



Universidad Nacional
de Trujillo

Journal of Advanced Mining Modeling (JAMM)

Página web de la revista: <https://revistas.unitru.edu.pe/index.php/jamm/index>



Journal of Advanced
Mining Modeling
(JAMM)

Optimización de tiempos para reducir costos en carguío y acarreo mediante un modelo de Red Neuronal Artificial

Fabrizio Ruiz-Santos^{1*}

1. Departamento de Ingeniería de Minas, Facultad de Ingeniería, Universidad Nacional de Trujillo, Trujillo, Perú.

Resumen

En minería subterránea, los procesos de carguío y acarreo constituyen una de las principales fuentes de costos operativos, especialmente cuando se generan tiempos improductivos o la vía de transporte no se encuentra en condiciones óptimas. Bajo este escenario, la investigación tuvo como objetivo reducir dichos costos mediante el control de tiempos y la mejora del mantenimiento de la vía. Se empleó un enfoque cuantitativo y un diseño no experimental, realizando una evaluación de los procesos existentes de carguío y transporte, considerando la distancia recorrida, los equipos utilizados y los tiempos involucrados. Durante 20 guardias se monitorearon las operaciones y se implementaron controles de tiempos de carguío y acarreo, así como la programación de una red neuronal para predecir los costos asociados. Los resultados obtenidos muestran que, al verificar los tiempos y las predicciones con los promedios, existe una diferencia de \$0.20 por tonelada métrica. Asimismo, al revisar los tiempos de transporte y el adecuado mantenimiento de la vía, los costos de soporte se redujeron de \$1.04 por tonelada métrica a \$0.90, logrando un ahorro adicional de \$0.14. Además, se concluyó que el control del tiempo y el mantenimiento adecuado de la vía permiten reducir los tiempos de carguío en un 11.45% y los tiempos de transporte en un 12.73% dentro de la unidad minera.

Palabras claves: Carguío, acarreo, costos, equipos, tiempo.

1. Introducción

Optimizar los costos de carguío y acarreo en las operaciones mineras es un desafío constante para las empresas del sector [1]. El objetivo principal es reducir los gastos asociados a estas actividades, mejorando así la rentabilidad y la eficiencia en la extracción de minerales [2]. Sin embargo, diversos factores pueden afectar negativamente la optimización de estos costos, como los tiempos improductivos en el proceso de carguío y acarreo, así como el deficiente mantenimiento de la vía de transporte [3].

Diversos estudios demuestran que los modelos de aprendizaje automático permiten capturar relaciones no lineales entre parámetros geometalúrgicos y operacionales, obteniendo predicciones más robustas que los métodos estadísticos tradicionales. En esta línea, se ha evidenciado que la integración de algoritmos de machine learning con enfoques espaciales avanzados permite mejorar significativamente la estimación de recursos minerales y la caracterización de depósitos complejos [4]. Asimismo, comparaciones recientes entre diferentes técnicas de aprendizaje automático han mostrado que los modelos híbridos y las redes neuronales presentan un desempeño superior en la categorización y clasificación mineral, especialmente en yacimientos de cobre con alta variabilidad espacial [5], [6].

Por otra parte, los modelos predictivos basados en aprendizaje automático también han mostrado una alta efectividad para la optimización de variables operativas. Se ha probado que técnicas supervisadas permiten predecir con precisión el costo unitario del acarreo en minería subterránea, utilizando como entradas tiempos del ciclo, distancias y características operativas del equipo [7]. En el ámbito de minería subterránea, arquitecturas neuronales avanzadas han permitido modelar fenómenos complejos como dilución, sobre excavación y costos asociados, demostrando que las redes profundas pueden representar de manera eficiente

procesos altamente no lineales vinculados al comportamiento geomecánico y a las condiciones de operación [8].

A nivel energético, los modelos híbridos de machine learning han mostrado ser capaces de predecir el consumo de combustible de camiones mineros mediante el análisis de velocidad, carga útil, pendientes y condiciones operativas, proporcionando una herramienta de optimización para reducir costos y mejorar la eficiencia de transporte [9]. Finalmente, evaluaciones comparativas de modelos predictivos aplicados a operaciones unitarias artesanales han demostrado que los algoritmos de aprendizaje automático superan de manera consistente a los métodos convencionales en la optimización de costos, ofreciendo mayor exactitud y capacidad de generalización [10].

El problema radica en que los tiempos improductivos durante la carga y el acarreo de minerales pueden generar costos adicionales y afectar el desempeño general de las operaciones mineras [11]. Estos tiempos improductivos pueden estar relacionados con factores como la falta de planificación, la ineficiencia en los procesos y la asignación inadecuada de recursos [12]. Por otro lado, el mal mantenimiento de la vía de transporte puede ocasionar retrasos, daños en los equipos e incrementar los costos operativos [13].

A pesar de que diversos estudios han abordado la optimización del cargo y el acarreo mediante simulación, algoritmos de despacho o modelos predictivos, la mayoría se ha centrado únicamente en los tiempos de operación y en la asignación de equipos. Sin embargo, existe una brecha importante en la literatura respecto a la integración simultánea del control operativo de tiempos y las condiciones reales de la vía como variables determinantes en los costos. Asimismo, pocos trabajos han utilizado modelos basados en redes neuronales para predecir de manera conjunta los costos derivados del cargo y acarreo en función de estos factores operacionales. Esta falta de estudios integrados limita la capacidad de las operaciones mineras para estimar con precisión los costos reales y optimizar de manera efectiva sus procesos.

