



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA



TESIS

**Modelo de redes neuronales para maximizar la cobertura de
camiones en chancadoras para Soc. Minera Cerro Verde S.A.A.**

**PARA OPTAR POR EL TÍTULO PROFESIONAL DE INGENIERO
ELECTRÓNICO**

AUTOR:

Bach. Chiarot Villegas, Teddy Vinicio

ASESOR:

Ing. Segura Altamirano, Segundo Francisco

ORCID: 0000-0002-0103-7222

LAMBAYEQUE – PERÚ

2022

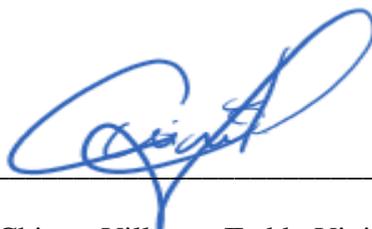
UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA

**Modelo de redes neuronales para maximizar la cobertura de camiones
en chancadoras para Soc. Minera Cerro Verde S.A.A.**

TESIS

**PARA OPTAR POR EL TÍTULO PROFESIONAL DE
INGENIERO ELECTRÓNICO**

PRESENTADO POR:



Bach. Chiarot Villegas, Teddy Vinicio

Tesista

ASESORADO POR:



Ing. Segura Altamirano, Segundo Francisco

Asesor

UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA

Modelo de redes neuronales para maximizar la cobertura de camiones en
chancadoras para Soc. Minera Cerro Verde S.A.A.

TESIS

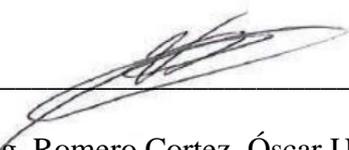
PARA OPTAR POR EL TÍTULO PROFESIONAL DE
INGENIERO ELECTRÓNICO

APROBADA POR EL SIGUIENTE JURADO:



M.Sc. Chiclayo Padilla, Hugo Javier

PRESIDENTE



Mg.Ing. Romero Cortez, Óscar Ucchelly

SECRETARIO



Mg.Ing. Nombera Lossio, Martín Augusto

VOCAL



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DECANATO

Ciudad Universitaria - Lambayeque



ACTA DE SUSTENTACIÓN VIRTUAL N° 030-2022-D/FACFyM

Siendo las 11:00 am del día 19 Setiembre del 2022, se reunieron vía plataforma virtual, <https://meet.google.com/qka-gwra-iam> los miembros del jurado evaluador de la Tesis titulada:

MODELO DE REDES NEURONALES PARA MAXIMIZAR LA COBERTURA DE CAMIONES EN CHANCADORAS PARA SOC. MINERA CERRO VERDE S.A.A.

Designados por Resolución N°796-2021-VIRTUAL-D/FACFyM de fecha 29 de octubre de 2021.

Con la finalidad de evaluar y calificar la sustentación de la tesis antes mencionada, conformada por los siguientes docentes:

M.Sc. Ing. Hugo Javier Chiclayo Padilla **Presidente**

Mg. Ing. Oscar Uchelly Romero Cortez **Secretario**

Mg. Ing. Martín Augusto Nombera Lossio **Vocal**

La tesis fue asesorada por el Ing. Segundo Francisco Segura Altamirano nombrado por Resolución N° N°796-2021-VIRTUAL-D/FACFyM de fecha 29 de octubre de 2021

El Acto de Sustentación fue autorizado por Resolución N°758-2022-VIRTUAL-D/FACFyM de fecha 8 de setiembre de 2022.

La Tesis fue presentada y sustentada por el Bachiller: Teddy Vinicio Chiarot Villegas y tuvo una duración de 30 minutos.

Después de la sustentación, y absueltas las preguntas y observaciones de los miembros del jurado se procedió a la calificación respectiva, otorgándole el Calificativo de 18 (Dieciocho) en la escala vigesimal, mención Muy Bueno.

Por lo que queda apto para obtener el Título Profesional de Ingeniero Electrónico, de acuerdo con la Ley Universitaria 30220 y la normatividad vigente de la Facultad de Ciencias Físicas y Matemáticas y la Universidad Nacional Pedro Ruiz Gallo.

Siendo las 12:10 pm se dio por concluido el presente acto académico, dándose conformidad al presente acto con la firma de los miembros del jurado.

M.Sc. Ing. Hugo Javier Chiclayo Padilla
Presidente

Mg. Ing. Oscar Uchelly Romero Cortez
Secretario

Mg. Ing. Martín Augusto Nombera Lossio
Vocal

Ing. Segundo Francisco Segura Altamirano
Asesor



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
UNIDAD DE INVESTIGACION



"Año del Fortalecimiento de la Soberanía Nacional"

CONSTANCIA DE SIMILITUD

N° 74-2022-VIRTUAL-UI-FACFyM

EL DIRECTOR DE LA UNIDAD DE INVESTIGACIÓN DE LA FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS DE LA UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO, HACE CONSTAR:

Que, el Bachiller **CHIAROT VILLEGAS TEDDY VINICIO**, de la Escuela Profesional de **INGENIERÍA ELECTRÓNICA**, ha cumplido con presentar la **SIMILITUD DE ORIGINALIDAD DE LA TESIS (TURNITIN)**, como requisito indispensable para la sustentación de la tesis, según detalle:

TÍTULO DE LA TESIS: "MODELO DE REDES NEURONALES PARA MAXIMIZAR LA COBERTURA DE CAMIONES EN CHANCADORAS PARA SOC. MINERA CERRO VERDE S.A.A."

- **ÍNDICE DE SIMILITUD: 5%**
- **ASESOR: Ing. Segundo Francisco Segura Altamirano.**

Se expide la presente, para la tramitación del Título Profesional, dispuesto en la **Directiva para la evaluación de originalidad de los documentos académicos, de investigación formativa y para la obtención de Grados y Títulos de la UNPRG.**

Lambayeque, 14 de octubre de 2022

Dr. WALTER ARRIAGA DELGADO
DIRECTOR UI-FACFyM

ANEXO 01

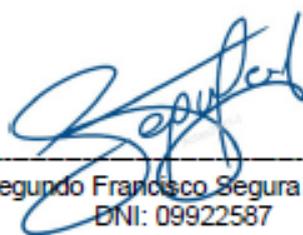
CONSTANCIA DE VERIFICACIÓN DE ORIGINALIDAD
(RESOLUCIÓN N° 626-2021-CU DEL 30 DE DICIEMBRE 2021)

Yo, Segundo Francisco Segura Altamirano, usuario revisor del documento titulado **MODELO DE REDES NEURONALES PARA MAXIMIZAR LA COBERTURA DE CAMIONES EN CHANCADORAS PARA SOC. MINERA CERRO VERDE S.A.A.** Cuyo autor es, Bach. Chiarot Villegas Teddy Vinicio, Identificado con Documento de Identidad 09922587; declaro que la evaluación realizada por el Programa Informático, ha arrojado un porcentaje de similitud de 5%, verificable en el Resumen de Reporte automatizado de similitudes que se acompaña.

El suscrito analizó dicho reporte y concluyó que cada una de las coincidencias detectadas dentro del porcentaje de similitud permitido no constituyen plagio y que el documento cumple con la integridad científica y con las normas para el uso de citas y referencias establecidas en los protocolos respectivos.

Se cumple con adjuntar el Recibo Digital a efectos de la trazabilidad respectiva del proceso.

Lambayeque, 27 de julio del 2022



Ing Segundo Francisco Segura Altamirano
DNI: 09922587
Asesor

(Precisar si es docente, asesor, docente investigador, administrativo u otro)

Se adjunta:

*Resumen de Reporte automatizado de similitudes

*Recibo Digital

DECLARACIÓN JURADA DE ORIGINALIDAD

El investigador principal Teddy Vinicio Chiarot Villegas y Segundo Francisco Segura Altamirano, asesor del trabajo de investigación “MODELO DE REDES NEURONALES PARA MAXIMIZAR LA COBERTURA DE CAMIONES EN CHANCADORAS PARA SOC. MINERA CERRO VERDE S.A.A.”, declaramos bajo juramento que este trabajo no ha sido plagiado, ni contiene datos falsos. En caso se demostrará lo contrario, asumimos responsablemente la anulación de este informe y por ende el proceso administrativo a que hubiera lugar.

Que puede conducir a la anulación del título o grado emitido como consecuencia de este informe.

Lambayeque, 22 de julio del 2022



Nombre el investigador: Bach. Teddy Vinicio Chiarot Villegas.



Nombre del asesor: Ing. Segundo Francisco Segura Altamirano.

Agradecimientos

En primer lugar, a Dios por darme vida y fuerzas para lograr esta desafiante meta. Luego, al Ing. Francisco Segura Altamirano quien en base a su experiencia y conocimiento me asesoró y encaminó en el desarrollo y obtención de los resultados alcanzados. A la empresa Soc. Minera Cerro Verde S.A.A., por permitirme utilizar su información para este proyecto de Tesis. Finalmente, a mi fiel amiga Ghiara Siesquen por su apoyo incondicional durante este difícil proceso.

Gracias por todo.

Teddy Vinicio Chiarot Villegas

Dedicatoria

Dedico esta tesis a mis abuelitos Vinicio Chiarot Mendoza y Elsa Azcárate Balmaceda quienes me apoyaron durante mis estudios y desde el cielo contemplan y celebran mis logros, a mis abuelitos Jose Villegas Camacho e Irma Manrique Olaya, quienes son fuente de inspiración y perseverancia, además reforzaron mi fuerza de voluntad para realizar esta tesis. Finalmente, a mi Familia que me han apoyado durante mis estudios y siempre están orgullosos de mis logros.

Gracias, por tanto.

Teddy Vinicio Chiarot Villegas

Resumen

Actualmente, durante los procesos de refrigerio y cambio de turno en las operaciones de la mina, se presentan retrasos en los equipos de acarreo, provocando una caída en el suministro de mineral en los chancadores a menos del 82% en promedio en una hora regular. Por ello, desarrollé un modelo de redes neuronales de aprendizaje profundo por refuerzo tipo Q-learning que asegura al menos el 90% del suministro de mineral, para lo cual generé un entorno de simulación análogo al entorno real, con datos obtenidos del análisis de la situación actual, permitiéndome probar a los agentes, en este caso los camiones, en diferentes escenarios considerando como acciones la selección de los equipos de carga y como recompensa el tiempo de ciclo, el tiempo de cola en los destinos y el tipo de material cargado, con estos resultados, entrené una red neuronal profunda, con la cual verifiqué que la solución propuesta asegura una cobertura de camiones en la trituradora superior al 90% durante las horas de refrigerio y cambios de turno, con tiempos de ejecución promedio menores a un milisegundo.

Palabras clave: aprendizaje profundo por refuerzo, aprendizaje tipo Q, ciclo de acarreo, Dispatch, redes neuronales.

Abstract

During the lunch break and shift change processes in the mine operations, there are delays in the hauling equipment, causing a drop in ore supply in the crushers to less than 82% on average in a regular hour. Therefore, we developed a model of deep learning neural networks by Q-learning type reinforcement that ensures at least 90% of the ore supply, for which they generated a simulation environment analogous to the real environment, with data obtained from the analysis of the current situation, allowing us to test the agents, in this case, the trucks, in different scenarios considering as actions the selection of the loading equipment and as a reward the cycle time, the queue time at the destinations and the type of material loaded, with these results, we train a deep neural network, with which we verify that the proposed solution ensures truck coverage in the crusher greater than 90% during lunch break and shift changes, with average execution times of less than one millisecond.

Keywords: Deep reinforcement learning, Q-type learning, mine haulage, Dispatch, Neural networks.

Índice general

Introducción	1
Capítulo I	2
Aspectos De La Investigación	2
1.1 Planteamiento de la Investigación.....	2
1.1.1 Síntesis de la Situación Problemática.....	2
1.1.2 Formulación del Problema de investigación	3
1.1.3 Hipótesis	3
1.1.4 Objetivos.....	3
1.2 Diseño Teórico	4
1.2.1 Antecedentes Internacionales.....	4
1.2.2 Antecedentes Nacionales	7
1.2.3 Definición y Operacionalización de Variables	7
1.3 Diseño Metodológico	8
1.3.1 Diseño de contrastación de hipótesis.	8
1.3.2 Población y Muestra	9
1.3.3 Técnicas, Instrumentos, equipos y materiales.....	9
Capítulo II.....	10
Marco Teórico.....	10
2.1 Modelo Biológico de las Neuronas	10
2.2 Redes Neuronales Artificiales RNA	10

2.2.1	Estructura	12
2.2.2	Fases de una red neuronal	13
2.3	Aprendizaje automático.....	13
2.4	Aprendizaje por refuerzo.....	14
2.4.1	Componentes.....	14
2.4.2	Función de la recompensa.....	15
2.4.3	Aprendizaje Q	16
2.5	Cadena de Markov	19
2.5.1	Proceso de recompensa y decisión.....	19
2.5.2	Utilidades y problemas relacionados al modelo oculto	20
2.6	Sistema de gestión de flota minera.....	21
2.6.1	Componentes.....	21
2.6.2	Proceso de acarreo	22
Capítulo III.....		27
Diseño Del Sistema.....		27
3.1	Situación Actual de la Empresa Sociedad Minera Cerro Verde S.A.A.	27
3.1.1	Equipos operativos.....	27
3.1.2	Cambio de turno.....	30
3.1.3	Refrigerio	32
3.1.4	Análisis de camiones operativos por hora	34
3.2	Diseño Elaborado En Python	40

3.2.1	Librerías y módulos	41
3.2.1.1	Simpy.....	41
3.2.1.2	Numpy	41
3.2.1.3	PyTorch	42
3.2.1.4	Pygame	43
3.2.1.5	Matplotlib	44
3.2.1.6	Módulos y bibliotecas internas de Python.....	44
3.2.2	Designación del tiempo de acarreo y equipos.....	45
3.2.2.1	Cuadre de camiones y carga de palas	45
3.2.2.2	Descarga en botaderos y chancadoras	47
3.2.2.3	Demora de los equipos por Refrigerio y Cambio de Turno en la mina.....	48
3.2.3	Proceso de la red neuronal	50
3.2.3.1	Modelo de la red neuronal.....	50
3.2.3.2	Eventos discretos	54
3.2.3.3	Entrenamiento de la red.....	56
Capítulo IV.....		57
Pruebas Y Resultados		57
4.1	Resultado del entrenamiento de la red	57
4.2	Visualización de eventos en la mina	58
4.3	Prueba de la red.....	59
Conclusiones.....		64

Recomendaciones	66
Bibliografía	67
Anexos	70

Índice De Tablas

Tabla 1 <i>Variable independiente</i>	7
Tabla 2 <i>Variable dependiente</i>	8
Tabla 3 <i>Diseño de Red Neuronal – ENTRADAS A LA RED</i>	51
Tabla 4 <i>Valor Q para cada par observación acción</i>	52

Índice De Figuras

Figura 1 <i>Estructura de la neurona</i>	10
Figura 2 <i>Modelo de una red RNA</i>	11
Figura 3 <i>Estructura de una red neuronal secuencial</i>	12
Figura 4 <i>Categorías del Machine Learning (aprendizaje automático)</i>	13
Figura 5 <i>Componentes del aprendizaje por refuerzo</i>	14
Figura 6 <i>Recompensa y penalización del aprendizaje por refuerzo</i>	16
Figura 7 <i>Metodología de aprendizaje tipo Q</i>	17
Figura 8 <i>Estrategia de probabilidad</i>	18
Figura 9 <i>Modelo del clima</i>	19
Figura 10 <i>Proceso de decisión</i>	20
Figura 11 <i>Sistema FCS: a) consola gráfica y b) unidad central</i>	21
Figura 12 <i>Dispatch en Operación</i>	22
Figura 13 <i>Pantalla de transacciones</i>	23
Figura 14 <i>Ciclo de acarreo</i>	24
Figura 15 <i>Mensaje de llegada</i>	24
Figura 16 <i>Mensaje de carga</i>	25
Figura 17 <i>Camión pasa por un punto intermedio o de comunicación</i>	25
Figura 18 <i>Distribución de rutas y tajos</i>	27
Figura 19 <i>Distribución de palas y cargadores</i>	28
Figura 20 <i>Ubicación de las chancadoras</i>	28
Figura 21 <i>Distribución de los botaderos</i>	29
Figura 22 <i>Distribución de camiones en el recorrido de la empresa minera</i>	29
Figura 23 <i>Proceso de detención de equipos durante el Cambio de turno</i>	31
Figura 24 <i>Parqueos para realizar cambio de turno en la mina.</i>	31

Figura 25 <i>Línea Temporal del Proceso de cambio de turno Operadores ingresantes</i>	32
Figura 26 <i>Proceso de decisión para detener los equipos</i>	33
Figura 27 <i>Estrategia para la detención de quipos en tres turnos</i>	33
Figura 28 <i>Detención de camiones durante turno noche</i>	34
Figura 29 <i>Categorías de tiempos para cálculo de Utilización y Disponibilidad de Equipos</i>	35
Figura 30 <i>Uso de Camiones operativos por hora en el turno día</i>	36
Figura 31 <i>Uso de Camiones operativos por hora en el turno noche</i>	36
Figura 32 <i>Uso de palas operativas por hora en el turno día</i>	37
Figura 33 <i>Uso de palas operativas por hora en el turno noche</i>	37
Figura 34 <i>Cantidad de descargas en chancadoras por hora en turno día</i>	38
Figura 35 <i>Cantidad de descargas en chancadoras por hora en turno noche</i>	38
Figura 36 <i>Cobertura de chancadoras demoras aguas arriba (turno día)</i>	39
Figura 37 <i>Cobertura de chancadoras demoras aguas arriba (turno noche)</i>	39
Figura 38 <i>Impacto de las demoras aguas arriba en la chancadora C1</i>	40
Figura 39 <i>Diseño del sistema</i>	41
Figura 40 <i>Dimensiones del array (numpy)</i>	42
Figura 41 <i>Visualización en Pygame</i>	43
Figura 42 <i>Diagrama en Matplotlib</i>	44
Figura 43 <i>Histograma para tiempos de cuadro de camiones en palas</i>	46
Figura 44 <i>Histograma para tiempos de carga de camiones en Palas</i>	46
Figura 45 <i>Histograma para tiempos de carga de camiones en Cargadores</i>	47
Figura 46 <i>Histograma para tiempos de descarga de camiones en los botaderos</i>	47
Figura 47 <i>Histograma para tiempos de descarga de camiones en Chancadoras</i>	48
Figura 48 <i>Histograma para Tiempos de demora de refrigerio en camiones</i>	49
Figura 49 <i>Histograma para Tiempos de demora de Cambio de Turno en camiones Turno día</i>	

.....	49
Figura 50 <i>Histograma para Tiempos de demora de Cambio de Turno en camiones Turno noche</i>	50
.....	50
Figura 51 <i>Interacción de aprendizaje con refuerzo y modelo de redes neuronales</i>	51
Figura 52 <i>Diseño de Red Neuronal – SALIDAS DE LA RED</i>	52
Figura 53 <i>Arquitectura de la red neuronal</i>	53
Figura 54 <i>Estrategia Epsilon greedy utilizada para el entrenamiento de la red</i>	56
Figura 55 <i>Resultados de la función de pérdida (Error Cuadrático Medio)</i>	57
Figura 56 <i>Cantidad de descargas totales al día por cada época de entrenamiento</i>	58
Figura 57 <i>Simulación de eventos discretos de la mina</i>	59
Figura 58 <i>Situación de los camiones: a) Operativos y b) Abastecimiento en las palas</i>	60
Figura 59 <i>Fila de camiones en la chancadora</i>	61
Figura 60 <i>Demoras Aguas Arriba en las chancadoras por hora en entorno de simulación</i>	62
Figura 61 <i>Uso de chancadoras por hora en entorno de simulación</i>	62
Figura 62 <i>Análisis de tiempo de respuesta del modelo Q-learning profundo</i>	63

Introducción

El presente proyecto de tesis tiene como fin realizar un modelo de redes neuronales para maximizar la cobertura de camiones en chancadoras para Soc. Minera Cerro Verde S.A.A.

Por ende, se propone los siguientes esquemas capitulares:

En el Capítulo I se expone los ASPECTOS DE LA INVESTIGACIÓN que indican la situación problemática con relación al costo de la industria minera y sistema de gestión de flota hacia algunas empresas, entre ellas está Soc. Minera Cerro Verde S.A.A. Por consiguiente, se enlistan los objetivos y diseño teórico del presente trabajo.

En el Capítulo II se detalla el MARCO TEÓRICO, el cuál brinda información esencial sobre las redes neuronales, tipos de aprendizaje, cadenas de Markov y sistema de gestión de flotas mineras Dispatch.

En el Capítulo III se realiza el DISEÑO DEL SISTEMA que abarca la situación actual de la empresa minera y el desarrollo específico del modelo de la red neuronal elaborado en Python.

En el Capítulo IV se presentan los RESULTADOS, el cuál muestra las pruebas de funcionamientos del modelo.

Finalmente, se destacan las CONCLUSIONES Y RECOMENDACIONES del trabajo basados en los objetivos específicos y desarrollo del proyecto práctico.

Capítulo I

Aspectos De La Investigación

1.1 Planteamiento de la Investigación

1.1.1 Síntesis de la Situación Problemática

Dentro de los costos más altos de la industria minera se encuentran los costos asociados al acarreo y carguío de mineral. Los costos operativos de acarreo y carguío en minas de tajo abierto representan aproximadamente el 50 % del costo total. Por ende, los desafíos para cumplir los planes diarios de tonelaje en la actividad minera se encuentran en periodos en los que se tiene déficit de camiones y palas. Estos tiempos, se traducen en una menor capacidad para mover material, ya sea como desmonte para continuar con el avance la mina o material llevado a los procesos de chancado (Moradi Afrapoli y Askari-Nasab, 2019).

Una correcta gestión de los recursos ayuda de manera notable, lo que conlleva a que la gran mayoría de la actividad minera cuente con un sistema de gestión de flota. Este tiene la intención de maximizar la producción de la mina, minimizar el uso de stockpiles, alimentar la chancadora de acuerdo con los objetivos y cumplir con las restricciones de mezcla de leyes. Sin embargo, los sistemas de gestión de flota cuentan con múltiples opciones que son configuradas por el operador del sistema de gestión de flota bajo su criterio y experiencia entre ellas se pueden mencionar la utilización y prioridades en las palas y chancadoras. Las decisiones de despacho impactan considerablemente la eficiencia de la operación y son de extrema importancia ya que una gran parte de los costos de la minería están asociados con las actividades de camión pala (de Carvalho & Dimitrakopoulos, 2021; Moradi Afrapoli y Askari-Nasab, 2019).

Existen muchas empresas que ofrecen sistemas de gestión de flota minera, entre ellos los que ofrecen mayor demanda están el Modular Mining Systems, Jigsaw Software y Wenco

instalados en 200, 130 y 65 mineras; respectivamente. Sin embargo, Micro mine con sistema Pitram y Caterpillar con CAT MINESTAR FEET son los próximos líderes en sistemas de gestión de flotas mineras (Moradi Afrapoli y Askari-Nasab, 2019).

En Perú, la gran minería también utiliza diferentes softwares de gestión de flota, dentro de los más importantes se encuentran el Modular Mining Systems, Jigsaw Software y Cat Minestar que cuentan con oficinas en Lima y son los principales proveedores de este tipo de software. En Arequipa, la empresa Sociedad Minera Cerro Verde S.A.A. cuenta con el software de gestión de flota de Modular Mining Systems S.R.L., en esta empresa se ha identificado que durante el cambio de turno, refrigerio y periodos de voladura se tienen déficit de camiones y de equipos de carguío representando estos momentos desafíos que son manejados por el operador de despacho de acuerdo con su criterio y experiencia.

1.1.2 Formulación del Problema de investigación

¿Cómo un modelo de redes neuronales puede maximizar la cobertura de camiones en chancadoras para Soc. Minera Cerro Verde S.A.A. durante periodos de baja capacidad de acarreo?

1.1.3 Hipótesis

El uso de un Modelo de Redes Neuronales de aprendizaje profundo por refuerzo Q- learning con un tiempo de procesamiento menor de cinco minutos permite maximizar la cobertura de camiones en chancadoras y asegurar al menos un 90 % de cobertura de camiones durante horas de baja capacidad de acarreo.

1.1.4 Objetivos

- **Objetivo General**

Demostrar que un modelo de redes neuronales de aprendizaje profundo por refuerzo Q-learning con un tiempo de procesamiento menor de cinco minutos asegure al menos un 90 % de cobertura de camiones durante horas de baja capacidad de acarreo.

- **Objetivos Específicos.**

- Realizar un estudio de la cobertura de camiones en chancadoras durante los periodos de baja capacidad de acarreo como son el refrigerio y cambio de turno.
- Identificar las variables que sirvan como recompensa y otorguen penalización en el modelo de redes neuronales.
- Diseñar e implementar un entorno que permita entrenar el modelo de redes neuronales.
- Realizar simulaciones y analizar la cobertura de camiones en chancadoras luego de implementar el modelo de redes neuronales.

1.2 Diseño Teórico

1.2.1 Antecedentes Internacionales

- Según (Zhang et al., 2020), El dinamismo del proceso de despacho es uno de los temas centrales de la optimización de operaciones en industrias tradicionales como la minería, ya que busca la asignación inteligente de los recursos adecuados en el momento y lugar adecuado. La automatización basada en datos está remodelando este campo. En su artículo, sugieren un innovador enfoque de aprendizaje profundo por refuerzo multiagente para resolver el problema de dinamismo del proceso de despacho. En su artículo demuestran que el método propuesto supera significativamente al método más adoptado por la industria en un 5.56% en términos de productividad.
- Según (De Carvalho y Dimitrakopoulos, 2021) desarrolló el proyecto “Integrating Production Planning with Truck-Dispatching Decisions through Reinforcement Learning While Managing Uncertainty” cuya finalidad es mejorar la adherencia al plan operativo y la utilización de la flota en un complejo contexto minero. Varias fuentes de incertidumbre operativa que surgen de las actividades de carga, transporte

y descarga pueden influir en la estrategia de despacho. Dada una secuencia fija de extracción de los bloques de mineral proporcionada por un plan de corto plazo, un modelo de simulador de eventos discretos emula la interacción que surgen de estas operaciones mineras. La repetición continua de este simulador y una función de recompensa, asociando un valor de puntuación a cada decisión de despacho, generan experiencias de muestra para entrenar un modelo de aprendizaje profundo por refuerzo de Q-learning. Los resultados muestran que el método basado en DDQN proporciona un flujo de procesamiento en los molinos con mayor throughput así mismo genera colas más cortas en diferentes destinos lo que demuestra una mejor utilización de la flota.

