tesis, con miras en la reducción del reentrenamiento de este, para esto se debe ahondar en técnicas de Big Data.
- Por otro lado, con ayuda de la investigación realizada se puede hacer una expansión en cuanto al conocimiento del dominio, pudiéndose extrapolar dicha información en otras áreas dentro de la empresa, tales como administrativas y/o operativas.

REFERENCIAS BIBLIOGRÁFICAS

- Ampuero, J. (2010). *Planeamiento de minado a corto y mediano plazo empresa minera los Quenuales S.A. unidad de producción Yauliyacu* (Licenciatura). Universidad Nacional de Ingeniería.
- Bardales, C., y Zamora, C. (2019). Estimación de las características geomecánicas del macizo rocoso mediante la inteligencia artificial.
- Barreto, L. (2017). *Optimización del número de camiones 785C CAT y cargador frontal 992K CAT mediante el match factor en la ruta mineral – stock pile Antapaccay – chancadora tintaya San Martín contratistas generales S.A.* (Licenciatura). Universidad Nacional de San Agustín, Arequipa.
- Barrios, M. (2015). *Optimización de los sistemas de control de un molino de bolas* (Licenciatura). Universidad Nacional de San Agustín, Arequipa.
- Bonzi, J. (2016). *Propuestas de mejora de la utilización efectiva en base a disponibilidad de la flota de carguío y transporte en minera los pelambres* (Licenciatura). Universidad de Chile, Chile.
- Brown, R. (2019). *What are Features in Machine Learning and Why it is Important?* Medium. <https://cogitotech.medium.com/what-are-features-in-machine-learning-and-why-it-is-important-e72f9905b54d>
- Brownlee, J. (2017, August 13). *Multivariate time series forecasting with LSTMs in keras.* Machinelearningmastery.Com. <https://machinelearningmastery.com/multivariate-time-series-forecasting-lstms-keras/>.
- Brownlee, J. (2019, February 26). *How to use learning curves to diagnose machine learning model performance.* Machine Learning Mastery.

<https://machinelearningmastery.com/learning-curves-for-diagnosing-machine-learning-model-performance/>

- Camus, D. (2009). *Determinación, modelación y mitigación de la generación de polvo en un stockpile minero* (Licenciatura). Universidad Técnica Federico Santa María, Chile.
- Carpio, W. (2018). *Aplicación de software minero minesight al planeamiento de corto plazo en minería a tajo abierto* (Tesis de grado). Universidad Nacional de San Agustín, Perú.
- Carrion, C. (2018). Aplicación de redes neuronales artificiales para la predicción de la recuperación de planta concentradora en Minsur SA–Unidad San Rafael.
- Chavez, E. (2019). *Instalación de chancadora short head para mejorar el análisis granulométrico del producto del chancado en Sociedad Minera el Brocal S.A.A., Pasco-2019* (Tesis de grado). Universidad Nacional Daniel Alcides Carrión, Perú.
- Choi, Y., y Lee, H. (2020). Trends in Mineral Resources Development Technology Using Artificial Intelligence. *ITFIND*, 1935, 13–24.
- Chollet, F. (2018). *Deep learning with Python* (Vol. 361). New York: Manning.
- CODELCO. (2018). *Proceso de chancado del cobre*. codelcoeduca.cl.
<https://www.codelcoeduca.cl/codelcoeduca/site/edic/base/port/chancado.html>
- Consejo Minero. (2001). *Gestión de Residuos Industriales Sólidos Mineros y Buenas Prácticas*. Recuperado de http://biblioteca.unmsm.edu.pe/redlieds/recursos/archivos/MineriaDesarrolloSostenible/ProduccionLimpia/ampl_residuos_solidos.pdf
- Contreras, F. (2018). Diseño de modelo predictivo multivariable para molienda en Compañía Minera Doña Inés de Collahuasi.