Para abordar este problema, es necesario establecer estrategias y soluciones efectivas que minimicen los tiempos improductivos durante la carga y el acarreo, además de implementar un mantenimiento óptimo de la vía de transporte [14]. En este sentido, el uso de programación en Python puede ser una herramienta valiosa para mejorar la estimación de los tiempos de cargo y acarreo, permitiendo una planificación más eficiente y una adecuada asignación de recursos. Asimismo, un correcto mantenimiento de la vía contribuirá a reducir los tiempos de espera, minimizar daños en los equipos y optimizar los costos operativos [15].

En este artículo se explorarán estrategias y técnicas específicas para mejorar la eficiencia en las actividades de cargo y acarreo de minerales, con énfasis en la gestión del tiempo y el mantenimiento de la vía. Se abordará el uso de programación en Python como herramienta para estimar los costos de cargo y acarreo con mayor precisión, así como para optimizar la planificación y la asignación de recursos [16]. Del mismo modo, se destacará la importancia de un adecuado mantenimiento de la vía de transporte y se presentarán prácticas recomendadas para asegurar su óptima conservación.

Optimizar los costos de cargo y acarreo en las operaciones mineras requiere enfrentar los tiempos improductivos y mejorar el mantenimiento de la vía de transporte [17]. El uso de Python puede mejorar la estimación de los tiempos de cargo y acarreo, posibilitando una planificación más efectiva y una correcta asignación de recursos. Además, un mantenimiento adecuado de la vía ayudará a minimizar los costos operativos y garantizar un funcionamiento eficiente [18].

Este artículo profundizará en las estrategias y técnicas que pueden implementarse para afrontar estos desafíos y lograr una gestión óptima de los costos de cargo y acarreo en operaciones mineras [19].

Este artículo se organiza de la siguiente manera: el punto 2 describe los materiales y métodos utilizados en la investigación, incluyendo la recolección de datos operativos y el diseño del modelo de red neuronal. El punto 3 presenta los resultados obtenidos en las etapas de cargo y acarreo. El punto 4 discute los hallazgos y su relevancia operativa para la unidad minera. Finalmente, el punto 5 expone las conclusiones principales y propone líneas de investigación futura.

2. Materiales y métodos

Este proyecto de investigación se centró en el proceso de acarreo de mineral en las operaciones mineras [20]. El objetivo principal fue proponer estrategias efectivas para minimizar los tiempos improductivos [21] y optimizar los costos asociados a esta etapa del proceso minero.

Para lograr este objetivo, se empleó un enfoque cuantitativo y se recopilieron datos reales obtenidos durante el desarrollo de las operaciones de cargo y acarreo [22]. Estos datos fueron fundamentales para realizar un

análisis descriptivo y aplicado, con el fin de comprender los patrones de comportamiento y establecer relaciones significativas entre los distintos viajes realizados en estos procesos [23].

El estudio se llevó a cabo utilizando un diseño experimental, lo que permitió realizar cambios controlados en las variables para obtener comparaciones significativas. Esto fue especialmente relevante al considerar los costos asociados con las operaciones de acarreo [24], ya que se buscaba determinar la forma más eficiente de optimizarlos [25].

En este contexto, se incorporó inteligencia artificial mediante el lenguaje de programación Python [26]. El uso de técnicas de inteligencia artificial permitió analizar los datos recopilados y generar modelos predictivos que ayudaron a identificar las mejores estrategias para optimizar los costos de las operaciones de acarreo de mineral.

El procedimiento metodológico seguido en este estudio se representa mediante un flujograma que integra el proceso operativo en campo con el desarrollo del modelo de predicción mediante una Red Neuronal Artificial (RNA), mostrando de manera secuencial cada etapa desde la recopilación y validación de datos hasta la generación de las predicciones de costos.




Figura 1 Flujograma de procesos

En la Figura 1, se presenta un flujograma de los procesos a realizarse, donde primero se identifican las operaciones a evaluar y se reúnen los datos operativos (tiempos de ciclo, distancias, capacidades de los equipos). Luego se realiza un análisis exploratorio (EDA) para entender la distribución y variabilidad de los tiempos, verificando si existen datos nulos o inconsistencias que deban depurarse. Con la información depurada, se prepara el dataset mediante la homologación y normalización de las variables para alimentar la RNA. Después se construye el modelo predictivo, seleccionando la arquitectura adecuada y entrenándolo para evaluar si alcanza un nivel aceptable de precisión.

Una vez que el modelo es estable, se procede a la estimación de costos optimizados tanto en carguío como en acarreo. Posteriormente, los resultados se integran comparando el desempeño previo versus el optimizado y analizando el impacto económico. Y por último, las conclusiones muestran que hubo reducción de tiempos, disminución de costos y que la RNA predice con buena precisión, permitiendo sustentar la toma de decisiones operativas.

Los resultados obtenidos a partir de este enfoque metodológico brindaron a la empresa minera una base sólida para la toma de decisiones informadas. A partir de los patrones identificados y las relaciones establecidas, fue posible proponer estrategias específicas que contribuyeron a minimizar los tiempos improductivos y reducir los costos asociados al acarreo de mineral [27].

Las siguientes tablas muestran los datos respectivos con los que se trabajará, evidenciando los diferentes tiempos que ocurren en cada viaje.

