



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA DE MINAS

CARGUÍO DINÁMICO PARA LA OPTIMIZACIÓN DE LA UTILIZACIÓN  
EFECTIVA DE CAMIONES DE MINERÍA A CIELO ABIERTO A ESCALA DE  
LABORATORIO

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL DE MINAS

FELIPE ANDRÉS BARRIOS ORMEÑO

PROFESOR GUÍA:  
MATÍAS PINTO AHUMADA  
PROFESOR CO-GUÍA:  
RICARDO ARIAS VICENCIO

MIEMBROS DE LA COMISIÓN:  
LUIS FELIPE ORELLANA ESPINOZA  
GONZALO MONTES ATENAS

SANTIAGO DE CHILE  
2020

RESUMEN DE LA MEMORIA PARA OPTAR  
AL TITULO DE: Ingeniero Civil de Minas  
POR: Felipe Andrés Barrios Ormeño  
FECHA: 22/07/2010  
PROFESOR GUÍA: Matías Pinto Ahumada

Los derrames de mineral se deben generalmente a eventos de sobredemanda de tonelaje por parte de la planta, a causa del protocolo de carguío utilizado, el cual busca generar un cono de mineral lo más centrado posible en la tolva. Sin embargo, al sobre cargar los camiones siguiendo este protocolo, se corre un alto riesgo de derrame de mineral, y con ello la consecuente merma en la utilización efectiva de la flota de transporte debido a una menor fluidez del circuito, afectando así los ingresos de la operación.

El presente trabajo es un estudio conceptual de un innovador método de carguío, denominado carguío dinámico, el cual tiene por objetivo prevenir la ocurrencia de derrames y así lograr altos estándares de utilización efectiva. Para ello utiliza información brindada por los sensores de los equipos de carguío, además de las características geométricas de la faena, y con ello recomienda cual debe ser la ubicación óptima de la próxima baldada a cargar en el camión, de tal forma que no ocurran derrames y el daño mecánico del equipo sea mínimo.

Para ello inicialmente se modela una mina open pit en el software para simulaciones Promodel con el objetivo de conocer como afectan los derrames a la utilización efectiva. Como resultado, la utilización efectiva resultante para el caso sin derrames es de 78,42%, mientras que para el caso de 1 derrame por cada ciclo de la flota, que en este caso representa el paso de 10 camiones por el circuito, cae en promedio a un 70%, y si se aumenta a 2 derrames por ciclo de flota cae a una utilización efectiva del orden de 66%. Este decremento se debe a las pérdidas operacionales de la flota debida a los derrames en ruta.

Posteriormente se aplican técnicas de Deep learning, utilizando un programa realizado en el lenguaje Python sobre una base de datos de carguío dinámico a escala laboratorio, cuyo input son la ubicación de los pases de carguío y los ángulos de rampa, de reposo del mineral y la gradiente de la carga respecto a la cola de la tolva, además de los esfuerzos sobre la tolva. El objetivo de esto es lograr predecir la ocurrencia de derrames y de daño en el equipo debido al carguío dinámico.

El resultado para la predictibilidad de ocurrencia de derrames es de un 80% de exactitud en la validación, y un tiempo de entrenamiento de 4,45 segundos. Mientras que la predictibilidad para la ocurrencia de daño es de un 80,89% en 4,54 segundos. Concluyendo así que es posible predecir tanto derrames como daño en el camión con la base de datos utilizada.

## Tabla de Contenido

|   |    |
|---|----|
| 1. INTRODUCCIÓN.....                                | 1  |
| 2. PROBLEMÁTICA.....                                | 2  |
| 3. MOTIVACIÓN.....                                  | 2  |
| 4. OBJETIVOS Y ALCANCES .....                       | 3  |
| 4.1. OBJETIVO GENERAL.....                          | 3  |
| 4.2. OBJETIVOS ESPECÍFICOS.....                     | 3  |
| 4.3. ALCANCES.....                                  | 3  |
| 5. MARCO TEÓRICO.....                               | 5  |
| 5.1. OPERACIONES UNITARIAS.....                     | 5  |
| 5.1.1 CARGUÍO .....                                 | 5  |
| 5.1.2 TRANSPORTE .....                              | 5  |
| 5.2. NORMA ASARCO .....                             | 6  |
| 5.3. INDICES OPERACIONALES DE GESTIÓN .....         | 7  |
| 5.4. CARGUÍO TRADICIONAL Y DINÁMICO .....           | 8  |
| 5.4.1. CARGUÍO TRADICIONAL .....                    | 8  |
| 5.4.2 CARGUÍO DINÁMICO .....                        | 8  |
| 5.5. KPI DE CARGA EN LA TOLVA.....                  | 9  |
| 5.5.1. RACK.....                                    | 9  |
| 5.5.2 ROLL.....                                     | 10 |
| 5.5.3 PITCH .....                                   | 10 |
| 5.6. ESTRUCTURA DE LA CARGA.....                    | 11 |
| 5.7. UTILIZACIÓN EFECTIVA.....                      | 12 |
| 5.8. DEEP LEARNING.....                             | 12 |
| 5.8.1 TIPOS DE APRENDIZAJE EN MACHINE LEARNING..... | 12 |
| 5.8.2 UNDERFITTING y OVERFITTING .....              | 14 |
| 5.8.3 VALIDACION.....                               | 17 |
| 5.8.4 VALIDACIÓN ESTÁTICA .....                     | 17 |
| 5.8.5 VALIDACIÓN DINÁMICA.....                      | 18 |
| 5.9 REDES NEURONALES ARTIFICIALES .....             | 19 |
| 5.9.1 PERCEPTRÓN MULTICAPA.....                     | 19 |
| 5.9.2 REDES NEURONALES CONVOLUCIONALES .....        | 21 |
| 5.9.3 REDES NEURONALES RECURRENTE .....             | 24 |
| 5.9.4. FUNCIÓN DE COSTO .....                       | 26 |

|        |  |    |
|--------|--|----|
| 5.9.5  | MÉTODO DEL DESCENSO DEL GRADIENTE .....                        | 26 |
| 5.9.6  | FORWARD PROPAGATION Y BACKPROPAGATION .....                    | 28 |
| 5.9.7. | BATCH y EPOCH .....  | 28 |
| 5.9.8. | MATRIZ DE CONFUSIÓN .....                                      | 29 |
| 6.     | METODOLOGÍA.....   | 32 |
| 6.1.   | CASO BASE.....   | 32 |
| 6.2.   | CASO PROPUESTO .....   | 32 |
| 6.3.   | SIMULACIÓN DE CIRCUITO DE TRANSPORTE DE MINERAL.....           | 32 |
| 6.3.1. | DESCRIPCIÓN.....   | 32 |
| 6.3.2  | ELEMENTOS DE SIMULACIÓN.....                                   | 33 |
| 6.3.3. | PARÁMETROS .....   | 34 |
| 6.3.4  | DESCRIPCIÓN DEL PROCESO.....                                   | 37 |
| 6.3.5  | FÓRMULAS DE CÁLCULO .....                                      | 38 |
| 6.4    | DEEP LEARNING.....   | 41 |
| 6.4.1. | DATASET .....  | 41 |
| 6.4.2. | PROBLEMÁTICA.....  | 43 |
| 6.4.4. | DETERMINACIÓN DE LAS FUNCIONES DE ACTIVACIÓN .....             | 43 |
| 6.4.5. | SELECCIÓN DE FUNCION DE COSTO Y MÉTODO DE OPTIMIZACIÓN .....   | 48 |
| 6.4.6. | DETERMINACIÓN DE LA RED NEURONAL.....                          | 48 |
| 6.5.   | EVALUACIÓN ECONÓMICA.....                                      | 50 |
| 6.5.1. | DESCRIPCIÓN Y PARÁMETROS A UTILIZAR.....                       | 50 |
| 6.5.2. | PRECIO DEL CU .....  | 51 |
| 6.5.3. | PRECIO DE PETROLEO.....  | 51 |
| 6.5.4. | COSTO DE MANTENCIÓN .....                                      | 52 |
| 6.5.5. | COSTO DE NEUMÁTICOS .....                                      | 52 |
| 6.5.6. | VALORES DE INCREMENTOS DE COSTOS .....                         | 52 |
| 7.     | RESULTADOS .....   | 54 |
| 7.1.   | SIMULACIÓN.....  | 54 |
| 7.1.1  | CASO BASE (SIN DERRAMES).....                                  | 54 |
| 7.1.2  | CASO 1 DERRAME POR CICLO DE FLOTA (CADA 10 CAMIONES).....      | 54 |
| 7.1.3. | CASO 2 DERRAMES POR CICLO DE FLOTA EN UNA MISMA ESTACIÓN ..... | 60 |
| 7.1.4  | CASO 2 DERRAMES POR CICLO DE FLOTA EN DISTINTOS LUGARES.....   | 65 |
| 7.2.   | DEEP LEARNING.....   | 75 |
| 7.2.1. | DETERMINACIÓN RED DE PREDICCIÓN DE DERRAMES.....               | 75 |
| 7.2.2. | RED NEURONAL DE PREDICCIÓN DE DAÑO .....                       | 78 |
| 7.3.   | EVALUACIÓN ECONÓMICA.....                                      | 80 |

|   |     |
|---|-----|
| 7.3.1 RESULTADOS CASO BASE .....  | 80  |
| 7.3.2. RESULTADOS PARA PEOR CASO .....                                  | 82  |
| 7.3.3. RESULTADOS PEOR CASO, INCREMENTOS AL 70% .....                   | 83  |
| 7.3.4 RESULTADOS PEOR CASO, PRECIO DEL COBRE 1 USD/lb .....             | 84  |
| 8. ANÁLISIS .....   | 85  |
| 8.1. ANÁLISIS DE SIMULACIÓN .....                                       | 85  |
| 8.2. DEEP LEARNING .....  | 93  |
| 8.2.1. ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 1 CAPA OCULTA .....   | 93  |
| 8.2.2 ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 2 CAPAS OCULTAS .....  | 95  |
| 8.2.3. ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 3 CAPAS OCULTAS ..... | 97  |
| 8.2.4. ANÁLISIS DE PREDICTIBILIDAD DE DAÑO CON 1 CAPA OCULTA .....      | 100 |
| 8.2.5. ANÁLISIS DE PREDICTIBILIDAD DE DAÑO CON 2 CAPAS OCULTAS .....    | 103 |
| 8.3. ANÁLISIS DE EVALUACIÓN ECONÓMICA .....                             | 105 |
| 9. CONCLUSIONES .....   | 107 |
| 10. TRABAJOS FUTUROS .....  | 109 |
| 11. BIBLIOGRAFÍA .....  | 111 |

## 1. INTRODUCCIÓN

La operación de carguío y de transporte representan un gran porcentaje del costo mina en la minería open pit, en torno al 50%, los cuales se pueden dividir en factores tales como desgaste (mecánico, electromecánico, neumáticos) y consumo de insumos (petróleo, lubricantes, etc.).

Es posible reducir los costos generados por estos factores por medio del uso de algoritmos que utilicen los datos que se generan al momento de cargar y transportar. Datos tales como el tonelaje, los esfuerzos sobre las distintas zonas del camión, la pendiente de rampa y particularmente la distribución de la carga en la tolva, que es donde nace la problemática a tratar en este trabajo de título.

Actualmente se sostiene que un carguío correcto debe ser tal que se logre obtener una carga final de forma cónica y lo más cercana posible al centro de la tolva. Esta manera de cargar el camión obedece a que los fabricantes de maquinaria recomiendan dicha metodología con el objetivo de no reducir la vida útil de los componentes.

No obstante, en una operación minera hay ocasiones en las que se debe sobrecargar los camiones, como por ejemplo cuando existe una mayor demanda de mineral por parte de la planta. Esta situación genera que un camión cargado de la manera tradicional, y sometido a las distintas rampas, tenga una mayor probabilidad de derramar mineral que el caso del mismo camión en condiciones normales de operación. Para evitar dichos derrames y así no afectar la fluidez del circuito de transporte, se decide operacionalmente cargar de manera desplazada hacia el frontis de la tolva, siendo este carguío efectuado de una manera totalmente discrecional y sin ningún cálculo asociado que respalde la nueva ubicación de cada baldada, provocando así sobreesfuerzos en el camión, los cuales son indeterminados al momento de tomar la decisión de reubicar los pases de carguío y afectan a posteriori la vida útil del equipo y sus componentes.

La propuesta que se entrega en este trabajo de título es un primer paso en la búsqueda de una solución teórica, basada en el trabajo de laboratorio y simulaciones, que optimice el proceso de carguío, utilizando tecnologías de procesamientos de datos como el deep learning, para posteriormente entregar una herramienta de decisión que permita a la persona que esté a cargo de la operación del equipo de carguío conocer cuál debe ser la posición óptima del pase a cargar. Esto con el objetivo de evitar la ocurrencia de derrames en ruta, sujeto a cumplir las exigencias de la demanda de mineral desde la planta y de minimizar los costos por el daño generado por este tipo de carguío, al cual se le denomina Carguío Dinámico.

Se estima concluir que es posible predecir la ocurrencia de derrames sólo con la posición del balde ante una pendiente dada, además de lograr obtener una correlación matemática entre posición del balde y esfuerzos en las suspensiones. También concluir que la metodología de carguío de los camiones debe estar sujeta a condiciones de operación y variables del momento para optimizar resultados finales, siendo para ello requerida la utilización de técnicas modernas que ayuden a los operadores a cargar los camiones de acuerdo a lo solicitado en el momento.

## **2. PROBLEMÁTICA**

Actualmente el carguío se realiza siguiendo las indicaciones del equipo de mantenimiento, de tal manera que la carga a transportar afecte lo menos posible el sistema de amortiguación del camión y otras componentes. Esto en términos prácticos radica en la formación de un cono, ubicado idealmente al centro de la tolva. Sin embargo, esta alternativa eventualmente provoca problemas de derrames cuando se sobre exige a la flota de transporte, dado que el cono del carguío tradicional derrama hacia la zona trasera de la tolva cuando este supera cierta altura y es sometido a alguna inclinación umbral, la cual alguna de las rampas evidentemente supera.

Los derrames de mineral en la rampa generan costos que están asociados a la decisión operacional frente a estos, la cual puede ser de tres maneras: detener el CAEX y solicitar limpieza de ruta, evadir el derrame, omitir la existencia de este y pasar por arriba. Esta decisión, en los casos segundo y tercero generalmente compete al operador del camión, y se hace en virtud de no afectar la fluidez del circuito de transporte, pero comprometiendo la vida útil de los neumáticos y otros componentes, en desmedro del costo de mantenimiento de la flota. Por otra parte, si el camión se detiene a esperar la limpieza de la ruta, se tendría una merma en cuanto a utilización efectiva de la flota de camiones y a su vez en el rendimiento de la flota.

Dada esta situación, operacionalmente se decide que el carguío sea ubicado preferentemente hacia la zona frontal de la tolva de manera discrecional y sin mediar análisis técnico alguno, provocando con ello una evidente mejora en la fluidez, previniendo derrames, pero sin tener información certera acerca del sobre costo y desgaste al que se somete el camión y sus componentes para tal efecto.

## **3. MOTIVACIÓN**

En las operaciones mineras existe una gran cantidad de datos y variables para la toma de decisiones en tiempo real. Sin embargo, la carencia de algoritmos para poder procesar dichos datos de manera eficiente e inteligente conlleva a la toma de decisiones de manera intuitiva, sin un asidero matemático ni científico.

Con las actuales tecnologías de procesamiento de datos como Deep learning; de visualización de datos como la realidad aumentada; el uso de digital twins para la interacción virtual en distintos tipos de actividades, además de los avances en el área de la inteligencia artificial, generan la posibilidad de dar un uso más acabado y profundo a la información actualmente disponible las operaciones mineras, principalmente la proveniente de los equipos en las distintas operaciones unitarias.

Es por esto que el presente trabajo busca ser un acercamiento preliminar al uso de tecnología de procesamiento de datos aplicado específicamente al proceso de carguío de camiones mineros en operaciones a cielo abierto, enfocado hacia un contexto de optimización global del circuito, el cual está sujeto a decisiones multivariadas.

A pesar de lo simple que es el proceso de carguío, hoy en día no existe una claridad técnico-económica respecto a la posibilidad de generar un procedimiento de operación dinámico que sea consistente con la realidad operativa del momento. Debido a esto, el presente trabajo de título se

presenta como un primer paso en miras de desarrollar una herramienta que permita a futuro definir el balance entre los resultados operacionales y el manejo eficiente de las variables del mantenimiento de los equipos de transporte en tiempo real, para así permitir un carguío que se adapte de mejor manera a las necesidades de la operación.

## **4. OBJETIVOS Y ALCANCES**

### **4.1. OBJETIVO GENERAL**

Crear una metodología de toma de decisiones dinámicas y en tiempo real relacionando el carguío eficiente de los camiones con la realidad operacional de la mina.

### **4.2. OBJETIVOS ESPECÍFICOS**

- Cuantificar el impacto de los derrames en la ruta en relación a la utilización efectiva de una flota de camiones.
- Demostrar que es posible predecir la ocurrencia de derrames de mineral con solo conocer el ángulo máximo de rampa, la posición de la baldada y el ángulo de reposo del mineral.
- Demostrar que es posible predecir la ocurrencia de daño en la estructura y/o componentes del camión solo conociendo la posición de la baldada y peso de la baldada.
- Demostrar escenarios donde el carguío de camiones puede afectar los resultados finales de la operación por impactos en la utilización efectiva sujeto a valores de ley y cumplimiento del programa.
- Demostrar como el costo de oportunidad puede derribar paradigmas entorno a un eficiente carguío de los camiones.

### **4.3. ALCANCES**

El alcance de este trabajo de título comprende lo siguiente:

Una operación simulada de minería a cielo abierto con las siguientes características:

- Flota de 10 camiones de 150 toneladas.
- 5 estaciones que son interpretadas como puntos de derrame para la simulación en el software Promodel y luego como una representación de una rampa a una pendiente dada en el modelo de Deep Learning.
- 2 equipos de apoyo cuya base se encuentra cercana al frente de carguío, y que posterior a la limpieza de la ruta vuelven a dicha base.