- Según (Bnouachir et al., 2020) desarrolló el tema “Intelligent Fleet Management System for Open Pit Mine” donde menciona que los sistemas de gestión de flotas actualmente cuentan con una arquitectura de control tradicional. Además, se convierte en un cuello de botella crítico en entornos abiertos y dinámicos donde la escalabilidad y la autonomía son factores clave para su éxito. En este artículo, se propone una arquitectura inteligente distribuida del Sistema de Gestión de Flotas para una mina a cielo abierto que permite el control de los vehículos mineros en tiempo real, de acuerdo con los requerimientos de los usuarios. Enriquecido por una capa de inteligencia posible gracias al uso de algoritmos de inteligencia artificial de alto rendimiento y un mecanismo de percepción confiable y eficiente basado en tecnologías de IoT y gobernado por un sistema de decisión inteligente e integrado que permite que el sistema de gestión de flota mejore su agilidad. Finalmente, este estudio propuso un modelo compuesto por tres capas: la capa del vehículo, la capa de procesamiento y la capa de decisión. Implementaron la primera versión de esta arquitectura y la probaron en la mina experimental Benguerir para mejorar y ampliar

su alcance de aplicación.

- Según (Baek y Choi, 2020) que desarrolló el tema “Deep Neural Network for Predicting Ore Production by Truck-Haulage Systems in Open-Pit Mines” utiliza un modelo de red neuronal profunda y el sistema de camiones a cielo abierto con el propósito de predecir el material durante el día. Se emplea como nodos de entrada, las condiciones de transporte y los tiempos de operación. Para verificar la eficacia del método propuesto, se generaron datos de entrenamiento para los modelos DNN procesando los datos de paquetes recolectados durante 2 meses. Finalmente, los resultados obtenidos en el estudio predijeron que la producción de mineral de la mañana y tarde es 11,40 y 8,87 %; respectivamente. Además, el error entre las producciones de mineral real y prevista en un día es de aproximadamente 4,17 %. Por consiguiente, se espera que el método de predicción de la producción de mineral propuesto pueda eliminar los problemas encontrados por los métodos convencionales de simulación de sistemas de transporte de camiones basados en algoritmos complejos.
- Según (Moradi Afrapoli y Askari-Nasab, 2019) desarrollo el tema “En Mining fleet management systems: a review of models and algorithms” tiene como objetivo revisar los modelos y algoritmos de los sistemas de gestión de flotas mineras. El propósito es comprender los algoritmos detrás de los sistemas de gestión de flotas y las soluciones académicas propuestas para identificar cualquier brecha en la literatura actual y abrir oportunidades y establecer preguntas de investigación sobre la planificación operativa integrada de simulación y optimización. Además, se revisa los sistemas de gestión de flotas industriales y los principales algoritmos; este sistema abarca tres problemas, tales como: despacho en tiempo real, optimización de la producción y ruta corta. Finalmente, las limitaciones de los algoritmos se documentan bajo términos de

viabilidad y optimización. Los resultados permiten evaluar los vínculos lógicos entre los componentes principales de un marco de planificación operativa de simulación y optimización con la teoría actual de los sistemas de gestión de flotas.

1.2.2 Antecedentes Nacionales

- En “Aplicación de redes neuronales artificiales para la predicción de la recuperación de planta concentradora en Minsur S.A. – Unidad San Rafael” (Carrión, 2018) se plantea que la problemática yace en la escases de mineral debido al tonelaje y algunas leyes, por lo que se hace necesario buscar un método de optimización de los procesos a fin de obtener recuperaciones de mineral en la planta concentradora. Para ello, se indaga modelos como la regresión lineal y el backpropagation que se aplican en el procesamiento de minerales, este último genera una distribución de pesos a través del aprendizaje.

1.2.3 Definición y Operacionalización de Variables

- Se tiene una variable independiente X denominada como el modelo de redes neuronales y una variable dependiente Y que es la cobertura de camiones en chancadoras, se detalla en las Tablas 1 y 2; respectivamente.

Tabla 1

Variable independiente

Variable	Definición	Operacionalización	Indicadores	Instrumento
Modelo de redes neuronales	Modelo matemático que emula la forma de trabajo de las neuronas biológicas	Se usará un modelo de Redes Neuronales de aprendizaje profundo por Refuerzo Q-learning. Su frecuencia de operación será cada vez que haya un camión descargue y necesite asignación a las palas, el tiempo de procesamiento debe ser menor a cinco minutos.	Valor de la función de pérdida Tiempo de ejecución del algoritmo	Se realizarán simulaciones en un ambiente de pruebas en el que se tendrá en cuenta el tiempo de ejecución del algoritmo y los resultados obtenidos

Tabla 2*Variable dependiente*

Variable	Definición	Operacionalización	Indicadores	Instrumento
La cobertura de camiones en chancadoras	Se define como el tiempo en el que la chancadora cuenta con camiones del total de tiempo disponible de la chancadora	Garantizar la cobertura de la chancadora por camiones al menos un 90 % del tiempo disponible. Se evitará sobre coberturas de las palas y las chancadoras con camiones con el fin de generar colas de camiones controladas	Tiempo de la chancadora sin camiones Cantidad de camiones en cola en palas Cantidad de camiones en cola en chancadoras	Se medirá a través de estudios para ver el impacto que se tiene en colas de palas, colas de chancadoras y lo principal la cobertura de camiones en chancadora

1.3 Diseño Metodológico

1.3.1 Diseño de contrastación de hipótesis.

El desarrollo del presente proyecto contempla un estudio sobre la situación actual de Soc. Minera Cerro Verde, donde se analiza el tiempo que la chancadora tiene camiones cada hora cuando es impactado por el déficit de equipos durante horas de refrigerio y cambio de turno. Luego, se procede con el diseño del modelo de red neuronal de aprendizaje por refuerzo profundo Q-learning. Para el caso del entorno, se extrae del estudio de la situación actual la cantidad de equipos, los tiempos del ciclo de acarreo y demoras durante refrigerio y cambio de turno para ser simulados. Los agentes son definidos como los camiones, las posibles acciones serán equivalentes a la cantidad de palas, por lo que el camión solo tendrá opción a elegir una pala y la recompensa, priorizará el movimiento de material mineral sobre el estéril y penalizará colas en palas y chancadoras. Se entrenará la red, probando distintas configuraciones de hiper-parámetros mediante el lenguaje de programación Python. Finalmente, se realizarán pruebas en el entorno de simulación con la red entrenada para comparar los tiempos que las chancadoras no tuvieron camiones con el estudio realizado de la situación actual, también se realizará una prueba de tiempo de ejecución del algoritmo.

1.3.2 Población y Muestra

- Se tiene una población finita de 3 chancadoras.
- La muestra corresponde al mismo número de la población, debido a que es un estudio de caso.

1.3.3 Técnicas, Instrumentos, equipos y materiales.

Como sustento teórico se empleará los modelos de redes neuronales por lo cual se hará uso de síntesis bibliográfica respaldada por libros. Además, se utilizará un software que permita generar un entorno en el cual pueda desarrollarse el aprendizaje profundo por refuerzo Q-learning. Por consiguiente, se cuenta con el software de Modular Mining Systems denominado Dispatch. Finalmente, para realizar simulaciones se hará uso de Python, el cual mediante otras librerías compatibles se procederá con las simulaciones y entrenamiento de la red neuronal.

Capítulo II

Marco Teórico

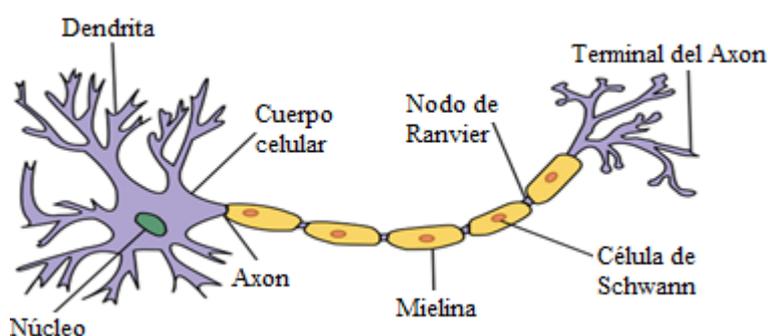
2.1 Modelo Biológico de las Neuronas

La neurona es una célula que está en el sistema nervioso, la cual funciona como unidad principal del tejido. Además, dirige los estímulos capaces de comunicarse entre sí, lo que no hace el resto de las células corporales. Así mismo, el cerebro humano posee más 100 mil millones de neuronas, junto con un promedio aproximado de 7 mil conexiones sinápticas con otras neuronas (Hagan et al., 2014). Por otro lado, las neuronas se distinguen de otras debido a la estructura tal como se indica en la Figura 1, donde se compone de los siguientes elementos (Andrade Tepán, 2013):

- Las dendritas (medio de entrada) son pequeñas ramificaciones encargadas de hacer sinapsis con las terminaciones del axón de otras neuronas.
- En cambio, el axón (medio de salida) forma parte de las células Schwann encargadas de trasladar los estímulos nerviosos desde el cuerpo de estas.

Figura 1

Estructura de la neurona



Nota: Tomado de (Andrade Tepán, 2013)

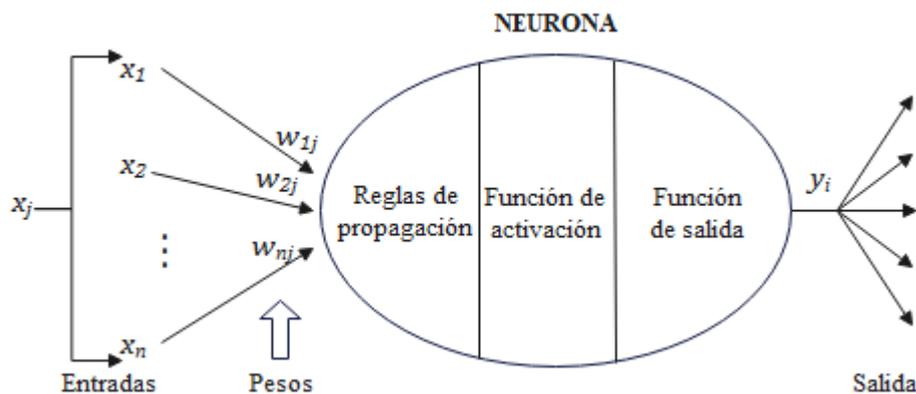
2.2 Redes Neuronales Artificiales RNA

La red RNA se define como una norma matemática que busca imitar la conducta del cerebro humano, el cual forma un sistema que cuente con las facultades de representar actividades

inteligentes, es decir, que cuente con la capacidad de poder aprender y resolver tareas asignadas. En la Figura 2 se visualiza que la variable $x_j = \{x_1, x_2, \dots, x_n\}$ es una representación de las entradas de la red RNA, el cual se encarga de recibir toda la información, previo a la colocación de los pesos expresados como $w_{ij} = \{w_{1j}, w_{2j}, \dots, w_{nj}\}$. Mientras tanto, en el núcleo se desarrollan todas las actividades que permiten resolver la salida de la neurona, este proceso depende mucho de la red con la que se esté trabajando. Por último, la salida se encarga de reintegrar la respuesta de la neurona (Torral Barrera, 2018).

Figura 2

Modelo de una red RNA



A continuación, se detalla los componentes internos de la neurona en una red RNA (Torral Barrera, 2018):

- Regla de propagación: incorpora la investigación procedente de las neuronas artificiales, facilitando la estimación eventual postsináptico de la neurona. Además, establece el posible resultado de correlación de las neuronas, tal como se expresa en la Ecuación 1.

$$net_i(t) = \sum_{j=1}^n w_{ij} \times x_j(t) \quad \text{Ec. 1}$$

- Función de activación $a_i(t)$: abastece la situación permanente de activación de la neurona, es decir, esta se encarga del funcionamiento de la neurona basado en el

potencial $net_i(t)$ al estado de implementación de la neurona anterior $a_i(t - 1)$, tal como se expresa en la Ecuación 2. Sin embargo, se suele obviar el estado anterior $a_i(t - 1)$ ya que en la mayoría de los modelos no es necesario el uso esta variable.

$$a_i(t) = f(a_i(t - 1), net_i(t)) \rightarrow a_i(t) = f(net_i(t)) \quad \text{Ec. 2}$$

- Función de salida: como su nombre lo indica, simboliza la salida vigente de la neurona y se expresa en base a la activación vista en la Ecuación 3.

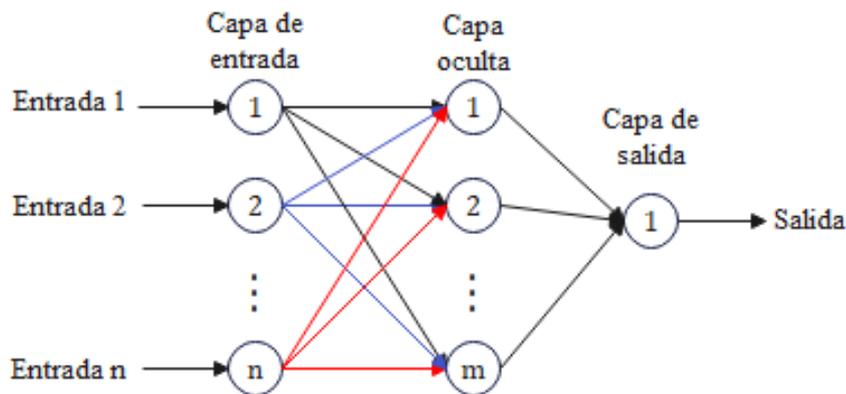
$$y_i(t) = a_i(t) = f(net_i(t)) \quad \text{Ec. 3}$$

2.2.1 Estructura

En general, las redes neuronales presentan varias etapas ya sea de entrada, ocultas y de salida, tal como se presenta en la Figura 3; es importante recalcar que la fase oculta puede contener múltiples capas. Para mejor sustentación, se describen el significado de cada etapa mencionada (Ruiz et al., 2001):

Figura 3

Estructura de una red neuronal secuencial



- Capa Entrada: recibe información (datos) directamente de fuentes externas a la red.
- Capas Ocultas: son dependientes de la red ya que no presentan un contacto directo con el entorno externo y el número de grados ocultos son de un valor mayor e igual a cero. Además, las neuronas se conectan de diferentes maneras; por ejemplo, en la Figura 3 se dice que las capas están totalmente conectadas.

- Capa de salida: transmite la información de la red al exterior.

2.2.2 Fases de una red neuronal

Las redes neuronales contienen una fase de entrenamiento y otra de validación, en la primera se define el tipo de estructura de la red, luego pasa a través de una serie de capas transformadas y activadas a fin de lograr el entrenamiento adecuado. Finalmente, la solución presenta mejores resultados cuando se utiliza una gran cantidad de datos en la entrada. Sin embargo, ante nuevos casos el entrenamiento de la red pueda que no sea aceptable, por lo que se genera la fase de validación y escoge un segundo conjunto de datos para controlar el proceso de aprendizaje. De esta forma, la red neuronal procesa información que no le fue entregada en el proceso de entrenamiento (Toral Barrera, 2018).

2.3 Aprendizaje automático

El aprendizaje automático forma parte de la inteligencia artificial, el cual brinda al ordenador la facultad de aprender sin la necesidad de ser programados. Así mismo, emplea algoritmos para localizar patrones de los datos y lograr construir un modelo predicción o clasificación para la resolución de problemas específicos. Ante ello, los algoritmos se rigen bajo tres formas de aprendizaje, supervisado, por refuerzo y no supervisado vistos en la Figura 4 (Torres.AI, 2021).

Figura 4

Categorías del Machine Learning (aprendizaje automático)



El aprendizaje de tipo supervisado utiliza un modelo capaz de aprender y hacer mapeos unitarios, es decir, una entrada/salida. Además, cuenta con etiquetas que implican usar datos, entre ellos donde se incluye la solución en la fase de entrenamiento. En caso de que el aprendizaje sea no supervisado, los datos no cuentan con etiquetas y por tanto el algoritmo debe clasificar la información por sí mismo. Por último, se tiene el aprendizaje por refuerzo, el cual es una ciencia que establece programas computarizados y muestran una inteligencia parecida a la inteligencia humana (Torres.AI, 2021).

2.4 Aprendizaje por refuerzo

El aprendizaje por refuerzo desarrolla un modelo como agente que sondea un campo desconocido y establece los hechos a desarrollar mediante la prueba y error. En pocas palabras, este modelo debe aprender solo a través de recompensas y castigos mediante las acciones realizadas por el agente (Torres.AI, 2021).

2.4.1 Componentes

A través de la Figura 5 se observa los componentes principales del aprendizaje por refuerzo y se describen a continuación (Lapan, 2018):

Figura 5

Componentes del aprendizaje por refuerzo



- **Agente:** se encarga de la interacción con el entorno efectuando ciertas acciones, tomando investigación y a su vez recibiendo recompensas por el mismo. En resumen, el agente resuelve problemas de forma más eficiente.
- **Entorno o ambiente:** es un factor que se limita ya sea por las retribuciones (adquiridos del entorno), acciones (desarrolladas por el agente o ingresos al ambiente) y observaciones (información extra de las recompensas que adquiere el agente).
- **Recompensa:** es un valor cuantitativo positivo o negativo que se obtiene del entorno y que brinda una retroalimentación al agente.
- **Acción:** es un comportamiento del agente desarrolla en el entorno y pueden ser rotaciones aceptadas por el juego u actividades. En el aprendizaje por refuerzo existen dos tipos de acciones, discretas y continuas. La primera se conforma como un grupo finito de cosas excluyentes en las que un agente pueda desplazarse de izquierda a derecha o viceversa. Por otro lado, las acciones continuas cuentan con valores relacionados con la acción, como por ejemplo la acción del volante de conducción de automóviles con ángulo de dirección y dirección diferente.
- **Observaciones:** se desarrolla como una parte referencial que el entorno le proporciona al agente e indica que es lo que sucede a su alrededor, este tipo de información es significativa para la nueva recompensa ya que contiene datos sobre los premios o castigos, junto con la puntuación adquirida.

2.4.2 Función de la recompensa

Para iniciar, se conoce que los agentes siempre empiezan en “blanco”, eso implica que ingresan sin ningún tipo de conocimiento ni mucho menos conocen el tipo de comportamiento que deben desarrollar. Luego, el agente empieza a tomar acciones aleatorias y mediante ellas recibe pistas que le permiten reconocer si lo que está desarrollando es correcto o erróneo, por lo que recibe un premio o castigo; respectivamente, como se aprecia

en la Figura 6 (Lapan, 2018).

Figura 6

Recompensa y penalización del aprendizaje por refuerzo



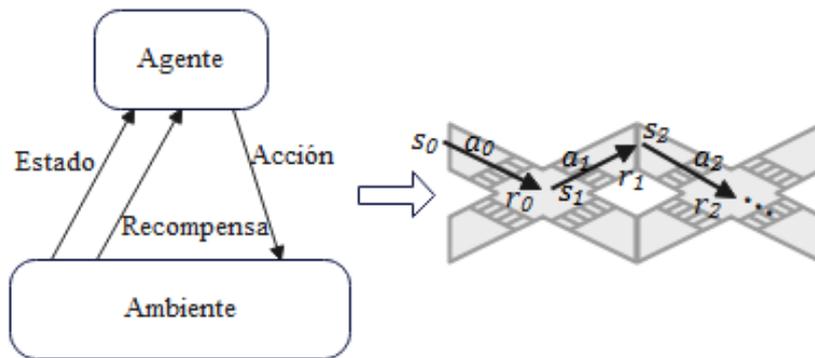
Se sitúa un ejemplo, donde la acción del agente premia con 100 puntos cuando llega a la meta, entonces existe mayor probabilidad de que vuelva elegir ese camino. Sin embargo, si le cambian el camino hacia el objetivo el agente puede generar equivocaciones. En resumen, lo que se busca es alcanzar un equilibrio entre examinar lo desconocido y los recursos del entorno. De ese modo, el agente debe analizar el medio e ir aprendiendo durante el desplazamiento para obtener premios y evitar en lo posible los castigos (Bagnato, 2020).

2.4.3 Aprendizaje Q

Q-Learning es parte de la metodología del aprendizaje por refuerzo, el cual combate las dificultades de aprendizaje para el control de agentes autónomos. Esto se produce por medio de pruebas y error dentro de un entorno dinámico, el cual brinda una señal que permita mejorar cada una de las acciones realizadas. Además, cuenta con la posibilidad de solucionar problemas de decisión, donde el beneficio de una acción está sujeta a una cadena de decisiones markovianos. En tiempo real, el agente se encuentra en cierta posición s_0 del entorno, luego toma una acción a_0 generando un nuevo estado y recompensa r_0 , y así sucesivamente tal como se presenta en la Figura 7 (Printista et al., 2000).

Figura 7

Metodología de aprendizaje tipo Q



El agente desarrolla una serie de acciones cuyos valores son definidos por la función de recompensa a lo largo del tiempo, como resultado el agente decide que acción tomar durante cada paso para maximizar el valor de recompensa. En general, se habla del entorno y tarea sin influencias externas previas, por lo que satisface la propiedad markoviana y se definen como un conjunto de estados S y acciones A posibles, probabilidades de transición $P(s, a, s')$, recompensas esperadas $R(s, a, s')$ y acumuladas R_t en el futuro, vistos en la Ecuación 4; donde γ es un factor de descuento cuyo valor oscila entre 0 a 1 (Printista et al., 2000).

$$\left\{ \begin{array}{l} S = \{s_0, s_1, s_2, \dots, s_n\} \\ A = \{a_0, a_1, a_2, \dots, a_n\} \\ P(s, a, s') = P\{s_{t+1} = s' | s_t = s, a_t = a\} \\ R(s, a, s') = E\{r_{t+1} | s_t = s, a_t = a, s_{t+1} = s'\}^2 \\ R_t = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \end{array} \right. \quad \text{Ec. 4}$$

Aplicando los métodos de la teoría de control, se aplica un algoritmo capaz de efectuar mejores predicciones en cada episodio, cuyo valor $\alpha \in (0, 1)$ va actualizando los valores de $Q(s, a)$, tal como se observa en la Ecuación 5. Este factor suele reducirse paso a paso o mantenerse firme, dependiendo de si se trabaja o no en un entorno estático (Printista et al., 2000).

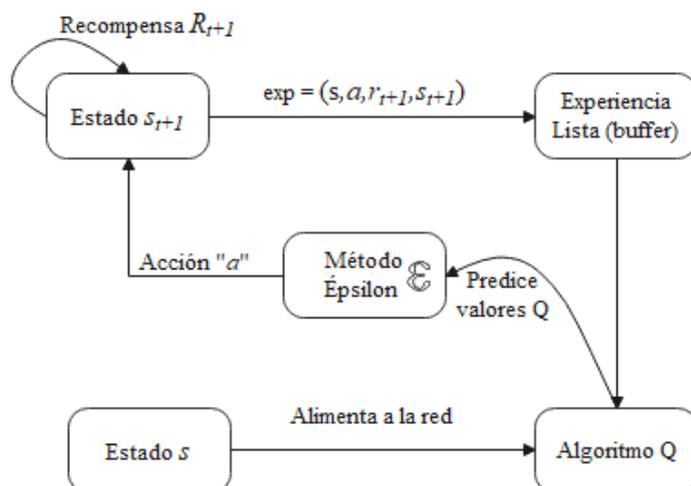
$$Q(s, a) = Q(s, a) + \alpha [r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad \text{Ec. 5}$$

El aprendizaje por refuerzo emplea ciertos criterios, detallados a continuación (Buedo Risueño, 2020):

- Define un número de episodios, el cual va registrando en una lista los valores de pérdida.
- Se establece acciones aleatorias bajo alguna política, por ejemplo, se puede tomar una dirección hacia delante, atrás, izquierda o derecha de un camino (ver Figura 7).
- Cada acción a conlleva una recompensa r y se genera un nuevo estado s_{t+1} .
- Reúne la transición (s, a, r, s') en el almacén de la experiencia (ver Figura 8), brindando actualizaciones por lotes en línea; donde cada experiencia se genera basado en probabilidades, tomando como valor ϵ para designar acciones y posteriormente, guardarlos en una lista. Por consiguiente, se descompone en tensores de mini lotes separados y realiza la iteración de esta y calcula las actualizaciones de los valores Q del mini lote. Luego, se almacena en una matriz final (Y) y se almacena el estado s de cada memoria en una variable X para formar un mini lote de entrenamiento por lotes (Zai y Brown, 2020).

Figura 8

Estrategia de probabilidad



- Luego, cuantifica el valor de Q acumulado.

- Y determina la función de pérdida a través del descenso del gradiente, el cuál disminuye el error dado en la predicción de la red neuronal.

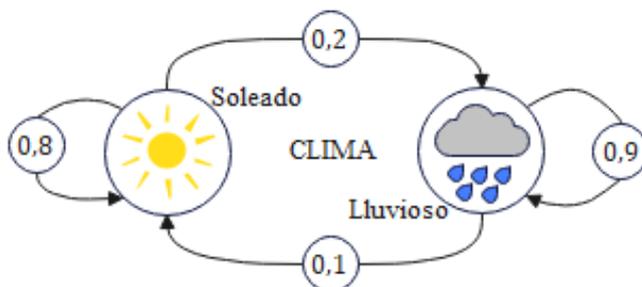
2.5 Cadena de Markov

Los modelos ocultos de Markov forman parte de una estrategia matemática probabilística para definir procesos y estados que no son notables y mensurables de forma directa, al contrario, esto se da a través de efectos externos e indagación (Marcano, 2010).