Tabla 1 Base de datos de carguío con la que se trabajará

N.º de viajes	de Tiempo de carguío (s)	de Tiempo de cargado (s)	de viaje Tiempo de descarga (s)	de Tiempo de retorno (s)	de vacío Total del ciclo (s)
1	90	131	54	88	363
2	89	130	53	86	358
.					
15	90	132	55	85	362
16	88	130	56	86	360
Total					5781
Tiempo promedio	90.00	130.63	54.44	86.25	361.31

Tabla 2 Base de datos de acarreo con la que se trabajará

N.º de viajes	Tiempo de carguío (s)	de Tiempo de viaje cargado (s)	Tiempo de descarga (s)	Tiempo de retorno (s)	de vacío Total del ciclo (s)	N.º de viajes
1	92	161	42	119	Four. Five	461
2	90	159	43	117	47	458
.						
15	90	159	42	119	49	459
16	91	161	40	117	53	461
Total						7358
Tiempo promedio	90.81	159.25	41.94	117.4	50.44	459.8

El diseño de la red neuronal se centró en evaluar una arquitectura óptima para la predicción de nuevos costos optimizados derivados de la reducción de los tiempos de carguío y acarreo debido al mantenimiento de la vía [28]. Para ello, se consideró cuidadosamente el número de capas ocultas, tomando en cuenta las características y la complejidad de los datos relacionados con este proceso de optimización.

Con respecto a la elección de las funciones para las capas ocultas, se realizaron análisis exhaustivos para determinar cuáles serían las más adecuadas en este contexto específico [29]. Se buscó seleccionar funciones capaces de capturar de manera eficiente las relaciones y patrones clave entre los tiempos de carguío y acarreo, así como los impactos resultantes sobre los costos.

En cuanto a la capa de salida de la red neuronal, se decidió utilizar la función softmax. Esta decisión se basó en la naturaleza del problema, el cual implica la predicción de múltiples categorías de costos optimizados. La función softmax permite asignar probabilidades a cada categoría, facilitando la interpretación de los resultados y la toma de decisiones informadas.

Por otro lado, dado que existe una única variable independiente, el modelo generalmente se denomina regresión bivariada debido a la presencia de dos variables: la independiente y la dependiente.

$$Y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

Esta es la ecuación del modelo de la RNA (Artificial Neural Network), donde X es la variable independiente y Y es la variable dependiente [18]. Los valores de determinan la pendiente de la línea y ε representa el error. Finalmente, se obtiene [29]:

$$\beta_0 = \bar{y} - \beta_1 \bar{x} \quad (2)$$




Figura 2 RNA model

Se muestra una red neuronal con una capa de entrada, una capa oculta y una capa de salida.

La capa de entrada recibe los datos de entrada, la capa oculta realiza operaciones y transformaciones intermedias, y la capa de salida produce la salida final del modelo.

3. Resultados

3.1. Minimizar los costos de carguío en US\$/Tm mediante el control de tiempos

En el control de los tiempos de carga, se realizaron 16 viajes utilizando equipos Scooptram de 2.65 yardas cúbicas, lo que representó un volumen de 2.01 metros cúbicos por viaje para transportar el mineral ubicado a una distancia de 135 metros. Sin embargo, en el carguío optimizada se programó reducir el número de viajes a 15, manteniendo la misma capacidad del balde.

La falta de mantenimiento en la ruta de recorrido ocasionó retrasos innecesarios en el tiempo de carguío y una falta de control en el carguío óptima del balde del Scooptram. Los tiempos de carguío calculados se especifican en la Tabla 3.

El mineral acumulado en el frente de la galería tenía un volumen de 30.40 metros cúbicos, equivalente a 76 toneladas métricas.

Tabla 3 Tiempos promedio previos de carguío con el equipo Scooptram

N.º de viajes	Tiempo de carguío (s)	de Tiempo de ida con carga (s)	Tiempo de descarga (s)	de Tiempo de retorno vacío (s)	Total del ciclo (s)
1	90	131	54	88	363
2	89	130	53	86	358
3	89	132	55	85	361
4	92	129	54	84	359
5	91	131	55	86	363
6	90	132	56	87	365

7	92	130	54	88	364
8	89	129	55	86	359
9	90	131	54	85	360
10	91	130	53	87	361
11	89	133	53	88	363
12	91	129	54	86	360
13	89	130	56	87	362
14	90	131	54	86	361
15	90	132	55	85	362
16	88	130	56	86	360
Total					5781
Tiempo promedio	90.00	130.63	54.44	86.25	361.31

La Tabla 3 muestra el tiempo promedio obtenido durante los 16 viajes del ciclo de carguío previo utilizando el equipo Scooptram con una capacidad de balde de 2.65 yardas cúbicas. El tiempo registrado fue de 5,781 segundos, lo que equivale a 96.35 minutos.

El costo de alquiler del Scooptram es de \$80 por hora, resultando en un costo de carguío de \$128.47.

Se cargaron un total de 76 toneladas métricas, lo que implica un costo por tonelada métrica de aproximadamente \$1.69.

La Figura 2 presenta una distribución detallada en porcentajes de los tiempos del ciclo de acarreo, donde el tiempo de carguío es el que consume la mayor proporción de tiempo, por lo que es el principal proceso para minimizar.




Figura 3 Distribución de los tiempos de acarreo

Mediante el uso de redes neuronales, se espera obtener un costo de \$1.67 por tonelada métrica, tal como se muestra en la Tabla 4.