- Ruta total de transporte de 10 Km, donde son 5 Km son de ida y 5 Km de vuelta. En la ruta de ida se consideran 5 estaciones: a 100 m, 400 m, 900 m, 1.9 Km, 3.4 Km.
- Las operaciones unitarias involucradas son el carguío y el transporte de mineral a planta.

Además, comprende el uso de datos brindados por el profesor guía los cuales corresponden a diversos experimentos de carguío de un camión a escala 1:14. Este camión es cargado siguiendo distintas configuraciones o posiciones de cada baldada respecto al plano horizontal de la tolva. Dicha información se compone por la ubicación individual de 3 baldadas, los esfuerzos en los lados derecho e izquierdo del camión y el ángulo formado por el extremo trasero de la tolva y el punto más alto del cono de carguío. Posteriormente se complementa con los valores asociados a las pendientes de las rampas y así entregar un valor binario, verdadero si cumple con los requisitos de derrame de mineral o falso en caso contrario (1 y 0). La base de datos utilizada es brindada por el profesor guía.

Otras configuraciones de camiones, equipos de apoyo, largos de ruta, distancia entre estaciones o ángulos de rampa no son consideradas.

Cabe destacar que la investigación se realiza dentro de un marco de análisis teórico de variables dentro del aspecto minero del tema tales como: frecuencia de derrame, ángulo de rampa, distancia de ocurrencia de derrame y esfuerzos sobre el camión; mientras que en el aspecto de redes neuronales artificiales se estudian variables tales como: cantidad de neuronas por capa, funciones de activación neuronal, cantidad de épocas y tamaño de batch. Algunas de estas variables están restringidas a la disponibilidad de data que se obtuvo de laboratorio, como por ejemplo el uso de solo 2 celdas de cargas para medir el esfuerzo sobre el camión en vez de las 4 necesarias y el uso de solo un tipo de material para el carguío.

La evaluación económica se realiza en base a las variables consideradas relevantes para la operación como son la ley de cobre, precio del cobre, precio del petróleo, costo de neumáticos y costo de mantenimiento. Además, se incorporan valores incrementales asociados al daño generado al camión debido al carguío dinámico, tanto en neumáticos como en la estructura del camión; además de incremento en el consumo de petróleo debido a la detención y posterior arranque del camión ante la ocurrencia de algún derrame en la ruta. Todos estos incrementos son valores meramente conceptuales y decididos de forma arbitraria. Otros costos asociados a la operación no se incluyen. Por ejemplo, no se incluye el costo de insumos indirectos (aceite, agua, etc.) o más puntuales como costo real de suspensiones, costo de reposición de partes, etc.

## 5. MARCO TEÓRICO

### 5.1. OPERACIONES UNITARIAS

Las operaciones unitarias a tratar en este apartado son las que están enmarcadas en el alcance de este trabajo, es decir el carguío y el transporte.

#### 5.1.1 CARGUÍO

Consiste en la operación de extracción de material, sea mineral o estéril, por medio de equipos mecánicos o electromecánicos denominados palas, los cuales poseen un balde metálico cuyo volumen va en relación a la demanda de mineral que requiera la operación, el cual posee dientes metálicos que cumplen la función de romper la frente de carguío la cual, agrietada y debilitada por el efecto de la tronadura, cede soltando material. Este último es atrapado por el balde, para luego ser depositado en la tolva de un camión por medio de una palada o pase, y luego repetir el proceso hasta llenar dicha tolva, para finalmente transportar el material a planta, botadero, o stock pile según sea el caso.

#### 5.1.2 TRANSPORTE

Es la operación unitaria consistente en el movimiento del material, sea este mineral o estéril, desde una posición de carguío dentro de la faena minera, a una ubicación designada para la descarga, la cual generalmente es el chancador primario en el caso del mineral y el botadero en el caso del estéril.

Esta operación debe realizarse dentro de un rango de tiempo llamado tiempo de ciclo, el cual debe ser lo más cercano posible al utilizado en la etapa del diseño de flota, para así ir en consonancia con las metas establecidas en corto, mediano y largo plazo.

El ciclo de transporte recién mencionado es posible dividirlo en distintas etapas:

$$T_{ciclo}[\text{min}] = TC + TVC + TD + TVV + TA + TD$$

Donde:

|           |   |
|-----------|---|
| TC [min]  | = Tiempo de carguío del camión por parte de la pala   |
| TVC [min] | = Tiempo de viaje cargado a chancador.  |
| TD [min]  | = Tiempo de descarga en chancador   |
| TVV [min] | = Tiempo de viaje vacío a la frente de carguío.   |
| TA [min]  | = Tiempo de aculatamiento, tanto en carguío como en chancado                                |
| TD [min]  | = Tiempo de demora. Hace referencia al tiempo perdido en esperas en colas o en imprevistos. |

El tiempo de demora idealmente debe ser cero para maximizar la utilización de la flota y tener un mayor volumen de viajes, pero en la práctica esto no sucede. Es por esto que se deben implementar

alternativas que busquen minimizar dicho factor, tal como ocurre con la propuesta del presente trabajo.

## 5.2. NORMA ASARCO

La norma ASARCO (American Smelting and Refining Co.) es la referencia que se utiliza en gran parte de la minería para establecer la distribución de tiempos que ocurren en toda operación y maquinaria involucrada en ella, para así obtener indicadores que darán a conocer los distintos desempeños de las flotas de equipos, facilitando así en gran parte la toma de decisiones gerenciales y operacionales.

Esta norma clasifica y describe en detalle cada uno de los estatus en que se encuentran los equipos en operación durante un período determinado de tiempo.

|            |                      |                         |                                |
|------------|----------------------|-------------------------|--------------------------------|
| Nominal    |                      |                         |                                |
| Disponible |                      |                         | No disponible<br>Mantenimiento |
| Operativo  |                      |                         | Reserva                        |
| Efectivo   | Demora<br>Programada | Demora No<br>Programada | Pérdidas<br>Operacionales      |

Tabla 5-1: Diagrama de distribución de tiempo según norma ASARCO

Tiempo Nominal (TN): Corresponde a las 24 horas del día donde el equipo está en faena.

Tiempo Disponible (TD): Es el tiempo donde el equipo está electromecánicamente operativo y dispuesto para trabajar.

Tiempo No disponible / Mantenimiento (TM): Es donde el equipo se encuentra sometido a mantenimiento preventivo y/o correctivo.

Tiempo Operativo (TO): Es el tiempo que el equipo se encuentra en condiciones de operar y con un operador asignado.

Tiempo de Reserva (TR): Tiempo donde el equipo está en condiciones de operar, pero hay superávit de equipos operando o hay déficit de operadores para asignar.

Tiempo Efectivo (TE): Es el tiempo donde el equipo está desempeñando las funciones para la cual fue fabricado.

Demora Programada (DP): Es el tiempo donde el equipo está en condiciones de operar, con operador asignado, pero este está en el horario de colación o en cambio de turno.

Demora no programada (DNP): Es el tiempo donde el equipo está en condiciones de operar, con operador asignado, pero las condiciones o circunstancias actuales no hacen posible que se ejecute el trabajo. Son demoras de las cuales no hay certeza de su duración.

Pérdidas operacionales (PO): Son los tiempos donde el equipo se encuentra en espera mientras está ejecutando su trabajo. Ejemplos de esto son demoras en la cola de la pala, demoras en la cola de chancado, etc.

### 5.3. INDICES OPERACIONALES DE GESTIÓN

Los índices operacionales fundamentales para el presente trabajo son los siguientes:

Disponibilidad Mecánica: Es la fracción del tiempo nominal que el equipo está en condiciones electromecánicas para operar, tanto haya o no un operador disponible para el equipo.

$$DM [\%] = 100 \times \frac{\textit{Tiempo Disponible}}{\textit{Tiempo Nominal}}$$

Utilización (UT): Es la fracción del tiempo disponible donde el equipo está con operador y puede desempeñarse en las tareas encomendadas.

$$UT [\%] = 100 \times \frac{\textit{Tiempo Operativo}}{\textit{Tiempo Disponible}}$$

Utilización Efectiva en base a disponibilidad (UEBD, o UE): Es la fracción del tiempo disponible donde el equipo se está desempeñando en las tareas para las cuales fue diseñado. Es por esto mismo que se considera el tiempo efectivo y no las demoras ni pérdidas operacionales. En el presente trabajo se hará referencia a este concepto como UE.

$$UE [\%] = 100 \times \frac{\textit{Tiempo Efectivo}}{\textit{Tiempo Disponible}}$$

Porcentaje de Pérdidas operacionales: Es la fracción de tiempo disponible en la cual el equipo debería estar desempeñándose en las labores para las cuales fue diseñado, y sin embargo está esperando en cola mientras se desarrolla uno o varios procesos, para después poder continuar con su labor normal.

$$PO\% [\%] = 100 \times \frac{\textit{Pérdidas Operacionales}}{\textit{Tiempo Disponible}}$$

En virtud de lo antes señalado, en este trabajo de título se busca gestionar de mejor manera la utilización efectiva de la flota de camiones, específicamente a través de la prevención de la ocurrencia de derrames en rampa, los cuales provocan pérdidas operacionales en caso de que los camiones que enfrenten el derrame se detengan a la espera de la limpieza de la ruta.

Estos derrames afectan directamente a la utilización efectiva de la flota, debido al incremento en las pérdidas operacionales ya mencionado. Por ello es importante aplicar medidas de prevención de derrames, como un estilo de carguío que permita realizar una mejor gestión de la utilización efectiva al evitar este tipo de pérdidas operacionales.

## **5.4. CARGUÍO TRADICIONAL Y DINÁMICO**

### **5.4.1. CARGUÍO TRADICIONAL**

Se define como carguío tradicional el que se realiza normalmente en las faenas a rajo abierto, el cual es el recomendado tanto por los equipos de mantenimiento de cada operación, como por los fabricantes y algunos autores. Este consiste en lograr, luego de los pases necesarios para llenar la tolva, un cono de material lo más centrado posible, de tal forma que los esfuerzos se distribuyan de una manera que no perjudiquen la infraestructura del camión ni sus componentes. Así, los fabricantes de camiones y las empresas de neumáticos recomiendan llenar los camiones de tal forma que la carga quede balanceada entre los dos ejes (delantero y trasero), para así no afectar las componentes mecánicas del camión, como a su vez la vida útil de los neumáticos, y evitar futuras fracturas en la estructura (Chamanara, 2013). Que la carga esté balanceada significa que el eje delantero debe soportar un 33,33% del peso total del camión y el eje trasero un 66,7% (Henze, 2015).

Sin embargo, los autores no consideran las exigencias operacionales las cuales pueden involucran el someter el camión a sobrecarga, provocando muchas veces derrames de mineral (Bonzi, 2016), los cuales son “limpiados” o extraídos de ruta por parte de los equipos de apoyo en el plazo más breve posible, con el objetivo de que no dañen los neumáticos de los camiones que vienen posteriormente, en caso que estos no se percaten u omitan la existencia de estos derrames en ruta.

Cabe señalar que, al momento de ejecutar la limpieza, el mineral derramado no se recupera. Es decir, el derrame no se vuelve a incorporar a la explotación, representando una fuga de ingresos, no considerada. Así mismo se debe tener en cuenta que la operación de limpieza provoca una pérdida de fluidez del circuito, provocando colas y con ello pérdidas operacionales y decremento de la utilización efectiva de la flota.

Operacionalmente, para evitar los derrames se decide ubicar la carga hacia la parte delantera del camión, sin ningún criterio matemático ni científico asociado, lo que en la literatura se considera como un error a corregir, puesto que afecta a la estructura y los componentes del camión, y con ello prescindiendo así de un potencial valor agregado al carguío, al incluir el componente operacional en el análisis. Ante esta disyuntiva aparece el concepto de carguío dinámico, el cual puede entregar ciertas directrices de como sobrellevar y/o evitar la urgencia operacional de los derrames de una manera tal que el daño sea calculado y acotado.

### **5.4.2 CARGUÍO DINÁMICO**

Se define como carguío dinámico, a una propuesta innovadora de técnica de carguío la cual involucra el conocimiento de antemano de una serie de datos, como por ejemplo la situación

electromecánica del camión, la condición de sus neumáticos, el tipo de mineral a cargar, el peso del mineral a cargar y las condiciones geométricas y ambientales de la faena (clima, tipo de suelo, presencia de barro, etc.).

Con esta información, y por medio de un algoritmo de procesamiento de datos, se entregan recomendaciones de la ubicación respecto a la tolva de la próxima palada a cargar, de tal forma que operador de la pala distribuya los pases con el objetivo de evitar así la ocurrencia de derrames, y al mismo tiempo minimizar los costos asociados al daño provocado a la infraestructura del camión por causa de este tipo de carguío.

Para ello se utiliza la información online que entregan los distintos sensores a los que se tiene acceso en la operación, lo cual por medio de un dispositivo y un software asociado permite al operador de la pala, o a una pala autónoma, conocer la posición exacta donde se debe depositar el próximo pase para así cumplir con la función objetivo mencionada en el párrafo anterior, y obtener con ello una mayor fluidez del circuito a un costo óptimamente mínimo.

## **5.5. KPI DE CARGA EN LA TOLVA**

Los indicadores clave de rendimiento (KPI) para el posicionamiento de la carga en la tolva son denominados Rack, Roll y Pitch, los cuales se utilizan indicadores de detección temprana ante posibles desempeños no satisfactorios. (Chamanara, 2013)

### **5.5.1. RACK**

Rack describe la fuerza de torsión ejercida sobre el equipo, la cual aplicada constantemente en las estructuras de los camiones provocan grietas y las repeticiones potenciales pueden disminuir la vida útil del equipo, siendo una causa importante de la rotura prematura de componentes y del chasis. Se calcula de la siguiente manera

$$RACK = (LF + RR) - (RF + LR)$$

Siendo:

RF: Esfuerzo medido en el puntal delantero derecho del camión

LF: Esfuerzo medido en el puntal delantero izquierdo del camión

LR: Esfuerzo medido en el puntal trasero izquierdo del camión

RR: Esfuerzo medido en el puntal trasero derecho del camión

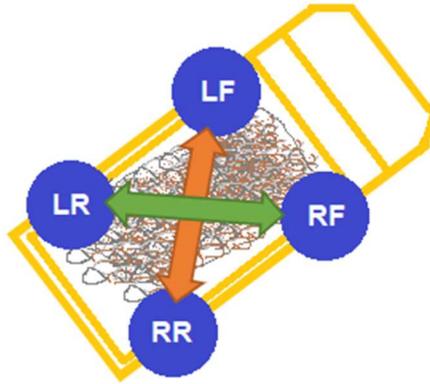


Imagen 5-1: Esquema de cálculo del indicador Rack

### 5.5.2 ROLL

El Roll se entiende como la diferencia entre las sumas de las suspensiones del lado derecho por la suma de las suspensiones del lado izquierdo. Este indicador refleja directamente el posicionamiento de las cargas debido a la comparación entre los lados. Por lo tanto, como debe buscar cargas centralizadas, se espera que los valores de esta KPI en cada ciclo de transporte sean nulos o cercanos a cero.

$$ROLL = (LF + LR) - (RF + RR)$$

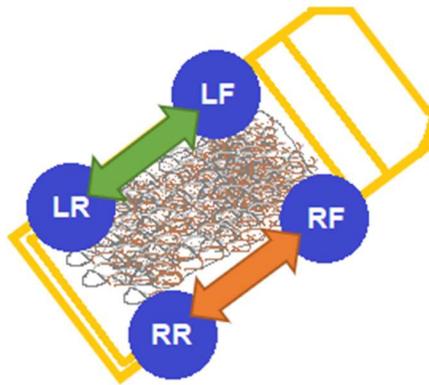


Imagen 5-2: Esquema de cálculo del indicador Roll

### 5.5.3 PITCH

El Pitch se define como el movimiento longitudinal del camión, el cual se calcula:

$$PITCH = (LF + RF) - (LR + RR)$$

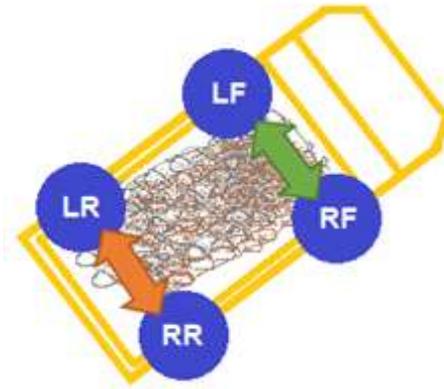


Imagen 5-3: Esquema de cálculo del indicador Pitch

En virtud que la carga sea distribuida de manera equitativa en todos los neumáticos (1/6 de carga por neumático), la carga debe dividirse en 1/3 de ella para el eje delantero y 2/3 para el eje trasero. Sin embargo, dicha proporción podría cambiar en caso que la carga útil no esté equilibrada. Esto ocurre generalmente debido a sobrecargas en la parte delantera o frontal, llegando al punto que en ocasiones se utiliza la cubierta en la parte delantera del camión, por error, para soportar una sobrecarga. Sobrecargas en la parte trasera son menos probables debido a que el material en la parte posterior tiene mayor probabilidad de caer del camión en movimiento. (Henze, 2015)

Sin embargo, el uso de la carga frontal excesiva acorta la vida útil de los neumáticos, llantas y el tren delantero en general. Siendo este el principal trade off a considerar al momento de proponer un método de carguío que escape de la búsqueda del equilibrio en la distribución de esfuerzos, orientado a un mejor desempeño operacional y considerando diversas variables de la faena y del equipo a cargar, al momento de realizar el carguío. (Chamanara, 2013)

## 5.6. ESTRUCTURA DE LA CARGA

Según el trabajo de Chamanara, la estructura de la carga a transportar debe ser cónica e idealmente coincidir el centroide del cono de la carga con el centroide de carga de diseño del equipo, pues dado que actualmente las cargas a transportar son de grandes dimensiones, cualquier pequeña diferencia provoca daño en el camión, acortando la vida útil de este. (Chamanara, 2013)

Sin embargo, posteriormente Henze (Henze, 2015) determina que la carga no es necesariamente cónica. Por lo tanto, rara vez su centroide estaría alineado con el vértice superior de la carga. Dado esto debió desarrollar un algoritmo que permitiese conocer un aproximado de la forma final de la carga y un algoritmo de búsqueda de vértices por medio de análisis de imágenes, para así dar con una forma más exacta de la carga final.