Además, se lo puede definir como a un conjunto de estados finitos, es decir, las observaciones forman secuencias de una cadena. Por ejemplo, el clima de una ciudad puede ser un día de lluvia o sol, el cual conforma un estado, una secuencia de esa observación a lo largo del tiempo conforma una cadena de estados. Pues bien, se pretende conocer la probabilidad de los días lluviosos en verano e invierno y hacer inclusión de la temporada. Al tener un día soleado, se presenta una probabilidad del 80% de que al siguiente día sea soleado, mientras que existe un 20% de probabilidad de que el siguiente día sea lluvioso; por otro lado, al ver un día lluvioso, se presentara un 10% de probabilidad de una mejora en el clima, a su vez un 90% de que el siguiente día se lluvioso, ver la Figura 9 (Lapan, 2018).

Figura 9

Modelo del clima



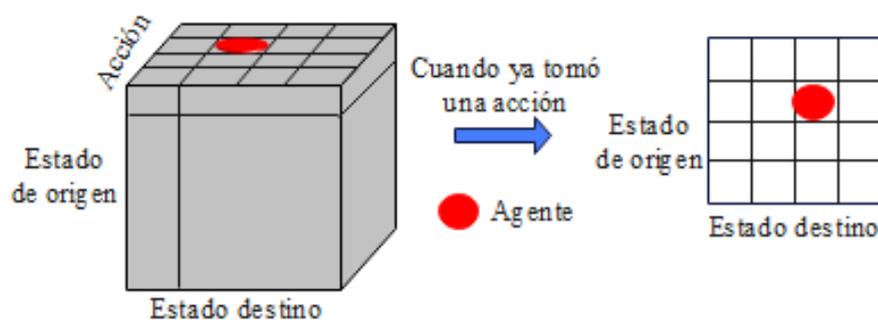
2.5.1 Proceso de recompensa y decisión

Para entregar las recompensas, se generaliza el modelo de Markov por lo que necesita agregar un valor a la transición de un estado a otro y capturar la dinámica del sistema. Las

recompensas se expresan de varias maneras, entre ellas la más generalizada es mediante la determinación de una matriz cuadrada bidimensional con el propósito de conseguir recompensas buenas o malas. Por medio de la Figura 10 se observa una matriz tridimensional conformada de los estados (origen, destino) y acciones; Sin embargo, se lo puede generalizar como una matriz de 2 dimensiones. (Lapan, 2018).

Figura 10

Proceso de decisión



Los agentes no observan las transiciones del estado, al contrario, cuentan con la facilidad de poder escoger una acción activa. Es decir, para cada estado, no se cuenta con una lista de números, pero si se cuenta con una matriz donde la magnitud de profundidad cuenta con las acciones del agente, mientras que la otra medida es el estado de destino, la cual salta después de la ejecución (Lapan, 2018).

2.5.2 Utilidades y problemas relacionados al modelo oculto

Los procedimientos del entorno producen salidas o datos que son tratados como señales discretas o continuas; así mismos son o no estacionarias dependiendo de cómo varíen o no las propiedades estadísticas. Además, existe la necesidad de realizar modelos para dichas señales con el objetivo de que se puedan describir teóricamente, simular, controlar, hasta lograr construir los procesos generadores. En el momento que se desarrolla un modelo oculto de Markov M y la sucesión de observaciones $y = \{y(1), y(2), \dots, y(t), \dots, y(T)\}$ se presentan tres problemas muy frecuentes, tales como (Maldonado, 2012):

- La evaluación para calcular eficientemente la probabilidad de que las observaciones sean generadas por el modelo $P(y/M)$.
- La decodificación para detectar la secuencia de estados y obtener un máximo $P(y/M)$.
- Y el entrenamiento para medir el mejor conjunto y maximizar $P(y/M)$.

2.6 Sistema de gestión de flota minera

Como se ha mencionado en el Apartado 1.2.1 existen diversos softwares de administración minera a gran escala; en este caso se menciona sobre el sistema Dispatch que presenta características ya sea para la comunicación de datos, sensor de posicionamiento global GPS para palas, perforadoras y tractores, delegar asignaciones automáticas a camiones de acarreo en las minas a cielo abierto, entre otras (MMS, 2016).

2.6.1 Componentes

Dispatch es un sistema con funciones óptimas y confiables por lo que contiene diversos componentes, entre los principales están (MMS, 2016):

- Un sistema computarizado de campo PTX, compuesto de una consola gráfica y la unidad central, visto en la Figura 11.a) y b); respectivamente, los cuales son instalados en los camiones, equipos auxiliares, palas y trituradoras.

Figura 11

Sistema FCS: a) consola gráfica y b) unidad central

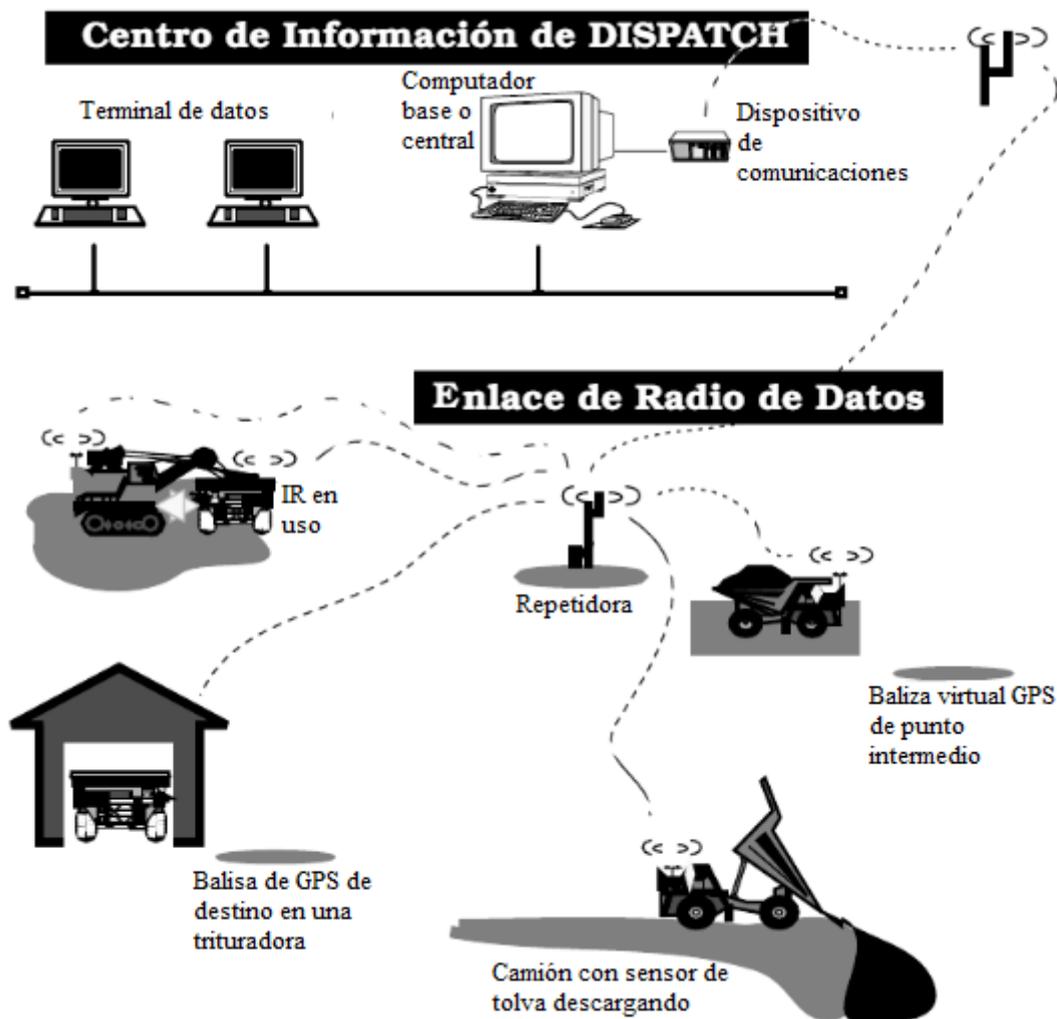


Nota: Tomado de Modular Mining Systems (MMS, 2016)

- Tecnologías GPS e infrarroja IR.
- El enlace de radio de datos, un computador base en el centro de información cuyo propósito es dar asignaciones automáticas a los camiones de acarreo, tal como se presenta en la Figura 12.

Figura 12

Dispatch en Operación



Nota: Tomado de Modular Mining Systems (MMS, 2016)

2.6.2 Proceso de acarreo

El proceso de acarreo parte del inicio de turno, donde cada operador ingresa al sistema Dispatch para posterior registro tanto del usuario como del camión, pala o chancadora, estos datos son enviados al centro de información. Una vez confirmado el registro, se envía un

mensaje al operador sobre la continuidad y revisiones obligatorias del equipo. Por consiguiente, se indica una pantalla de transacciones en la Figura 13, donde el operador y equipo está listo para proceder con el ciclo de acarreo.

Figura 13

Pantalla de transacciones

<div style="display: flex; justify-content: space-between; border-bottom: 1px solid black; padding-bottom: 5px;"> Arriba Abajo PrevPag ProxPag Imprimir Actualizar Borrar Ayuda Salir </div>										
12-ABR-94		Transacciones de DISPATCH					07:10:19			
CARGAS					TONELADAS					
	Total	Mineral	Lixiv	Esteril	No-P	Total	Mineral	Lixiv	Esteril	No-P
Turno:	0	0	0	0	0	0	0	0	000	
Hora Anterior:	0	0	0	0	0	0	0	0	000	
Hora Actual:	0	0	0	0	0	0	0	0	000	
Numero de Camiones:			Actual: 0.9		Se Requieren:		4.2			
*** Diego Vega (5555), operador del Grupo C, ENTRO en Camión C33.07:06:23 ### C33 está LISTO después de Cambiar Turno en el AREA de CAMBIO TURNO.07:10:19										

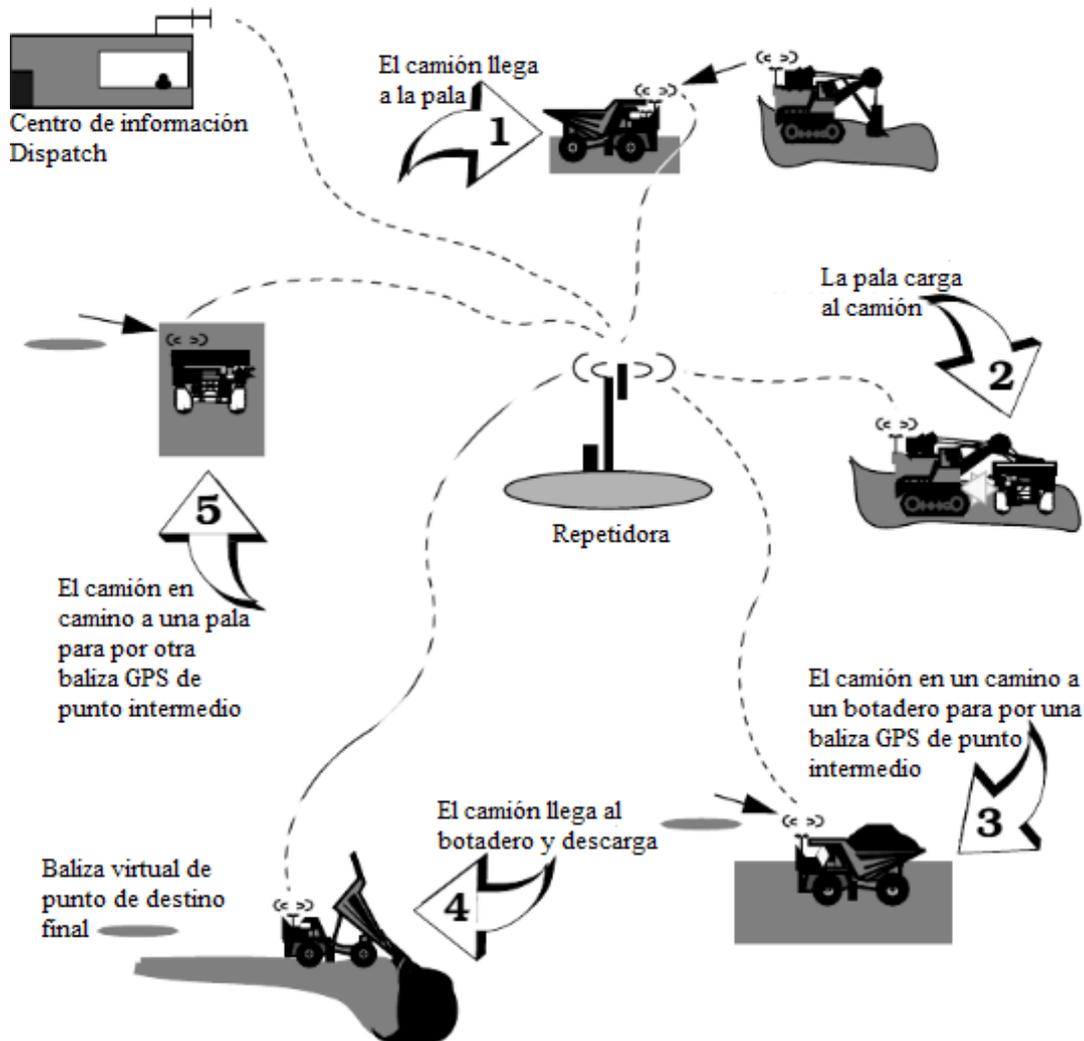
Nota: Tomado de Modular Mining Systems (MMS, 2016)

A continuación, se describe una serie de pasos en la Figura 14 para un típico ciclo de acarreo (MMS, 2016):

- De entrada, se observa como el camión va hacia la pala y una vez que entre al área de cobertura de la baliza, este informa a Dispatch (despliega un mensaje en la pantalla de transacciones al operador) que el camión ha llegado a su primer destino, tal como se indica en la Figura 14.
- Por consiguiente, se procede con la carga al camión y una vez completado este proceso, es informado al sistema Dispatch.

Figura 14

Ciclo de acarreo



Nota: Tomado de Modular Mining Systems (MMS, 2016)

Figura 15

Mensaje de llegada

12-ABR-94 Transacciones de DISPATCH 07:10:19

	CARGAS					TONELADAS				
	Total	Mineral	Lixiv	Esteril	No-P	Total	Mineral	Lixiv	Esteril	No-P
Turno:	0	0	0	0	0	0	0	0	000	
Hora Anterior:	0	0	0	0	0	0	0	0	00 0	
Hora Actual:	0	0	0	0	0	0	0	0	000	
Numero de Camiones:			Actual: 0.9		Se Requieren: 4.2					

*** Diego Vega (5555), operador del Grupo C, ENTRO en Camión C33.07:06:23
 ### C33 está LISTO después del Cambio de Turno en AREA de CAM. TURNO.07:10:19
 *** C33 asignado desde el AREA de CAM. TURNO a la Pala P2.07:10:19
 --- C33 debe llegar a Pala P2 en 3.5 minutos.07:10:19
 --- C33 llegó a Pala P2 (650 Galones)07:13:50

Nota: Tomado de Modular Mining Systems (MMS, 2016)

- Luego, el software examina a que chancadora debe enviar la carga, esto lo hace acorde al material registrado y disponibilidad de las zonas de descarga, como se ve en la Figura 16.

Figura 16

Mensaje de carga

12-ABR-94		Transacciones de DISPATCH					07:16:48			
		CARGAS					TONELADAS			
	Total	Mineral	Lixiv	Esteril	No-P	Total	Mineral	Lixiv	Esteril	No-P
Turno:	1	0	0	1	0	90	0	0	9000	
Hora Anterior:	0	0	0	0	0	0	0	0	000	
Hora Actual:	1	0	0	1	0	90	0	0	0900	
Numero de Camiones:		Actual: 0.9			Se Requieren: 4.2					

```

*** Diego Vega (5555), operador del Grupo C, ENTRO en Camion C33.07:06:23
### C33 esta LISTO despues del Cambio de Turno en AREA de CAM. TURNO.07:10:19
*** C33 asignado desde el AREA de CAM. TURNO a la Pala P2.07:10:19
--- C33 debe llegar a Pala P2 en 3.5 minutos.07:10:19
--- C33 llevo a Pala P2 (650 Galones)07:13:50
--- C33 cargando en Pala P2; Pala P2 improductiva durante 4.1 minutos.07:14:06
--- P2 debe cargar C33 en 2.7 minutos. 07:14:06
--- P2 cargo a C33 con Material Esteril.07:16:48
*** C33 asignado de Pala P2 a Botadero B6107:16:48
--- C33 debe llegar a Botadero B61 en 7.2 minutos.07:16:48
    
```

Nota: Tomado de Modular Mining Systems (MMS, 2016)

- Previo a que llegue el camión a la chancadora, pasa por una baliza virtual intermedia (punto de comunicación), cuya función es de monitorear el tiempo que se tarda durante el ciclo de acarreo, tal como se observa en la Figura 17.

Figura 17

Camión pasa por un punto intermedio o de comunicación

```

--- C33 debe llegar a Pala P2 en 3.5 minutos.07:10:19
--- C33 llevo a Pala P2 (650 Galones)07:13:50
--- C33 cargando en Pala P2; Pala P2 improductiva durante 4.1 minutos.07:14:06
--- P2 debe cargar C33 en 2.7 minutos. 07:14:06
--- P2 cargo a C33 con Material Esteril.07:16:48
*** C33 asignado de Pala P2 a Botadero B6107:16:48
--- C33 debe llegar a Botadero B61 en 7.2 minutos.07:16:48
--- C33 llevo al "punto de comunicacion" PC00107:20:01
    
```

Nota: Tomado de Modular Mining Systems (MMS, 2016)

- Pasa un tiempo y el camión llega al destino final que es la chancadora; ante ello, el software ha determinado en tiempo real el proceso de acarreo. Finalmente, el camión pasa por otro punto intermedio, previo a la llegada a otra pala y así sucesivamente se

repite el ciclo.

Existen descansos tales como el refrigerio de los operadores, cambio de turno, mantenimiento, reabastecimiento de combustible y procesos de voladura que se producen en las minas, por lo que Dispatch realiza cálculos de optimización y asignación antes de que los operadores entren al sistema (MMS, 2016).

Capítulo III

Diseño Del Sistema

3.1 Situación Actual de la Empresa Sociedad Minera Cerro Verde S.A.A.

Sociedad Minera Cerro Verde S.A.A es una de las empresas más conocidas del sector minero en Perú, el cual está enfocada a la extracción/producción del cobre y molibdeno en un 18.2 y 27%; respectivamente (Cerro Verde, 2022).

3.1.1 Equipos operativos

Actualmente, la empresa minera cuenta dispone de 110 camiones, 13 palas, 2 cargadores, y 3 chancadoras primarias, los cuales se encuentran distribuidos entre los tajos de Santa Rosa y Cerro verde, tal como se presenta en la Figura 18. Además, cuenta con una integración entre los tajos de Santa Rosa y Cerro Verde.

Figura 18

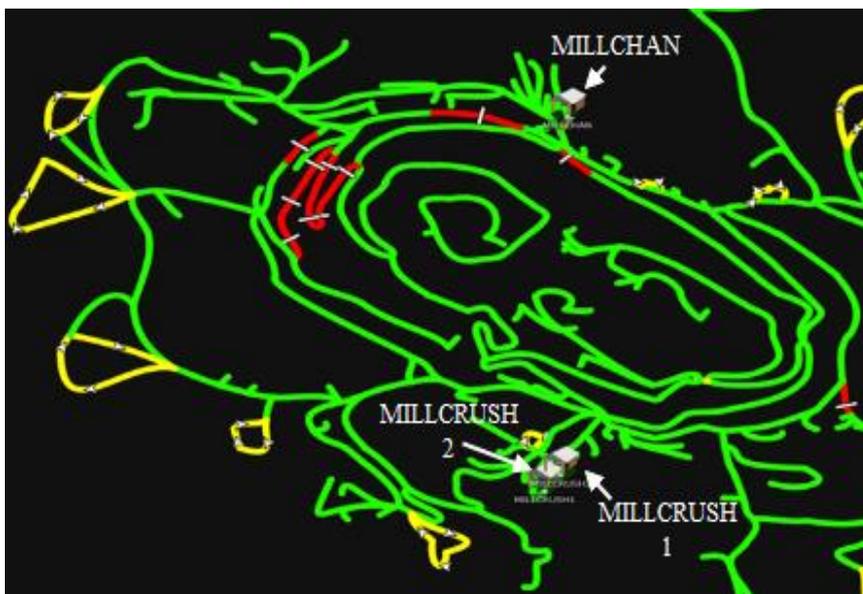
Distribución de rutas y tajos



En la Figura 19 se observa la distribución de las palas y cargadores, donde es importante mencionar, que las palas pueden cambiar de ubicación dependiendo de la necesidad operativa y el plan de minado diario.

Figura 19*Distribución de palas y cargadores*

En cambio, las chancadoras son posiciones fijas, es decir, no cambian de ubicación, tal como se presenta en la Figura 20.

Figura 20*Ubicación de las chancadoras*

Por medio de la Figura 21 se observa algunos botaderos, donde se aloja el material estéril o contenido de bajo rendimiento, los cuales son apilados en montones fuera del área de

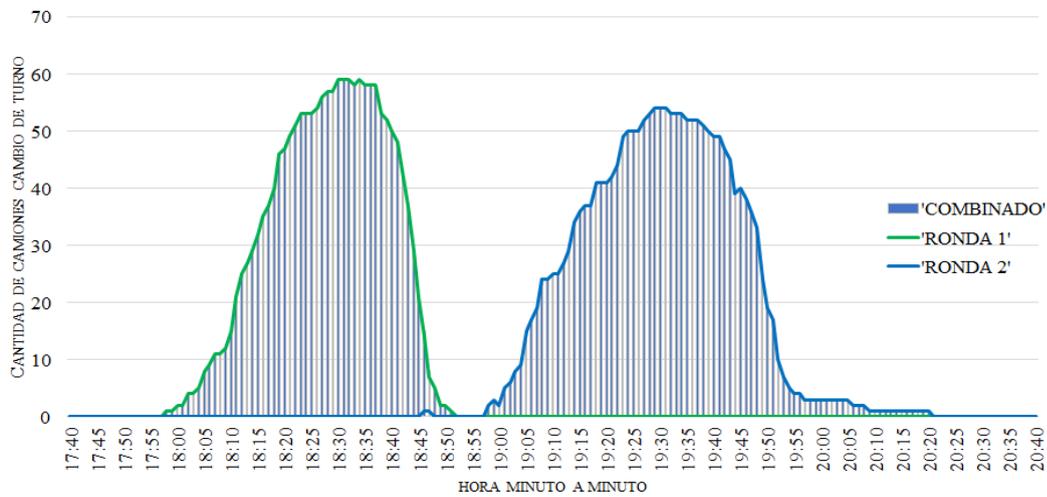
El propósito de la actividad minera consiste en trasladar el material con ley de mineral a las chancadoras. Actualmente, la cantidad de equipos se encuentran eficientemente dimensionados permitiendo mantener el objetivo de cubrir a la chancadora cuando todos los equipos se encuentran operativos. De igual manera no todos los camiones van a la chancadora, debido a que, para el avance de la mina es necesario ir descubriendo el mineral, por lo cual, se requiere desplazar el material estéril, más conocido como desmonte, todos los días. Durante las horas en las que se cuenta con el total de los equipos, no hay dificultad para cubrir a la chancadora con camiones, sin embargo, existen ciertos periodos de tiempo cuyos equipos operativos se detienen ya sea para hacer el relevo de operador (cambio de turno) o debido al refrigerio. Por consiguiente, las chancadoras bajan su cobertura de camiones y se presenta un déficit de camiones y palas en la mina.

3.1.2 Cambio de turno

Las actividades de la mina se realizan las 24 horas del día, siendo distribuidas en dos fases horarias de 12 horas, por lo que se tiene el cambio de turno a las 07:30 horas y 19:30 horas, en cada uno de estos eventos, se detienen todos los camiones y palas de manera sistemática. Con la finalidad de no dejar desbastecida a la chancadora, cada uno de estos eventos no se puede ejecutar en un solo paso y por lo tanto se realiza el cambio de turno en dos rondas separadas en el tiempo. La Figura 23 muestra un gráfico de la distribución en el tiempo cada minuto de la detención de equipos durante las horas de cambio de turno, se puede apreciar las dos rondas.

Figura 23

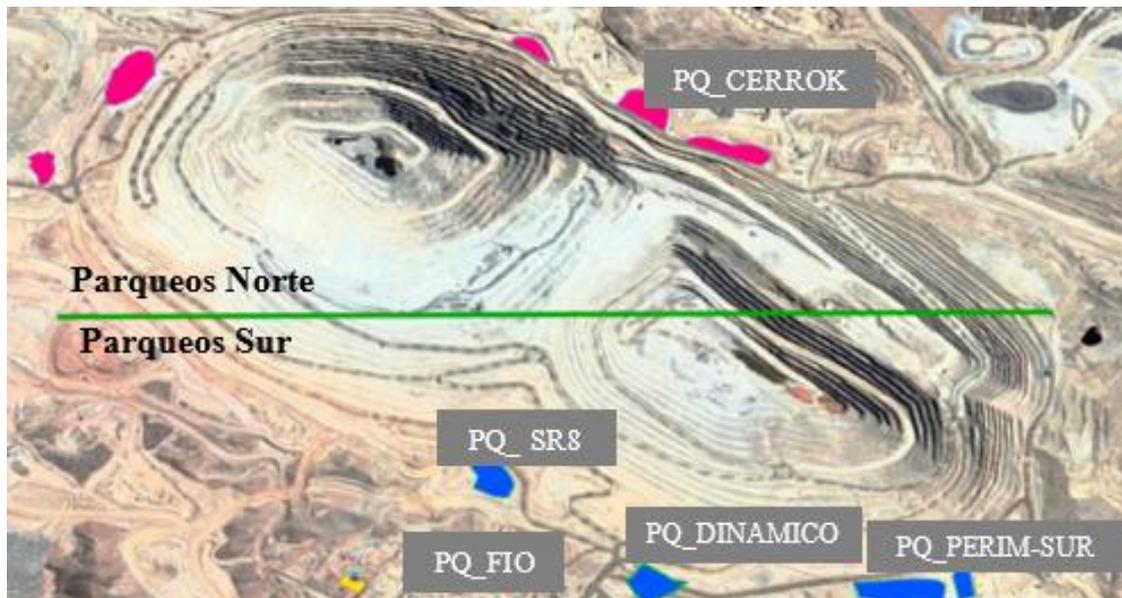
Proceso de detención de equipos durante el Cambio de turno



En la Figura 24 se indica los parqueos para detener los equipos durante las horas de cambio de turno.