Estas predicciones se basan en el análisis de datos utilizando técnicas avanzadas de machine learning, lo que proporciona un alto grado de precisión y confiabilidad en las estimaciones realizadas.

Tabla 4 Predicción en Python de los costos de carguío (no optimizados)

ITEMS	Valor
Tiempo de carguío (s)	90

Tiempo de viaje cargado (s)	130.63
Tiempo de descarga (s)	54.44
Tiempo de retorno vacío (s)	86.23
Predicción USD/TM	1.69

Se presentan las predicciones más precisas del costo estimado de acarreo por tonelada métrica. Mediante el uso de redes neuronales, es posible visualizar con precisión el impacto que los tiempos de carguío tienen sobre los costos operativos.

Se realizó una optimización del sistema de carguío de mineral utilizando equipos Scooptram con una capacidad de balde de 2.65 yardas cúbicas. Se llevaron a cabo trabajos de mantenimiento en las rutas y se controló la capacidad óptima de carguío del cucharón durante el proceso.

Los tiempos obtenidos se detallan en la Tabla 5. Estos datos son relevantes para evaluar la eficiencia y la rentabilidad del proceso de carguío de mineral, así como para tomar decisiones informadas que permitan maximizar la productividad en la extracción minera.

Tabla 5 Tiempos promedio de carguío optimizados con el equipo Scooptram

N.º de viajes	Tiempo carguío (s)	de Tiempo de ida con carga (s)	Tiempo de descarga (s)	de Tiempo retorno (s)	de vacío	Total del ciclo (s)
1	82	127	52	81		342
2	80	128	50	83		341
3	82	126	50	82		340
4	81	128	52	81		342
5	80	129	51	81		341
6	81	126	50	82		339
7	83	127	51	80		341
8	80	129	50	81		340
9	82	127	51	82		342
10	82	129	50	80		341
11	80	128	51	83		342
12	81	129	50	80		340
13	82	127	50	83		342
14	81	128	51	81		341
15	82	126	52	80		340
Total						5114
Tiempo promedio	81.27	127.60	50.73	81.33		340.9

La Tabla 5 registra el tiempo promedio de los 15 viajes del ciclo de carguío optimizado utilizando el equipo Scooptram con una capacidad de balde de 2.65 yardas cúbicas. El tiempo promedio obtenido fue de 85.23 minutos, equivalente a 5114 segundos.

Considerando el costo de alquiler del Scooptram de \$80 por hora, se estima que el costo de transporte es de \$1.49 por tonelada métrica. Esta estimación se basa en una producción de 76 toneladas métricas por turno. La Figura 3 muestra una comparación entre el tiempo promedio de carguío previo y el tiempo optimizado realizado con el equipo Scooptram de 2.65 yardas cúbicas. Esta representación visual resalta las mejoras significativas en eficiencia y rendimiento logradas gracias a la optimización del proceso de carga.




Figura 4 Comparación de los tiempos de carga

La Figura 3 muestra una comparación entre el tiempo promedio previo de los 16 viajes realizados, que fue de 96.35 minutos, y el tiempo promedio optimizado de los 15 viajes efectuados, que fue de 85.23 minutos. Esta optimización ha logrado una reducción significativa de 11.12 minutos en el tiempo promedio de carga. Estos resultados destacan la efectividad de las mejoras implementadas y su impacto en la eficiencia operativa. Asimismo, mediante la aplicación de programación con redes neuronales, se ha realizado una predicción del nuevo costo asociado al proceso de carga. La Tabla 6 muestra una reducción significativa en los costos estimados.

Esta nueva metodología de predicción, basada en algoritmos avanzados de machine learning, ha permitido obtener una estimación más precisa y detallada de los costos asociados al proceso de carga.

Tabla 6 Predicción en Python de los costos de carguío (optimizada)

ITEMS	VALOR
Tiempo de carguío (s)	81.27
Tiempo de viaje cargado (s)	127.60
Tiempo de descarga (s)	50.73
Tiempo de retorno vacío (s)	81.33
Predicción USD/TM	1.49

La Tabla 6 muestra cómo, al contar con menores tiempos gracias al buen mantenimiento de la vía y a que esta se encuentra en condiciones óptimas para su operación, también se reducen los costos, lo que genera beneficios rentables para la empresa minera.

La Figura 4 presenta una comparación visual entre los costos de transporte antes y después de la optimización utilizando el equipo Scooptram de 2.65 yardas cúbicas.

Esta representación gráfica resalta de manera clara y concisa los beneficios obtenidos mediante la implementación de mejoras en el proceso de carga; se puede observar claramente la diferencia de costos antes y después de la optimización, lo que evidencia los impactos positivos alcanzados gracias a las mejoras implementadas.




Figura 5 Comparación de los costos de carga

La Figura 5 muestra claramente la diferencia en los costos entre ambos tiempos, lo que demuestra el impacto positivo de la optimización. El análisis de costos revela una reducción significativa en los gastos asociados a la carga tras la implementación de las mejoras propuestas.

3.2. Reducir los costos de acarreo en US\$/Tm mediante el mantenimiento de la vía y la predicción de tiempos y costos

Se utilizó un vehículo Dumper con capacidad de 10 toneladas métricas (Tm) para trasladar el material desde el punto de carguío hasta la tolva principal, recorriendo una distancia total de 365 metros.