Para efectos de este trabajo, cuando se mencione carguío tradicional se asumirá que se intenta cargar de manera cónica, sin necesariamente serlo. Mientras que para el carguío dinámico se asumirá un estilo de carga no cónico, buscando optimizar la ubicación en vista de prevenir derrames.

## **5.7. UTILIZACIÓN EFECTIVA**

La gestión de la utilidad efectiva es algo de suma importancia dentro de toda faena minera, pues a un mejor rendimiento de este indicador, implica un mejor desempeño operacional y mayor aprovechamiento del capital invertido en el equipo.

En el caso del transporte de mineral, una de las causas que provoca mayores pérdidas operacionales, y con ello una deficiencia en la utilización efectiva son los derrames de mineral. Esto debido a que dichos derrames de mineral deben ser removidos de la ruta, para así no provocar daños a los neumáticos que pasen por sobre estos, ni mayor desgaste a estos al tratar de esquivarlos con maniobras. La pérdida operacional que provocan según Bonzi es de amplio rango, va del orden de 1,5 minutos hasta los 25 minutos solo para ejecutar la limpieza (Bonzi, 2016)

Lo que Bonzi no considera es como influyen estos derrames finalmente a la flota completa, ni tampoco un sistema de carguío que permita prevenir este fenómeno, pues lo que aconseja en su tesis es que los paleros tengan mayor precaución en la ubicación de las baldadas al momento de cargar, evitar la mala estivación de carga y a su vez evitar la sobrecarga de los camiones. Sin embargo, una de las premisas de este trabajo es que la metodología de carguío dinámico se adapte a la operación, incluyendo eventos de sobrecarga de mineral a planta.

## **5.8. DEEP LEARNING**

Deep Learning o aprendizaje profundo es un sub campo del machine learning o aprendizaje de máquina, cuyos algoritmos están inspirados en la estructura cerebral, lo que se conoce como redes neuronales artificiales. Se diferencia del machine learning principalmente por la profundidad de la red neuronal, la cual se asocia principalmente a la cantidad de datos de entrada disponibles y a la infraestructura computacional utilizada. Estos dos requisitos son importantes, debido a que sin la cantidad suficiente de datos es difícil lograr un modelo satisfactorio, en caso que este modelo sea orientado a resolver problemas complejos que requieran un alto grado de abstracción en la información; y así mismo, al incrementar la complejidad del modelo, la maquinaria computacional necesaria debe tener cada vez mayor capacidad y potencia.

Al ser el deep learning un subcampo del machine learning, comparten los mismos conceptos y bases, las cuales se muestran a continuación.

### **5.8.1 TIPOS DE APRENDIZAJE EN MACHINE LEARNING**

Machine Learning o aprendizaje automático, es la rama del campo de la inteligencia artificial que investiga la manera de dotar a las máquinas la capacidad de aprendizaje. En este aprendizaje, el conocimiento adquirido por la máquina proviene de un conjunto de experiencias a las cuales se somete a la máquina o por datos externos de experiencias anteriores.

Dentro del aprendizaje automático es posible encontrar 3 tipos: el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje reforzado.

El aprendizaje supervisado se caracteriza por disponer de información estructurada de entrada y de salida, cuyo objetivo es determinar las relaciones entre los datos de entrada y los de salida utilizando alguna técnica apropiada y así obtener una función que permita determinar una relación con cierto grado de precisión entre dichas variables y su respectivo resultado. Dentro de este grupo es posible encontrar técnicas tales como los árboles de decisión, las redes neuronales artificiales, naive Bayes. En este capítulo se profundizará la información respecto al aprendizaje supervisado, y muy en particular respecto a las redes neuronales artificiales, que fue la herramienta utilizada en este trabajo de título.

Por otra parte, el aprendizaje no supervisado tiene por objetivo inferir la naturaleza de los datos de entrada, determinando patrones y características del conjunto de estos. Es muy útil en el análisis exploratorio de los datos, pudiendo identificar su estructura. Por ejemplo, puede identificar tendencias en una base de datos de consumidores en una casa comercial, pudiendo inclusive segmentar a los usuarios con métodos de agrupamiento. Con ello se haría más fácil orientar bien una inversión en marketing para dicha empresa.

Mientras que en el aprendizaje reforzado la máquina tiene por objetivo maximizar una función de recompensa, para lo cual la máquina debe experimentar de manera iterativa que acciones tomar ante un entorno al que es sometida, de tal manera de lograr dicha maximización. Así la máquina va mapeando en su sistema un conjunto de situaciones vividas (experiencias) y otro de acciones tomadas, y esto a su vez asociado a la existencia o no de recompensa. Este método de aprendizaje es ideal para funciones donde se requiera interactividad de la máquina ante situaciones futuras inexploradas por ella, con cierto grado de aleatoriedad y de carácter multivariable, como es el caso del trabajo en los automóviles autónomos, por mencionar un ejemplo.

Ahora se profundizará en el concepto del aprendizaje supervisado y algunos tópicos asociados a este como son las redes neuronales artificiales, el deep learning, el underfitting y el overfitting.

## APRENDIZAJE SUPERVISADO

Es aquel tipo de aprendizaje donde a la máquina se le hace entrega de un conjunto de datos tabulados de entrada y de salida, los cuales se dividen principalmente en dos sub conjuntos estrictos, uno de datos de entrenamiento y otro sub conjunto de datos de prueba.

La tarea de la máquina en este caso consiste en encontrar una función que relacione a las variables de entrada de cada caso tabulado del conjunto de entrenamiento, de tal forma que el resultado de dicha función coincida con el resultado entregado en la base de datos. Según sea el resultado buscado este modelo puede relacionarse a un problema de regresión, cuyo resultado sería numérico, o estar relacionado a un problema de clasificación, cuyo resultado sería una etiqueta de clase. Un ejemplo de un problema de regresión es generar el pronóstico del clima de un día futuro siguiendo información de los sensores meteorológicos, mientras que un problema de clasificación se puede ejemplificar en el reconocimiento de una imagen de un perro o un gato y que la máquina sea capaz de categorizar cada imagen como tal.

En el caso de que se trate de un problema de regresión, que es donde se enfoca este trabajo de título, se tiene un set de datos  $X$ , que puede ser representado por un vector de lo que se conoce como características, o los datos de entrada. Por ejemplo, en una fruta puede ser el color, la dulzura, la suavidad, etc. Así el set de características es  $X = \{X_1, X_2, X_3, \dots X_n\}$ .

Por otro lado, se tiene un conjunto de etiquetas, que para efectos del ejemplo revelará si la fruta está en óptimas condiciones para su consumo, o aún requiere maduración, a la que se asignarán los valores 1 y 0 respectivamente. A este conjunto se le denominará  $Y = \{1,0\}$ .

Con esto es posible definir el conjunto de datos de entrenamiento  $S$  como el conjunto finito de pares en  $X \times Y$  tal que  $S = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_m, Y_m)\}$ , con  $X = \{X_1, X_2, X_3, \dots, X_n\}$ . Al sistema se le pide una regla de predicción, la cual es en este caso la función  $h: X \rightarrow Y$ , esta función se le llama predictor, o hipótesis, o clasificador. Esta hipótesis será usada para predecir nuevas etiquetas para futuros sets de características, para eso se denomina  $A(S)$  a la hipótesis entregada por el algoritmo de aprendizaje  $A$ , utilizando el set de datos  $S$ .

El set de datos  $X$  se asume que es generado por una distribución de probabilidad  $D$ , la cual se desconoce, luego se asume la existencia de una función correcta de etiquetado,  $f: X \rightarrow Y$ , tal que

$$f(X_{i1}, X_{i2}, X_{i3}, \dots, X_{in}) = Y_i, \forall i \in \{1, 2, 3, \dots, m\}$$

Siendo la función  $f$  desconocida para el algoritmo.

Sin embargo, este modelo está sujeto a errores, los cuales se manifiestan al comparar para todo  $x$  aleatorio en  $X$ , la función  $h(x)$  con la función  $f(x)$ . Cuando estas funciones tienen resultados diferentes para el mismo valor de argumento, se está en presencia de un error de generalización. Este error puede provenir de dos fuentes, el primero atribuible a un entrenamiento deficiente el cual entrega una baja precisión en la etapa de entrenamiento (underfitting), y otro error que proviene de la etapa de prueba del modelo con el conjunto de datos de prueba por un sobreajuste de la función a los datos de entrenamiento (overfitting).

### 5.8.2 UNDERFITTING y OVERFITTING

Dentro de los algoritmos de aprendizaje supervisado puede ocurrir que exista un ajuste deficiente respecto a los datos de entrenamiento, o underfitting, lo que se traduce en un modelo con poca precisión tanto en los datos de entrenamiento como también en los datos del conjunto de prueba.

Una de las causas del underfitting es la consideración de un modelo deficiente o demasiado simple para el conjunto de datos a modelar. Por ejemplo, tratar de modelar con una regresión lineal un conjunto de datos que siguen un patrón parabólico.

Otra causa es desarrollar el entrenamiento con información incompleta, como el caso en que los datos sean de la forma  $ax + by = z$ , pero se trabaje con datos del tipo  $ax = z$ .

Otra causa de underfitting es no tener suficientes características relevantes de entrada, para ello se debe generar un mayor número de estas con la información que se conozca del modelo, o aplicando funciones sobre las características que ya se conocen.

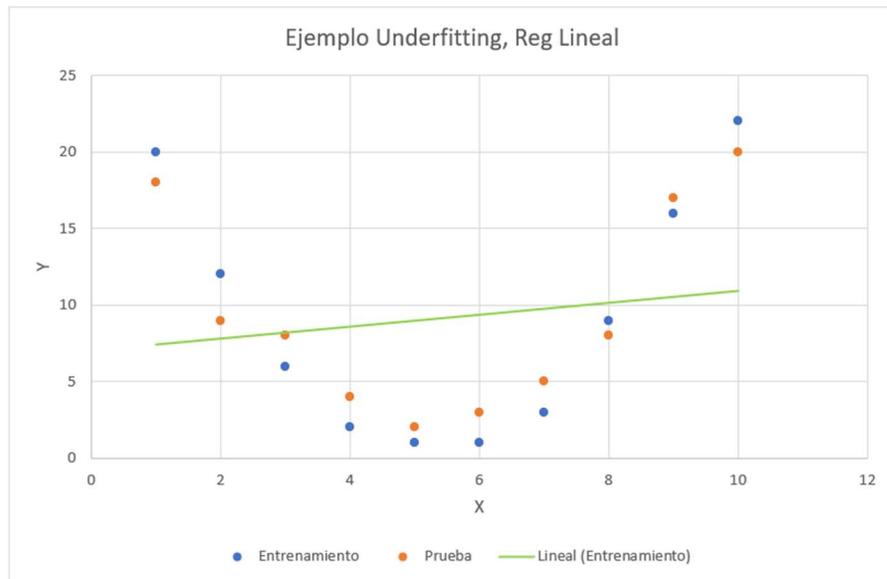


Gráfico 5-1: Underfitting debido al uso de un modelo demasiado simple para los datos a modelar

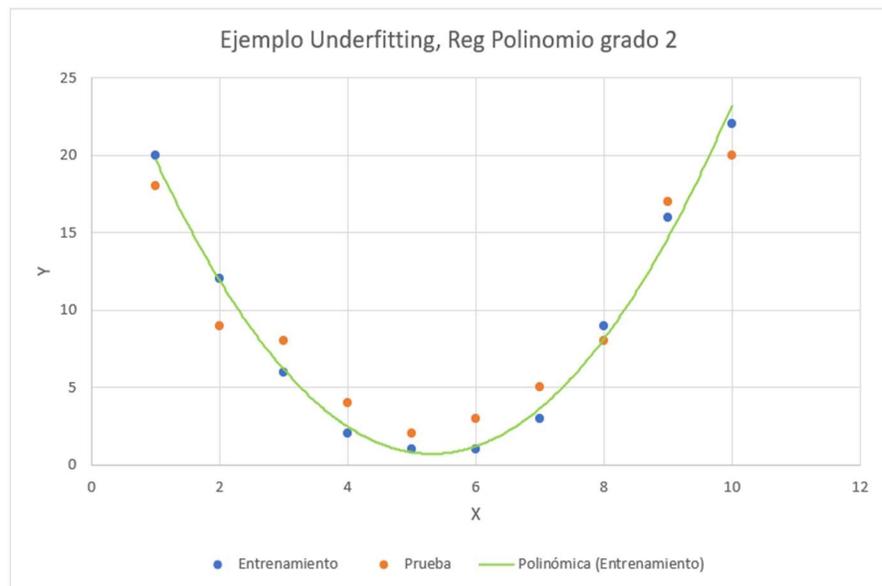


Gráfico 5-2: Solución al underfitting, complejizar el modelo aumentando de grado el polinomio.

Por el contrario, puede ocurrir también que exista lo que se conoce como overfitting o sobreajuste. Esto es una suerte de “memorización” de los datos de prueba por parte de la máquina, de tal forma que se hace imprecisa al leer nueva información. Ocurre cuando el modelo utilizado es demasiado complejo para el conjunto de datos a entrenar. Por ejemplo, el uso de un polinomio para determinar la función de hipótesis puede derivar en el uso de un polinomio de grado alto, dado que será atractiva su alta precisión con los datos de entrenamiento. Sin embargo, una vez pasada a la etapa de prueba esta precisión cae abruptamente. Esta es una señal clara de la presencia de sobreajuste, para lo cual se debe, en este ejemplo, bajar el grado del polinomio usado.

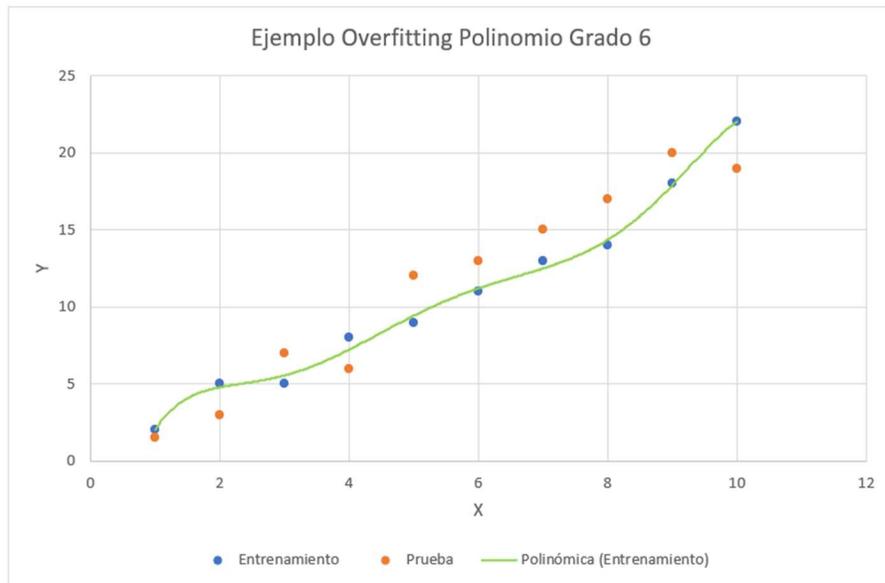


Gráfico 9-3: Sobreajuste u overfitting por uso de un modelo más complejo que lo necesario

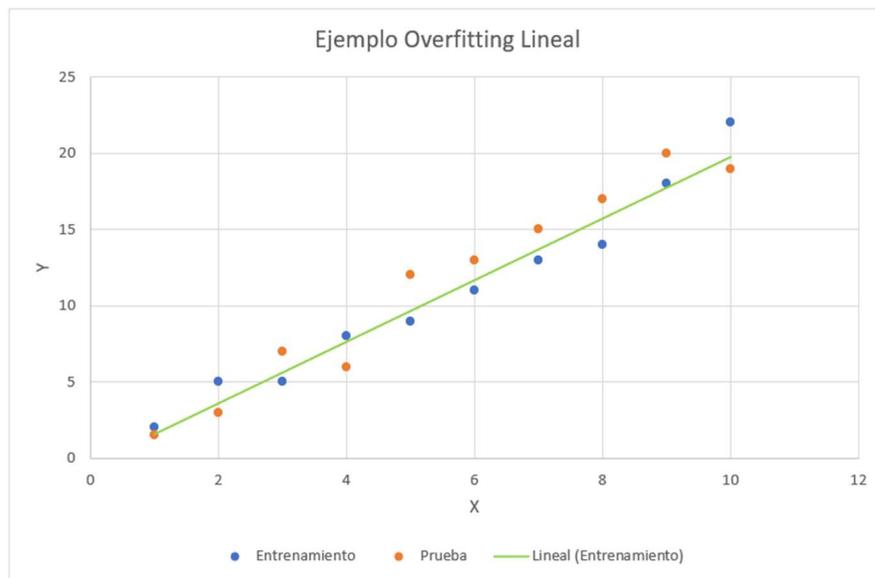


Gráfico 9-4: La generación de un modelo más simple evita problemas de overfitting

En el presente trabajo se trabaja con los gráficos de la función de costo, donde es claro apreciar el overfitting de una función de costo, al sobre ajustarse a los datos de entrenamiento, generando mejores predicciones con esos datos, es decir un error cada vez menor, mientras que para los datos de validación el error llega a un valor mínimo, dependiendo de la configuración de los parámetros (capas neuronales, número de neuronas por capa, funciones de activación) y de los hiperparámetros (batch y epochs) conceptos que se tratan igualmente en este capítulo. El siguiente gráfico enseña esta diferencia cada vez más amplia entre el valor de la función de coste de entrenamiento y de validación de una red.

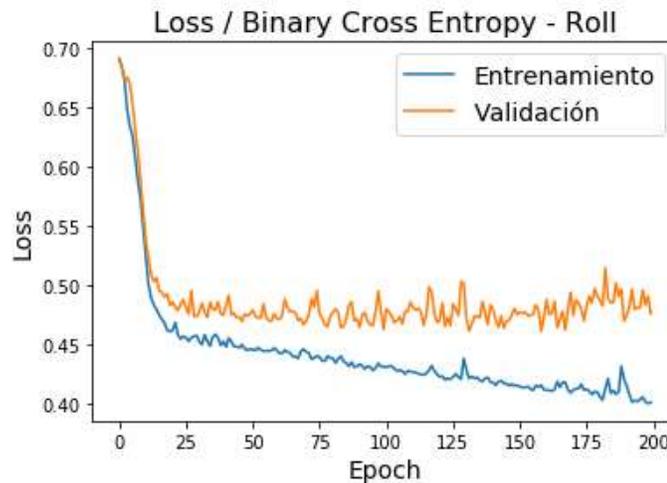


Gráfico 9-5: Overfitting entre las funciones de coste de entrenamiento y validación

La técnica generalmente utilizada para controlar el problema del error por overfitting es la validación cruzada, o cross validation en inglés.