- Cruz, J. (2016). *Planeamiento de Minado a corto plazo con la implementación de herramientas informáticas en CIA minera Catalina Huanca S. A. C.* (Licenciatura). Universidad Nacional de San Agustín de Arequipa.
- Deloitte. (2018). *Future of mining with AI: Building the first steps towards an insight-driven organization.* Deloitte.Com.
<https://www2.deloitte.com/content/dam/Deloitte/global/Documents/Energy-and-Resources/deloitte-norcat-future-mining-with-ai-web.pdf>
- Dindarloo, S., y Siami-Irdemoosa, E. (2017). Data mining in mining engineering: results of classification and clustering of shovels failures data. *International Journal of Mining, Reclamation and Environment*, 31(2), 105-118.
- Escobed, L. (2014). Informe técnico análisis de riesgos en las diferentes áreas de operación en planta concentradora y su interacción con la seguridad y medio ambiente.
- Franco-Sepúlveda, G., Del Rio-Cuervo, J. C., y Pachón-Hernández, M. A. (2019). State of the art about metaheuristics and artificial neural networks applied to open pit mining. *Resources Policy*, 60, 125–133.
- Fu, Y., y Aldrich, C. (2020). Deep Learning in Mining and Mineral Processing Operations: A Review. *IFAC-PapersOnLine*, 53(2), 11920-11925.
- Galdames, B. (2015). *Apuntes Curso Gestión de Operaciones Mineras* (Licenciatura). Universidad de Chile.
- Goodfellow, I., Bengio, Y., & Courville, A. (2017). Deep learning (adaptive computation and machine learning series). Cambridge Massachusetts, 321-359.
- González, R. (2014). Python para todos.

- Herrera, C., y Jorge, J. (2019). *Estimación de reservas mineras utilizando software comercial y software libre en la compañía minera S. A. A. - Unidad Cerro de Pasco* (Licenciatura). Universidad Nacional de Huancavelica.
- IBM. (01 de mayo de 2020). What is deep learning? Recuperado el 29 de septiembre de 2021, de IBM Cloud Education website: <https://www.ibm.com/cloud/learn/deep-learning>
- Infaimon. (13 de noviembre de 2019). Machine Learning y Deep Learning: ¿Cuáles son sus ventajas? Recuperado el 29 de septiembre de 2021, de <https://blog.infaimon.com/ventajas-del-machine-learning-y-deep-learning-para-la-evolucion-de-la-vision-artificial/>
- Iquiapaza, C. (2018). *Replanteo de polígonos de extracción para optimizar el proceso de minado en mina Toquepala* (Licenciatura). Universidad Nacional de San Agustín, Arequipa.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112, p. 18). New York: springer.
- Jung, D., y Choi, Y. (2021). Systematic Review of Machine Learning Applications in Mining: Exploration, Exploitation, and Reclamation. *Minerals*, 11(2), 148.
- Krizhevsky, A., Sutskever, I., y Hinton, G. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- Leiva, D. (2019). *Implementación del Sistema Dispatch: Control de equipos de carguío y acarreo en minería a cielo abierto para optimizar costos operativos en la Compañía Minera Shougang Hierro Perú S. A. A - Mina 5 - Marcona - Perú* (Licenciatura). Universidad Nacional Santiago Antúnez de Mayolo.

- Linares, E. L. R. (2018). Un nuevo enfoque predictivo de la fragmentación en la Voladura de Rocas. *Industrial data*, 21(1), 17-26.
- McCarthy, J. (2007). What is artificial intelligence?. *Computer Science Department*.
- Mitchell, R., Michalski, J., y Carbonell, T. (2013). An artificial intelligence approach. Berlin: Springer.
- Mittal, A. (2019). *Understanding RNN and LSTM - Aditi Mittal - Medium*. Medium. <https://aditi-mittal.medium.com/understanding-rnn-and-lstm-f7cdf6dfc14e>
- Morales, N., y Jélvez, E. (2019). Modelo integrado de simulación y optimización para planes mineros de corto plazo en minería a cielo abierto. *Journal of Mining Engineering and Research*, 2(2), 150-158.
- Muharemi, F., Logofătu, D., y Leon, F. (2019). Machine learning approaches for anomaly detection of water quality on a real-world data set. *Journal of Information and Telecommunication*, 3(3), 294–307.
- Muñoz, J., y Álvarez, E. (2009). Métodos de imputación para el tratamiento de datos faltantes: aplicación mediante R/Splus.
- Orellana, F., Morales, N., y Jélvez, E. (2019). Modelo integrado de simulación y optimización para planes mineros de corto plazo en minería a cielo abierto. *Journal of Mining Engineering and Research*, 2(2).150-158.
- Ouanan, H., y Abdelwahed, E. (2019). Image processing and machine learning applications in mining industry: Mine 4.0. *2019 International Conference on Intelligent Systems and Advanced Computing Sciences (ISACS)*.
- Perez, J. (2002). *Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto*. (doctorado). Universidad de Alicante.