En el primer acarreo, se realizaron 16 viajes, como se muestra en la Tabla 7, utilizando este Dumper de 10 Tm para transportar un total acumulado de 150 Tm de mineral.

Para calcular los costos asociados a este acarreo, se utiliza un costo de alquiler del Dumper de 76 USD por hora.

Tabla 7 Tiempos promedio previos de acarreo con el Dumper

N.º de viajes	Tiempo de carguío (s)	Tiempo de ida con carga (s)	Tiempo de descarga (s)	Tiempo de retorno vacío (s)	Total del ciclo (s)	N.º de viajes
1	92	161	42	119	45	461
2	90	159	43	117	47	458
3	89	161	42	118	48	460
4	91	160	41	117	47	456
5	92	159	42	117	49	458
6	91	160	43	116	51	461
7	92	157	41	117	54	460
8	90	159	43	118	52	462
9	91	158	42	117	51	459
10	89	159	43	119	53	461
11	90	161	42	116	54	463
12	92	159	40	117	53	460
13	91	158	42	119	51	461
14	92	157	43	116	50	458
15	90	159	42	119	49	459
16	91	161	40	117	53	461
Total						7358
Tiempo Promedio	90.81	159.25	41.94	117.4	50.44	459.8

De acuerdo con la Tabla 7, el tiempo promedio previo de acarreo utilizando el Dumper con capacidad de 10 toneladas métricas (TM) fue de 7358 segundos, equivalente a 122.63 minutos o aproximadamente 1.04 horas.

Considerando un costo de alquiler del Dumper de 76 USD por hora, en este caso el costo de acarreo se estima en aproximadamente 1.04 USD por TM.

Esto puede verificarse en la Tabla 8, que se presenta a continuación con una estimación más precisa.

Tabla 8 Predicción en Python de los costos de acarreo (no optimizados)

ITEMS	VALOR
Tiempo de carguío (s)	90.81
Tiempo de viaje cargado (s)	159.25
Tiempo de descarga (s)	41.94
Tiempo de retorno vacío (s)	117.44
	50.44
Predicción USD/TM	1,034

La Tabla 8 presenta las predicciones más precisas del costo estimado de acarreo por tonelada métrica, basadas en los tiempos promedio registrados para cada operación del ciclo de acarreo.

Asimismo, es posible realizar un análisis más visual de estos tiempos y de cómo se distribuyen en cada operación, tal como se aprecia en la Figura 6.




Figura 6 Distribución de los tiempos de acarreo

La Figura 6 muestra una distribución de los tiempos, a partir de la cual se puede visualizar y analizar que existe un mayor consumo de tiempo en el viaje con carga del Dumper dentro de la unidad minera.

Al realizar el mantenimiento de la vía de la unidad minera, se observa una reducción en los tiempos, lo cual puede apreciarse con mayor detalle en la Tabla 9.

Tabla 9 Tiempos promedio de acarreo optimizados con el Dumper

N.º de viajes	Tiempo de carguío (s)	Tiempo de ida con carga (s)	Tiempo de descarga (s)	Tiempo de retorno vacío (s)	Total ciclo (s)	N.º de viajes
1	89	157	40	113	34	433
2	88	156	39	109	33	427
3	89	155	38	110	36	428
4	88	156	39	112	33	427
5	87	158	38	110	36	429
6	88	155	40	109	34	427
7	87	156	39	110	35	429
8	88	155	37	112	34	427
9	87	157	39	110	33	426

10	88	156	39	109	36	427
11	87	157	40	110	35	429
12	88	155	38	112	36	428
13	87	156	39	110	37	429
14	88	157	40	109	3. 4	427
15	89	156	38	112	35	428
Total						6421
Tiempo Promedio	87.87	156.13	38.87	110.4	34.73	428.0

De acuerdo con la Tabla 9, el tiempo promedio optimizado de acarreo con el Dumper de 10 toneladas métricas (Tm) fue de 6421 segundos, lo que equivale a 107.02 minutos.

Considerando un costo de alquiler del Dumper de 76 USD por hora, en este caso, el costo de acarreo optimizado se estima en aproximadamente 0.90 USD por tonelada métrica.

En el acarreo optimizado, se realizaron 15 viajes utilizando el Dumper con capacidad de 10 toneladas métricas para transportar un total de 150 Tm de mineral acumulado.

Esto puede verificarse en la Tabla 10, que se presenta a continuación con una estimación más precisa.

Tabla 10 Predicción en Python de los costos de acarreo (optimizada)

ITEMS	Valor
Tiempo de carguío (s)	87.87
Tiempo de viaje cargado (s)	156.13
Tiempo de descarga (s)	38.87
Tiempo de retorno vacío (s)	110.47
	34.73
Predicción USD/TM	0.9

La Tabla 10 presenta las predicciones más precisas del costo estimado de acarreo por tonelada métrica, basadas en los tiempos promedio ya optimizados registrados para cada operación del ciclo de acarreo.

Esta representación visual destaca las mejoras significativas en eficiencia y rendimiento logradas mediante la optimización del proceso de acarreo.