### 5.8.3 VALIDACION

La validación, en aspectos generales, es la técnica de verificar la precisión del entrenamiento en una etapa previa al proceso de probar el modelo con los datos de test de la partición inicial en un algoritmo de aprendizaje supervisado.

Esta técnica consiste en dividir y reservar un segmento fijo de los datos de entrenamiento, para luego proceder a entrenar con la información restante y así posteriormente utilizar este segmento reservado en la etapa de validación de la función de hipótesis. Es importante esta división estricta pues de lo contrario, es decir al existir datos destinados a validación dentro del entrenamiento, podría ocurrir sesgo y la precisión entregada no sería real. Por lo tanto, los datos de validación se asumen como información nueva, que no ha sido procesada en el entrenamiento, por lo que se compara las etiquetas de estos datos de validación con las etiquetas que entrega la función de hipótesis para estas nuevas características, obteniendo así la precisión de la validación según qué porcentaje de aciertos se obtenga.

Dentro de los métodos de validación hay dos grandes grupos, los métodos estáticos y los métodos dinámicos o cruzados.

### 5.8.4 VALIDACIÓN ESTÁTICA

Los métodos estáticos son aquellos que realizan el proceso de validación con un conjunto fijo de datos, es decir hacen el proceso recién descrito solo una vez. Los aspectos favorables de este método son una mayor rapidez y mayor economía en recursos computacionales que los métodos dinámicos, es decir no se necesita mayor trabajo ni infraestructura para conseguir un resultado satisfactorio. Por otra parte, los aspectos desfavorables son que se requiere de datos distribuidos aleatoriamente y que la base de datos no posea información duplicada, para evitar la existencia de error por sesgo, mientras que en aspectos estadísticos es menos precisa que la validación cruzada,

la cual se verá que recorre por completo las entradas de entrenamiento. Dentro de este tipo de validación es posible encontrar el hold-up validation y el stacked validation.

Mientras en el hold-up validation se realiza la metodología que se acaba de explicar, es decir reservar un porcentaje de los datos de entrenamiento sólo una vez y con ellos realizar la validación, en el stacked validation se realiza el mismo hold-up validation, pero (n-1) veces a una base de datos de entrenamiento dividida en (n) partes siguiendo el siguiente protocolo.

Sea E la base de datos de entrenamiento, se divide en n partes,  $E[1]$ ,  $E[2]$ , ...,  $E[n]$ :

- El primer paso es entrenar los datos de  $E[1]$  y usar de validación los datos de  $E[2]$ .
- El segundo paso es entrenar los datos de  $E[1] \cup E[2]$ , usando  $E[3]$  para la validación.
- El tercer paso es entrenar  $E[1] \cup E[2] \cup E[3]$ , usando  $E[4]$  para la validación
- El (n-1) paso es entrenar  $E[1] \cup E[2] \cup \dots \cup E[n - 1]$ , usando  $E[n]$  para la validación

La metodología de stacked validation se utiliza para la información de tipo pila, como por ejemplo las series de tiempo, donde se puede encontrar ejemplos de precios históricos de commodities, acciones de la bolsa, etc. Fenómenos que pueden ser modelados utilizando redes neuronales recurrentes como se verá más adelante.

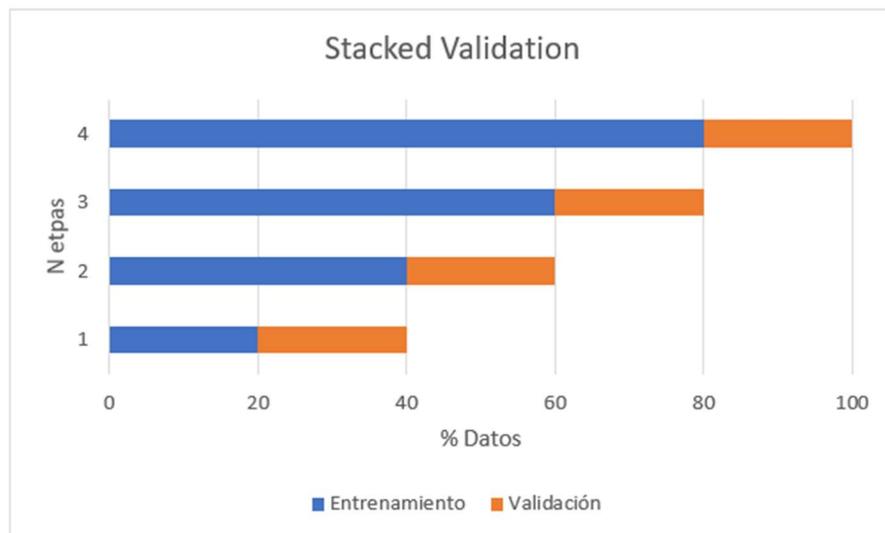


Gráfico 9-6: Esquema de como funciona la metodología de Stacked validation

### 5.8.5 VALIDACIÓN DINÁMICA

la validación dinámica o cruzada es una técnica estadística consiste en realizar el procedimiento de validación a todo el conjunto de entrenamiento de manera segmentada e iterativa. Dentro de esta metodología están las técnicas de k-fold cross validation, random sampling y leave one out cross validation (LOOCV), siendo más popular el k-fold cross validation que se detallará a continuación.

En el k-fold cross validation el grupo de datos de entrenamiento se divide en k partes. Luego se toma 1 de estas partes como conjunto de validación, a esta parte se le denomina como k fold, y al

resto de los datos se les denomina k-1. Luego se procede a entrenar con el segmento k-1, para posteriormente utilizar el k fold para el proceso de validación. En continuación se itera el proceso, utilizando como segmento de validación el siguiente k fold, y los datos restantes, incluyendo el k fold de la iteración anterior, se utilizan como datos de entrenamiento, repitiendo el proceso hasta que todas las k fold hayan servido a la tarea de validar la función de hipótesis. Luego se realiza una media aritmética de los resultados, siendo este valor la precisión entregada por la técnica.

Si bien esta técnica es estadísticamente superior y muy utilizada, es de un alto costo computacional y demanda mayor tiempo que las técnicas estáticas, en especial respecto de la hold-up validation.

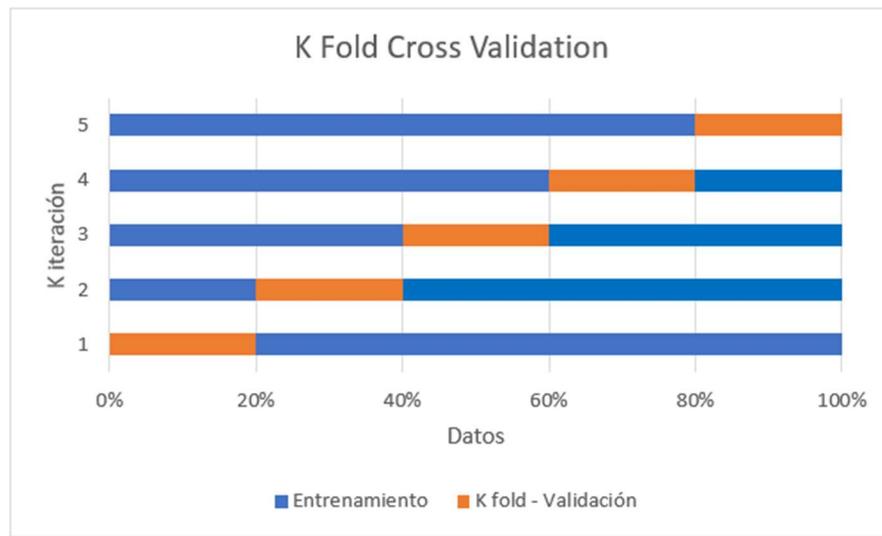


Gráfico 9-7: Esquema de la metodología K Fold Cross Validation

## 5.9 REDES NEURONALES ARTIFICIALES

Tal como su nombre lo indica, las redes neuronales artificiales son una emulación del funcionamiento de las redes neuronales biológicas, donde las neuronas son emuladas por lo que se denomina un perceptrón.

### 5.9.1 PERCEPTRÓN MULTICAPA

El perceptrón es la representación de la neurona. Este no es más que un nodo, desde un punto de vista topológico, donde se aplica a la información de entrada, desde las características  $(x_1, x_2, \dots, x_n)$ , una ponderación con parámetros de peso de los arcos de entrada, o pesos sinápticos,  $(w_1, w_2, \dots, w_n)$ , para luego entregar un valor 1 en caso que  $U \leq \sum(w_i x_i)$ , o entregar un valor 0 en caso contrario, siendo U un valor umbral de una función de activación tipo escalón.

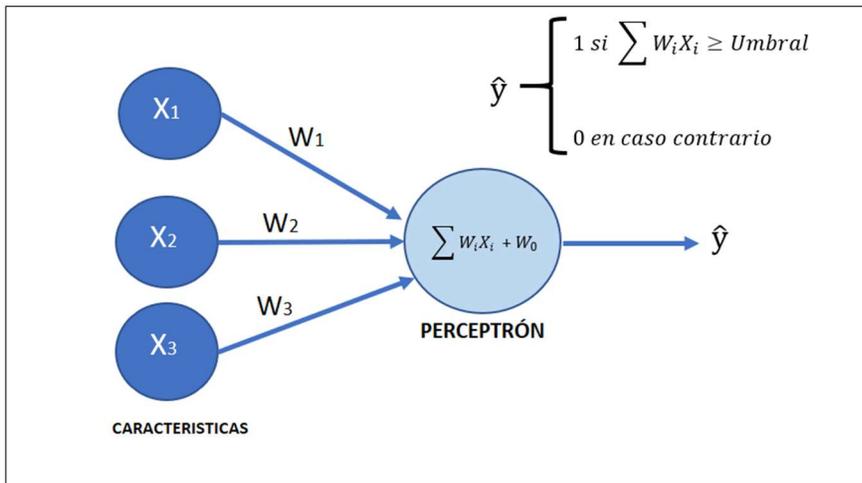


Imagen 9-1: Esquema del perceptrón y los pesos sinápticos  $w_i$

Para generar una red se necesita conectar dos o más perceptrones, dependiendo de si esta conexión es en serie (distintos niveles) o en paralelo (en el mismo nivel). Cuando están en paralelo se dice que están en la misma capa, donde reciben la misma información de la capa anterior y los cálculos realizados los pasarán a la capa siguiente. A la primera capa se le denomina capa de entrada, mientras que la última capa se llama capa de salida. Las capas intermedias son conocidas como capas ocultas. Este tipo de red es la que se conoce como perceptrón multicapa.

Cuando los perceptrones se ubican en serie, o de manera secuencial, una capa recibe información de la otra anterior. De este último proceso nace lo que se conoce como conocimiento jerarquizado.

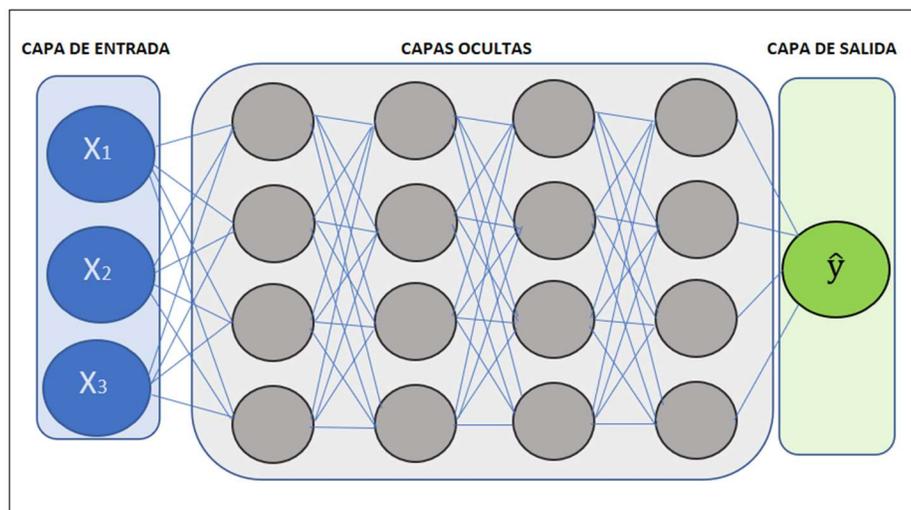


Imagen 9-2: Esquema de la red neuronal artificial perceptrón multicapa

El conocimiento jerarquizado es que a medida que se hace más profunda la red neuronal, al aumentar el número de capas, el conocimiento se puede ir complejizando y abstrayendo más, logrando obtener información más elevada o elaborada que en las primeras capas donde se obtiene información más básica. Pues es un procesamiento continuo de información ya procesada, generando así conocimiento. Dado este concepto de profundidad en la red y complejidad en el

conocimiento obtenido es donde nace el concepto de Deep Learning, el cual se explicará en más adelante en este mismo capítulo.

Sin embargo, el uso de este tipo de perceptrón es similar a resolver un problema de regresión lineal del tipo  $y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$ . Por lo tanto, una red neuronal de este tipo, que a grandes rasgos es una concatenación de funciones lineales, colapsaría y se reduciría al ejemplo inicial de 1 perceptrón.

Para evitar este colapso es que se aplica a cada perceptrón una función que permita romper con esta linealidad, esta función es la función de activación. La tarea de esta función es alterar el valor de salida, en caso que este sea distinto de cero, agregando deformaciones no lineales según el tipo de función que se utilice.

Dentro de estas funciones es posible encontrar la función escalón, que es lo mismo que ya se analizó en este capítulo al otorgar valores de 1 y 0 según la condición de superar un valor umbral o no; también está la función sigmoide, la función tangente hiperbólica, y la función rectificadora lineal o relu.

Además de la ya conocida red tipo perceptrón multicapa, existen otros tipos de redes neuronales artificiales, los cuales por su arquitectura están diseñados para diversas tareas. Estas son las redes neuronales convolucionales y las redes neuronales recurrentes.

## 5.9.2 REDES NEURONALES CONVOLUCIONALES

Se trata de un tipo de red neuronal encargada del reconocimiento de patrones y muy utilizada para el reconocimiento de imágenes, de audio, de texto, etc. Consiste en una serie de filtros, las llamadas convoluciones, que se aplican a una imagen para lograr obtener características de ella, como por ejemplo líneas, sombras, zonas de brillo, zonas de contraste, colores, etc.

La imagen original es recorrida pixel a pixel por estos filtros, que son matrices las cuales multiplican punto a punto sus componentes por los pixeles correspondientes en cada iteración. Como cada filtro sirve para obtener solo 1 característica de la imagen, se hace necesaria la aplicación de varios de ellos, los cuales se van apilando en lo que se conoce como profundidad de la capa convolucional.

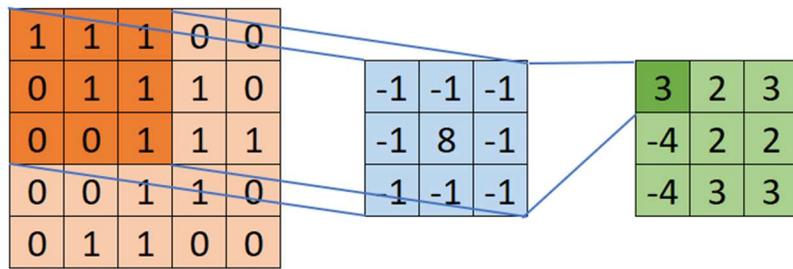


Imagen Original

Filtro

Resultado



$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$



Imagen 9-3: Uso de filtro sobre una imagen entregada (Fuente: towardsdatascience.com)

El recorrido de esta imagen por parte del filtro se va haciendo pixel por pixel, pero puede hacerse cada 2, 3, o más pixeles por cada lectura del filtro en la imagen. Esto es lo que se conoce como stride. Por ejemplo, en la imagen del filtro anterior la lectura es pixel a pixel, lo que se conoce como stride 1. Sin embargo, si se aplica un filtro stride 2 sobre la imagen, que es una lectura cada 2 pixeles tanto en el eje horizontal como vertical, resulta una matriz de 2x2, en vez del resultado anterior que era una matriz de 3x3. En otras palabras, aplicando stride se obtiene una imagen más comprimida una vez aplicado el filtro.

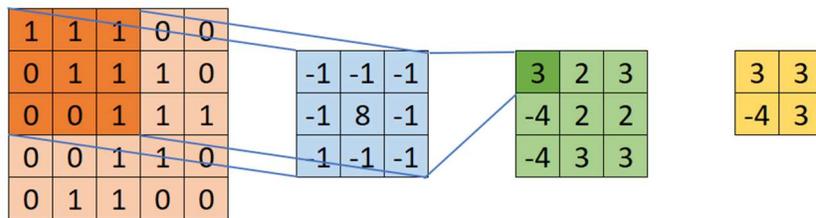


Imagen Original

Filtro

Resultado  
Stride= 1

Resultado  
Stride = 2

Imagen 9-4: Diferencia en la aplicación de un filtro con stride 1 y stride 2

Otra técnica fundamental para este tipo de redes es el pooling. El pooling es la extracción de un número característico que representa a cada lectura del filtro sobre la imagen. Esto se realiza con el objetivo de ir reduciendo las dimensiones X e Y de la imagen, generando posteriormente redes más pequeñas, lo que implica un ahorro de tiempo y costo computacional al momento de procesar la red. Dentro de las técnicas de pooling está el max pooling, que rescata el valor máximo dentro de un conjunto de datos, y el average pooling, que es el promedio aritmético de los datos de la lectura.

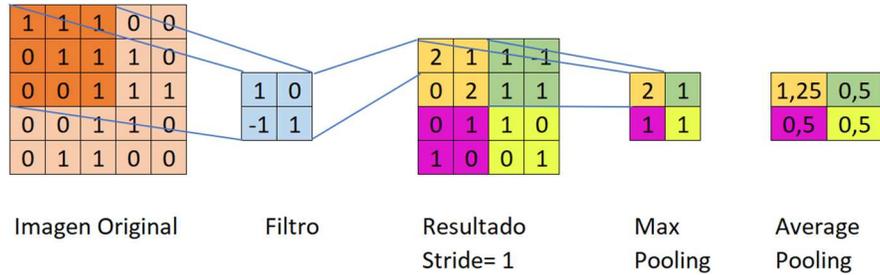


Imagen 9-5: Aplicación de max pooling y average pooling sobre el resultado de una convolución.