- Portugal, I., Alencar, P., y Cowan, D. (2018). The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, 97, 205-227.
- Parisaca, C. (2015). *Evaluación del circuito de chancado y optimización de su performance de planta de óxidos Tintaya – Antapaccay* (Licenciatura). Universidad Nacional de San Agustín, Arequipa.
- Prashanth, S. (2021). Understanding loss functions in Machine Learning. *Engineering Education (EngEd) Program / Section*. <https://www.section.io/engineering-education/understanding-loss-functions-in-machine-learning/>
- Ramesh, A., Kambhampati, C., Monson, J., y Drew, P. (2004). Inteligencia artificial en medicina. *Anales del Real Colegio de Cirujanos de Inglaterra*, 86(5), 334–338.
- Ramesh, B., Jahed, D., Tonnizam, E., y Changthan, S. (2018). Rock fragmentation prediction through a new hybrid model based on imperial competitive algorithm and neural network. *Smart Construction Research*, 2(3). doi:10.18063/scr.v2i3.397.
- Rendyk. (2021, May 26). *Tuning the hyperparameters and layers of neural network deep Learning*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2021/05/tuning-the-hyperparameters-and-layers-of-neural-network-deep-learning/>
- Roman, V. (2019, February 6). *Introducción al Machine Learning: Una guía desde cero*. Ciencia y Datos. <https://medium.com/datos-y-ciencia/introduccion-al-machine-learning-una-guia-desde-cero-b696a2ead359>
- Rosebrock, A. (2019). Keras vs. tf.keras: What's the difference in TensorFlow 2.0? PyImageSearch. <https://pyimagesearch.com/2019/10/21/keras-vs-tf-keras-whats-the-difference-in-tensorflow-2-0/>

- Sevilla, M. (2011). *El planeamiento estratégico y su incidencia administrativa en la Dirección Regional de Energía y Minas del Gobierno Regional de Ancash 2010-2014* (Tesis de doctorado). Universidad Nacional de Trujillo, Perú.
- Sharma, N., Sharma, R., & Jindal, N. (2021). Machine learning and deep learning applications-a vision. *Global Transitions Proceedings*, 2(1), 24-28.
- Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., ..., y Hassabis, D. (2017). *Mastering the game of go without human knowledge*. *Nature*, 550(7676), 354-359.
- Sotelo, G. (2016). Desarrollo de una librería neuronal en control builder 5.1 para controlar el nivel de mineral al interior de un molino de bolas.
- TensorFlow. (2021). *TensorFlow*. Recuperado el 1 de septiembre de 2021, de Tensorflow.org website: <https://www.tensorflow.org/>
- Tineo, R. (2018). *Planeamiento Estratégico para mejorar la calidad de servicio de la empresa C & L CONIGE S.A.C., Chiclayo* (Tesis de maestría). Universidad César Vallejo, Perú.
- Torres, J., Mejía, D., Moreyra, P., Oré, J., & Oscco, S. (2021). Geometalurgia y el futuro de la minería digital en el Perú. *Revista Del Instituto de Investigación de La Facultad de Geología, Minas, Metalurgia y Ciencias Geográficas de La Universidad Nacional Mayor de San Marcos (Impresa)*, 24(47), 163–179.
- Torres, S. (2018). *Estudio de evaluación económica de una secuencia minera para un modelo de stock pile generado bajo simulación condicional* (Tesis de maestría). Universidad de Chile.

Vargas, M. (2011). Modelo de planificación minera de corto y mediano plazo incorporando restricciones operacionales y de mezcla (Tesis de maestría). Universidad de Chile, Santiago de Chile.

Zela, A. (2017). Planificación y programación del mantenimiento de instrumentación de la planta de chancado primario Compañía Antapaccay.