Figura 7 Comparación de los tiempos de acarreo

La

Figura 7 muestra una comparación entre el tiempo promedio previo de los 16 viajes realizados, que fue de 122.63 minutos, y el tiempo promedio optimizado de los 15 viajes efectuados, que fue de 107.02 minutos. Esta optimización ha logrado una reducción significativa de 15.61 minutos en el tiempo promedio de acarreo. Estos resultados destacan la efectividad de las mejoras implementadas y su impacto en la eficiencia operativa. Se presenta una comparación visual entre los costos de transporte antes y después de la optimización utilizando el equipo Dumper de 10 Tm. Esta representación gráfica resalta de manera clara y concisa los beneficios obtenidos mediante la implementación de mejoras en el proceso de acarreo. En la Figura 8, se observa claramente la diferencia en los costos antes y después de la optimización, lo que evidencia los impactos positivos alcanzados gracias a las mejoras implementadas.




Figura 8 Comparación de los costos de acarreo

El gráfico de la Figura 8 muestra la comparación de los costos previos con respecto a los optimizados, lo que refleja una variación de 0.142 USD/TM a favor tras la obtención de los nuevos tiempos al optimizar la ruta de la unidad minera.

3.3. Mejorar la eficiencia de carguío y acarreo mediante la optimización de tiempos y la reducción de costos operativos

Como se muestra en las Tablas 5 y 9 de tiempos optimizados, las mejoras en las vías por donde se realizan las operaciones de carguío contribuyen significativamente a la optimización de costos, lo que genera importantes beneficios económicos para la empresa minera.

Gracias a la programación de redes neuronales, es posible predecir en tiempo real los costos operativos de carguío y acarreo, conociendo tanto los costos estimados como los costos reales del proceso mencionado, tal como se muestra en las Figura 9 y

Figura 10.




Figura 9 Costo real / Costo estimado de carga




Figura 10 Costo real / Costo estimado de carga

Las Figura 9 y

Figura **10** muestran el comportamiento de los costos estimados esperados en la unidad minera con respecto a los costos reales que se tienen, toda esta variación producto de la optimización de tiempos, lo cual evidencia una disminución en los costos.

La optimización de tiempos y el adecuado mantenimiento de las vías son aspectos fundamentales en el área de carguío y acarreo en minería. La eficiencia desempeña un papel crucial en el proceso de carguío y transporte de mineral para la productividad y rentabilidad de la empresa minera.

La Tabla 11 muestra las ventajas más importantes de esta optimización de tiempos en relación con el mantenimiento de la vía.

Tabla 11 Beneficios de mejorar la eficiencia de carguío y acarreo

Beneficios de la optimización del tiempo mediante el mantenimiento de la vía	Mejora en la eficiencia de carguío y acarreo en la Galería Santa Catalina	Costos
Reducción del tiempo de espera	Mayor fluidez en el proceso de carguío y acarreo, evitando retrasos y tiempos de espera innecesarios.	Reducción de costos por tiempos de inactividad.
Mejor aprovechamiento de los equipos de carguío y acarreo	Mayor productividad al aprovechar de manera óptima los recursos disponibles, evitando tiempos improductivos.	Reducción de costos debido al subuso o infrautilización de equipos.
Menor desgaste de equipos	Los equipos de carguío y acarreo se utilizan de forma más eficiente, lo que puede reducir el desgaste y prolongar su vida útil.	Reducción de los costos de mantenimiento y reemplazo de equipos.
Mayor seguridad en la operación	El adecuado mantenimiento de la vía y una mejor gestión del tiempo reducen el riesgo de accidentes y mejoran la seguridad general.	Reducción de costos asociados a accidentes y daños en los equipos.
Optimización de rutas y recorridos	La vía se mantiene en condiciones óptimas, lo que permite seleccionar las rutas más eficientes y reducir la distancia recorrida, generando ahorro de tiempo y costos.	Reducción de costos por consumo de combustible y desgaste de neumáticos.
Reducción de los costos operativos	Al reducir los tiempos de espera, optimizar el uso de los equipos y minimizar el desgaste, se logra una disminución de los costos operativos.	Reducción general de los costos operativos de carguío y acarreo.

La Tabla 11 muestra que los beneficios se fundamentan en la premisa de que un adecuado mantenimiento de la vía y una gestión eficiente del tiempo generan beneficios rentables para la empresa minera.

4. Discusiones

Los resultados del estudio muestran que la optimización del ciclo de carguío y acarreo mediante el control de tiempos y la mejora de la vía permitió reducir los tiempos operativos entre 11% y 12% y disminuir los costos totales en 0.34 USD/TM.

Esto coincide con lo reportado por Baek & Choi (2017), quienes demostraron que pequeñas reducciones en el tiempo de ciclo pueden generar mejoras significativas en la productividad total del sistema de transporte. De forma similar, Enkhchuluun et al. (2023) señalaron que el viaje con carga es el componente del ciclo que más influye en los costos totales, lo cual se observa también en este estudio, donde esta etapa mostró la mayor reducción tras el mantenimiento de la vía.

Por otro lado, los trabajos de Soofastaei et al. (2015) y Meneses & Sepúlveda (2023) evidencian que el mal estado de la vía incrementa el consumo de combustible, la resistencia al rodado y los tiempos de desplazamiento. Los resultados de esta investigación confirman esta relación, mostrando que el simple mantenimiento de la vía redujo el tiempo de acarreo en más de 15 minutos por ciclo.

5. Conclusiones

El estudio de investigación demostró que, mediante la implementación de un control efectivo de los tiempos de carguío y acarreo de mineral, así como un adecuado mantenimiento de la vía, se logró una reducción significativa en los costos asociados a estas actividades.