Así las capas ocultas se convierten en una concatenación de filtros, que le dan la profundidad a la convolución y luego de ello se aplica pooling a los filtros. A ese resultado se le aplican nuevamente una serie de filtros, para luego aplicar pooling. Finalizando la iteración entre convolución y pooling, la información reducida en sus dimensiones X e Y, pero incrementada en su profundidad, pasa por un perceptrón multicapa, tal como muestran las siguientes imágenes.

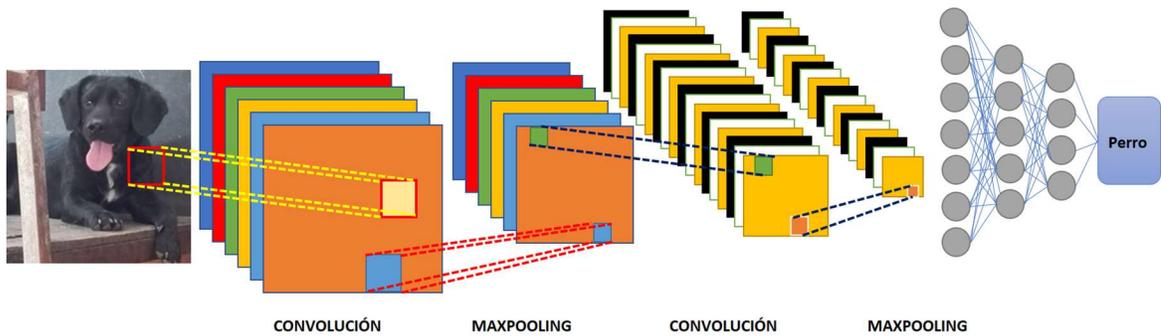


Imagen 9-6: Esquema de cómo funciona una red neuronal convolucional.

Finalmente, a medida que se profundiza en la capa oculta, se va haciendo cada vez más compleja la información obtenida por medio de los filtros. Comenzando por líneas, luces y sombras, luego patrones, partes de objetos, hasta llegar al reconocimiento de objetos.

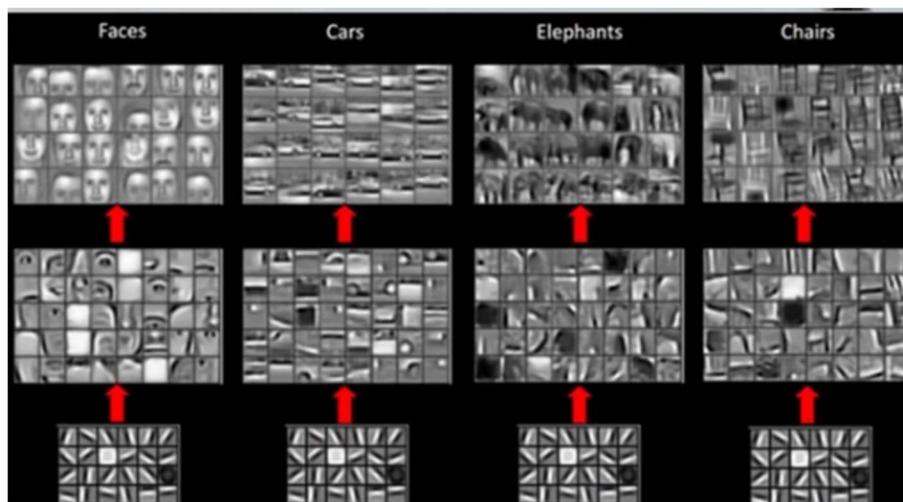


Imagen 9-7: Reconocimiento de patrones e imágenes en una red convolucional (Fuente: towardsdatascience.com)

En la imagen anterior, en las convoluciones iniciales (abajo) se obtienen características básicas de la imagen. A medida que la red se va profundizando, luego de varias convoluciones y aplicaciones de pooling se van obteniendo elementos más complejos de la imagen (ojos, bocas, detalles) que aparecen en la zona media, para finalmente poder llegar a un grado de abstracción y reconocimiento tal que puede reconocer caras, animales y objetos (arriba).

### 5.9.3 REDES NEURONALES RECURRENTE

Las redes ya vistas pueden clasificar los datos, reconocer patrones, reconocer imágenes, y por medio de estas reconocer audio y escritura, predecir situaciones binarias. Sin embargo, no pueden reconocer secuencias de datos, como el caso de música, videos, películas, etc. Como así también no tienen la capacidad de generar nueva información, sino solo recibir y clasificar.

Es en este contexto donde se utiliza la técnica de las redes neuronales recurrentes, las cuales están diseñadas arquitectónicamente para trabajar con secuencias de datos, es decir datos de tamaño variable y correlacionados con su vecindad, como una escena en un video o una conversación en el estudio de lenguaje natural, donde en el caso del video hay una cantidad variable de frames y un frame está correlacionado con el frame anterior, así como también ambos con los frames futuros. O en una conversación las palabras son de cantidad variable y también correlacionadas unas con otras.

Esta arquitectura que se menciona en el párrafo anterior hace referencia a otro estilo de perceptrón o neurona, el cual esta vez involucra una suerte de “memoria a corto plazo”, al incorporar la salida o activación de la clasificación del tiempo  $t-1$  en el tiempo  $t$ . Dado esto es que se utilizan en el Deep Learning de actividades donde las series de tiempo son parte fundamental, como por ejemplo el comportamiento del clima y la actividad bursátil.

Por otra parte, al ser capaces de reconocer secuencias de palabras, como también generarlas, las hace muy útiles en el campo del estudio del lenguaje natural, donde es posible encontrar grandes



Imagen 9-10: Esquema de cómo funciona una red neuronal recurrente de tipo one to many

También está la técnica de many to one, donde uno entrega una secuencia de información y recibe una sola etiqueta. Por ejemplo, el caso de la calificación de sentimientos donde es posible dar una crítica a una app, un restaurant o una película, la red reconoce el texto y otorga una calificación según la emoción reconocida en dicho texto.

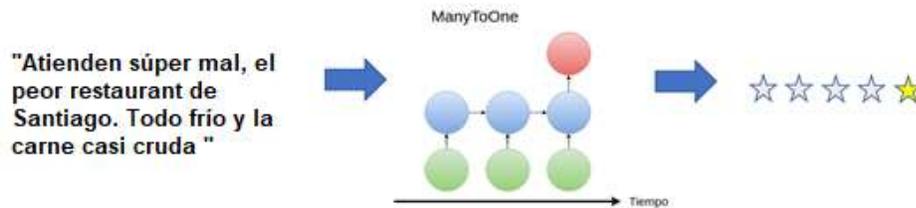


Imagen 9-11: Esquema de cómo funciona una red neuronal recurrente de tipo many to one

#### 5.9.4. FUNCIÓN DE COSTO

La función de costo es la función que representa que tan preciso es el modelo. En esta función se relaciona la etiqueta entregada por el modelo con el valor real. Al ser el modelo una función paramétrica, donde los pesos sinápticos son los parámetros, son estos los que se deben ajustar para lograr una etiqueta tal que entregue un grado de precisión satisfactorio.

Sea  $h_w(x) = w_0 + w_1x$  la función de hipótesis,  $f(x) = y$  la función que entrega la etiqueta y para las características  $x$ , se definirá como función de costo  $J(x)$  la función que representa la diferencia o error entre  $h(x)$  y  $f(x)$ . Cabe recordar que esta función  $J(x)$  puede deberse a la ocurrencia de underfitting, overfitting, o por ruido en los datos entregados.

Para calcular  $J(w)$  existen diversas alternativas, tales como el error cuadrático medio, error absoluto medio, la entropía cruzada binaria. Con el objetivo de ejemplificar, se utilizará el error cuadrático medio.

Así se tiene  $J(w_0, w_1) = \frac{1}{2N} \sum_{i=1}^N h_w(x_i) - y_i$ , con el objetivo de lograr  $\min_{w_0, w_1} J(w_0, w_1)$  y así obtener un modelo optimizado para realizar predicciones, clasificaciones o la tarea para la que fue diseñado.

Para el cálculo de esta minimización, el algoritmo más utilizado es el descenso del gradiente.

#### 5.9.5 MÉTODO DEL DESCENSO DEL GRADIENTE

El algoritmo de gradiente descendiente es un proceso iterativo en el que se ajustan los valores  $w_i$ , comenzando con valores aleatorios, hasta que se obtiene el mínimo error. El ajuste que se realiza es proporcional al negativo del gradiente de la función de pérdida en un punto específico  $\nabla J(w_i)$ . Los parámetros se ajustan de manera paralela, es decir, todos los valores se ajustan al mismo tiempo.

Dado que el ajuste depende del gradiente, a medida que se acerca a un punto mínimo, es decir que su valor se hace cercano a cero, el paso, que es la distancia entre mediciones, se hace cada vez más pequeño. Al contrario, si la medición se va alejando del mínimo, los pasos incrementan de tamaño. Hay que asegurarse que los pasos no sean muy pequeños pues incrementaría el tiempo de entrenamiento considerablemente, ni tampoco que sean demasiado grandes pues el proceso nunca lograría converger a un óptimo. El tamaño del paso se determina multiplicando el valor del gradiente en el primer punto medido con un factor que se denomina tasa de aprendizaje.

Así:

Sea  $w_{i,j}$  valor del peso  $w_i$  en el paso  $j$ , con  $i, j \in \mathbb{N}_0 \wedge j \leq 1000 \wedge i < \#pesos$

Con el punto  $w_i = (w_0, w_1, \dots, w_n)$ , donde  $w_0, w_1, \dots, w_n$  son valores conocidos

Sea  $J(w_{i,j})$  el valor de la función de coste  $J$  en el punto  $w_i$  en el paso  $j$

$$w_{i,j+1} = w_{i,j} - \text{Tamaño del paso}_{i,j}$$

$$\nabla(J(w_{i,j+1})) = \frac{\partial J(w_{i,j+1})}{\partial w_i}$$

$$\text{Tamaño del paso}_{i,j+1} = \nabla(J(w_{i,j+1})) * \text{Tasa de aprendizaje}$$

$$w_{i,j+2} = w_{i,j+1} - \text{Tamaño del paso}_{i,j+1}$$

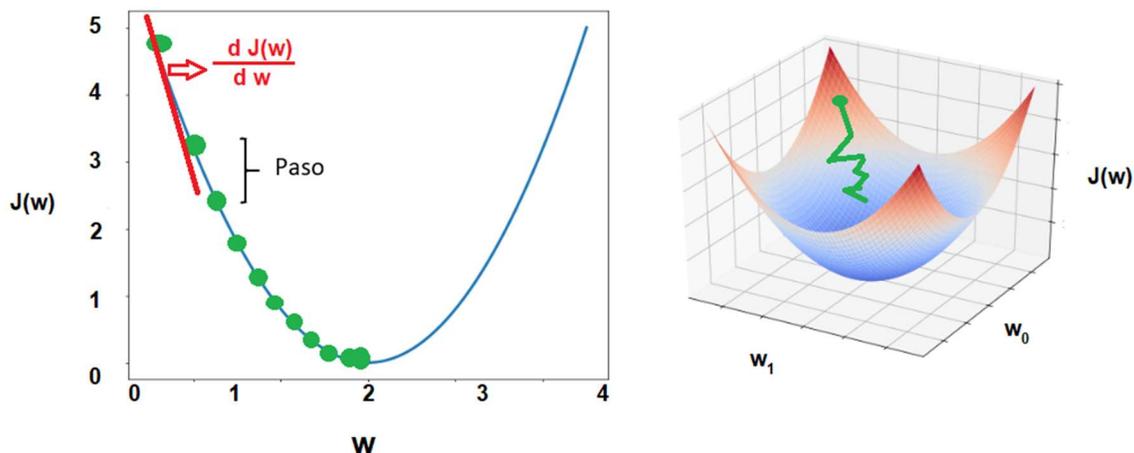


Imagen 9-12: Esquema de cómo funciona el método de descenso del gradiente.

El algoritmo se detiene cuando el tamaño del paso converge a un punto lo suficientemente cercano a cero. Sin embargo, el método a su vez se puede diseñar para un número máximo de pasos donde se estime que pueda converger, para así no incrementar el costo computacional de manera innecesaria. En el ejemplo anterior el número de pasos, representado por la letra  $j$ , es de 1000 como valor máximo.

### 5.9.6 FORWARD PROPAGATION Y BACKPROPAGATION

Por Forward propagation se entiende el proceso que ya se ha descrito de entregarle una serie de características a la red neuronal, y esta por medio de las funciones de activación y los pesos sinápticos, pasar a las capas neuronales siguientes, hasta llegar a la capa de salida, donde se obtiene la etiqueta de clasificación.

Esta etiqueta de clasificación posteriormente es evaluada respecto al resultado real ya conocido, como se acaba de ver en la función de costo. Se busca calcular su error, o también conocido como “loss” o “pérdida”, lo cual se hace por ejemplo utilizando el error cuadrático medio y el método del descenso del gradiente. Sin embargo, este error debe ser calculado para toda la red “aguas arriba”, puesto que los parámetros de una capa están relacionados con los parámetros de las capas anteriores, haciendo necesario minimizar la función de coste utilizando todos los parámetros de la red. Para hacer este recorrido a contracorriente se utiliza el algoritmo de Backpropagation.

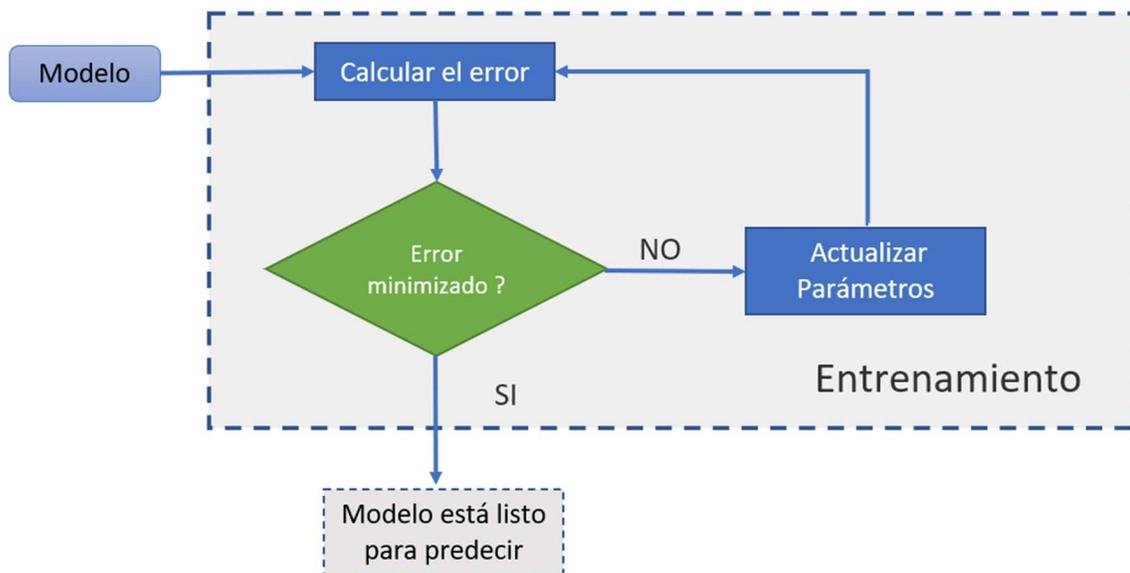


Imagen 9-13: Esquema de cómo funciona el algoritmo de backpropagación

El backpropagation es un algoritmo que recorre la red neuronal en sentido inverso, es decir desde la capa de salida hasta la capa de entrada, con el objetivo de reducir el error de pérdida  $J(w)$  por medio de la modificación de los valores de los pesos sinápticos de los arcos de la red. Esto es una modificación masiva y a contracorriente de los  $w_i$  en la red capa a capa y neurona a neurona.

### 5.9.7. BATCH y EPOCH

Para calcular los valores de los pesos sinápticos en la red, es posible ir variando la cantidad de información entregada previo a cada paso en el algoritmo del descenso del gradiente y también la cantidad de veces que toda la información será procesada completamente (en forward y backpropagation) para ir buscando el ya mencionado mínimo del error.

A esta cantidad de información a procesar se le llama lote o batch, mientras que las veces que se procesa la información completa se le conoce como época o epoch. Ambos son hiperparámetros de la red neuronal, es decir son valores que se configuran durante el proceso de entrenamiento a voluntad de la persona que está desarrollando la red. Para poder encontrar un valor satisfactorio de estos se debe iterar con diversos valores tanto de epoch como de batch, hasta dar con una configuración que se ajuste al modelo.

Los métodos de optimización, como el descenso del gradiente o el algoritmo ADAM, ven modificados sus resultados en función al tamaño del batch y a la cantidad de epochs utilizadas para calcular los valores de la red. Un excesivo valor de epochs para un entrenamiento puede llevar eventualmente a la ocurrencia de overfitting, mientras que un valor muy bajo de epoch puede resultar en un underfitting.

Por otro lado, el tamaño del batch puede ser de todo el volumen de datos de una vez, lo que se conoce como descenso del gradiente batch; o también el tamaño del batch puede ser de 1, es decir cada dato es leído por la red y luego se calcula el error, lo que se conoce como descenso del gradiente estocástico. También existe una tercera alternativa que es trabajar con un tamaño de batch mucho más pequeño que el conjunto completo de datos, pero más grande que 1, lo cual se conoce como mini batch, el cual es el más utilizado.

En este trabajo se utilizará tanto el descenso del gradiente estocástico, el cual asegura al modelo a converger a un mínimo global, como también tamaños de mini batch, que le otorgan más estabilidad y rapidez al resultado que el descenso estocástico, el cual por una parte es costoso y lento computacionalmente, y por otra parte entrega un resultado final con mucho ruido, debido al hecho de que entrega un resultado del error por cada dato leído, mientras que el descenso por mini batch resulta en una gráfica más suave o estable.