Figura 24

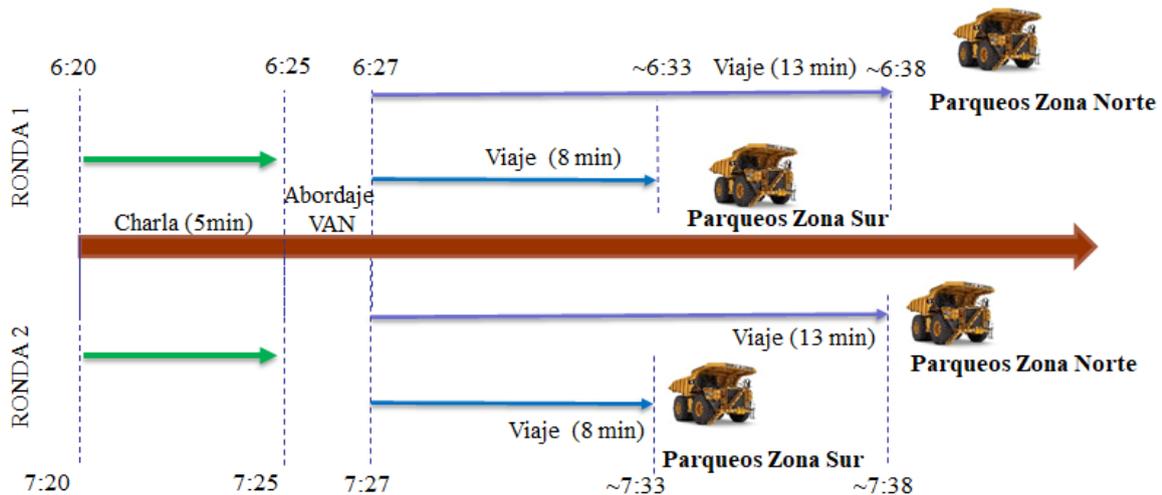
Parqueos para realizar cambio de turno en la mina.



Finalmente, en la Figura 25 mostramos un gráfico donde se aprecia el proceso y la línea de tiempo de los eventos acontecidos durante el cambio de turno para los operadores ingresantes.

Figura 25

Línea Temporal del Proceso de cambio de turno Operadores ingresantes

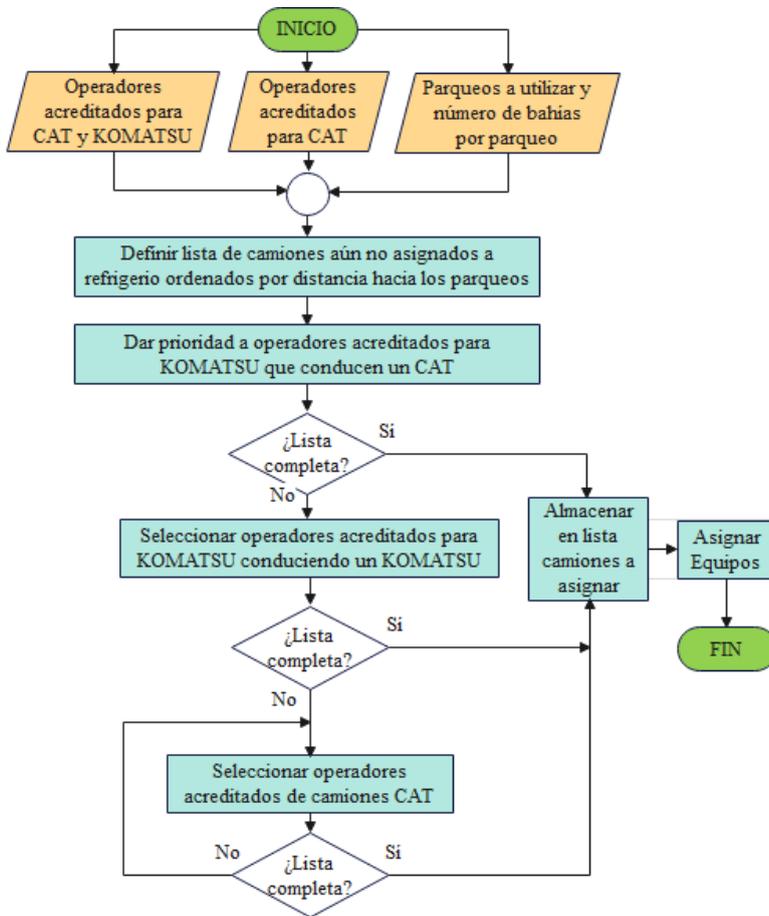


3.1.3 Refrigerio

Durante las actividades en la mina se realiza una detención operativa de los equipos cuando llega la hora de los refrigerios, de igual manera que en cambio de turno, no se pueden detener todos los equipos en una sola ronda, por lo que en este caso los equipos son detenidos en tres rondas en los horarios de 11:30-12:30, 12:30-13:30 y 13:30-14:30; el cual detiene aproximadamente un tercio de la flota en cada ronda de parada en los equipos. La Figura 26 muestra el proceso de toma de decisión de los supervisores para seleccionar a los equipos que bajan en cada una de las rondas.

Figura 26

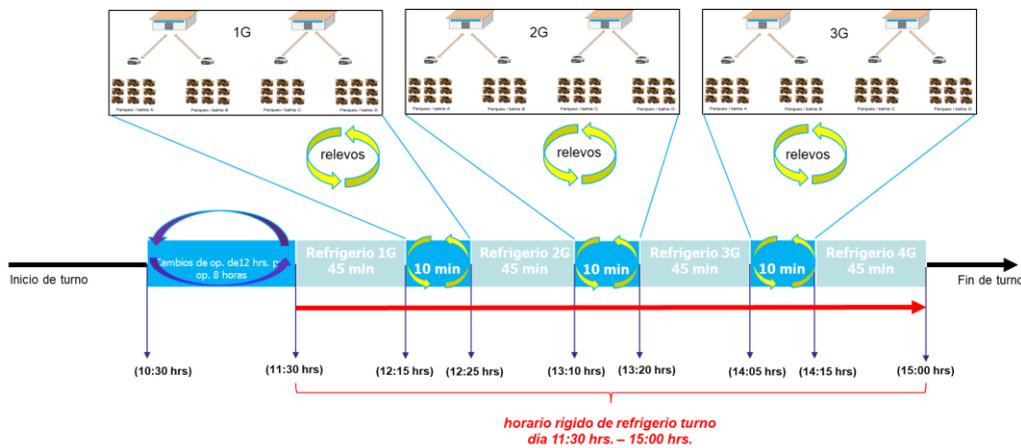
Proceso de decisión para detener los equipos



La Figura 27 muestra la línea de tiempo de la detención operativa de equipos al refrigerio y su regreso a la operación.

Figura 27

Estrategia para la detención de quipos en tres turnos

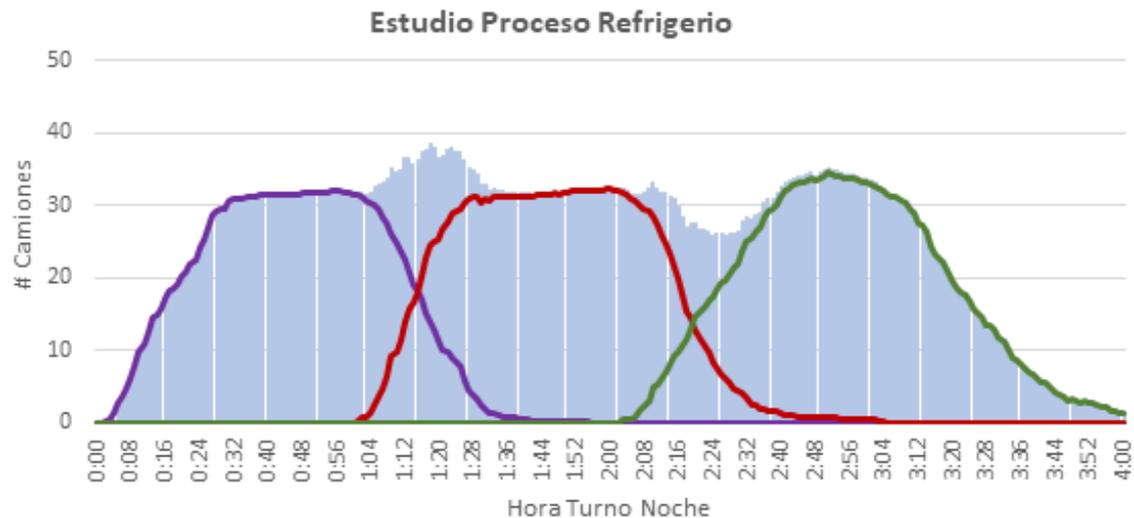


horario rígido de refrigerio turno día 11:30 hrs. - 15:00 hrs.

Finalmente, en la Figura 28 se muestra un gráfico de cada minuto durante el proceso de refrigerio donde se identifica la distribución de camiones con la demora categoría refrigerio.

Figura 28

Detención de camiones durante turno noche



3.1.4 Análisis de camiones operativos por hora

Para calcular el tiempo operativo de los camiones en la empresa minera, se hace uso del sistema Dispatch, cada camión cuenta con una pantalla abordo, en la cual, codifican sus categorías para poder obtener un correcto cálculo de porcentaje de disponibilidad y porcentaje de utilización de los equipos. Por medio de la Figura 29 se observa como el tiempo calendario T_C se distribuye en el tiempo disponible T_D y malogrado (no disponible); a su vez, cada uno de ellos tienen subcategorías, como en el caso del tiempo disponible que se divide en el tiempo Operativo T_O , Demoras Operativas y demoras no operativas, estas subcategorías nos permiten calcular, cuanto del tiempo disponible fue usado el equipo, a esto se le llama utilización del equipo.

Figura 29

Categorías de tiempos para cálculo de Utilización y Disponibilidad de Equipos

TIEMPO CALENDARIO				
TIEMPO DISPONIBLE			TIEMPO MALGRADO	
TIEMPO OPERATIVO	DEMORAS OPERATIVAS	DEMORAS NO OPERATIVAS Y RESERVAS	PLANEADO	NO PLANEADO
TIEMPO CALENDARIO	= Representa el total de Horas en un periodo determinado (Ej. Para un día serían 24 horas).			
TIEMPO DISPONIBLE	= Las cantidad de Horas disponibles del equipo.			
TIEMPO MALGRADO	= Las horas no disponibles de un equipo, puede ser por mantenimiento programado o un evento fortuito.			
TIEMPO UTILIZADO	= Las Horas disponibles en las que un equipo fue utilizado.			
DEMORAS NO OPERATIVAS Y RESERVAS	= Las Horas que el equipo estuvo disponible pero no estuvo siendo usado.			

El cálculo de la disponibilidad $D\%$ expresado en porcentaje se define como la razón entre el tiempo disponible y calendario, tal como se presenta en la Ecuación 6.

$$D\% = \frac{T_D}{T_C} \times 100 [\%] \quad \text{Ec. 6}$$

En cambio, para determinar el porcentaje de utilización $U\%$ se define como la relación entre el tiempo operativo T_O y disponible T_D , visto en la Ecuación 7.

$$U\% = \frac{T_O}{T_D} \times 100 [\%] \quad \text{Ec. 7}$$

En segunda instancia, se ha realizado un estudio basado en la información del mes de abril del presente año (2022), con el propósito de calcular la cantidad de camiones operativos en mina por hora; donde se establece los tiempos T_O de todos los camiones en cada hora, lo cual nos permite estimar la cantidad de camiones operativos en la empresa minera durante esa hora. Por medio, de las Figuras 30 y 31 se observa como disminuye la cantidad de camiones durante el proceso de cambio de turno y refrigerio ya sea en el turno día o noche. A pesar de que los horarios son similares para los eventos de cambio de turno y refrigerio, los turnos día

y noche presentan características distintas.

Figura 30

Uso de Camiones operativos por hora en el turno día

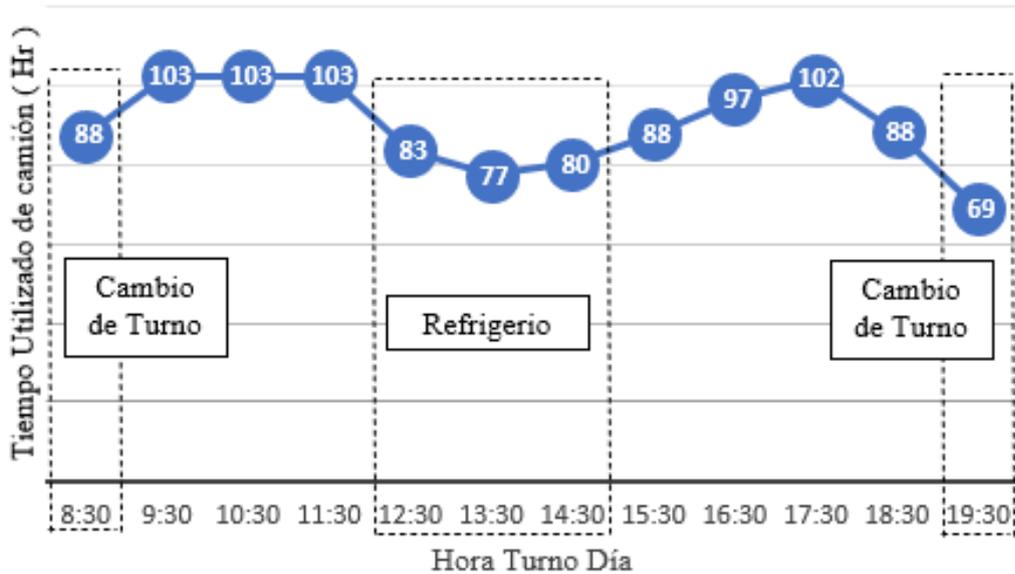
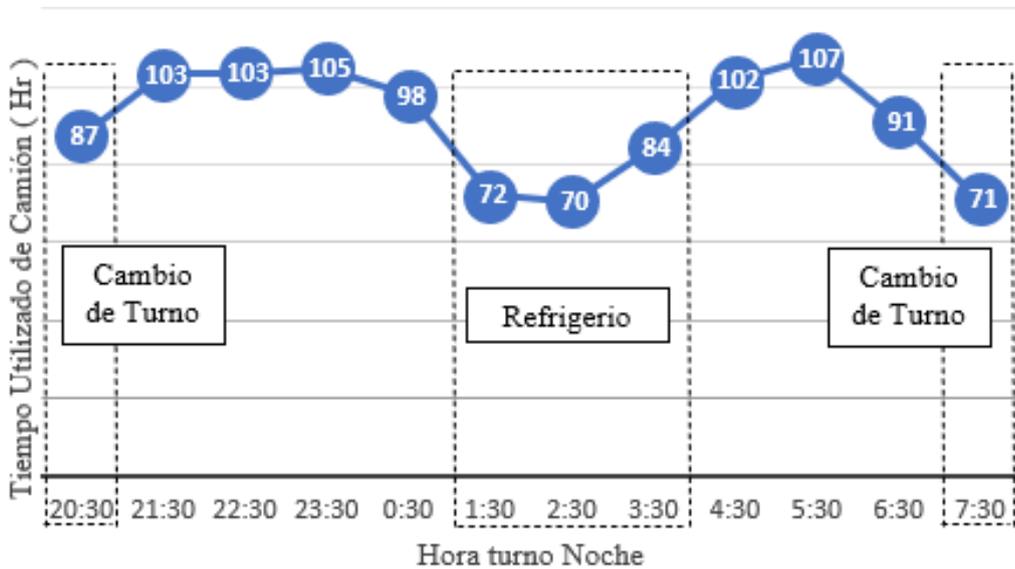


Figura 31

Uso de Camiones operativos por hora en el turno noche



Los operadores de palas de igual manera realizan el cambio de turno y refrigerio, en estos casos los operadores suelen tener algunos relevos con el propósito de que en todo momento haya palas operativas. Sin embargo, por simple inspección se observa en las Figuras 32 y 33 como baja de una a cuatro unidades la cantidad de palas disponibles.

Figura 32

Uso de palas operativas por hora en el turno día

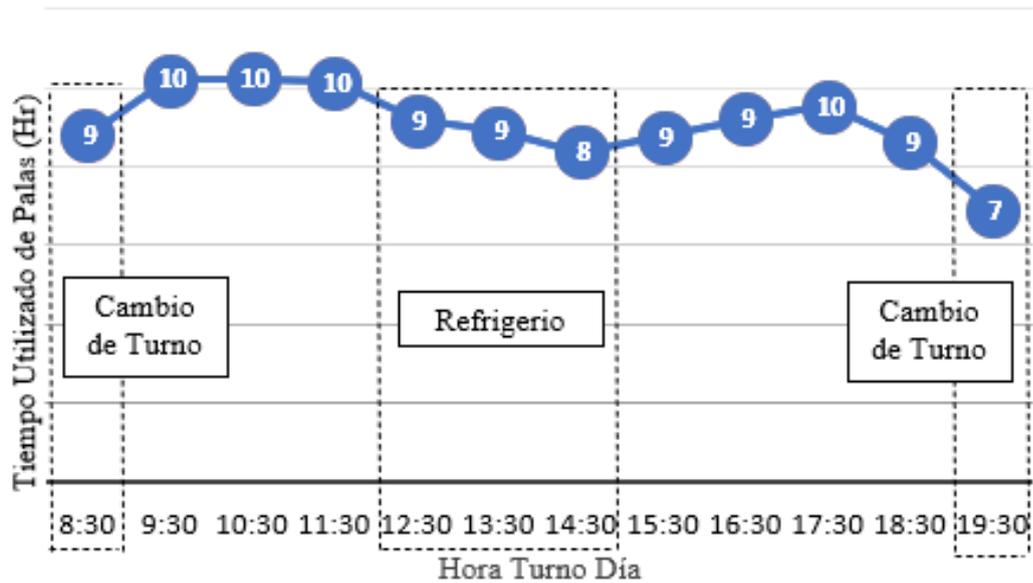
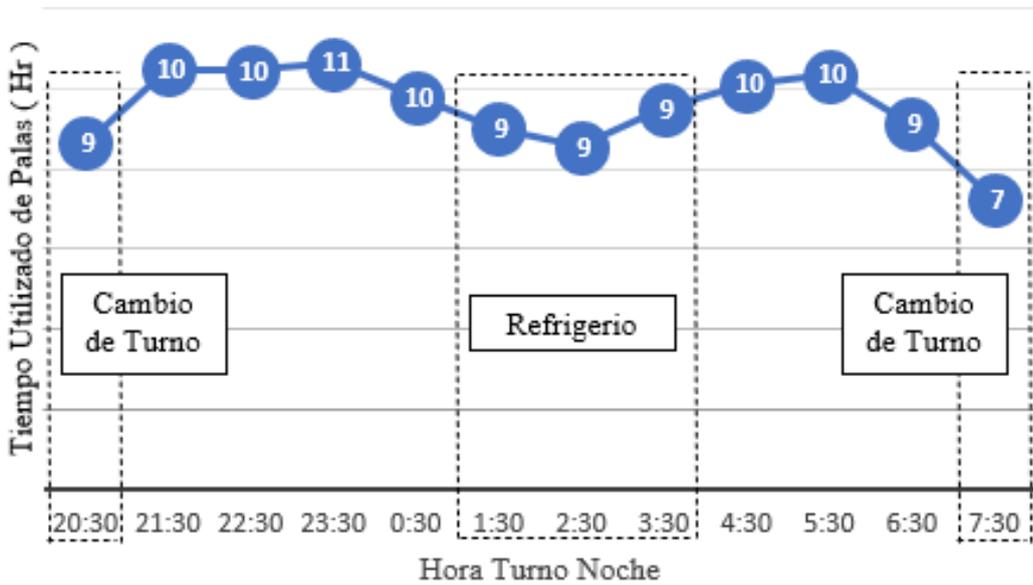


Figura 33

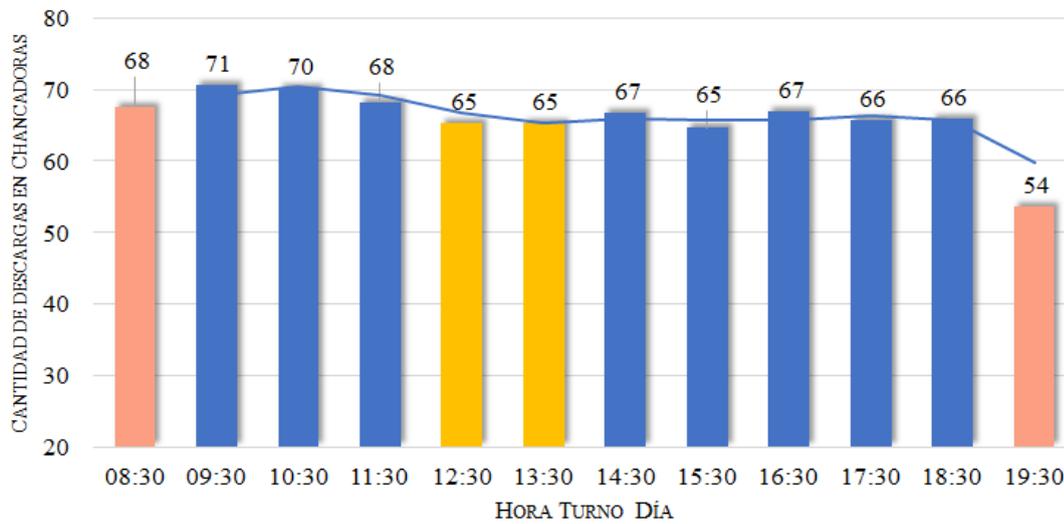
Uso de palas operativas por hora en el turno noche



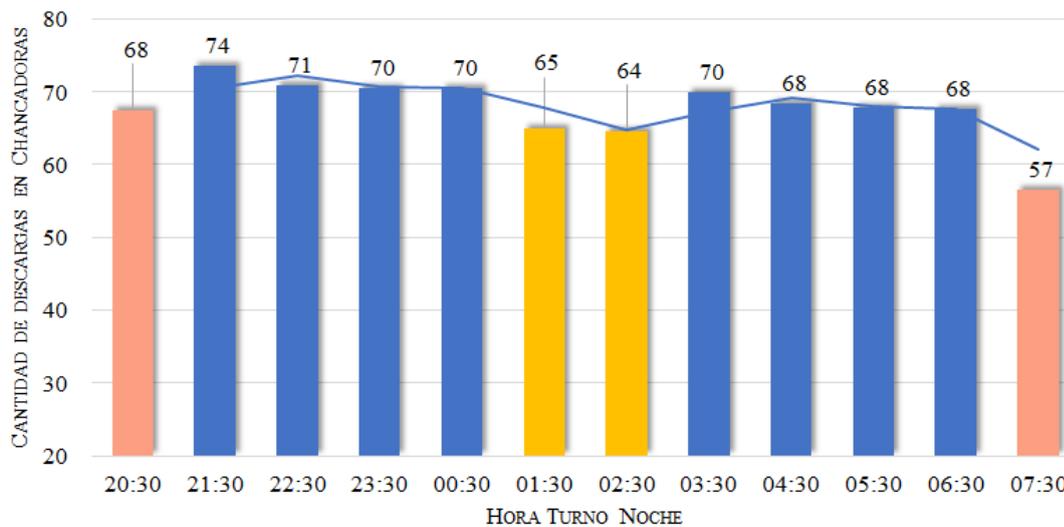
Estos procesos mencionados se reflejan de igual manera, en el tonelaje por hora alimentado a las chancadoras, en las Figuras 34 y 35 en los turnos día y noche, respectivamente, mostramos la cantidad de camiones descargados por hora en las chancadoras.

Figura 34

Cantidad de descargas en chancadoras por hora en turno día

**Figura 35**

Cantidad de descargas en chancadoras por hora en turno noche



En las chancadoras existe un evento denominado “Demoras Aguas Arriba” que indica el porcentaje de tiempo en el que NO hubo camiones en las chancadoras. Además, se analiza este evento en una de las chancadoras para verificar el impacto en los horarios de cambio de turno y refrigerio. Los resultados los podemos ver en las Figuras 36 y 37.