En específico, se obtuvo una disminución de los costos de carguío y acarreo de 2.73 USD/Tm a 2.39 USD/Tm, lo que representa un beneficio económico de 0.34 USD/Tm. Estos resultados respaldan la importancia de un control riguroso de los tiempos de carguío y acarreo, ya que se lograron mejoras significativas en la eficiencia operativa y en la rentabilidad financiera.

Asimismo, se determinó que el control de los tiempos de carga, en particular, contribuyó de manera importante a la reducción de costos. Los costos de carguío mostraron una disminución de 1.69 USD/Tm a 1.49 USD/Tm, generando un beneficio adicional de 0.20 USD/Tm. Esta conclusión evidencia la relevancia de gestionar eficientemente los tiempos de carguío para optimizar los recursos y minimizar los costos asociados.

De igual manera, los controles de tiempo de acarreo y el mantenimiento adecuado de la vía también tuvieron un impacto beneficioso en la reducción de costos. Los costos de acarreo se redujeron de 1.04 USD/Tm a 0.90 USD/Tm, generando un beneficio adicional de 0.14 USD/Tm. Estos resultados resaltan la importancia de mantener la vía en condiciones óptimas, lo que contribuye a una mayor eficiencia en el acarreo y a la reducción de los costos asociados.

Para futuras investigaciones, se sugiere explorar el uso de tecnologías avanzadas en el control de los tiempos de carguío y acarreo, así como en el mantenimiento de vías. Por ejemplo, la implementación de sistemas de monitoreo en tiempo real y análisis de datos podría proporcionar información más precisa y detallada sobre los tiempos de carguío y transporte, permitiendo una gestión aún más eficiente de estos procesos.

Además, podrían investigarse nuevas metodologías y técnicas para el mantenimiento de vías, como el uso de materiales más duraderos o equipos automatizados para la inspección y reparación de la infraestructura. También sería relevante analizar el impacto de estas mejoras en otros aspectos del proceso minero, tales como la seguridad ocupacional y el impacto ambiental.

En resumen, las futuras investigaciones podrían profundizar en la optimización de los procesos de carguío y acarreo, buscando nuevas formas de reducir costos, mejorar la eficiencia y minimizar los impactos negativos.

6. Conflicto de Intereses

Los autores declaran que no tienen conflictos de interés.

7. Referencia

- [1] Anticon, J.Y.; Noriega, E.M.; Cotrina, M.A.; Arango, M.S.M. (2024). Evaluation of Predictive Models for the Optimization of the Cost of Unit Operations in Artisanal Underground Mining. *Mathematical Modelling of Engineering Problems*, 11(4), 2901–2911.
DOI: <https://doi.org/10.18280/mmep.111103>
- [2] Baek, J.; Choi, Y. (2017). A New Method for Haul Road Design in Open-Pit Mines to Support Efficient Truck Haulage Operations. *Applied Sciences*, 7(7), 747.
DOI: <https://doi.org/10.3390/app7070747>
- [3] 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.
DOI: <https://doi.org/10.3390/app10051657>

- [4] Baunier de Melo, W. (2021). Optimization of truck allocation in mines using differential evolution algorithm. *International Journal for Innovation Education and Research*, 9(8), 338–350.
DOI: <https://doi.org/10.31686/ijer.vol9.iss8.3303>
- [5] Cotrina, MA; Araujo, J.J.; Mamani, J.N. et al. (2025). Estimación de recursos minerales mediante cópulas espaciales y aprendizaje automático optimizado con metaheurísticas en un yacimiento de cobre. *Earth Sci Inform*, 18, 514.
DOI: <https://doi.org/10.1007/s12145-025-02009-2>
- [6] Cotrina, MA; Marquina, JJ; Riquelme, Á.I. (2025). Comparación de técnicas de aprendizaje automático para la categorización de recursos minerales en un yacimiento de cobre en Perú. *Nat Resour Res*, 34, 2007–2025.
DOI: <https://doi.org/10.1007/s11053-025-10505-x>
- [7] Cotrina, M.A.; Marquina, J.J. (2025). Hybrid Machine Learning Models for Mineral Resource Classification in a Copper Deposit in Peru. *Math Geosci*.
DOI: <https://doi.org/10.1007/s11004-025-10247-9>
- [8] Cotrina, M.; Marquina, J.; Polo, J. (2025). Prediction of unit haulage cost in an underground mine using machine learning techniques. *Journal of Sustainable Mining*, 24(2), Article 9.
DOI: <https://doi.org/10.46873/2300-3960.1454>
- [9] Cotrina, MA; Marquina, JJ; Mamani, J.N. (2025). Application of artificial neural networks for the categorization of mineral resources in a copper deposit in Peru. *World Journal of Engineering*, ahead-of-print.
DOI: <https://doi.org/10.1108/WJE-01-2025-0004>
- [10] Cotrina, M.A.; Vera, J.K.; Arango, S.M. (2025). An Intelligent Approach to Predicting Dilution, Overbreak and Costs in Underground Mining Using Kolmogorov-Arnold Networks. *Mathematical Modelling of Engineering Problems*, 12(3), 815–828.
DOI: <https://doi.org/10.18280/mmep.120308>
- [11] Cotrina, M.; Marquina, J.; Mamani, J.; Arango, S.; Gonzalez, J.; Noriega, E.; Antonio, E. (2025). Hybrid machine learning techniques to predict fuel consumption of dump trucks in an open-pit mine in Peru. *International Journal of Mining and Mineral Engineering*, 1–20.
DOI: <https://doi.org/10.1504/IJMME.2025.145583>
- [12] Enkhchuluun, B.; Batgerel, B.-O.; Ping, C. (2023). Cycle Time Analysis Mining Dump Trucks. *International Journal of Geosciences*, 14, 689–709.
DOI: <https://doi.org/10.4236/ijg.2023.148037>
- [13] Gu, Q.; Lu, C.; Li, F.; Wan, C. (2008). Monitoring Dispatch Information System of Trucks and Shovels in an Open Pit Based on GIS/GPS/GPRS. *Journal of China University of Mining and Technology*, 18(2), 288–292.
DOI: [https://doi.org/10.1016/S1006-1266\(08\)60061-9](https://doi.org/10.1016/S1006-1266(08)60061-9)
- [14] Huayanca, D.; et al. (2023). Application of Discrete-Event Simulation for Truck Fleet Management in Mining. *Applied Sciences*, 13(7).
DOI: <https://doi.org/10.3390/app13074093>
- [15] Icarte, G.; Riveros Araya, E.; Herzog, O. (2020). An Agent-based System for Truck Dispatching in Open-pit Mines. *ICAART 2020*.
DOI: <https://doi.org/10.5220/0008961800730081>