#### 5.9.8. MATRIZ DE CONFUSIÓN

Una matriz de confusión es una técnica para medir resumidamente el rendimiento de un algoritmo de clasificación.

A veces la exactitud de la clasificación (accuracy) por sí sola puede ser errónea si se dispone de un número desigual de etiquetas en cada clase (0 y 1 en este caso) o si tiene más de dos clases en su conjunto de datos. En ese caso, el calcular una matriz de confusión entrega una mejor idea de lo bien, o mal, que el modelo está trabajando y qué tipos de errores está cometiendo.

Esta matriz se divide en los siguientes conceptos:

Verdadero positivo o True Positive (TP): Es un valor que es positivo (valor 1) en los datos de entrada y el modelo lo predice como positivo.

Verdadero negativo o True Negative (TN): Es un valor que es negativo (valor 0) en los datos de entrada y el modelo lo predice como negativo.

Falso positivo o False Positive (FP): Es un valor que es negativo (valor 0) en los datos de entrada y el modelo lo predice como positivo.

Falso negativo o False Negative (FN): Es un valor que es positivo (valor 1) en los datos de entrada y el modelo lo predice como negativo.

Luego se tiene la siguiente matriz:

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | TN         | FP |
|      | 1 | FN         | TP |

Tabla 9-2: Matriz de confusión.

Luego los datos se distribuyen según la predicción de clasificación que realice el modelo, por ejemplo, una matriz de 100% de accuracy sería tal que acertara en todas las etiquetas, tanto positivas como negativas. Suponiendo que son 70 las etiquetas positivas a pronosticar y 55 las negativas, resulta una matriz como la siguiente

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | 55         | 0  |
|      | 1 | 0          | 70 |

Tabla 9-3: Matriz de confusión ejemplo de 100% de exactitud

Por otro lado, si esta matriz tuviese 30% de exactitud aproximadamente, podría verse como sigue:

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | 17         | 38 |
|      | 1 | 49         | 21 |

Tabla 9-4: Matriz de confusión ejemplo de 30% de exactitud

Las fórmulas relacionadas a la matriz de confusión son:

$$Exactitud (accuracy) = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precisión = \frac{TP}{TP + FP}$$

$$Recall (sensibilidad) = \frac{TP}{TP + FN}$$

La exactitud es la proporción de datos que fueron bien pronosticados en relación a los datos totales. Mientras que la precisión entrega la proporción de pronósticos positivos que realmente acertaron,

en relación a todos los elementos pronosticados como positivos. Finalmente, la sensibilidad o recall es la proporción de los aciertos para el conjunto de los elementos positivos en relación a todos los elementos positivos reales de la base de datos original.

Como se mencionará posteriormente, existe una gran diferencia de cantidad elementos entre los datos que resultan en derrame y los que resultan en “sin derrame”, lo que podría conllevar a mediciones erróneas. Sin embargo, en estos casos especiales, para poder determinar si el modelo tiene un buen o mal desempeño de clasificación, se suele utilizar, según la literatura, el coeficiente de correlación de Matthews (MCC), el cual inclusive funciona para los casos cuando los grupos a clasificar son de cardinalidades muy diferentes. (Chicco et al., 2020) (Boughorbel et al., 2017)

$$MCC = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}}$$

MCC adopta valor 1 cuando la clasificación es perfecta (100% de aciertos en verdaderos positivos y verdaderos negativos), -1 cuando hay 100% de desaciertos y 0 cuando es lo mismo que una predicción aleatoria.

## **6. METODOLOGÍA**

### **6.1. CASO BASE**

Actualmente, el estado del arte respecto al carguío de camiones de extracción (CAEX) indica que este debe siempre generar una forma idealmente cónica, y ubicada en la zona central de la tolva para así distribuir los esfuerzos, de tal manera que se acerque a lo esperado por el diseño del fabricante (OEM) y con ello evitar daños en los componentes del camión.

### **6.2. CASO PROPUESTO**

La posición del balde sobre el camión, y con ello la manera de cargar, debe determinarse en función de variables de peso, pendientes, ley cargada, consumo de combustible entre otros. Para ello la tesis se desarrolla bajo la siguiente metodología:

- 1) Simulación de una mina a rajo abierto, con el objetivo de determinar cuánto afectan los derrames a la utilización efectiva de la flota de transporte.
- 2) Desarrollo de 2 redes neuronales en el lenguaje de programación Python, con el objetivo de determinar la posibilidad de predecir tanto la ocurrencia de derrames, como también la ocurrencia de daño sobre el camión, desde datos de laboratorio.
- 3) Desarrollo de una comparación económica de casos, para lo cual se realizó un programa en Python, que permitiese usar la información brindada por las redes neuronales en un modelo simple de simulación diaria del proceso de una mina.

### **6.3. SIMULACIÓN DE CIRCUITO DE TRANSPORTE DE MINERAL**

#### **6.3.1. DESCRIPCIÓN**

Se realiza la simulación de una mina a rajo abierto en lo concerniente a su operación de carguío de mineral y transporte de mineral hacia la planta de chancado primario. Esta operación dispone de una flota de 10 camiones activos de 150 toneladas, 1 pala, 1 chancador y 2 equipos de apoyo para limpieza de la ruta. Además, la mina dispone de 5 estaciones que representan puntos en la ruta donde hay ocurrencia de derrames de mineral. Estos puntos están ubicados a 100 metros, 400 metros, 900 metros, 1900 metros y 3400 metros respecto al frente de extracción. Para simular una disponibilidad mecánica del 80%, el modelo se configura para una operación de 19,2 horas diarias, dentro de las cuales se consideran 3 horas de demoras programadas que corresponden a 2 cambios de turno de 30 minutos cada uno y 2 periodos de colación de 1 hora cada uno. Promodel está configurado para trabajar por minutos, luego esas 19,2 horas pasan a ser 11520 minutos, dado que el sistema se compone de 10 camiones.

El objetivo de esta simulación es estimar un rango de tiempo de pérdida operacional debido a la ocurrencia de derrames, y consecuentemente un rango de pérdida de utilización efectiva en función a este tiempo obtenido. Para ello se somete al modelo a diversos casos o configuraciones de ocurrencia de derrames, los cuales se iteran en 1000 ocasiones.

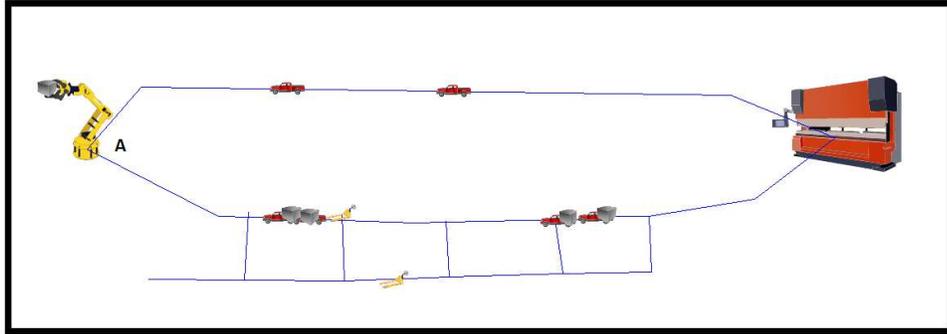


Imagen 8-1: Referencia del modelo realizado en Promodel en funcionamiento. Los recursos de color rojo representan a los CAEX y van en sentido antihorario desde el punto A.

### 6.3.2 ELEMENTOS DE SIMULACIÓN

#### *Entidad*

Se utiliza la alternativa Raw material (materia prima) ofrecida por el software Promodel. Esta posee una velocidad propia, la cual es insignificante en cualquier caso pues es transportada por un recurso (el recurso pick-up que hace las veces de camión). Su entrada está en el punto 1 de la imagen 6.

#### *Locaciones*

Pala: Locación donde se efectúa el carguío de los recursos, corresponde al número 1 en la imagen 6.

CHX: Chancador, número 13 en la imagen 6.

Cola\_Pala: Locación de origen de los recursos, donde vuelven al dejar de ser utilizados y esperan ser requeridos por la Pala. Número 14 en la imagen 6.

E(i): Estaciones donde se producen los derrames, con i de 1 a 5. Ubicadas a 100 m., 400 m., 900 m., 1900 m., 3400 m. respectivamente en relación al frente de carguío. Corresponde a los números 3, 5, 7, 9 y 11 de la imagen 6

Cola\_E(i): Punto de espera en caso de ocurrencia de derrame en E(i), ubicado a 1 m. de cada estación de derrame. Corresponde a los puntos 2, 4, 6, 8 y 10 de la imagen 6.

Cola\_Chx: Cola del chancador. En la imagen 6 corresponde al número 12.

BaseEqAux: Punto base de los equipos de apoyo, ubicado cerca del frente de carguío. Corresponde al punto 15 en la imagen 6.

Pato(j): Punto paralelo a los E(i) para acudir a la limpieza de los derrames. Corresponde a los puntos desde el 16 hasta el 20 en la imagen 6.

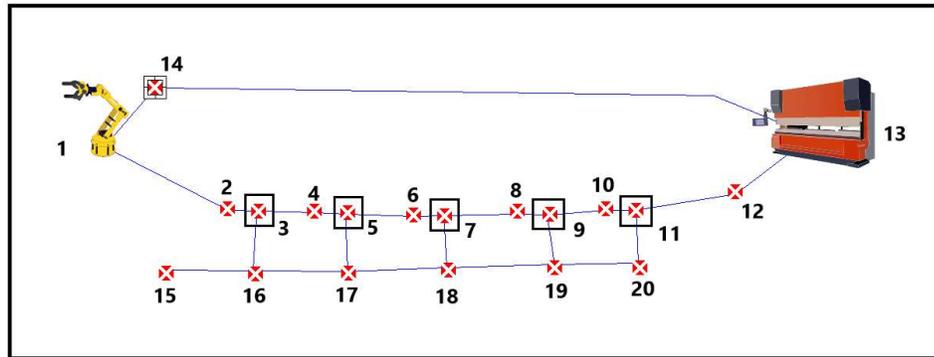


Imagen 8-2: Locaciones y redes utilizadas en el modelo en Promodel

### Recursos

Pickup(i): Cumple las funciones de transporte de las entidades, simulando el transporte de mineral por medio de camiones. (i=1 a 10).

Pallet Truck (j): Este recurso representa el equipo de apoyo que cumple las funciones de limpieza de ruta. (j = 1,2)

### Redes

Se dispone de 2 redes independientes, las cuales solo interactúan en el caso de ocurrencia de derrames. La red de transporte, representada con color rojo en la imagen 7, es por donde los camiones se desplazan para acarrear el mineral desde la pala al chancador, para luego volver a la cola de la pala. Mientras la red de equipos de apoyo, representada por el color verde, es la red donde se mueven los equipos de apoyo que cumplen las funciones de limpieza de ruta en caso de existir derrames de mineral.

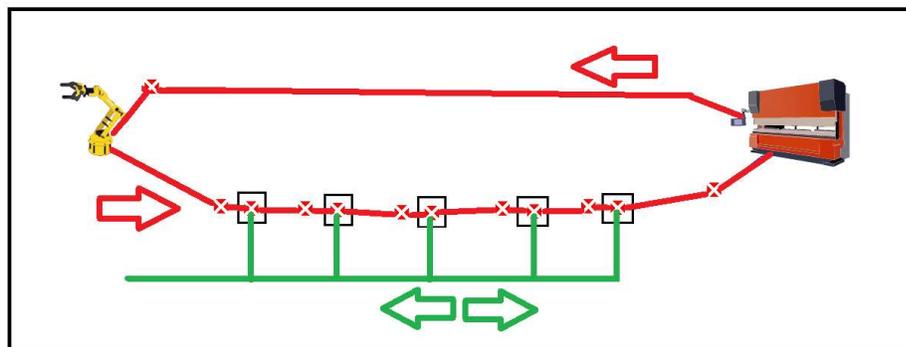


Imagen 8-3: Representación gráfica de las redes utilizadas en el modelo estudiado.

En la imagen 8-3, las flechas representan la dirección del movimiento de los recursos que utilizan cada una de las redes (camiones en la red roja, equipos de apoyo en la red verde)

### 6.3.3. PARÁMETROS

Los parámetros que se consideran tanto para los tiempos muertos del modelo (demoras programadas y pérdidas operacionales), velocidades de los recursos y tiempos de uso de las locaciones son los siguientes:

#### *Velocidad de recursos*

Cada una de las velocidades de los recursos sigue una distribución triangular, con los argumentos que aparecen en la siguiente tabla.

|                 | Velocidad [Kph] (Distribución Triangular) |      |        | Semilla |
|-----------------|---|------|--------|---------|
|                 | Mínimo                                    | Moda | Máximo |         |
| Camión Cargado  | 14  | 15   | 16     | 1 - 3   |
| Camión Vacío    | 28  | 30   | 32     | 1 - 2   |
| Equipo de apoyo | 18  | 20   | 22     | 1 - 2   |

Tabla 8-1: Velocidades y números semilla de los recursos utilizados

Se decidió el uso de esta distribución por el hecho de que se conoce el rango y la moda del fenómeno a modelar, en este caso tanto la velocidad de los camiones y de los equipos de apoyo, pero se desconoce la distribución de esta.

Además, se asume a efectos de simplicidad del modelo que estos recursos tienen velocidad constante, suceso que en la realidad no ocurre dado que hay aceleraciones y desaceleraciones involucradas. En otras palabras, una vez iniciado cada viaje desde la pala, el equipo no cambia su velocidad hasta descargar en el chancador. Asimismo, una vez que emprende marcha hacia la zona de carguío, el equipo adopta una velocidad única dentro del rango otorgado como velocidad de camión vacío.

#### *Tiempos muertos*

Los tiempos muertos de las locaciones por pérdida operacional son por número de entidades procesadas y por reloj. Esto con el objetivo de simular por ejemplo 1 o 2 derrames por cada ciclo de la flota, en el caso de las entidades, y simular las colaciones y cambios de turno en caso de los tiempos muertos por reloj. En síntesis, tanto las demoras programadas como las pérdidas operacionales, estas últimas sólo en parte, se representan por medio de los tiempos muertos. Las pérdidas operacionales también están conformadas por el Tiempo Inactivo (T.I) que es el tiempo que el camión está en la cola de la pala.

|    | Demoras Programadas por N° Entidades |                   |            |
|----|--------------------------------------|-------------------|------------|
|    | Tipo de Elemento                     | Tiempo de bloqueo | N° Semilla |
| E1 | Locación                             | 3 + T (3,4,5)     | 1, 2       |
| E2 | Locación                             | 3 + T (3,4,5)     | 1, 2       |
| E3 | Locación                             | 3 + T (3,4,5)     | 1, 2       |
| E4 | Locación                             | 3 + T (3,4,5)     | 1, 2       |
| E5 | Locación                             | 3 + T (3,4,5)     | 1, 2       |

Tabla 8-2: Locaciones con tiempo muerto por número de entidades procesadas (pérdida operacional)

Las locaciones cuyo TM corresponda a entidades procesadas, variarán en la frecuencia y en la primera ocurrencia de estos TM caso a caso para así simular distintos escenarios.

| Caso                     | Frecuencia<br>1er Lugar | 1a Ocurrencia<br>1er Lugar | Frecuencia<br>2º Lugar | 1a Ocurrencia<br>2o Lugar |
|--------------------------|-------------------------|----------------------------|------------------------|---------------------------|
| 1 derrame,<br>1 lugar    | 10                      | 5                          | No aplica              | No aplica                 |
| 2 derrames,<br>1 lugar   | 5                       | 1                          | No aplica              | No aplica                 |
| 2 derrames,<br>2 lugares | 10                      | 1                          | 10                     | 6                         |

Tabla 8-3: Configuración de Frecuencias y de Ocurrencias de derrames en distintos casos

La frecuencia hace referencia a cuantas entidades o unidades de materia prima deben pasar por una estación de derrame antes de que esta se bloquee a causa de un derrame luego de la primera ocurrencia de este. (1ª ocurrencia en la tabla). Por ejemplo, el caso de 2 derrames en 2 lugares significa que ocurre un primer derrame en una estación y luego el segundo en una estación distinta. La ocurrencia de este primer derrame es luego de haber pasado 1 camión por la estación. El segundo derrame, que sería el primero en ocurrir en la segunda estación, ocurre luego de que por dicha locación hayan pasado 6 camiones. Luego, en ambas estaciones, la ocurrencia del próximo derrame será luego de haber pasado 10 camiones. Es decir, luego del 11avo camión en la primera estación y luego del 16avo camión en la segunda estación.

Para la frecuencia se asigna el valor 10 en el caso de 1 derrame y en el de 2 derrames en 2 lugares, para que así se cumpla la condición de que exista 1 derrame por punto por cada vez que pasen 10 camiones, es decir la flota en operación. La frecuencia 5 sigue una lógica similar, la cual es que se genere un derrame tras el paso de 5 camiones, y así cumplir con la ocurrencia de 2 derrames tras el paso de la flota.

Las primeras ocurrencias, que es cuando la estación o punto de derrames queda detenido por primera vez, tienen el valor de 1 y 6 para el caso de 2 derrames en 2 lugares distintos, y frecuencia 10. Estos valores 1 y 6 fueron elegidos de manera arbitraria como representación conceptual de primera ocurrencia en derrame, usando como referencia el caso de 2 derrames en un mismo punto, donde la primera ocurrencia ocurre luego del paso de la entidad 1, y la segunda ocurre luego del paso de la entidad 6, puesto que la frecuencia en ese caso es de 5.

Estas demoras en las estaciones, en conjunto con la demora en la cola del chancador y en la cola de la pala constituyen las pérdidas operacionales, las cuales provocan la disminución de la utilización efectiva de la flota de camiones, tal como se verá en el apartado de fórmulas de cálculo del modelo.

Por otro lado, los tiempos muertos de los recursos (camiones y equipos de apoyo), en términos del software de modelamiento y de algunas locaciones, como son la pala y el chancador, son por medio de reloj y constituyen las demoras programadas de la operación

|                 | Demoras Programadas |             |          |
|-----------------|---------------------|-------------|----------|
|                 | Tipo de Elemento    | Primera Vez | Duración |
| Camión          | Recurso             | 0 min.      | 3 hr.    |
| Equipo de Apoyo | Recurso             | 0 min.      | 3 hr.    |
| Pala            | Locación            | 0 min.      | 3 hr.    |
| CHX             | Locación            | 0 min.      | 3 hr.    |

Tabla 8-4: Demoras programadas de recursos y locaciones

Se establece un único lapso de 3 horas como tiempo muerto por reloj, esto dado que al hacerlo de manera separada arrojaba un comportamiento errático en la flota de camiones, alejándose del comportamiento a simular. Este tiempo muerto representaría a la demora programada asociada a colación y cambio de turno.