Figura 36

Cobertura de chancadoras demoras aguas arriba (turno día)

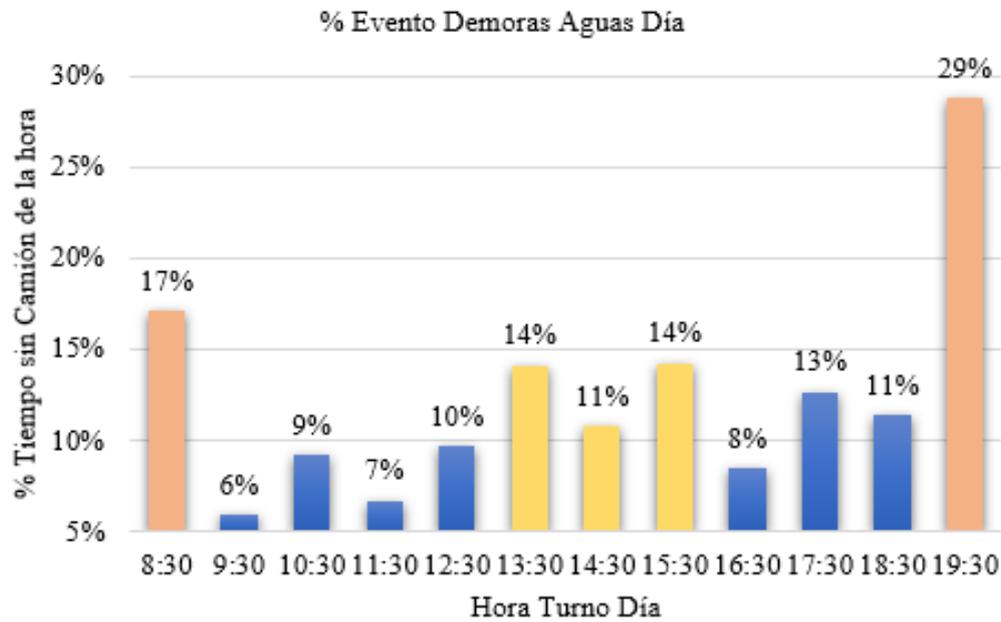
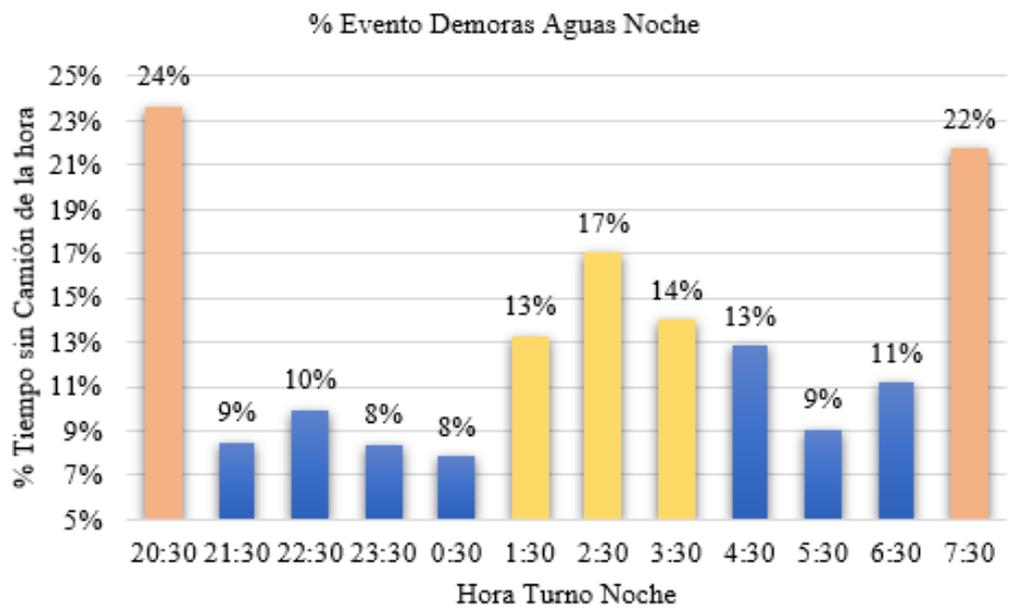


Figura 37

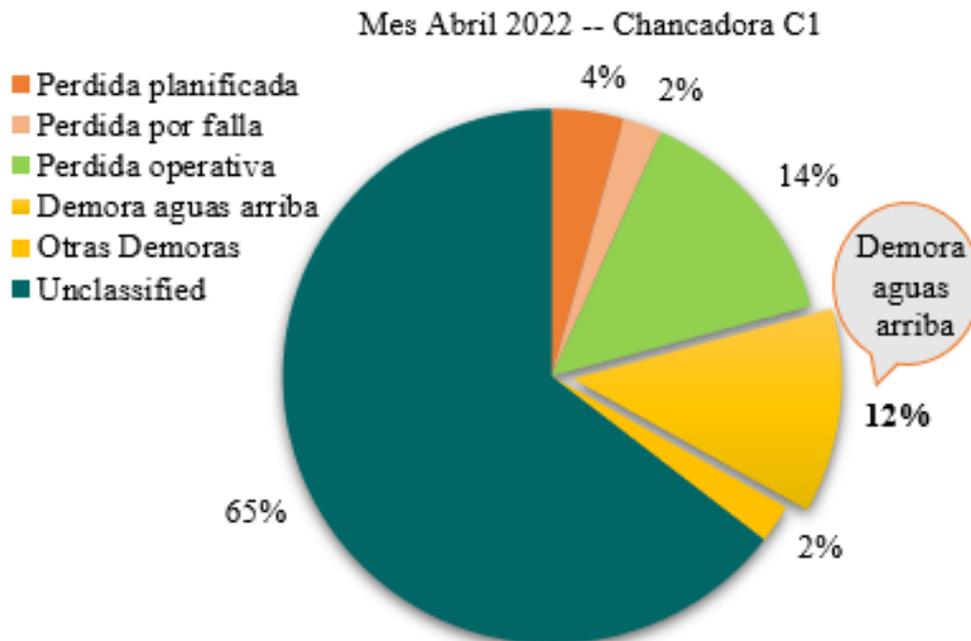
Cobertura de chancadoras demoras aguas arriba (turno noche)



En el mes de abril del 2022 se observa el impacto (12 %) que tiene en la utilización de una de las chancadoras el evento de Demoras Aguas Arriba, es decir, el tiempo que la chancadora no tuvo camión, tal como se presenta en la Figura 38.

Figura 38

Impacto de las demoras aguas arriba en la chancadora C1



3.2 Diseño Elaborado En Python

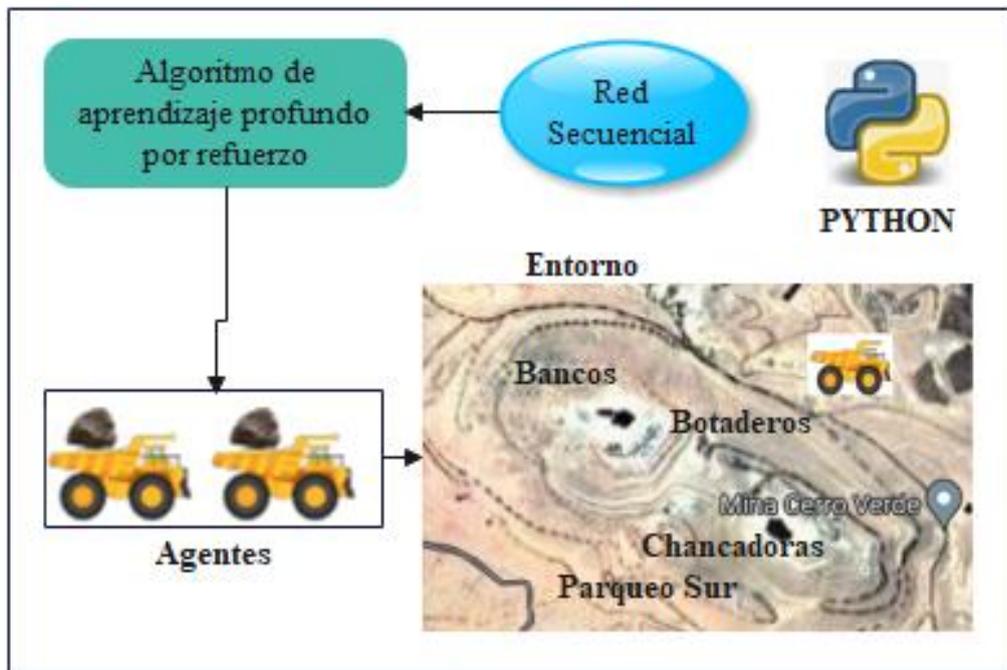
De acuerdo con la teoría revisada en el apartado 2.4, se diseña el modelo de redes neuronales de aprendizaje por refuerzo profundo Q-learning. Inicialmente definimos el entorno, el cual utiliza información del apartado 3.1 junto con información de un estudio de tiempos de ciclo de acarreo. Luego, pasamos a definir los agentes, en nuestro caso serán los camiones. Para el caso de las acciones, se considera la posibilidad de dirigirse a las palas disponibles.

Finalmente, se define una ecuación para la recompensa (ver Figura 39).

Usaremos el lenguaje de programación de código abierto Python, junto con algunas librerías que nos permitirán simular el proceso en el tiempo necesario y la librería Pytorch de Python que nos permitirá entrenar el modelo de red neuronal.

Figura 39

Diseño del sistema



3.2.1 Librerías y módulos

3.2.1.1 Simpy

Es una biblioteca que ayuda a la simulación de eventos discretos y emplea funciones de Python para modelar componentes activos denominados agentes, clientes o vehículos. Los procesos van dentro de un entorno, donde los agentes interactúan entre sí y con él, por lo que se crean sucesos y rendimientos *yield*. Por ejemplo, cuando se produce un acontecimiento en el proceso, este último se suspende y se reanuda cuando ocurre el evento. Entre sus características, se puede emplear un tiempo de espera *timeout* para que el proceso se apague y se produzca el evento mencionado. Finalmente, se crea un método denominado Environment o entorno para crear todos los demás sucesos pertenecientes al proceso (Simpy, 2020).

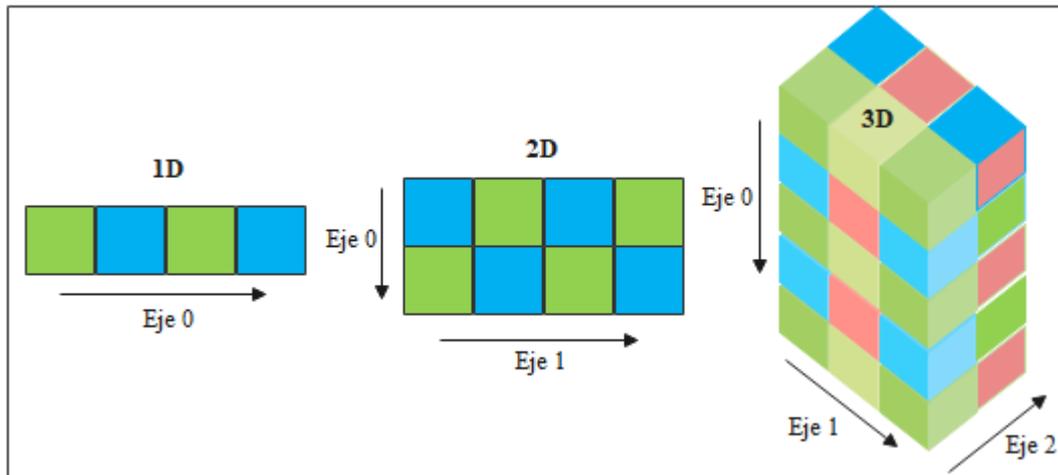
3.2.1.2 Numpy

La librería Numpy tiene como finalidad el análisis de datos y cálculo numérico en un alto

volumen de datos, estos a su vez se representan mediante una estructura denominada Array que dependerá del número de dimensiones (1D, 2D, 3D), tal como se muestra en la Figura 38 (Alberca Sánchez, 2022).

Figura 40

Dimensiones del array (numpy)



Existen diversas funciones con las que se puede generar un array, tales como (Alberca Sánchez, 2022):

- Una lista o tupla *np.array(lista)*.
- Ceros *np.zeros(dimensiones)*.
- Elementos aleatorios *np.random.random(dimensiones)*, entre otros.

3.2.1.3 PyTorch

La librería PyTorch tiene como propósito optimizar el aprendizaje profundo a través de tensores (estructuras multidimensionales) y mediante la unidad de procesamiento gráfico GPU. A continuación, se define algunos bloques de construcción de las redes neuronales (PyTorch, 2022):

- Modelo de red neuronal secuencial denominado *torch.nn.Sequential()*.
- Transformación lineal de la salida y en función de una entrada x , tal que $y = xA^T + b$ y se expresa como *torch.nn.Linear(x, y)*.

- Capa de activación que rectifica elemento a elemento desde 0 hasta un valor máximo *torch.nn.ReLU()*.
- Función de pérdida en base al error mínimo cuadrado *torch.nn.MSELoss()*.
- Optimizador tipo Adam que depende del modelo de la red neuronal y tasa de aprendizaje *lr*, expresado como *torch.optim.Adam(modelo, lr)*.

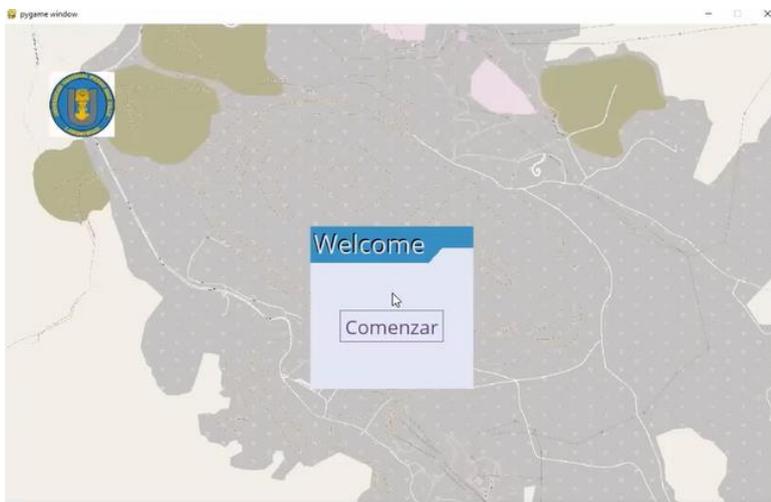
3.2.1.4 Pygame

Pygame utiliza una secuencia de módulos orientada en general a los videojuegos, eso implica una creación de programas multimedia compatibles con Python. A continuación, se describen algunos comandos (Pygame, 2022):

- `Pygame.image.load()` realiza la apertura de una imagen, el cual admite formatos bmp, gif, jpeg, png, entre otros; tal como se presenta en la Figura 41.

Figura 41

Visualización en Pygame



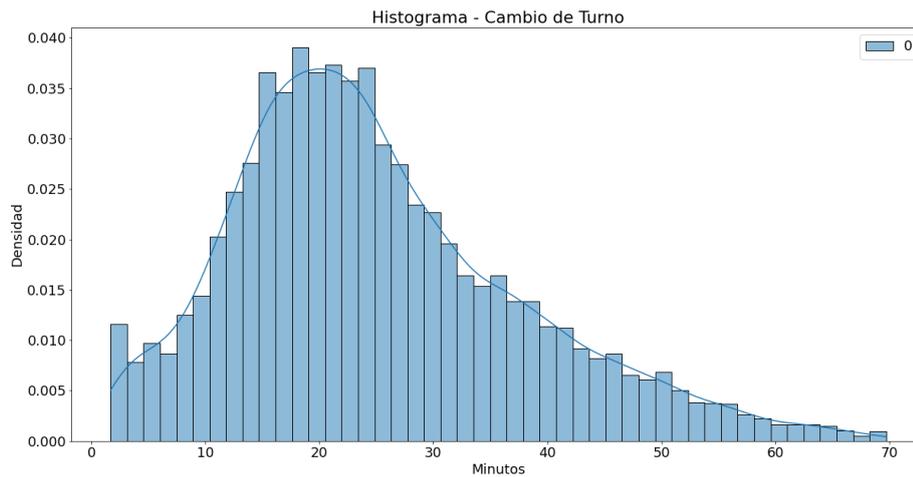
- `Pygame.transform.scale()` hace un escalamiento del tamaño de la figura.
- `Pygame.display.set_mode()` inicializa la pantalla a ser visualizada.
- `Pygame.transform.flip()` voltea la imagen vertical y horizontalmente.
- `Pygame.font.SysFont()` define el tipo y tamaño de las letras.

3.2.1.5 Matplotlib

Esta biblioteca tiene la capacidad de hacer figuras animadas, estáticas e interactivas, según se presenta en la Figura 42 (Matplotlib, 2021).

Figura 42

Diagrama en Matplotlib



3.2.1.6 Módulos y bibliotecas internas de Python

Existen una gran cantidad de módulos dentro de Python que realizan funciones como generadores, contenedores, aritméticas, entre otras detalladas a continuación (Python, 2022):

- Se utiliza un contenedor generalizado de colas *collection.deque()* para devolver un elemento emergente seguro.
- El módulo Random genera números aleatorios de un rango establecido, ya sea de tipo:
 - Entero *random.randint(m, n)*; donde m y n son números pertenecientes a los números naturales.
 - *random.sample(población, k)* que devuelve una lista de elementos únicos k , de la población.
 - Distribución normal *random.normalvariate(μ, σ)*; donde μ representa la media y σ es la desviación estándar.

- Pickle es un módulo encargado de ensamblar estructuras de datos mediante protocolos binarios, es decir, que el objeto se convierte en una secuencia de bytes.
- Mediante la biblioteca *openpyxl* permite leer (*load_workbook*) y escribir archivos de Excel.

3.2.2 Designación del tiempo de acarreo y equipos

Se realiza un análisis durante el ciclo de acarreo en un periodo de 30 días con la finalidad de obtener los tiempos durante las demoras debido al refrigerio y cambio de turno, traslado de camiones, cuadro y carga de palas, descarga en chancadoras y botaderos. Además, se utiliza un script en transact-SQL y el sistema Dispatch para determinar y extraer los tiempos de acarreo; respectivamente. Con el uso del Dispatch se hace uso de la media móvil de los cuatro últimos viajes a través del sensor de posicionamiento global GPS ubicado en cada uno de los equipos.

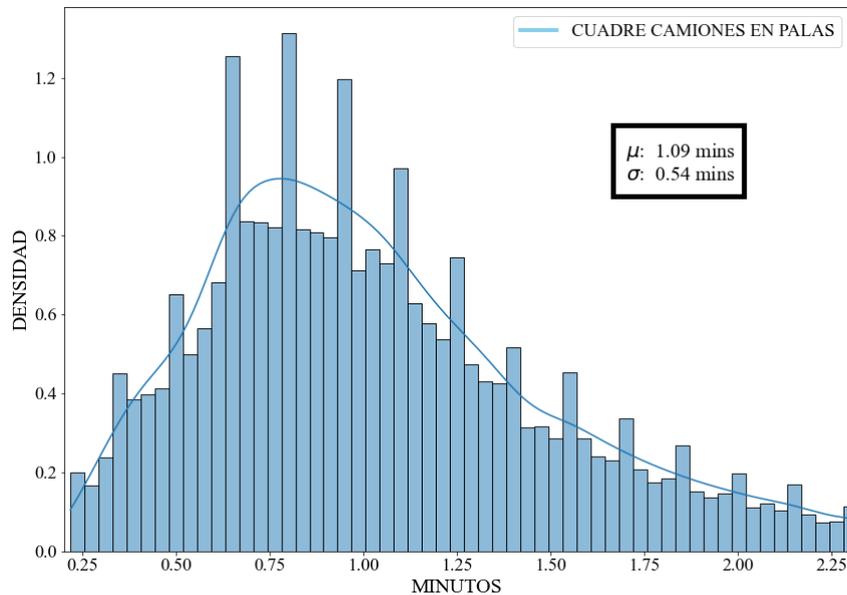
De la empresa minera, se seleccionan 15 palas cuya posición no es fija, 4 botaderos (desmonte), 3 chancadoras y un parqueo de camiones en la zona sur de la Empresa Minera. Además, Dispatch brinda información con coordenadas mina; por lo que se realiza una conversión al mapa cartográfico WGS84, es decir, en coordenadas de longitud y latitud; tal como se indican en los Anexos 1 al 3. Por consiguiente, se realizaron 252 combinaciones entre las diversas localizaciones de carga y descarga. En cambio, para la ubicación del parqueo de camiones se utiliza 50 combinaciones.

3.2.2.1 Cuadre de camiones y carga de palas

El cuadro de los camiones en la pala corresponde al tiempo que se demora el camión, desde que llega a la pala, hasta ubicarse en posición para ser cargado por la pala. En la Figura 43 se observa un estudio estadístico para determinar el tiempo de cuadro ante el uso de diversos camiones, donde se destaca una media $\mu = 1.09 \text{ mins}$ y desviación estándar $\sigma = 0.54 \text{ mins}$.

Figura 43

Histograma para tiempos de cuadro de camiones en palas



Para el estudio de tiempos de carga de las palas, se ha dividido la información en dos categorías, una enfocada en las palas ($\mu = 1.30 \text{ mins}$, $\sigma = 0.45 \text{ mins}$) y otra en los cargadores ($\mu = 4.80 \text{ mins}$, $\sigma = 1.32 \text{ mins}$), tal como se muestran en las Figuras 44 y 45; respectivamente.

Figura 44

Histograma para tiempos de carga de camiones en Palas

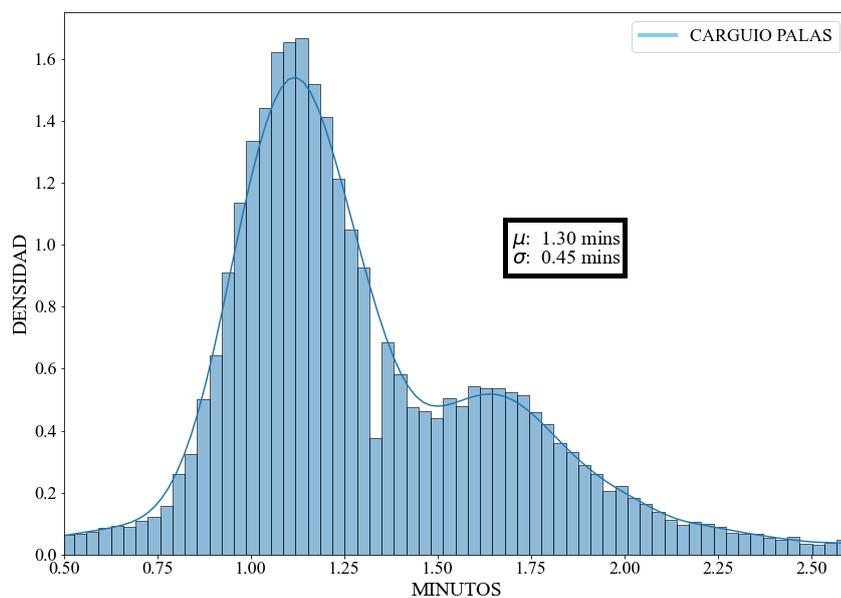
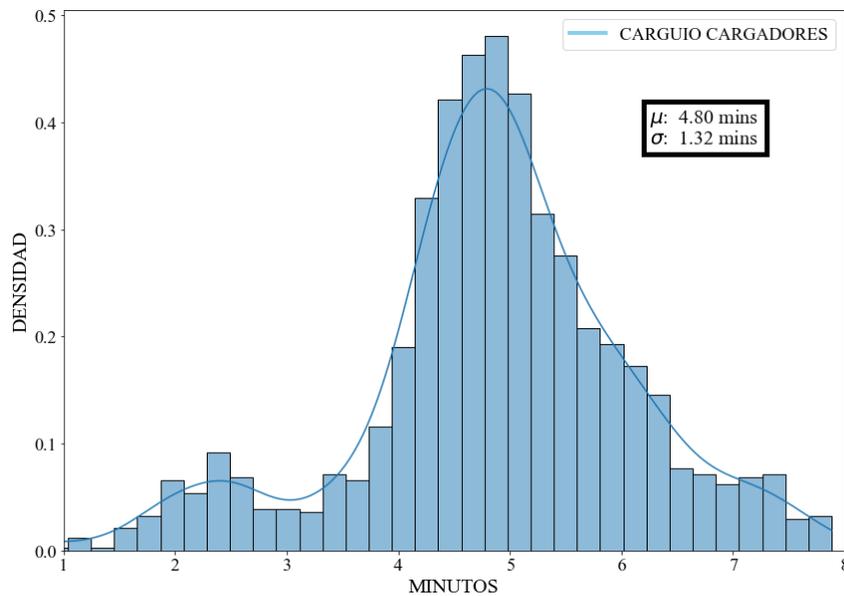


Figura 45

Histograma para tiempos de carga de camiones en Cargadores

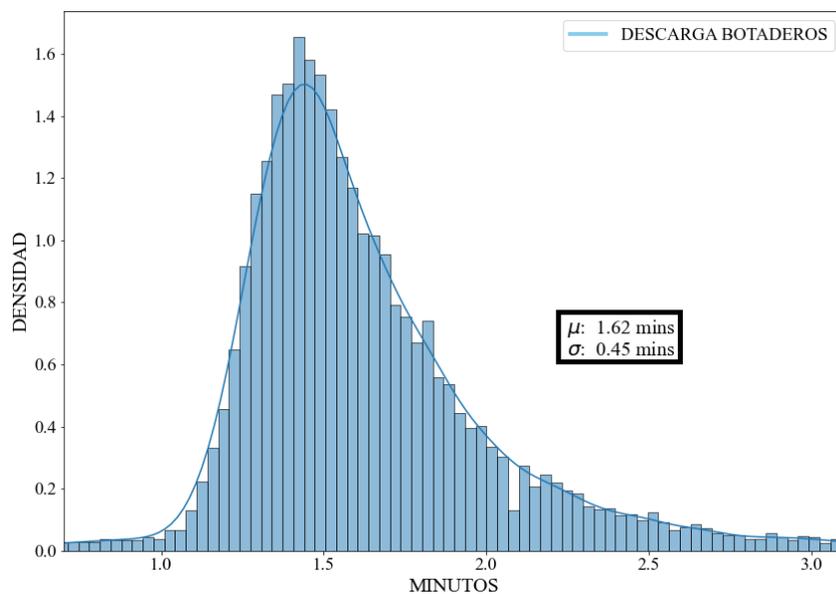


3.2.2.2 Descarga en botaderos y chancadoras

En el caso de los botaderos se tiene un tiempo de cuadro uniforme, debido a que no cuenta con restricciones, es decir, que no se producen colas durante el desmonte de material posee una $\mu = 1.62 \text{ mins}$ y $\sigma = 0.45 \text{ mins}$, visto en la Figura 46.