- [16] Karikari, Y.S.; Askari Nasab, H. (2024). A Comprehensive Simulation Model for Mining Operations: Development, Implementation, and Validation Using HaulSim. *Technical Report*, University of Alberta. DOI: <https://doi.org/10.13140/RG.2.2.33986.08649>
- [17] Kecojevic, V.; Komljenovic, D. (2005). Haul truck cycle-time prediction in open-pit mines using artificial neural networks. *International Journal of Surface Mining, Reclamation and Environment*, 19(1), 1–17. DOI: <https://doi.org/10.1080/13895260500032564>
- [18] Krause, A.; Musingwini, C. (2019). Estimating truck-shovel fleet productivity using discrete-event simulation. *International Journal of Mining, Reclamation and Environment*, 33(5), 299–313. DOI: <https://doi.org/10.1080/17480930.2018.1438522>
- [19] Mandal, S.K.; Dey, S.; Bhar, C. (2018). Analysis of Factors Which Influence the Cycle Time of Dumpers of Open Cast Coal Mines to Improve Production. *Modelling, Measurement and Control C*, 78(3), 289–302. DOI: https://doi.org/10.18280/mmc_c.780303
- [20] Meneses, D.; Sepúlveda, F.D. (2023). Modeling Productivity Reduction and Fuel Consumption in Open-Pit Mining Trucks Considering Road Deterioration. *Mining*, 3(1), 96–105. DOI: <https://doi.org/10.3390/mining3010006>
- [21] Mnzool, M.; Almujiabah, H.; Bakri, M.; Gaafar, A.; Elhassan, A.A.M.; Gomaa, E. (2024). Optimization of cycle time for loading and hauling trucks in open-pit mining. *Mining of Mineral Deposits*, 18(1), 18–26. DOI: <https://doi.org/10.33271/mining18.01.018>
- [22] Pathan, S.M.; et al. (2025). Simulation Optimization of Shovel-Truck System in Open-Pit Mines. *Applied Technology & Research*, 2025. DOI: <https://doi.org/10.1155/atr/7939037>
- [23] Shah, K.S.; Rehman, S.U. (2020). Modeling and Optimization of Truck–Shovel Allocation to Mining Faces in Cement Quarry. *Journal of Mining and Environment*, 11(1), 21–30. DOI: <https://doi.org/10.22044/jme.2019.8329.1712>
- [24] Shakenov, A.; Śładkowski, A.; Stolpovskikh, I. (2022). Haul Road Condition Impact on Tire Life of Mining Dump Truck. *Mining Journal (NVNGU)*, 2022(6), Art. 025. DOI: <https://doi.org/10.33271/nvngu/2022-6/025>
- [25] Simon, V.; Pellerin, R.; Gamache, M. (2025). Predicting Haul Truck Travel Times in Underground Mines. *Mining, Metallurgy & Exploration*, 42(4), 1989–2009. DOI: <https://doi.org/10.1007/s42461-025-01293-2>
- [26] Soofastaei, A.; Aminossadati, S.; Kizil, M.S.; Knights, P. (2015). The Effect of Rolling Resistance on Fuel Consumption and Greenhouse Gas Emissions by Haul Trucks in Surface Mines. *Tribology International*, 92, 222–234. DOI: <https://doi.org/10.1016/j.triboint.2015.06.007>
- [27] Wang, X.; Dai, Q.; Bian, Y.; Zhang, M. (2023). Real-time truck dispatching in open-pit mines. *International Journal of Mining, Reclamation and Environment*, 37(6), 400–420. DOI: <https://doi.org/10.1080/17480930.2023.2201120>

[28] Wang, X.; Dai, Q.; Bian, Y.; Xie, G. (2023). Real-time truck dispatching in open-pit mines. *International Journal of Mining, Reclamation and Environment*, 37(7), 1–20.
DOI: <https://doi.org/10.1080/17480930.2023.2201120>

[29] Zhang, Y.; et Eal. (2022). Determination of Truck–Shovel Configuration of Open-Pit Mines using Simulation and Mathematical Modelling. *Sustainability*, 14(19), 12338.
DOI: <https://doi.org/10.3390/su141912338>