Vale mencionar un detalle dentro de los parámetros ya mencionados, este es el de los casilleros donde aparecen los números semilla. Estos números corresponden a series numéricas utilizadas por el programa para la ejecución del modelo. De no modificarse este número semilla al ejecutar 2 o más veces el modelo, se obtendrá el mismo resultado. Esto representa un problema si se desean más de 500 iteraciones, el cual es el límite de la versión de Promodel utilizada. Dado que en el presente trabajo se utilizaron 1000 iteraciones hubo que recurrir a esta alternativa.

#### 6.3.4 DESCRIPCIÓN DEL PROCESO

El sistema funciona diariamente por 19,2 horas, dentro de los cuales se consideran 3 horas correspondientes a demoras programadas, las cuales se utilizan al principio de cada turno con el objetivo de que el modelo no pierda fluidez y se asemeje a una operación real.

Luego de esto comienza la operación con el carguío, donde la Pala se mantiene en esa operación sobre el camión durante T (2.8, 3, 3.5) minutos, para luego liberar al camión y este emprende marcha hacia la zona de chancado primario.

En caso de que alguna de las estaciones de derrame cumpla con la condición para bloquearse, lo que significa la existencia de un derrame, se procede a esperar 3 minutos para así simular el periodo que demora el camión siguiente en percatarse de este derrame, y luego se solicita a algún equipo de apoyo disponible a que acuda a ejecutar la limpieza de la ruta. Dicha limpieza sigue la distribución de demora T (3, 4, 5) minutos, luego de ello se libera al equipo de limpieza y el camión continúa su camino hacia la siguiente estación, que de estar bloqueada puede repetir el proceso en su totalidad, en caso de ser el primer camión en percatarse, o repetirlo en parte en caso que ya haya otro equipo en la cola de dicha estación. En el caso de estar desbloqueadas todas las estaciones, el equipo continúa su viaje hacia el chancador primario.

En el chancador primario el equipo procede a descargar siguiendo una distribución de demora de T (0.5, 0.75, 0.8) minutos. Luego libera al camión para que este emprenda rumbo hacia la cola de la pala y repetir el proceso.

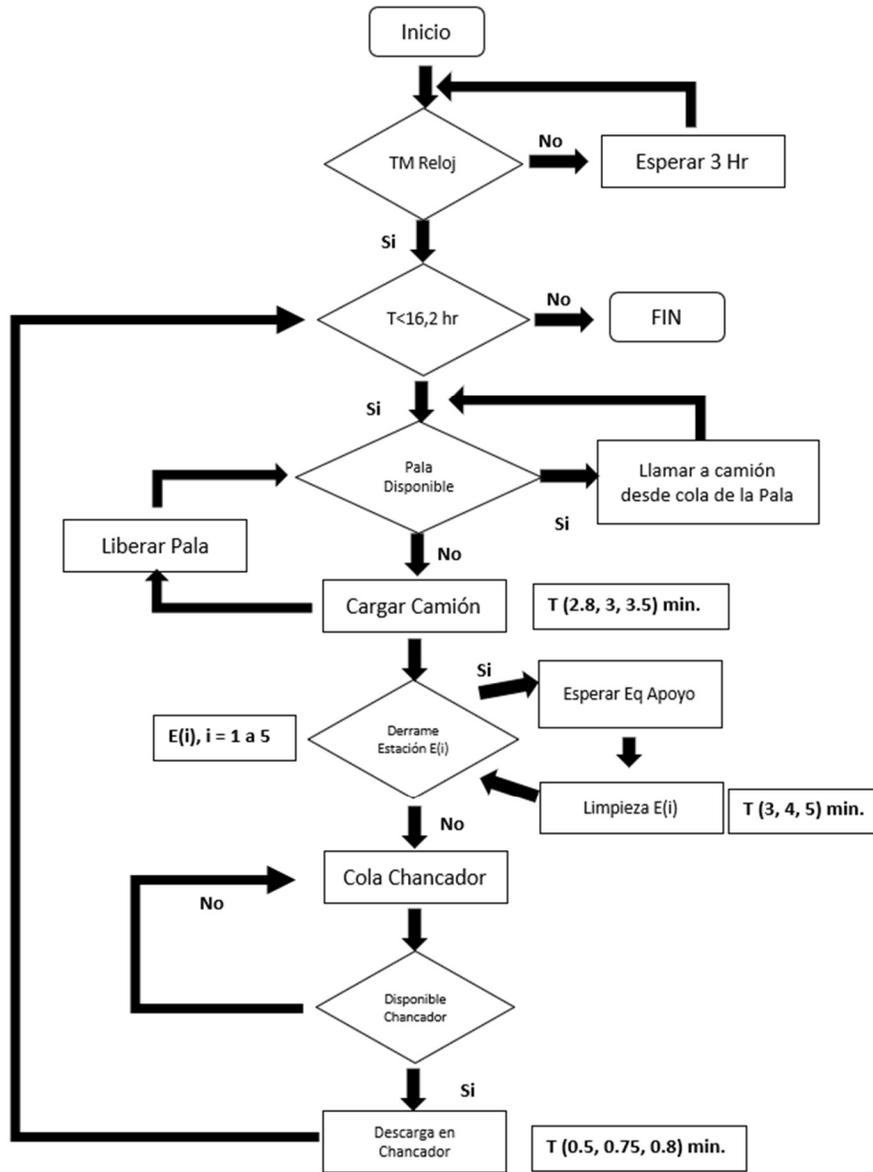


Imagen 8-4: Esquema del algoritmo de simulación.

### 6.3.5 FÓRMULAS DE CÁLCULO

Para efectuar los cálculos de demoras y pérdidas de utilización efectiva en cada simulación se utilizan principalmente los datos obtenidos de las pestañas “Recursos Estados”, “Locación Resumen” y “Resource Resumen” de la planilla Excel entregada como resultado por Promodel luego de cada ejecución.

Desde la pestaña “Locación Resumen” se multiplican los datos de las columnas “Total Entradas” y “Tiempo por entrada promedio [min]” como muestra la siguiente fórmula.

$$Uso\ de\ Locación_i\ [min] = Total\ Entradas_i \times Tiempo\ por\ entrada\ promedio_i\ [min]$$

Esta fórmula se aplica para las locaciones Cola E1, Cola E2, Cola E3, Cola E4, Cola E5 y Cola Chx, las cuales fueron configuradas con una capacidad de hasta 99 elementos con el objetivo de generar colas en caso que haya ocurrencia de derrame en alguna de las estaciones de derrame, o en el caso que haya una demora en el chancado. Mientras que, en las locaciones como las estaciones de derrame, junto con la de la pala y la de chancado, su configuración solo permite 1 entidad por vez, obligando que las colas se generen en las locaciones de mayor capacidad.

La cola de la pala no se considera en este cálculo, dado que no se informa directamente debido a que Promodel solo entrega información de locaciones donde hayan pasado las entidades (Materia prima), las cuales finalizan su circuito en la estación de chancado. Por lo tanto, el cálculo del tiempo de la pérdida operacional por cola en la pala se determina desde la columna denominada “% inactivo”, en la pestaña “Recursos Estados” del archivo Excel generado por Promodel. Este dato representa el porcentaje de tiempo que el recurso (camión) está inactivo respecto del total. En los anexos de este trabajo aparece mayor información acerca del archivo Excel generado y sus componentes.

La suma de los usos de locación, que es la suma de las colas salvo la cola de la pala, es el tiempo total de demora generada por el o los derrames ocurridos en el circuito, tal como se muestra en la siguiente ecuación.

$$Total\ Demora[\text{min}] = \sum_i Uso\ de\ Locación_i [\text{min}]$$

Promodel considera 5 estados para los camiones:

En uso (TUN [min], Tiempo de Uso Nominal): El camión está cumpliendo su función. Vale tanto para cuando lleva la carga, como para cuando está siendo cargado y para cuando está siendo descargado. Por lo tanto, el tiempo de demora tanto en las colas de derrame, como también en la cola de chancado, se considera tiempo en uso, al cual se le debe restar el valor de “Total Demora” para obtener así el verdadero tiempo que se está utilizando en lo relativo a la carga a transportar.

Viaje para utilizar (VPU [min]): Es el viaje que hace el camión desde la cola de la pala hasta la posición bajo el balde para ser cargado.

Viaje a estacionar (VE [min]): Corresponde al viaje realizado por el camión desde la planta de Chancado hasta la cola de la pala.

Inactivo (IN [min]): Es el periodo que el camión pasa en la cola de la pala.

Down (DW [min]): Es el periodo que el camión está en alguna demora programada.

Con esto es posible definir el “tiempo de uso real” (TUR) como la resta entre el “Tiempo de Uso Nominal” y el tiempo “Total Demora”, quedando así:

$$Tiempo\ en\ Uso\ Real\ [\text{min}] = TUN - Total\ Demora$$

Por lo tanto, el Tiempo en Uso Real es el tiempo de carga, transporte y descarga de los camiones, menos el tiempo de espera en las distintas colas posibles, exceptuando la cola de la pala.

Con esto es posible obtener la utilización efectiva (UE) del camión de la siguiente forma:

$$Utilidad Efectiva [\%] = 100 \times \left( \frac{TUR[\text{min}] + VPU[\text{min}] + VE[\text{min}]}{24[\text{hr}] * DM * 60\left[\frac{\text{min}}{\text{hr}}\right]} \right)$$

Donde 24 representa las horas totales del día, DM es la disponibilidad mecánica y 60 representa a los minutos por hora, quedando para una DM de 80%:

$$UE[\%] = 100 \times \left( \frac{TUR[\text{min}] + VPU[\text{min}] + VE[\text{min}]}{1152[\text{min}]} \right)$$

Finalmente, las fórmulas utilizadas para saber cuánto afecta cada derrame al tiempo de ciclo y a la utilización efectiva son las siguientes.

$$Demora \text{ por derrame } [\text{min}] = \frac{IN(\text{flota})[\text{min}] + Total \text{ Demora}(\text{flota})[\text{min}]}{Nderrames \times Ncamiones}$$

Donde “IN (flota)” corresponde a la suma de los tiempos inactivos de todos los camiones en el día; igualmente “Total Demora (flota)” corresponde a la suma de los minutos diarios que pasan todos los camiones en las colas, a excepción la cola de la pala. “N derrames” es el número de derrames en el día, y “N camiones” es el número de camiones en la flota.

La demora por derrame representa un promedio de pérdida operacional por camión. Para calcular la pérdida operacional de la flota, se debe multiplicar la Demora por Derrame por el total de la flota, o en este caso N camiones.

Para estimar la pérdida de utilización efectiva por cada derrame se calcula como sigue:

$$Pérdida UE \text{ por derrame } [\%] = \frac{UE \text{ ideal promedio} - UE_i}{Nderrames}$$

UE ideal promedio es la utilización efectiva promedio del caso sin derrames, el cual se verá en el siguiente apartado.

$$Pérdida \text{ de UE por Minuto perdido } \left[ \frac{\%}{\text{min}} \right] = \frac{Pérdida UE \text{ por derrame}}{Demora \text{ por derrame}}$$

## 6.4 DEEP LEARNING

Posteriormente se programa un modelo de redes neuronales artificiales utilizando el lenguaje de programación Python, con el objetivo de demostrar que es posible predecir eventos de derrame mediante el posicionamiento del balde en el carguío. Esto con el objetivo de explotar la aparente no linealidad entre las variables que determinan la ocurrencia de derrame, como son distribución de la carga en la tolva, ángulo de rampa y ángulo de reposo del material. Dado esto, existe un incentivo para utilizar un algoritmo de clasificación binaria para determinar la ocurrencia o no de eventos de derrame. Igualmente se utiliza este procedimiento para determinar si es posible predecir si hay daño en el camión asociado al carguío dinámico.

Para ello se utiliza una base de datos de laboratorio, brindada por el profesor guía, la cual está compuesta por distintas ubicaciones respecto a la tolva de 3 paladas en un camión a escala 1:14, además de la gradiente que forma el material respecto al extremo posterior de la tolva y las lecturas de los esfuerzos izquierdo y derecho que ejerce el material sobre el camión.

El código fuente desarrollado para el cálculo de las redes neuronales está en la sección de anexos.

### 6.4.1. DATASET

El dataset se compone de 1406 entradas, las cuales se componen de 6 datos cada una, los cuales son:

- Ubicación pase 1 de la pala
- Ubicación pase 2 de la pala
- Ubicación pase 3 de la pala
- Ángulo formado en la vertical del camión por el punto más alto del cono de mineral con el extremo trasero de la tolva, o “cola de pato”. Ángulo cuyo vértice está en la cola de pato. Se le denominará “ángulo máximo de carga”
- Lectura de amortiguación izquierda
- Lectura de amortiguación izquierda

Las ubicaciones de los pases se dividen en 12 sectores:

- 1 y 2 en la parte trasera de la tolva
- 3 y 4 en la parte delantera
- 5,6,7,8 en la parte izquierda
- 9,10,11,12 en la parte derecha

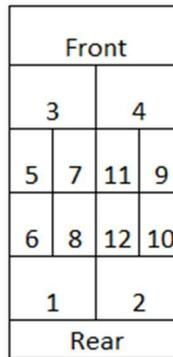


Imagen 9-14: Esquema de distribución de pases de carguío

Con esta información se transformó posteriormente el ángulo entregado a radianes y luego a porcentaje:

$$\begin{aligned} \text{ángulo en radianes} &= \text{ángulo en grados} * 0,0174533 \\ \text{ángulo en porcentaje} &= 100 * \text{Tan}(\text{ángulo en radianes}) \end{aligned}$$

Se determinó que el camión derramaba cuando tenía un ángulo máximo de carga superior al ángulo de reposo del material menos la pendiente de la rampa.

A su vez se determinó que existía daño en el carguío cuando este tenía un factor de Roll igual o superior a 2:

$$|\text{Esfuerzo lado izquierdo} - \text{Esfuerzo lado derecho}| \geq 2$$

Luego se procede a modificar y completar la base de datos a utilizar como entrada de tal forma que su versión operativa es la siguiente:

- Ubicación pase 1
- Ubicación pase 2
- Ubicación pase 3
- Valores 1 en caso de derramar y 0 en caso de no derramar
- Valores 1 en caso de haber daño y 0 en caso de no haber daño
- Valor del Roll

Quedando así los datos con la siguiente distribución:

|            | # elementos | % Total |
|------------|-------------|---------|
| Derrama    | 361         | 25,68   |
| No derrama | 1045        | 74,32   |
| Daño       | 913         | 64,94   |
| No daño    | 493         | 35,06   |

Tabla 9-1: distribución de datos de entrada

Se destaca en la tabla de predicción de derrames la existencia de una notoria diferencia entre ambos grupos de datos, lo que podría llevar eventualmente a lecturas erróneas en el caso de discriminar posteriormente los resultados solo por la exactitud del modelo, dado que si solo se pusieran 0 en la variable independiente (vector de resultados), se tendría una exactitud aproximada del 74%. Es por ello que también se debe considerar una métrica a seguir para determinar de mejor manera cual configuración de red neuronal es mejor. Para este trabajo, y fundamentado en la diferencia cardinal entre ambos grupos de datos, se decide utilizar el coeficiente de Correlación de Matthews, explicado en el marco teórico.

#### 6.4.2. PROBLEMÁTICA

La idea principal de la generación de este modelo de predicción de derrames por medio de la ubicación de los pases de las palas y la posterior aplicación de Deep learning es otorgar a futuro una herramienta al operador de la pala, la cual entregará información en línea de las condiciones en que se encuentra el equipo al que procederá a cargar, con el objetivo de reducir la probabilidad de derrame al menor costo posible.

Para esto es necesario que la herramienta entregue resultados con un alto grado de confianza en tiempos inferiores a 10 segundos. Es por ello que la métrica a utilizar será el coeficiente de correlación de Matthews, el cual entregará el grado de clasificación o predictibilidad del modelo para la configuración de parámetros e hiperparámetros otorgada.

#### 6.4.3. MÉTODO DE VALIDACIÓN A UTILIZAR

Como método de validación de las redes neuronales se utilizará el método estático hold up validation. Esto dado que la base de datos es pequeña, sigue un orden aleatorio y no tiene datos duplicados. Se descarta el uso de validación cruzada principalmente por no contar con la infraestructura computacional para llevarla a cabo de manera eficiente.

#### 6.4.4. DETERMINACIÓN DE LAS FUNCIONES DE ACTIVACIÓN

Para determinar cuál función de activación se utilizará en la capa de salida se dispuso de una red de 4 capas ocultas de 5 neuronas cada una, más una capa de salida de 1 neurona. Para esta red se realizaron pruebas con 3 tipos de funciones, la función Relu, la función sigmoidea y la función softmax, utilizando a su vez estas mismas 3 funciones como función de activación de la capa inicial, y solo utilizando la función Relu en las capas ocultas intermedias. Todas las pruebas fueron con un tamaño de batch de 60 y una cantidad de 200 epoch, utilizando la función de costo de entropía cruzada binaria, además del optimizador Adam.