Figura 46

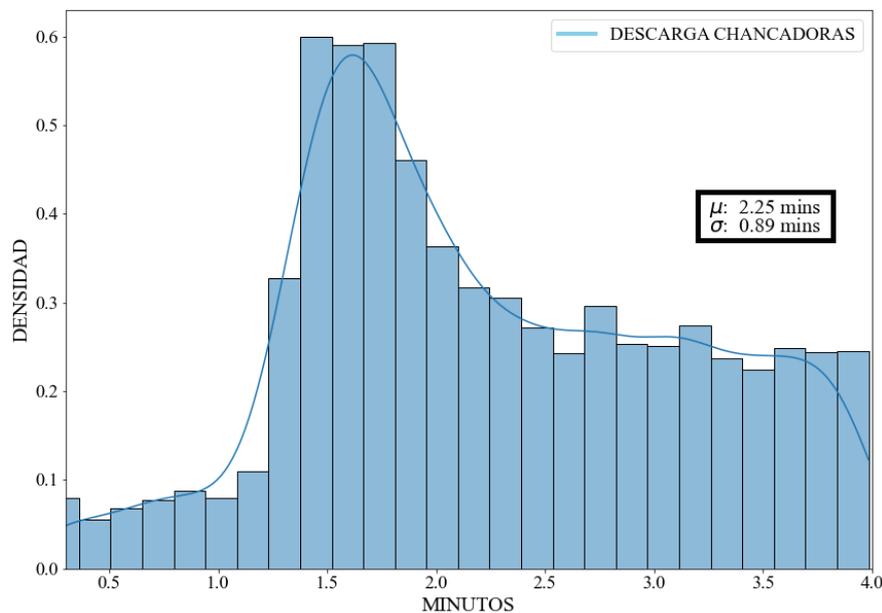
Histograma para tiempos de descarga de camiones en los botaderos



En el caso de las chancadoras se forman colas de camiones, por lo que, a diferencia de los botaderos, presentan restricciones al momento de dar pase a los equipos. En la Figura 47 se observa los valores de tiempo de descarga en las chancadoras que tienen unas estadísticas de $\mu = 2.25 \text{ mins}$ y $\sigma = 0.89 \text{ mins}$, la desviación estándar alta se debe a que los tiempos de descarga son variados y dependen de las características mineralógicas del material (como dureza, fractura, entre otros).

Figura 47

Histograma para tiempos de descarga de camiones en Chancadoras



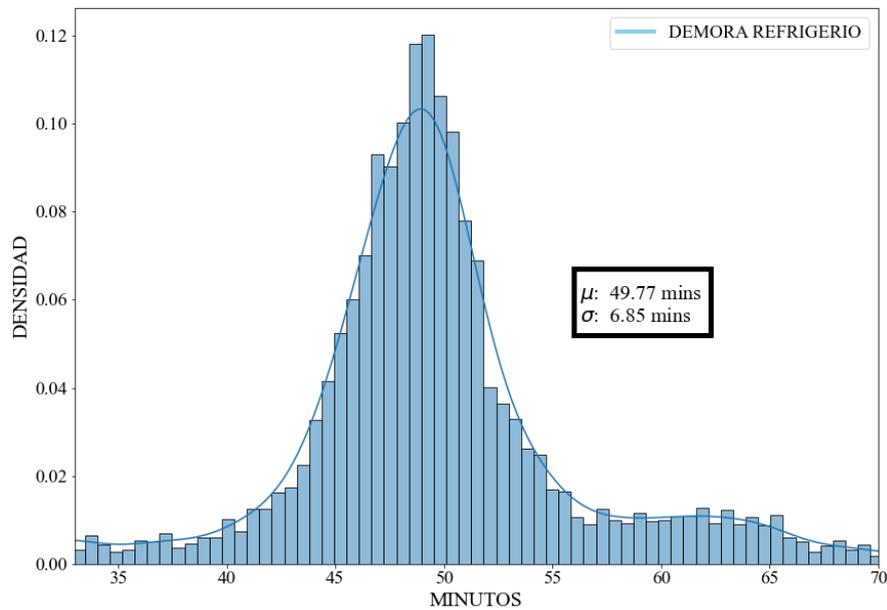
3.2.2.3 Demora de los equipos por Refrigerio y Cambio de Turno en la mina

A continuación, se analiza los tiempos de demoras existentes en la mina en un periodo de 30 días que corresponden al mes Abril del 2022. Por consiguiente, los datos que se presentan corresponden a la categoría de demoras en camiones por refrigerio y cambio de turno, estas demoras, al igual que los tiempos de ciclo del camión, no son siempre valores fijos, por lo que se generará una curva normal con el promedio y desviación estándar para incluir estas demoras en el simulador de eventos discretos Simpy. En primera instancia, se analiza el refrigerio, para determinar el promedio y desviación estándar el cual presenta estadísticas de

$\mu = 49.77 \text{ mins}$ y $\sigma = 6.85 \text{ mins}$, esto se evidencia en la Figura 48.

Figura 48

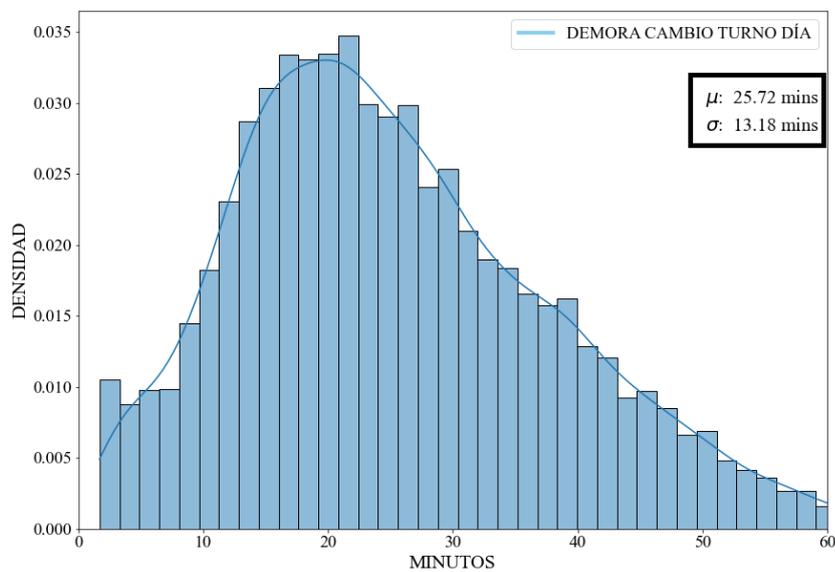
Histograma para Tiempos de demora de refrigerio en camiones



Durante el cambio de turno entre las 18:30 horas a 19:30 horas, correspondiente al turno día, se obtiene una distribución cuyos parámetros son $\mu = 25.72 \text{ mins}$ y $\sigma = 13.18 \text{ mins}$, presentado en la Figura 49.

Figura 49

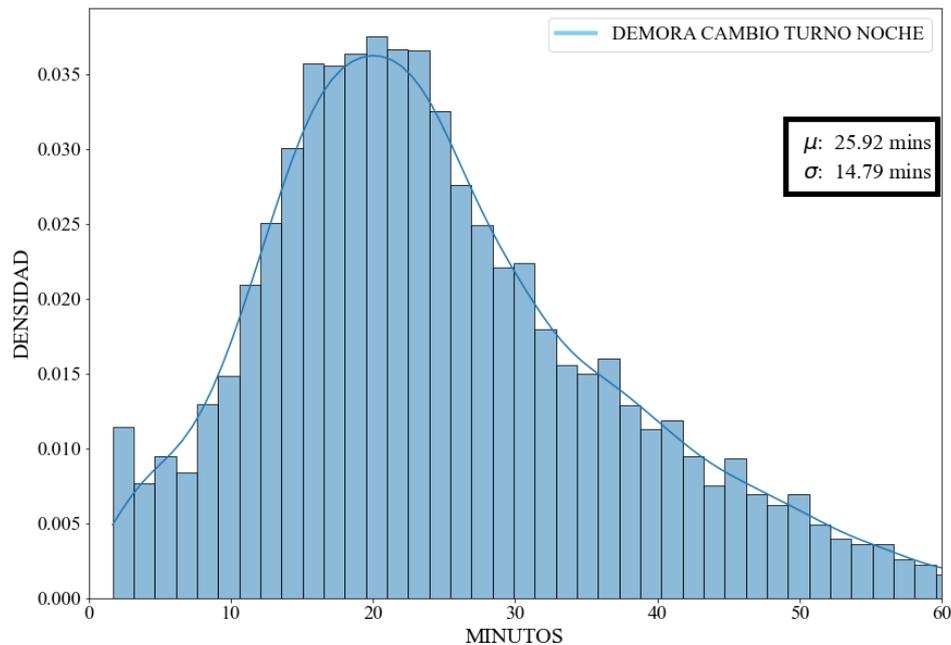
Histograma para Tiempos de demora de Cambio de Turno en camiones Turno día



Durante el cambio de turno entre las 06:30 horas a 07:30 horas, correspondiente al turno noche, se obtiene una distribución cuyos parámetros son $\mu = 25.92 \text{ mins}$ y $\sigma = 14.79 \text{ mins}$, presentado en la Figura 50.

Figura 50

Histograma para Tiempos de demora de Cambio de Turno en camiones Turno noche



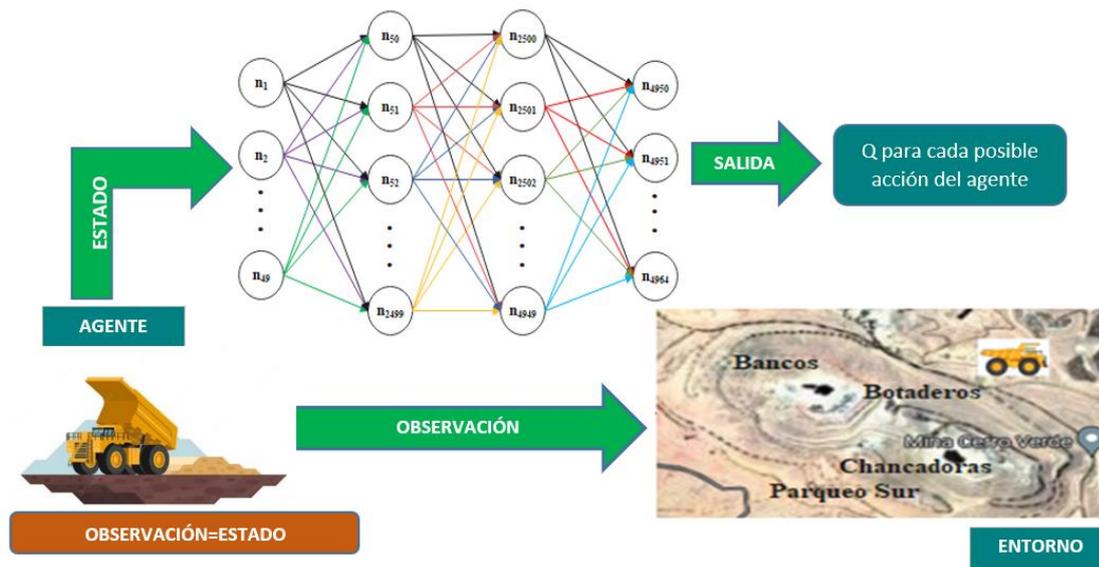
3.2.3 Proceso de la red neuronal

3.2.3.1 Modelo de la red neuronal

Acorde con el modelo de aprendizaje por refuerzo profundo Q-learning, la red neuronal recibe como ingreso la observación del agente sobre el entorno y la salida se conforma por el conjunto de valores Q de la observación con cada una de las posibles acciones que el agente puede tomar (ver Figura 51).

Figura 51

Interacción de aprendizaje con refuerzo y modelo de redes neuronales



La observación de cada agente sobre nuestro entorno está definida como los tiempos de viaje hacia cada pala (15 datos), la cola en cada una de las palas (15 datos), la cantidad de equipos en camino a cada pala (15 datos), la cola en cada chancadora (3 datos) y la cantidad de otros agentes en el entorno (1 dato), tal como se observa en la tabla 3, estos 49 datos corresponden a la entrada de red neuronal.

Tabla 3

Diseño de Red Neuronal – ENTRADAS A LA RED

VARIABLE	CANTIDAD DE DATOS
Tiempo de viaje vacío hacia cada pala	15
Cola de camiones en cada pala	15
Cantidad de equipos en camino a cada pala	15
Cola de camiones en cada chancadora	3
Cantidad de otros agentes en el entorno	1
TOTAL	49

Para el caso de la salida, acorde a la teoría revisada en el apartado 2.4, cada salida representa el valor Q de dirigirse a cada pala dependiendo de la observación actual del agente (Tabla 4).

Tabla 4

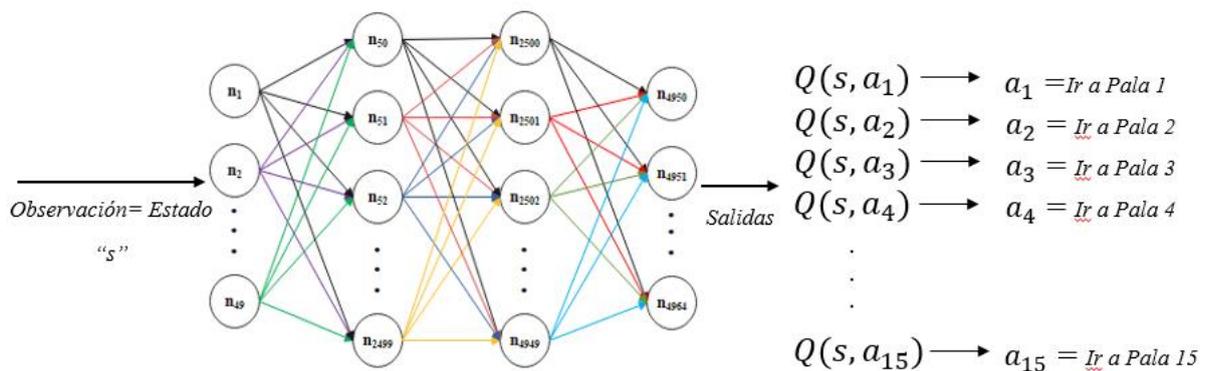
Valor Q para cada par observación acción

		Acciones posibles 15= Número de palas				
		Acciones				
	Observaciones	$A_1 = Ir a Pala 1$	$A_2 = Ir a Pala 2$	$A_3 = Ir a Pala 3$...	$A_{15} = Ir a Pala 15$
observaciones infinitas	1	$Q(1, A_1)$	$Q(1, A_2)$	$Q(1, A_3)$	$Q(1, A_{15})$
	2	$Q(2, A_1)$	$Q(2, A_2)$	$Q(2, A_3)$	$Q(2, A_{15})$
	3	$Q(3, A_1)$	$Q(3, A_2)$	$Q(3, A_3)$	$Q(3, A_{15})$
	⋮	⋮	⋮	⋮	⋮

Siendo la mina un ambiente variable, el agente tiene un rango de observaciones infinitas, la red neuronal se encarga de calcular el valor Q dependiendo del estado actual, tal como visualiza en la figura 52, por esta razón la red tiene 15 salidas, que corresponden a la cantidad de palas en la mina.

Figura 52

Diseño de Red Neuronal – SALIDAS DE LA RED



Para el caso de la función de recompensa R_t , su valor se determina en base a dos variables, primero el tiempo desde que el camión es asignado a una pala hasta que el camión descarga y

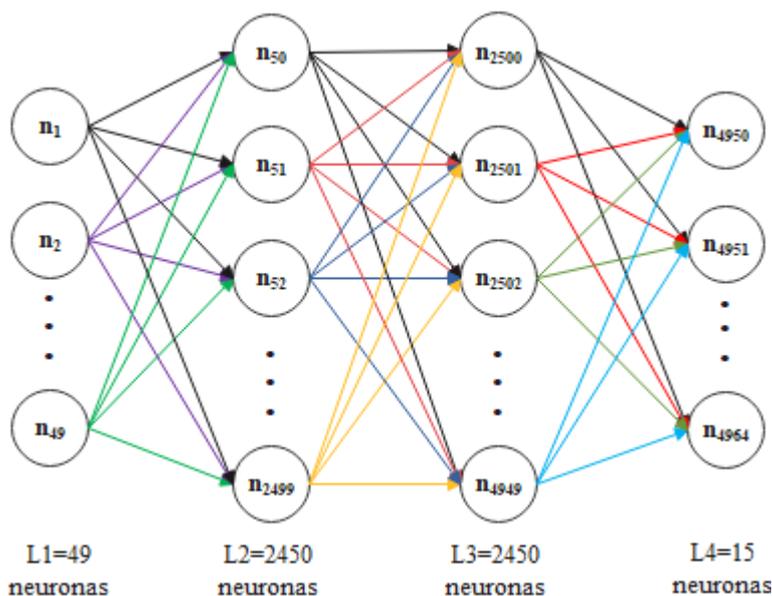
solicita una nueva asignación, esto se le conoce como tiempo de ciclo total ΔT_{ciclo} , este se ve afectado por la cola de camiones en los destinos chancadora o botadero, por lo que un lugar que tenga mucha cola será poco recompensado. En segundo lugar, el material que el agente acarrea, se define la variable tipo de material $T_{material}$ la cual será 0 o 1 dependiendo si el camión cargó desmonte o mineral; respectivamente. Finalmente, se le proporciona un 50% de recompensa adicional cuando el agente ha cargado mineral, es decir selecciona una pala de mineral como acción, por ende, su descarga va directamente a la chancadora. Esto se ve en la ecuación 8.

$$R_t = \frac{(T_{material} + 2)}{\Delta T_{ciclo}} \quad \text{Ec. 8}$$

Se elabora con Pytorch el modelo de la red neuronal teniendo en consideración todo lo revisado anteriormente, colocando las neuronas de entrada, capas ocultas y salida en 49, 4900 y 15; respectivamente tal como se muestra en la Figura 53.

Figura 53

Arquitectura de la red neuronal



Finalmente, se establecen los hiper-parámetros para entrenar la red neuronal:

- Se utiliza una tasa de aprendizaje $\alpha = 0.0001$.

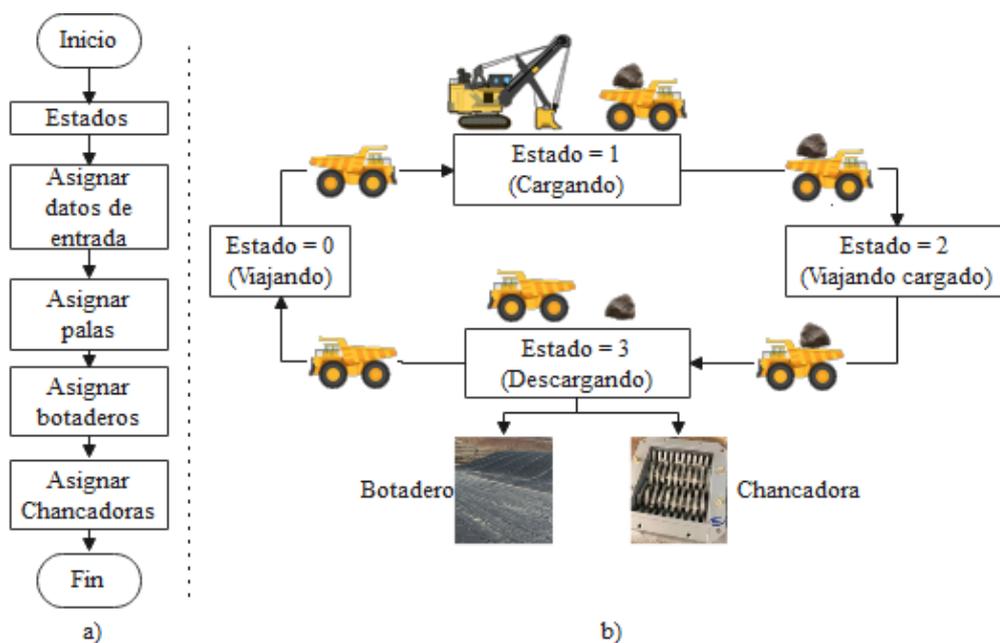
- Se coloca una estrategia de probabilidad $\varepsilon = 0.8$.
- Se coloca la función `MSELoss()` y un optimizador Adam; este último ayuda a actualizar los pesos acorde a los datos de entrenamiento con la finalidad de reducir el error durante el aprendizaje de la red (Zai y Brown, 2020).

3.2.3.2 Eventos discretos

A través de la biblioteca Simpy se diseña un objeto en Python que contiene las condiciones de inicio de la mina, es decir, el ambiente, los estados, acciones, cambios de turno, refrigerios, acciones y equipos activos. Además, se detallan los siguientes procesos (ver Figura 54.a) que se realizan durante el ciclo de acarreo:

Figura 54

Diseño de eventos discretos



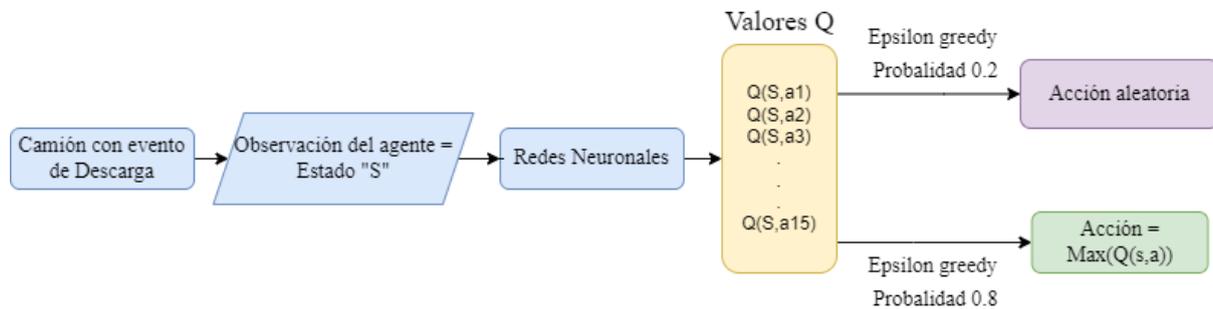
- En la Figura 54.b) se observa los estados que poseen los camiones durante el ciclo de acarreo, tales como:
 - Cuando el estado es igual a cero, implica que los camiones están viajando desde el punto de origen hacia la pala más cercana.
 - En caso de que el estado sea igual a uno, indica que el camión se cuadró con la

pala y se está llevando a cabo la carga de material.

- Luego, el camión sigue su camino preestablecido (*estado* = 2) hasta llegar a una chancadora, cuando transporta mineral; caso contrario va hacia el botadero. Por tanto, llegado a este punto se considera un *estado* = 3 y se procede con la descarga de material. Luego, regresa al punto de origen e inicia un nuevo ciclo.
- Los tiempos de duración en el ciclo de acarreo utilizan las distribuciones normales vistas en el Apartado 3.2.2, dependiendo del estado en el que se encuentren los camiones.
- También se toma en consideración una baja de equipos operativos cuando se encuentren dentro de las horas de refrigerio (11:30 – 14:30) y cambio de turno (6:30 – 7:30, 18:30 – 19:30).
- Por consiguiente, se colocan algunas condiciones que se llevan a cabo dentro de la mina; a su vez corresponden a la capa de entrada del modelo de la red neuronal, detalladas a continuación:
 - Se colocan los tiempos de viaje vacío de los camiones hacia las 15 palas.
 - Cantidad de camiones que hay en cada pala.
 - Cantidad de camiones que hay en cada chancadora.
 - Camiones asignados y están viajando a cada pala.
- Se asignan las palas y se da la recompensa cuando un camión esté descargado (no posea material) y se establece usando la estrategia ϵ greedy, se designa de forma aleatoria con una probabilidad de ($\epsilon = 0.2$); caso contrario $1 - \epsilon$, la red estima el valor máximo Q de las 15 palas y se va guardando las acciones en un vector (ver Apartado 2.4.3). Por último, se asignan los botaderos y chancadoras (ver Figura 54).

Figura 54

Estrategia Epsilon greedy utilizada para el entrenamiento de la red



3.2.3.3 Entrenamiento de la red

A continuación, se designan algunos parámetros:

- El tamaño de la memoria, la cantidad total de camiones (110 unidades) y el número de épocas igual a 2500 (criterio de diseño).
- Se crea un vector de experiencia, donde se guardan todos los estados, acciones y recompensa durante un día de simulación en la mina.
- Cada camión, es considerado un agente y se realizan recompensas individuales por agente, su valor se determina en base al tiempo desde que el camión es asignado a una pala hasta que el camión descarga, ya sea en chancadora o botadero, este tiempo de ciclo total incluye la cola que hizo el camión en cierto destino, por lo que un lugar que tenga mucha cola será poco recompensado. En segunda instancia, se le proporciona un 50% de recompensa adicional cuando el agente se mueve hacia palas de mineral, por ende, su descarga va directamente a la chancadora.
- Cuando el tamaño de la experiencia supera cierto valor (10000) se selecciona una muestra, se ingresa en los mini lotes con el propósito de generar el algoritmo de aprendizaje tipo Q, tal como se mencionó en el Apartado 2.4.3.
- Finalmente, se calcula la función de pérdida y se almacena en un archivo el modelo de la red neuronal.

Capítulo IV

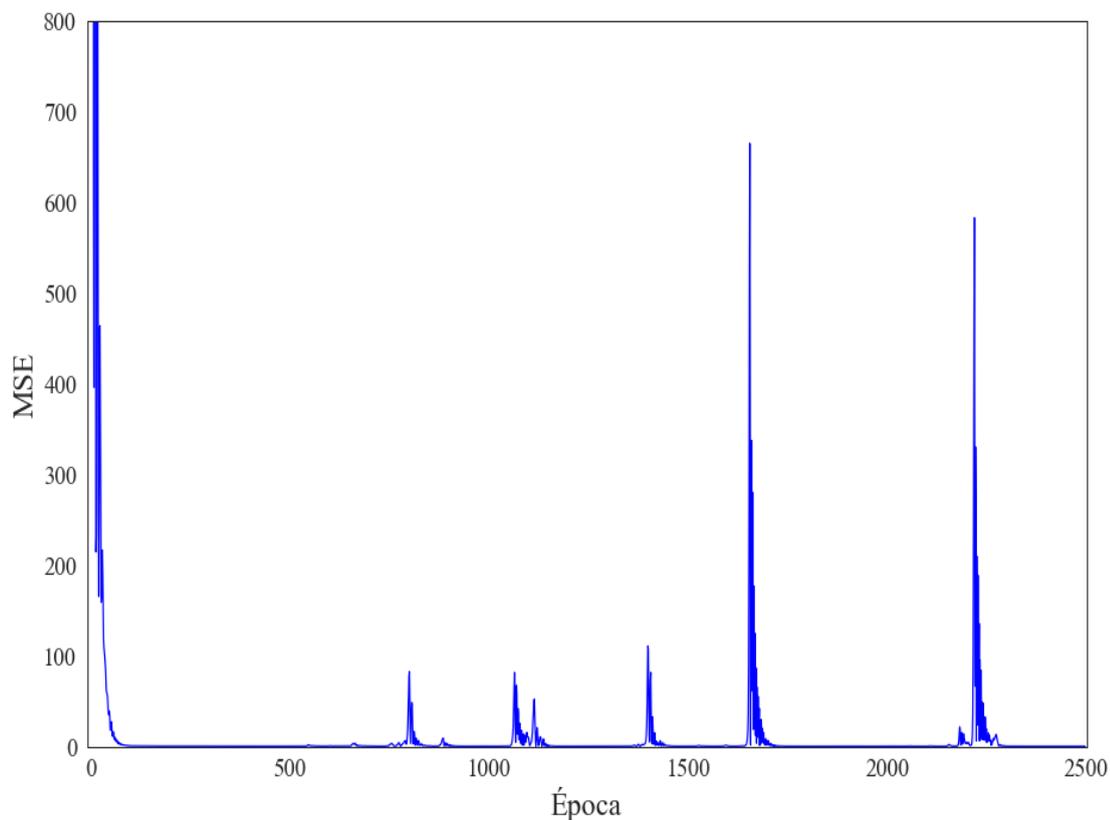
Pruebas Y Resultados

4.1 Resultado del entrenamiento de la red

A través de la Figura 55 se visualiza el error cuadrático medio. Este error se utiliza para determinar la función de pérdida durante el entrenamiento de la red neuronal bajo el aprendizaje profundo por refuerzo. Por tanto, permite dar una idea sobre la desviación entre los valores generados en los eventos discretos de las condiciones de la mina y sus correspondientes predicciones, eso implica que, ante una reducción de error, la red se vuelve más eficiente.

Figura 55

Resultados de la función de pérdida (Error Cuadrático Medio)

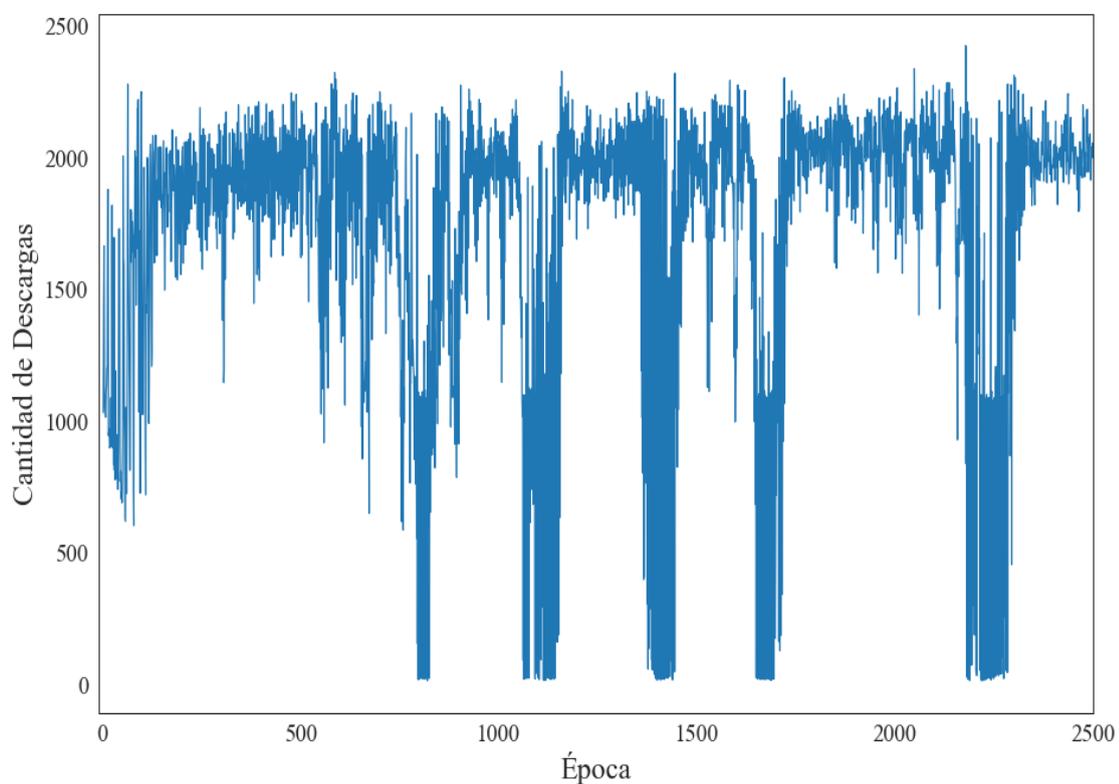


En cada época del entrenamiento se capturó la salida de la cantidad de descargas total del día para ir teniendo una idea del comportamiento en el aspecto de movimiento de material, se

puede evidenciar en la Figura 56 como conforme va ajustando sus parámetros la cantidad de descargas se incrementa. En efecto, se pueden visualizar en altas épocas de entrenamiento picos de valores bajo de descargas, esto tiene explicación en la estrategia ϵ greedy mencionada en el apartado 2.4.3, es normal ver este tipo de comportamientos al entrenar un modelo Q-learning con estrategia de exploración ϵ greedy.

Figura 56

Cantidad de descargas totales al día por cada época de entrenamiento



4.2 Visualización de eventos en la mina

Por medio del módulo Pygame se realiza una simulación de los eventos de acarreo en la mina durante un día completo, equivalente a 86400 segundos; como se observa en la Figura 57.

Además, se puede controlar la velocidad de operación y observar la situación en cualquier periodo de tiempo.

Figura 57

Simulación de eventos discretos de la mina



4.3 Prueba de la red

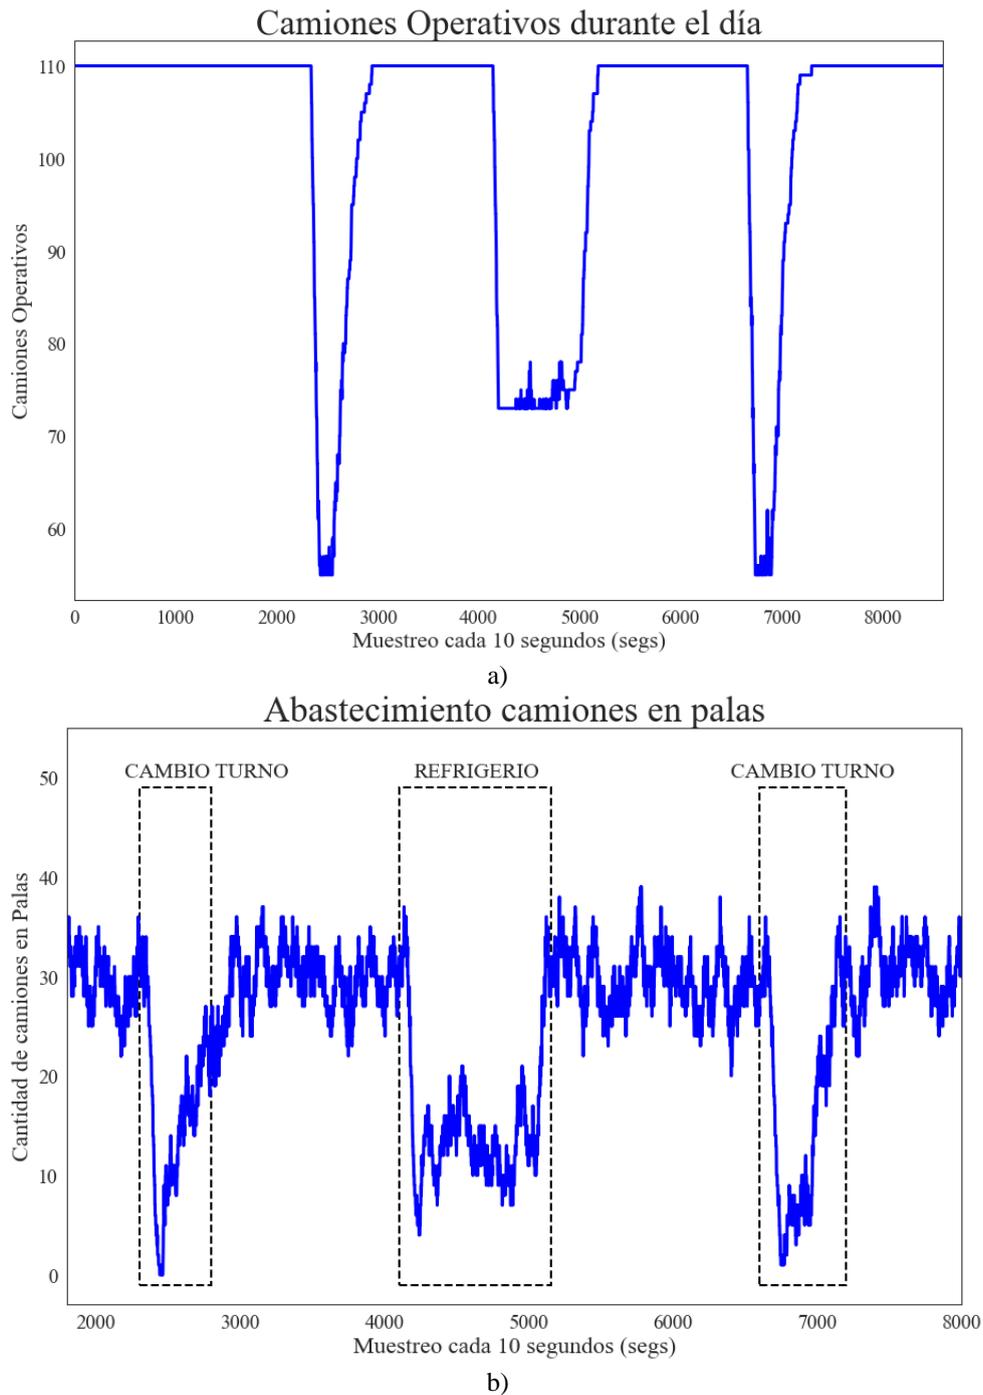
Se efectúa la prueba del sistema, el cual utiliza las mismas librerías y demás condiciones del modelo indicado en los Apartados 3.2.2 y 3.2.3, a excepción del entrenamiento de la red neuronal. A continuación, se detallan los resultados de cada proceso desarrollado en la mina:

- Se realiza un muestreo de cada 10 segundos y se estima que la cantidad total de camiones cargados disminuye a 55 unidades cuando se presenta el evento cambio de turno, a los 25000 y 70000 segundos aproximadamente, equivalente a las 6h56 y 19h26 horas; respectivamente. En cambio, se tiene un estimado de 75 camiones durante el evento refrigerio, entre los 40000 a 50000 segundos o más bien dicho entre 11h06 y 13h53 horas, tal como se muestra en la Figura 58.a).
- De la Figura 58.b) se observa que las condiciones de muestreo son de 10 segundos, por lo que se muestra una baja de camiones durante el cambio de turno y refrigerio a

un total aproximado de 10 y 15 camiones haciendo filas en las palas; respectivamente. Y dentro de la operación normal de funcionamiento, se prevé entre 20 a 40 camiones haciendo cola en las palas.

Figura 58

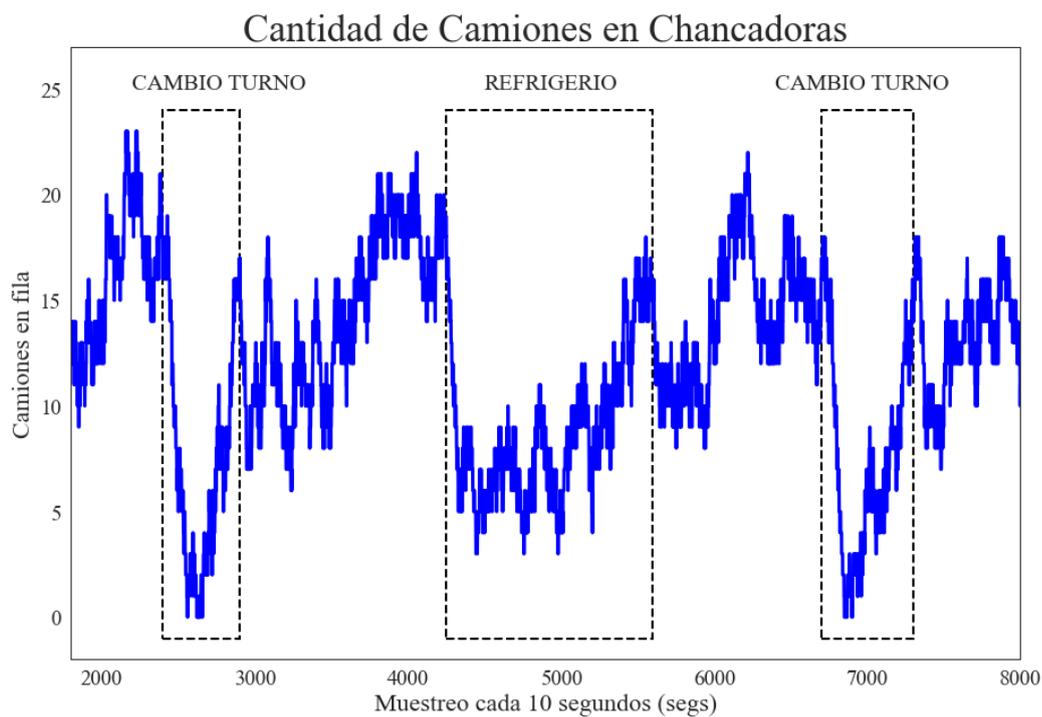
Situación de los camiones: a) Operativos y b) Abastecimiento en las palas



- Se realiza un muestreo cada 10 segundos y se estima que, la cantidad de camiones en las chancadoras disminuye durante el refrigerio (3 - 10 unidades) y cambio de turno (1 – 5 unidades), tal como se indica en la Figura 59. En el resto de las horas, varía entre 7 a 20 camiones aproximadamente.

Figura 59

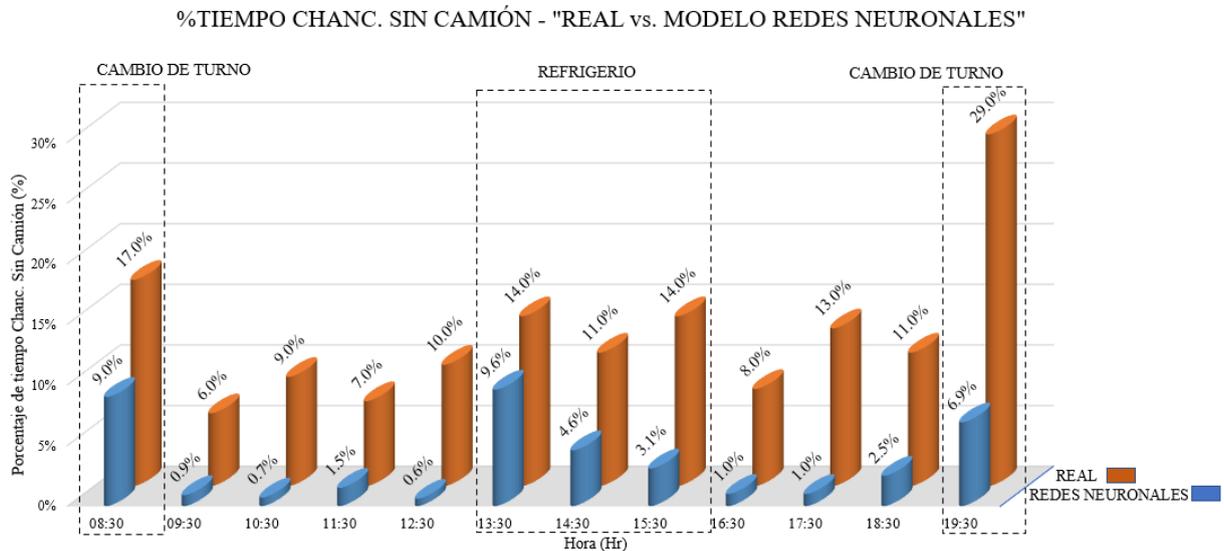
Fila de camiones en la chancadora



- Se realiza una simulación del día completo por horas y se analiza el tiempo que las chancadoras no tuvieron camiones, para ello se realiza el cálculo de las demoras aguas arriba con los resultados de la simulación, se verifica que en todas las horas es menor al 10% tal como muestra la Figura 60, se adjunta también la información recolectada en el análisis de la situación actual de las demoras aguas arriba (Apartado 3.1.4).

Figura 60

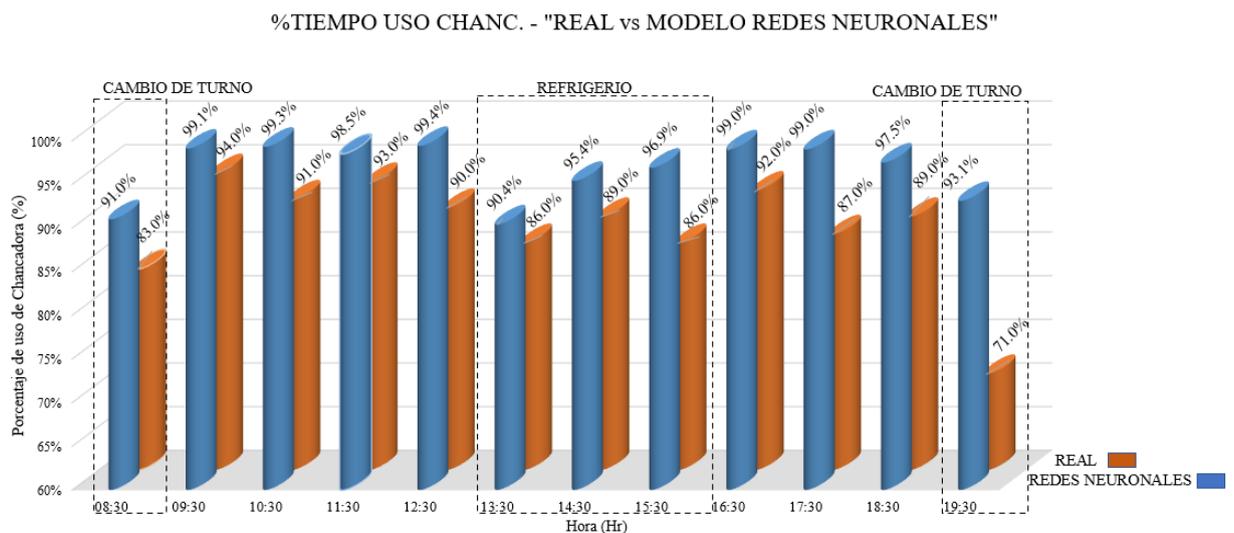
Demoras Aguas Arriba en las chancadoras por hora en entorno de simulación



- De los resultados estimamos el uso de la chancadora por hora, se evidencia que opera cerca del 100% en horas sin eventos, en el caso de los eventos cambio de turno y refrigerio, se verifica que operan con un poco más del 90% con camiones, se coloca la información real para poder comparar (ver Figura 61).

Figura 61

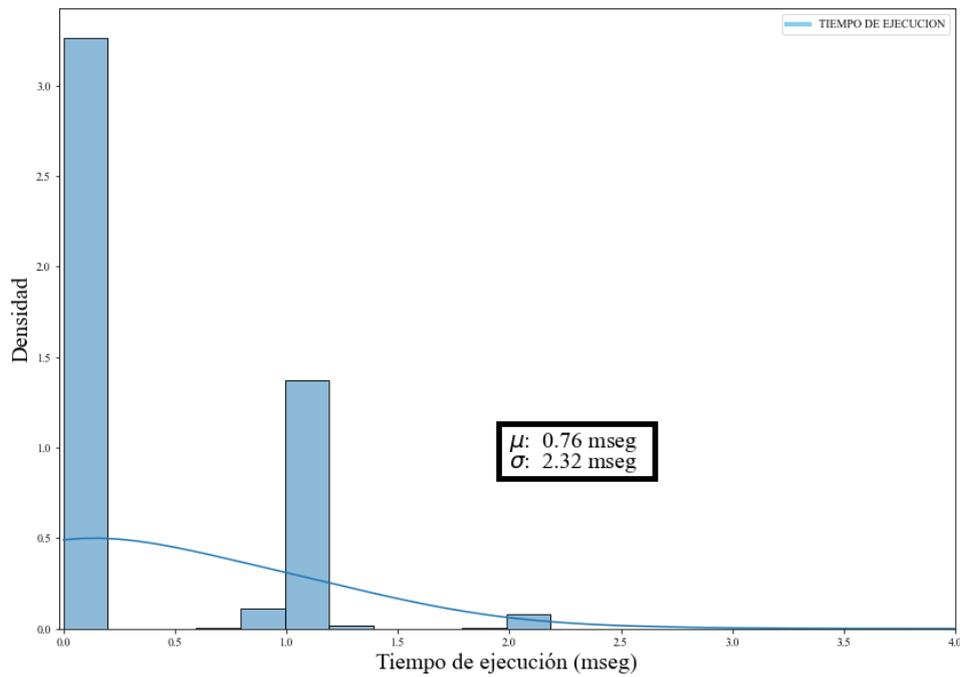
Uso de chancadoras por hora en entorno de simulación



- Finalmente, se procede a realizar una prueba para determinar el tiempo de respuesta del algoritmo, se realizaron 1000 ejecuciones del modelo y se capturó el tiempo de ejecución para cada caso teniendo resultados promedios menores a un milisegundo, $\mu = 0.76 \text{ msecs}$ con $\sigma = 2.32 \text{ msecs}$; lo cual se evidencia en la Figura 62.

Figura 62

Análisis de tiempo de respuesta del modelo de redes neuronales



Conclusiones

- Se realiza varios estudios relacionados con el ciclo de acarreo ya sea para el turno día o turno noche, donde se determina una baja de camiones operativos entre el 45 – 60% y 35 – 45% cuando existe cambios de turno y refrigerios; respectivamente. En cambio, cuando se trata del uso de palas presenta una baja de una a cuatro unidades por día en las horas de los eventos indicados anteriormente. Además, existen otro tipo de demoras como las pérdidas planificadas, por falla, operativas en las chancadoras y equipos.
- Para el diseño del aprendizaje por refuerzo profundo Q-learning, se define como el agente a cada camión, las acciones que puede realizar el agente son igual a la cantidad de palas del entorno, por lo que solo puede elegir una de las palas, la observación del agente se compone por los tiempos de viaje a cada pala, la cola de camiones en cada pala y cada chancadora; y la cantidad de camiones en ruta hacia cada pala, para el caso de la recompensa asignamos un peso mayor al mineral y lo dividimos entre el tiempo total de ciclo del agente ; lo cual recompensa la poca cola de camiones y la priorización de mineral.
- Para el diseño del entorno, se realizó un estudio de los tiempos de acarreo, del cual se obtienen las distribuciones de tiempos reales para cada etapa del ciclo de acarreo, de igual manera para las demoras en periodos de cambio de turno y refrigerio y tiempos de viaje, mediante el simulador de eventos discretos Simpy se recrean estas distribuciones de tiempo lo cual contribuye a un entorno muy similar a la realidad que nos permitirá entrenar la red neuronal.
- El modelo de redes neuronales presenta 49 neuronas de entrada, 4900 neuronas en la capa oculta y 15 neuronas en la capa de salida. Se construye el algoritmo de aprendizaje por refuerzo profundo bajo las condiciones de operación día de la mina,

siendo las 49 neuronas de entrada correspondientes a la observación del agente y las 15 neuronas de salida estiman los valores máximos de Q para luego proceder con el entrenamiento de la red.

- Finalmente, en los resultados se observa que el modelo mantiene una cobertura del uso de la chancadora por encima de 90% durante el horario de cambio de turno y refrigerio, con una cola de camiones en las ubicaciones aceptable y con un tiempo de ejecución promedio menor a un milisegundo para cada asignación de camiones a palas.

Recomendaciones

- Las pruebas se realizaron en un computador Intel Core i7 con 8 GB de RAM instalada, por lo que el periodo de entrenamiento de la red neuronal se llevó a cabo en 12 horas para un total de 2500 épocas. En caso de que se desee entrenar nuevamente a la red, tomar en consideración esta condición, se recomienda utilizar mayores recursos de procesamiento en el computador para disminuir el tiempo de entrenamiento de la red.
- Para que el modelo incluya una mayor cantidad de variables, como restricciones en las chancadoras o palas, se sugiere probar una red convolucional y un periodo de entrenamiento con más épocas.
- Analizando la información real de la mina nos encontramos con temas operativos que ocurren diariamente, por ejemplo, cambios en el plan de minado o detenciones no planificadas de equipos, se puede profundizar esta investigación incluyendo estas variables.

Bibliografía

- Alberca Sánchez, A. (2022). *La librería Numpy*. Aprende con Alf. <https://aprendeconalf.es/docencia/python/manual/numpy/>
- Andrade Tepán, C. (2013). Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación. *Universidad Politécnica Salesiana Sede Cuenca*, 152.
- Baek, J., & Choi, Y. (2020). Deep Neural Network for Predicting Ore Production by Truck-Haulage Systems in Open-Pit Mines. *Applied Sciences*, 10(5), 1657. <https://doi.org/10.3390/app10051657>
- Bagnato, J. (2020, diciembre). *Aprendizaje por Refuerzo | Aprende Machine Learning*. <https://www.aprendemachinelearning.com/aprendizaje-por-refuerzo/>
- Bnouachir, H., Chergui, M., Machkour, N., Zegrari, M., Chakir, A., Deshayes, L., Semmar, A., & Medromi, H. (2020). Intelligent Fleet Management System for Open Pit Mine. *International Journal of Advanced Computer Science and Applications*, 11(5). <https://doi.org/10.14569/IJACSA.2020.0110543>
- Buedo Risueño, Á. (2020). Desarrollo de un agente mediante Deep Q-Learning en un entorno de juegos de plataformas. *Universitat Oberta de Catalunya*, 101.
- Carrión, C. (2018). Aplicación de redes neuronales artificiales para la predicción de la recuperación de planta concentradora en minsur s.a. – Unidad san rafael. *Universidad Nacional de San Agustín de Arequipa*, 94.
- Cerro Verde. (2022). *Minería de Cobre y Molibdeno en Arequipa / Sociedad Minera Cerro Verde*. <https://www.cerroverde.pe/>
- de Carvalho, J. P., & Dimitrakopoulos, R. (2021). Integrating Production Planning with Truck-Dispatching Decisions through Reinforcement Learning While Managing Uncertainty. *Minerals*, 11(6), 587. <https://doi.org/10.3390/min11060587>
- Hagan, M., Demuth, H., Beale, M., & Orlando de Jesus. (2014). *Neural Network Design* (2da

- edicion). <https://hagan.okstate.edu/nnd.html>
- Lapan, M. (2018, junio 24). *Deep Reinforcement Learning Hands-On Pdf—Libribook*. Libribook.Com. <https://libribook.com/ebook/12425/deep-reinforcement-learning-hands-pdf>
- Maldonado, L. (2012). *Los modelos ocultos de Markov, MOM*. 14(3), 7.
- Marcano, C. R. (2010). Uso de modelos ocultos de markov para modelar proceso de supresión de efectos nódicos en celdas de reducción electrolítica de aluminio primario. *Universidad, Ciencia y Tecnología*, 14(55), 103–108.
- Matplotlib. (2021). *Matplotlib—Visualization with Python*. <https://matplotlib.org/>
- MMS. (2016). *Ayuda del Sistema DISPATCH® 6.6.1*. Modular Mining Systems, Inc.
- Moradi Afrapoli, A., & Askari-Nasab, H. (2019). Mining fleet management systems: A review of models and algorithms. *International Journal of Mining, Reclamation and Environment*, 33(1), 42–60. <https://doi.org/10.1080/17480930.2017.1336607>
- Printista, A. M., Errecalde, M. L., & Montoya, C. I. (2000). *Una implementación paralela del algoritmo de Q-Learning basada en un esquema de comunicación con caché*. 12.
- Pygame. (2022). *Pygame in all the languages*. Pygame in all the languages. <https://www.pygame.org/news>
- Python. (2022). *Welcome to Python.org*. Python.Org. <https://www.python.org/>
- PyTorch. (2022). *PyTorch*. <https://www.pytorch.org>
- Ruiz, C. A., Basualdo, M. S., & Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. 55.
- Simpy. (2020). *Overview—SimPy 4.0.2.dev1+g2973dbe documentation*. <https://simpy.readthedocs.io/en/latest/>
- Toral Barrera, J. (2018). *Redes Neuronales—Cucei.udg.mx .2. Modelo de una red neuronal*. *Las redes neuronales son modelos matemticos que intentan reproducir el*

comportamiento del cerebro humano. El principal—[PDF Document]. fdocuments.es.
<https://fdocuments.es/document/redes-neuronales-cuceiudgmwwwuceiudgmxsitesdefaultfilespdftoralbarrerajamiearelipdfpdf.html>

Torres, A. I., J. (2021, abril 16). Introducción al aprendizaje por refuerzo. *Aprendizaje Por Refuerzo Profundo*. <https://medium.com/aprendizaje-por-refuerzo/1-introducci%C3%B3n-al-aprendizaje-por-refuerzo-92c9239aed90>

Zai, A., & Brown, B. (2020). Deep Reinforcement Learning in Action. *Manning Publications Co*, 383.

Zhang, C., Odonkor, P., Zheng, S., Khorasgani, H., Serita, S., & Gupta, C. (2020). *Dynamic Dispatching for Large-Scale Heterogeneous Fleet via Multi-agent Deep Reinforcement Learning*. <https://doi.org/10.48550/arXiv.2008.10713>

Anexos

Anexo 1

Ubicaciones de bancos, botaderos, chancadoras y parqueo de camiones

Equipos	Etiquetas	Latitud	Longitud
	CV2663-414	-16,53975199	-71,60436591
	CV2675-020	-16,5226025	-71,59549575
	CV2693-902	-16,52260742	-71,60528948
	CV2693-903	-16,52254078	-71,59974041
	CV2736-035	-16,51920177	-71,60796175
	CV2743-912	-16,52421275	-71,61286478
	CV2785-001	-16,54263703	-71,61517394
Bancos	SR2258-107	-16,53965101	-71,58625643
(Lugares de Carga)	SR2288-275	-16,53321657	-71,59333154
	SR2438-234	-16,53767657	-71,59530293
	SR2438-621	-16,54116852	-71,59221894
	SR2453-936	-16,5394352	-71,59711655
	SR2686-020	-16,54786626	-71,59017099
	SR2692-015	-16,54812687	-71,59322073
	SR2702-001	-16,54726426	-71,58474533
	SR2765-001	-16,55568686	-71,58724733
	SR2824-036	-16,5509742	-71,60855585
	SR2825-036	-16,5525298	-71,60633644
	BOTSO-2800_ZAR	-16,5479277	-71,61504813
Botaderos	DDMNO-2734_CU3	-16,53199891	-71,62789942
(Desmante)	DDMNO-2734_CU4	-16,52546208	-71,62574002
	P1XF3-2720_01	-16,52852842	-71,57614613
Chancadoras	MILLCHAN	-16,52462614	-71,59489478
(Mineral)	MILLCRUSH1	-16,55094206	-71,59659509
	MILLCRUSH2	-16,54985107	-71,59562448
Parqueo Camiones	PQ_PERIM-SUR	-16,5471031	-71,5731026

Anexo 2

Tiempos de viajes – Ciclos

Origen	Destino	Distancia (m)	Viaje Vacío (s)	Viaje Lleno (s)
BOTSO-2800_ZAR	CV2663-414	4995	618	820
BOTSO-2800_ZAR	CV2675-020	7513	867	1060
BOTSO-2800_ZAR	CV2693-902	5998	633	808
BOTSO-2800_ZAR	CV2693-903	6609	688	879
BOTSO-2800_ZAR	CV2736-035	5680	588	728
BOTSO-2800_ZAR	CV2743-912	5591	613	766
BOTSO-2800_ZAR	CV2785-001	1153	135	162
BOTSO-2800_ZAR	SR2258-107	8432	1890	2121
BOTSO-2800_ZAR	SR2288-275	7697	1776	1969
BOTSO-2800_ZAR	SR2438-234	6772	1185	1521
BOTSO-2800_ZAR	SR2438-621	5546	1057	1370
BOTSO-2800_ZAR	SR2453-936	6224	1122	1423
BOTSO-2800_ZAR	SR2686-020	3320	560	668
BOTSO-2800_ZAR	SR2692-015	3288	544	639
BOTSO-2800_ZAR	SR2702-001	3947	630	761
BOTSO-2800_ZAR	SR2765-001	5138	755	963
BOTSO-2800_ZAR	SR2824-036	2769	310	400
BOTSO-2800_ZAR	SR2825-036	2447	271	395
DDMNO-2734_CU3	CV2663-414	3236	407	510
DDMNO-2734_CU3	CV2675-020	5566	680	758
DDMNO-2734_CU3	CV2693-902	4051	446	506
DDMNO-2734_CU3	CV2693-903	4662	501	577
DDMNO-2734_CU3	CV2736-035	3733	401	426
DDMNO-2734_CU3	CV2743-912	3644	426	464
DDMNO-2734_CU3	CV2785-001	2784	293	408
DDMNO-2734_CU3	SR2258-107	10195	1991	2280
DDMNO-2734_CU3	SR2288-275	9460	1877	2128
DDMNO-2734_CU3	SR2438-234	8535	1286	1680

DDMNO-2734_CU3	SR2438-621	7309	1158	1529
DDMNO-2734_CU3	SR2453-936	7987	1223	1582
DDMNO-2734_CU3	SR2686-020	5083	661	827
DDMNO-2734_CU3	SR2692-015	5051	645	798
DDMNO-2734_CU3	SR2702-001	5710	731	920
DDMNO-2734_CU3	SR2765-001	6901	856	1122
DDMNO-2734_CU3	SR2824-036	5112	538	729
DDMNO-2734_CU3	SR2825-036	4790	499	724
DDMNO-2734_CU4	CV2663-414	3982	465	583
DDMNO-2734_CU4	CV2675-020	4488	584	665
DDMNO-2734_CU4	CV2693-902	2973	350	413
DDMNO-2734_CU4	CV2693-903	3584	405	484
DDMNO-2734_CU4	CV2736-035	2655	305	333
DDMNO-2734_CU4	CV2743-912	2566	330	371
DDMNO-2734_CU4	CV2785-001	3530	351	481
DDMNO-2734_CU4	SR2258-107	9084	1646	2017
DDMNO-2734_CU4	SR2288-275	8729	1565	1897
DDMNO-2734_CU4	SR2438-234	9281	1344	1753
DDMNO-2734_CU4	SR2438-621	8055	1216	1602
DDMNO-2734_CU4	SR2453-936	8733	1281	1655
DDMNO-2734_CU4	SR2686-020	5829	719	900
DDMNO-2734_CU4	SR2692-015	5797	703	871
DDMNO-2734_CU4	SR2702-001	6456	789	993
DDMNO-2734_CU4	SR2765-001	7647	914	1195
DDMNO-2734_CU4	SR2824-036	5858	596	802
DDMNO-2734_CU4	SR2825-036	5536	557	797
MILLCHAN	CV2663-414	6816	702	937
MILLCHAN	CV2675-020	388	46	48
MILLCHAN	CV2693-902	1965	222	280
MILLCHAN	CV2693-903	1288	161	170
MILLCHAN	CV2736-035	2965	314	438

MILLCHAN	CV2743-912	2876	339	476
MILLCHAN	CV2785-001	6364	586	848
MILLCHAN	SR2258-107	6468	1299	1608
MILLCHAN	SR2288-275	5733	1185	1457
MILLCHAN	SR2438-234	7888	1133	1739
MILLCHAN	SR2438-621	6662	1005	1593
MILLCHAN	SR2453-936	7340	1070	1642
MILLCHAN	SR2686-020	4756	587	1006
MILLCHAN	SR2692-015	4724	570	977
MILLCHAN	SR2702-001	5383	655	1099
MILLCHAN	SR2765-001	6574	780	1301
MILLCHAN	SR2824-036	8692	833	1179
MILLCHAN	SR2825-036	8370	794	1174
MILLCRUSH1	CV2663-414	5450	618	777
MILLCRUSH1	CV2675-020	5518	912	1089
MILLCRUSH1	CV2693-902	6730	1020	1254
MILLCRUSH1	CV2693-903	6053	959	1144
MILLCRUSH1	CV2736-035	7509	790	967
MILLCRUSH1	CV2743-912	7420	815	1005
MILLCRUSH1	CV2785-001	3870	434	543
MILLCRUSH1	SR2258-107	6431	1539	1673
MILLCRUSH1	SR2288-275	5696	1425	1522
MILLCRUSH1	SR2438-234	5290	914	1131
MILLCRUSH1	SR2438-621	4064	786	985
MILLCRUSH1	SR2453-936	4742	851	1034
MILLCRUSH1	SR2686-020	1319	204	236
MILLCRUSH1	SR2692-015	883	133	150
MILLCRUSH1	SR2702-001	1946	272	329
MILLCRUSH1	SR2765-001	3137	397	531
MILLCRUSH1	SR2824-036	3078	390	506
MILLCRUSH1	SR2825-036	2756	351	501

MILLCRUSH2	CV2663-414	5302	598	760
MILLCRUSH2	CV2675-020	5370	892	1072
MILLCRUSH2	CV2693-902	6582	1000	1237
MILLCRUSH2	CV2693-903	5905	939	1127
MILLCRUSH2	CV2736-035	7361	770	950
MILLCRUSH2	CV2743-912	7272	795	988
MILLCRUSH2	CV2785-001	3722	414	526
MILLCRUSH2	SR2258-107	6283	1519	1656
MILLCRUSH2	SR2288-275	5548	1405	1505
MILLCRUSH2	SR2438-234	5142	894	1114
MILLCRUSH2	SR2438-621	3916	766	968
MILLCRUSH2	SR2453-936	4594	831	1017
MILLCRUSH2	SR2686-020	1171	184	219
MILLCRUSH2	SR2692-015	735	113	133
MILLCRUSH2	SR2702-001	1798	252	312
MILLCRUSH2	SR2765-001	2989	377	514
MILLCRUSH2	SR2824-036	2930	370	489
MILLCRUSH2	SR2825-036	2608	331	484
P1XF3-2720_01	CV2663-414	9363	1021	1369
P1XF3-2720_01	CV2675-020	3300	433	547
P1XF3-2720_01	CV2693-902	4512	541	712
P1XF3-2720_01	CV2693-903	3835	480	602
P1XF3-2720_01	CV2736-035	5512	633	870
P1XF3-2720_01	CV2743-912	5423	658	908
P1XF3-2720_01	CV2785-001	8911	905	1280
P1XF3-2720_01	SR2258-107	6897	1394	1815
P1XF3-2720_01	SR2288-275	6162	1280	1664
P1XF3-2720_01	SR2438-234	8444	1296	1986
P1XF3-2720_01	SR2438-621	7930	1264	1962
P1XF3-2720_01	SR2453-936	8608	1329	2011
P1XF3-2720_01	SR2686-020	5185	682	1213

P1XF3-2720_01	SR2692-015	5153	665	1184
P1XF3-2720_01	SR2702-001	5812	750	1306
P1XF3-2720_01	SR2765-001	7003	875	1508
P1XF3-2720_01	SR2824-036	7929	1007	1649
P1XF3-2720_01	SR2825-036	7607	968	1644
CV2663-414	BOTSO-2800_ZAR	4965	510	774
CV2663-414	DDMNO-2734_CU3	3360	362	514
CV2663-414	DDMNO-2734_CU4	3132	335	483
CV2663-414	MILLCHAN	4487	562	719
CV2663-414	MILLCRUSH1	5442	601	843
CV2663-414	MILLCRUSH2	5318	597	854
CV2663-414	P1XF3-2720_01	6772	796	921
CV2675-020	BOTSO-2800_ZAR	7041	776	1224
CV2675-020	DDMNO-2734_CU3	5793	607	857
CV2675-020	DDMNO-2734_CU4	4635	495	736
CV2675-020	MILLCHAN	425	81	63
CV2675-020	MILLCRUSH1	6075	648	752
CV2675-020	MILLCRUSH2	5951	644	763
CV2675-020	P1XF3-2720_01	3288	411	393
CV2693-902	BOTSO-2800_ZAR	5138	540	952
CV2693-902	DDMNO-2734_CU3	3890	371	585
CV2693-902	DDMNO-2734_CU4	2732	259	464
CV2693-902	MILLCHAN	2691	365	569
CV2693-902	MILLCRUSH1	5615	631	1021
CV2693-902	MILLCRUSH2	5491	627	1032
CV2693-902	P1XF3-2720_01	4976	599	771
CV2693-903	BOTSO-2800_ZAR	5840	602	1062
CV2693-903	DDMNO-2734_CU3	4592	433	695
CV2693-903	DDMNO-2734_CU4	3434	321	574
CV2693-903	MILLCHAN	3393	427	679
CV2693-903	MILLCRUSH1	6317	693	1131

CV2693-903	MILLCRUSH2	6193	689	1142
CV2693-903	P1XF3-2720_01	5678	661	881
CV2736-035	BOTSO-2800_ZAR	5596	559	657
CV2736-035	DDMNO-2734_CU3	3804	391	448
CV2736-035	DDMNO-2734_CU4	2646	279	327
CV2736-035	MILLCHAN	3091	444	550
CV2736-035	MILLCRUSH1	6015	710	1002
CV2736-035	MILLCRUSH2	5891	706	1013
CV2736-035	P1XF3-2720_01	5376	678	752
CV2743-912	BOTSO-2800_ZAR	5507	552	667
CV2743-912	DDMNO-2734_CU3	3715	384	458
CV2743-912	DDMNO-2734_CU4	2557	272	337
CV2743-912	MILLCHAN	3002	437	560
CV2743-912	MILLCRUSH1	5926	703	1012
CV2743-912	MILLCRUSH2	5802	699	1023
CV2743-912	P1XF3-2720_01	5287	671	762
CV2785-001	BOTSO-2800_ZAR	1069	143	141
CV2785-001	DDMNO-2734_CU3	2855	293	423
CV2785-001	DDMNO-2734_CU4	2627	266	392
CV2785-001	MILLCHAN	5542	717	906
CV2785-001	MILLCRUSH1	4638	620	805
CV2785-001	MILLCRUSH2	4514	616	816
CV2785-001	P1XF3-2720_01	7827	951	1108
SR2258-107	BOTSO-2800_ZAR	7904	814	1699
SR2258-107	DDMNO-2734_CU3	9821	997	1920
SR2258-107	DDMNO-2734_CU4	9593	970	1889
SR2258-107	MILLCHAN	6749	640	1447
SR2258-107	MILLCRUSH1	6444	662	1368
SR2258-107	MILLCRUSH2	6320	658	1379
SR2258-107	P1XF3-2720_01	6916	695	1438
SR2288-275	BOTSO-2800_ZAR	7238	758	1488

SR2288-275	DDMNO-2734_CU3	9155	941	1709
SR2288-275	DDMNO-2734_CU4	8927	914	1678
SR2288-275	MILLCHAN	6083	584	1236
SR2288-275	MILLCRUSH1	5778	606	1157
SR2288-275	MILLCRUSH2	5654	602	1168
SR2288-275	P1XF3-2720_01	6250	639	1227
SR2438-234	BOTSO-2800_ZAR	5717	609	1158
SR2438-234	DDMNO-2734_CU3	7634	792	1379
SR2438-234	DDMNO-2734_CU4	7406	765	1348
SR2438-234	MILLCHAN	4676	447	923
SR2438-234	MILLCRUSH1	4257	457	827
SR2438-234	MILLCRUSH2	4133	453	838
SR2438-234	P1XF3-2720_01	4843	502	914
SR2438-621	BOTSO-2800_ZAR	5341	573	1082
SR2438-621	DDMNO-2734_CU3	7258	756	1303
SR2438-621	DDMNO-2734_CU4	7030	729	1272
SR2438-621	MILLCHAN	4300	411	847
SR2438-621	MILLCRUSH1	3881	421	751
SR2438-621	MILLCRUSH2	3757	417	762
SR2438-621	P1XF3-2720_01	4467	466	838
SR2453-936	BOTSO-2800_ZAR	6401	668	1274
SR2453-936	DDMNO-2734_CU3	8318	856	1495
SR2453-936	DDMNO-2734_CU4	8090	829	1464
SR2453-936	MILLCHAN	5360	521	1039
SR2453-936	MILLCRUSH1	4941	554	943
SR2453-936	MILLCRUSH2	4817	519	954
SR2453-936	P1XF3-2720_01	5527	615	1030
SR2686-020	BOTSO-2800_ZAR	3236	391	542
SR2686-020	DDMNO-2734_CU3	5153	579	763
SR2686-020	DDMNO-2734_CU4	4925	552	732
SR2686-020	MILLCHAN	5141	564	681

SR2686-020	MILLCRUSH1	1257	206	170
SR2686-020	MILLCRUSH2	1133	171	181
SR2686-020	P1XF3-2720_01	5070	629	631
SR2692-015	BOTSO-2800_ZAR	3215	354	544
SR2692-015	DDMNO-2734_CU3	5132	542	765
SR2692-015	DDMNO-2734_CU4	4904	515	734
SR2692-015	MILLCHAN	5522	595	774
SR2692-015	MILLCRUSH1	832	125	120
SR2692-015	MILLCRUSH2	708	90	131
SR2692-015	P1XF3-2720_01	5451	660	724
SR2702-001	BOTSO-2800_ZAR	3863	437	635
SR2702-001	DDMNO-2734_CU3	5780	625	856
SR2702-001	DDMNO-2734_CU4	5552	598	825
SR2702-001	MILLCHAN	4238	466	571
SR2702-001	MILLCRUSH1	1884	252	263
SR2702-001	MILLCRUSH2	1760	217	274
SR2702-001	P1XF3-2720_01	4167	531	521
SR2765-001	BOTSO-2800_ZAR	5054	717	998
SR2765-001	DDMNO-2734_CU3	6971	905	1219
SR2765-001	DDMNO-2734_CU4	6743	878	1188
SR2765-001	MILLCHAN	5683	774	965
SR2765-001	MILLCRUSH1	3075	532	626
SR2765-001	MILLCRUSH2	2951	497	637
SR2765-001	P1XF3-2720_01	5612	839	915
SR2824-036	BOTSO-2800_ZAR	2685	324	488
SR2824-036	DDMNO-2734_CU3	5183	609	866
SR2824-036	DDMNO-2734_CU4	4955	582	835
SR2824-036	MILLCHAN	7067	913	1188
SR2824-036	MILLCRUSH1	3016	461	584
SR2824-036	MILLCRUSH2	2892	426	595
SR2824-036	P1XF3-2720_01	8216	1096	1303

SR2825-036	BOTSO-2800_ZAR	2363	307	446
SR2825-036	DDMNO-2734_CU3	4861	592	824
SR2825-036	DDMNO-2734_CU4	4633	565	793
SR2825-036	MILLCHAN	6745	896	1146
SR2825-036	MILLCRUSH1	2694	444	542
SR2825-036	MILLCRUSH2	2570	409	553
SR2825-036	P1XF3-2720_01	7894	1079	1261

Anexo 3

Tiempos de viajes desde el Parqueo Perim-Sur

Origen	Destino	Distancia (m)	Viaje vacío (s)	Viaje lleno (s)
PQ_PERIM-SUR	CV2663-414	5855	706	839
PQ_PERIM-SUR	CV2675-020	4556	490	599
PQ_PERIM-SUR	CV2693-902	5743	586	729
PQ_PERIM-SUR	CV2693-903	4877	501	614
PQ_PERIM-SUR	CV2736-035	6759	685	1026
PQ_PERIM-SUR	CV2743-912	6670	704	1064
PQ_PERIM-SUR	CV2785-001	3913	456	628
PQ_PERIM-SUR	SR2258-107	6854	1456	1679
PQ_PERIM-SUR	SR2288-275	6188	1344	1552
PQ_PERIM-SUR	SR2438-234	4670	937	1052
PQ_PERIM-SUR	SR2438-621	4294	889	1009
PQ_PERIM-SUR	SR2453-936	5354	1002	1129
PQ_PERIM-SUR	SR2686-020	1268	126	197
PQ_PERIM-SUR	SR2692-015	1649	186	244
PQ_PERIM-SUR	SR2702-001	365	39	46
PQ_PERIM-SUR	SR2765-001	1810	180	294
PQ_PERIM-SUR	SR2824-036	4414	524	710
PQ_PERIM-SUR	SR2825-036	4092	485	705
PQ_PERIM-SUR	BOTSO-2800_ZAR	4090	435	649
PQ_PERIM-SUR	DDMNO-2734_CU3	6007	668	855
PQ_PERIM-SUR	DDMNO-2734_CU4	5779	641	824
PQ_PERIM-SUR	P1XF3-2720_01	4394	519	550
PQ_PERIM-SUR	MILLCHAN	4465	483	600
PQ_PERIM-SUR	MILLCRUSH1	2111	248	314
PQ_PERIM-SUR	MILLCRUSH2	1987	241	305
CV2663-414	PQ_PERIM-SUR	5855	670	948
CV2675-020	PQ_PERIM-SUR	4556	479	558
CV2693-902	PQ_PERIM-SUR	6244	671	942

CV2693-903	PQ_PERIM-SUR	6946	733	1052
CV2736-035	PQ_PERIM-SUR	6644	753	921
CV2743-912	PQ_PERIM-SUR	6555	746	931
CV2785-001	PQ_PERIM-SUR	3913	573	752
SR2258-107	PQ_PERIM-SUR	6857	748	1459
SR2288-275	PQ_PERIM-SUR	6191	698	1248
SR2438-234	PQ_PERIM-SUR	4670	543	918
SR2438-621	PQ_PERIM-SUR	4294	504	842
SR2453-936	PQ_PERIM-SUR	5354	611	1034
SR2686-020	PQ_PERIM-SUR	1268	195	170
SR2692-015	PQ_PERIM-SUR	1649	248	268
SR2702-001	PQ_PERIM-SUR	365	59	60
SR2765-001	PQ_PERIM-SUR	1810	373	454
SR2824-036	PQ_PERIM-SUR	4414	727	831
SR2825-036	PQ_PERIM-SUR	4092	710	789
BOTSO-2800_ZAR	PQ_PERIM-SUR	4179	610	812
DDMNO-2734_CU3	PQ_PERIM-SUR	5874	740	945
DDMNO-2734_CU4	PQ_PERIM-SUR	6610	800	1007
P1XF3-2720_01	PQ_PERIM-SUR	4394	509	683
MILLCHAN	PQ_PERIM-SUR	4254	429	521
MILLCRUSH1	PQ_PERIM-SUR	2111	334	372
MILLCRUSH2	PQ_PERIM-SUR	1987	309	345

ProyectoFinalTeddyChiarot

INFORME DE ORIGINALIDAD

5%

INDICE DE SIMILITUD

5%

FUENTES DE INTERNET

1%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

hdl.handle.net

Fuente de Internet

2%

2

repositorio.unprg.edu.pe

Fuente de Internet

1%

3

doku.pub

Fuente de Internet

<1%

4

Submitted to Universidad Alas Peruanas

Trabajo del estudiante

<1%

5

Submitted to Universidad Carlos III de Madrid

Trabajo del estudiante

<1%

6

www.scribd.com

Fuente de Internet

<1%

7

repositorio.uarm.edu.pe

Fuente de Internet

<1%

8

www.coursehero.com

Fuente de Internet

<1%

9

es.scribd.com

Fuente de Internet

<1%

10	www.aai.com.pe Fuente de Internet	<1 %
11	repositorio.uisek.edu.ec Fuente de Internet	<1 %
12	www.cio.mx Fuente de Internet	<1 %
13	kipdf.com Fuente de Internet	<1 %
14	www.comxport.com Fuente de Internet	<1 %



Excluir citas Activo

Excluir coincidencias < 15 words

Excluir bibliografía Activo



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por Turnitin. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Teddy Vinicio Chiarot Villegas
 Título del ejercicio: PerfilMaestria
 Título de la entrega: ProyectoFinalTeddyChiarot
 Nombre del archivo: BorradorFinal_Tchiarot_260722_1.docx
 Tamaño del archivo: 4.66M
 Total de páginas: 98
 Total de palabras: 14,850
 Total de caracteres: 79,876
 Fecha de entrega: 27-jul.-2022 11:52a. m. (UTC-0500)
 Identificador de la entrega: 1875867222