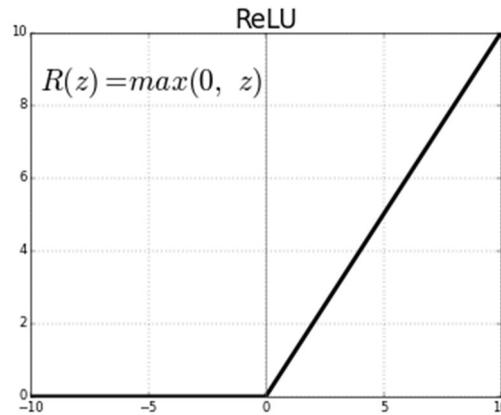


Gráfico 9-8: Función Relu (Fuente: ml4a.github.io)

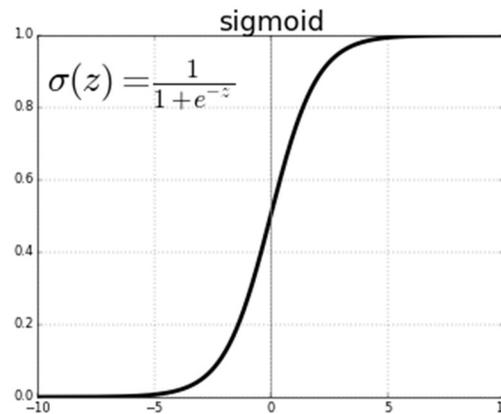


Gráfico 9-9: Función Sigmoidea (Fuente:ml4a.github.io)

| N | IN   | OUT  | Precisión Entrenam. [%] | Precisión Valid. [%] | Exactitud [%] | Precisión [%] | Recall [%] | Tiempo [s] | MCC    | rank |
|---|------|------|-------------------------|----------------------|---------------|---------------|------------|------------|--------|------|
| 1 | relu | sig  | ceros                   | ceros                | 70,92         | indef         | 0          | 7,66       | 0      |      |
| 2 | relu | sig  | 78,09                   | 78,67                | 76,24         | 62,3          | 46,34      | 7,28       | 0,3843 | 8    |
| 3 | relu | sig  | 78,98                   | 80                   | 77,3          | 63,64         | 51,22      | 6,31       | 0,4207 | 4    |
| 4 | sig  | sig  | 77,31                   | 80                   | 78,01         | 71,74         | 40,244     | 7,19       | 0,4147 | 7    |
| 5 | sig  | sig  | 78,09                   | 80                   | 78,01         | 69,23         | 43,9       | 7,11       | 0,4204 | 5    |
| 6 | sig  | sig  | 77,42                   | 79,11                | 78,37         | 73,33         | 40,24      | 7,63       | 0,4246 | 3    |
| 7 | sig  | sig  | 77,86                   | 80                   | 78,37         | 70,59         | 43,9       | 7,08       | 0,4295 | 1    |
| 8 | relu | soft | unos                    | unos                 | 29,08         | 29,08         | 100        | 6,94       | 0      |      |

|    |      |      |       |       |       |       |       |       |        |   |
|----|------|------|-------|-------|-------|-------|-------|-------|--------|---|
| 9  | sig  | soft | unos  | unos  | 29,08 | 29,08 | 100   | 8,203 | 0      |   |
| 10 | soft | sig  | 77,86 | 79,56 | 78,01 | 70    | 42,68 | 6,641 | 0,4183 | 6 |
| 11 | soft | sig  | 78,31 | 79,11 | 78,01 | 69,23 | 43,9  | 7,516 | 0,4204 | 5 |
| 12 | sig  | relu | ceros | ceros | 70,92 | indef | 0     | 7,72  | 0      |   |
| 13 | sig  | relu | 78,22 | 79,54 | 78,37 | 71,43 | 42,68 | 6,86  | 0,4277 | 2 |
| 14 | sig  | relu | 77,64 | 80    | 78,37 | 72,34 | 41,46 | 6,83  | 0,4260 | 3 |
| 15 | relu | relu | ceros | ceros | 70,92 | indef | 0     | 7,06  | 0      |   |
| 16 | relu | relu | ceros | ceros | 70,92 | indef | 0     | 7,06  | 0      |   |
| 17 | soft | relu | ceros | ceros | 70,92 | indef | 0     | 6,55  | 0      |   |
| 18 | soft | relu | ceros | ceros | 70,92 | indef | 0     | 6,55  | 0      |   |
| 19 | soft | soft | unos  | unos  | 29,08 | 29,08 | 100   | 7,31  | 0      |   |

Tabla 9-5: Lista de pruebas para distintas funciones de activación

En la tabla 9-5 las funciones son de entrada (IN) y de salida (OUT). Estas son: Relu (relu), sigmoidea (sig), softmax (soft).

Las precisiones de entrenamiento que se categorizan como ceros y unos son precisiones indefinidas debido a que el modelo estableció el valor 0 para todas las predicciones, o estableció el valor 1 para todas las predicciones.

| MCC por tipo de f.a. de salida |        |        |
|--------------------------------|--------|--------|
| f.a.                           | Media  | DS     |
| Relu                           | 0,1220 | 0,2083 |
| Sig                            | 0,3703 | 0,1395 |
| Soft                           | 0,0000 | 0,0000 |

Tabla 9-6: Matthews (MCC) para distintas funciones de activación en la capa de salida

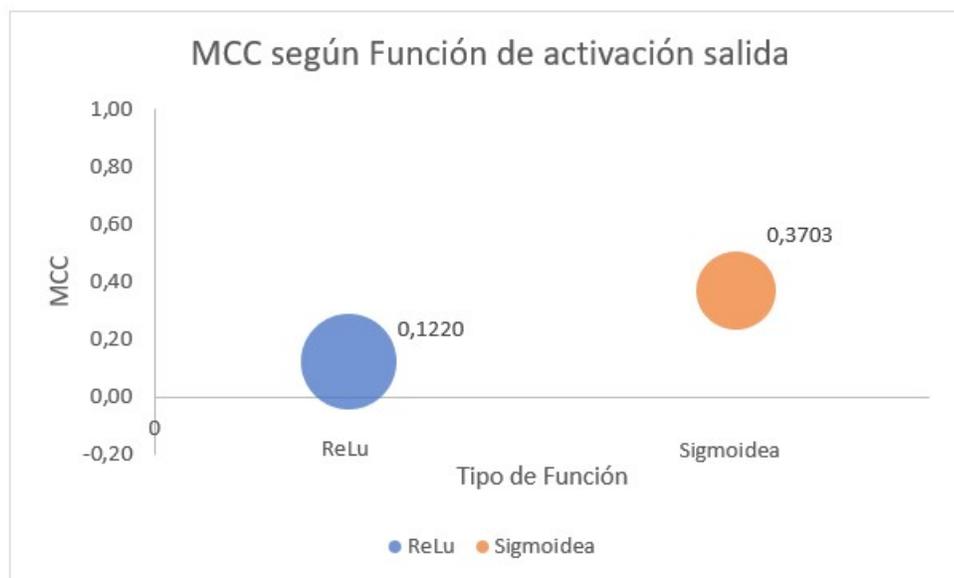


Gráfico 9-10: Valores de MCC para distintas funciones de activación en la capa de salida

En las pruebas 1, 12, 15, 16, 17, 18 el modelo no tuvo aprendizaje lo que puede deberse a que las neuronas cuya función de activación es Relu hayan “muerto”, hecho conocido como “dying ReLu”,

es decir el valor asociado a estas neuronas pertenece al conjunto de valores donde esta neurona se hace cero, propagando ese valor a las demás neuronas. Existe una solución para dicho problema, el cual es utilizar la función de activación Leaky Relu, la cual incorpora una pendiente en la zona negativa del dominio, en vez que solo sea cero. Sin embargo, en este trabajo no fue necesario probar con dicha función, dado que se hay otras alternativas con las cuales se puede trabajar sin problemas.

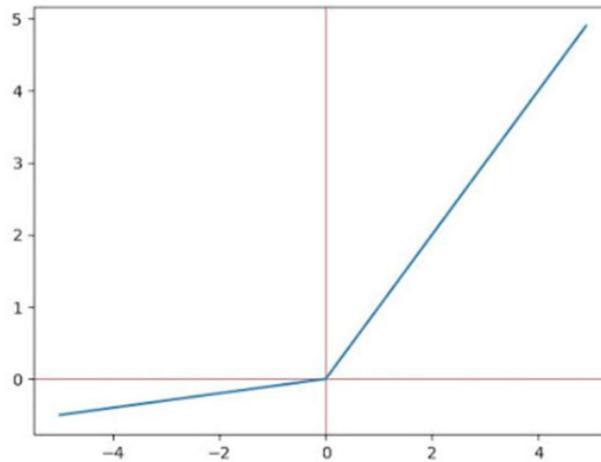


Gráfico 9-11: Función Leaky Relu (Fuente: datatechnotes.com)

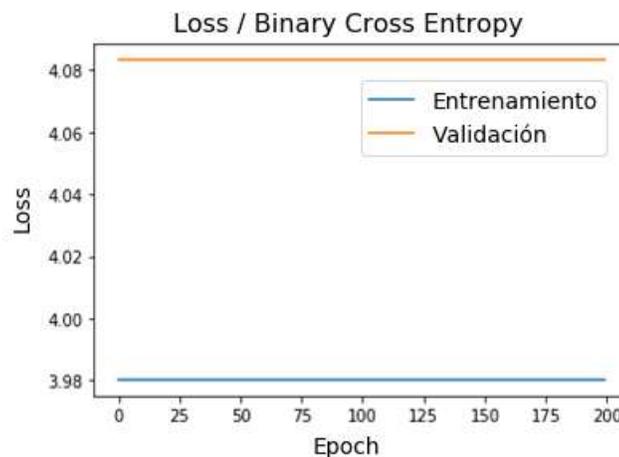


Gráfico 9-12: Función de costo donde existe “dying ReLu”

|      |   | Predicción |   |
|------|---|------------|---|
|      |   | 0          | 1 |
| Real | 0 | 200        | 0 |
|      | 1 | 82         | 0 |

Tabla 9-7: Matriz de confusión de los casos 1, 12, 15, 16, 17, 18.

El gráfico de la función de costo de las pruebas mencionadas anteriormente es dos líneas completamente paralelas, lo cual deja en evidencia la ausencia de aprendizaje en esta red, puesto que nunca se minimiza el error de las predicciones.

En las pruebas 8, 9 y 19 la función de salida es la función softmax, la cual es una excelente función de activación si el objetivo es clasificar entre 3 o más alternativas, pero no así cuando es un problema binario. Esto sucede pues la función softmax siempre va a entregar el valor 1 por respuesta cuando en la capa de salida haya solo 1 neurona, que es el caso de una clasificación binaria que solo responde 0 o 1, mientras que para una clasificación de elementos, como por ejemplo imágenes de perros, gatos y conejos, la función softmax tendrá una capa de salida de 3 neuronas, cada una de un valor representativo a la probabilidad de dicha respuesta, donde la suma de estas 3 es la probabilidad total que es siempre 1. Por lo tanto, se descarta su uso como función de activación de la capa de salida.

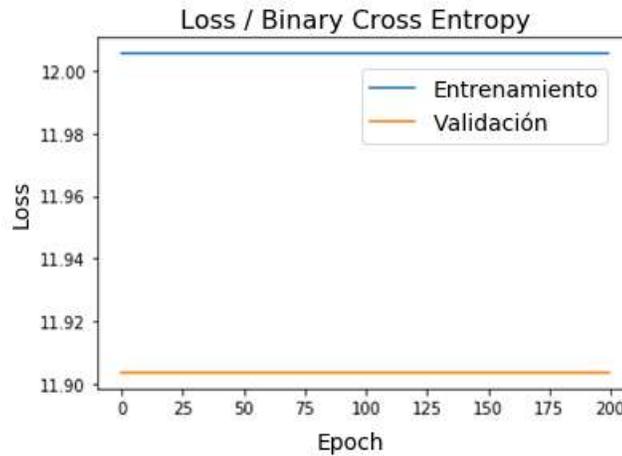


Gráfico 9-13: Función de costo donde la función de activación de la salida es softmax.

|      |   | Predicción |     |
|------|---|------------|-----|
|      |   | 0          | 1   |
| Real | 0 | 0          | 200 |
|      | 1 | 0          | 82  |

Tabla 9-8: Matriz de confusión de los casos 8, 9 y 19.

Finalmente, los casos que presentan mejor ranking, evaluados según la métrica que se está utilizando, fueron rankeados del 1 al 7. Las funciones de activación que mejor se desempeñaron como salida fueron las ReLu y las sigmoidea. Sin embargo, la función de salida ReLU puede presentar, tal como en los otros casos, resultados de “muerte neuronal”, es por este motivo que se selecciona a la función sigmoidea. A su vez, la literatura también confirma esta decisión al ser la función sigmoidea la preferida para las tareas de clasificación binaria. (Chollet. 2018) (Goodfellow, et al., 2016)

Para la capa de entrada la función sigmoidea funcionó bien en estas pruebas, por lo tanto, es la elegida para ser utilizada. Así mismo la función ReLu se utiliza generalmente para las capas intermedias, conocidas como capas ocultas. (Goodfellow, et al., 2016)

| MCC por tipo de f.a. de entrada |       |    |
|---------------------------------|-------|----|
| f.a.                            | Media | DS |

|      |        |        |
|------|--------|--------|
| Relu | 0,1342 | 0,2082 |
| Sig  | 0,3179 | 0,1963 |
| Soft | 0,1678 | 0,2297 |

Tabla 9-9: MCC para distintas funciones de activación en la capa de entrada

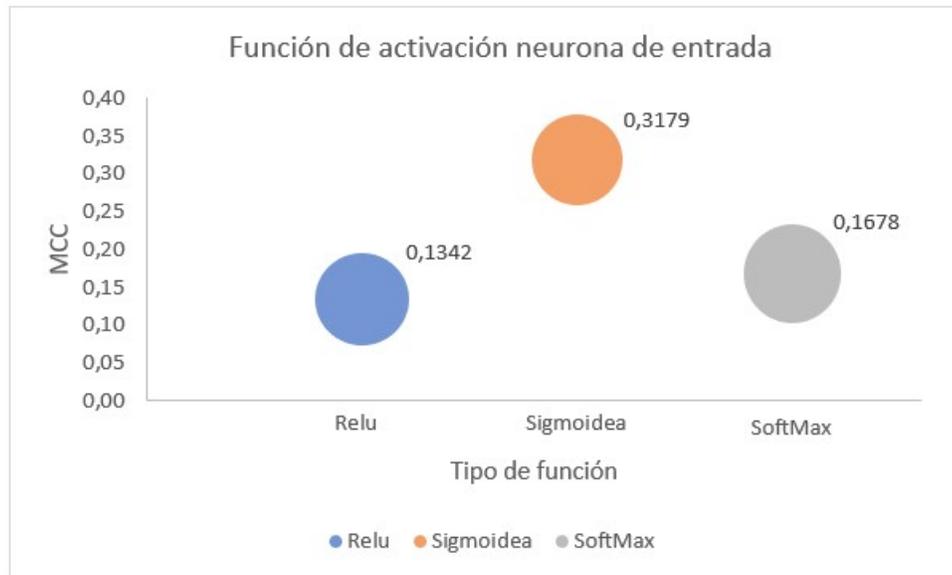


Gráfico 9-14: Valores de MCC para distintas funciones de activación de entrada

#### 6.4.5. SELECCIÓN DE FUNCION DE COSTO Y MÉTODO DE OPTIMIZACIÓN

La elección de la función de costo está ligada a la función de activación de la unidad de salida (Goodfellow, et al., 2016), que en este caso es la función sigmoidea. Dado esto se utiliza la función de costo de entropía cruzada binaria, pues en combinación con la función sigmoidea en la capa de salida han demostrado tener grandes resultados y ser la solución por excelencia para los casos de clasificación binaria. (Chollet. 2018)

Cabe recordar que la función de costo es la función por la cual se calcula el error del modelo de clasificación o predicción. Dicha función está asociada a un método de optimización de cálculo, el cual permite encontrar un mínimo en la función de costo con mayor rapidez que el método del descenso del gradiente original. Esto se produce gracias a el control del tamaño del paso en cada iteración dentro del cálculo del error por medio de una elección arbitraria de la tasa de aprendizaje. Como método de optimización se utilizó el algoritmo ADAM, uno de los más utilizados actualmente (Chollet. 2018) y en especial para problemas de clasificación binaria.

#### 6.4.6. DETERMINACIÓN DE LA RED NEURONAL

Se realizó un análisis para determinar que configuración neuronal satisfacía de mejor manera las condiciones necesarias para la predicción, las cuales son alcanzar un valor de MCC tan alto como permita el modelo, y que el tiempo total entre entrenamiento y validación sea inferior a 10 segundos. Para ello se estudiaron diferentes alternativas de cantidad de capas ocultas, cantidad de neuronas por capa, número de epochs y tamaño de batch.

#### 6.4.6.1. RED NEURONAL DE PREDICCIÓN DE DERRAMES

Inicialmente se configura la red con 1 capa oculta. Esta capa oculta será de 3, 7 o 23 neuronas y cada alternativa será calculada con un mismo tamaño de batch, pero con distinta cantidad de epochs, es decir se utilizan en todos los casos la misma cantidad de datos por lectura, pero se aumenta el número de lecturas para determinar los valores finales.

Los valores de los parámetros e hiperparámetros, entendiéndose por hiperparámetros el tamaño del batch y el número de epochs) fueron seleccionados arbitrariamente como valores iniciales, para luego ir modificándolos en caso de ser necesario en búsqueda de la obtención de un mejor resultado, el cual es obtener un coeficiente de correlación de Matthews lo más alto posible dentro de un tiempo menor a 10 segundos. Este tiempo se determina pensando en un posterior uso en la operación de carguío, de tal forma de no afectar mayormente el tiempo de ciclo de carguío.

##### PREDICTIBILIDAD CON 1 CAPA OCULTA

Para el caso de 3 neuronas, como también para los casos de 7 y 23 neuronas, se seleccionó un tamaño de batch de 20 y distinta cantidad de epochs, desde 500 épocas el mayor, para luego ir disminuyendo la cantidad de epochs y así saber con esto desde que número de epochs puede comenzar un posible error por overfitting. Sin embargo, para esta configuración de neuronas e hiperparámetros no hubo existencia de overfitting.

##### PREDICTIBILIDAD CON 2 CAPAS OCULTAS

Para este análisis se seleccionaron configuraciones de 3 y 7 neuronas en la primera capa oculta y de 10, 20 y 40 neuronas en la segunda capa oculta. Se excluyó esta vez la alternativa de 23 neuronas en la primera, pues al agregar una segunda capa oculta de neuronas a la red, se incrementa el tiempo de entrenamiento, el cual ya era cercano a la condición solicitada, pudiendo excederla. Este incremento de tiempo se hará evidente en los siguientes análisis de 2 y 3 capas de neuronas.

Los análisis de cada alternativa se realizaron con una configuración de hiperparámetros de la siguiente forma:

- Batch de tamaño 20
- Epochs: 100 y 50

No se consideraron los casos de 230 y 500 epoch, esto a causa de que aún logrando buenos resultados de predictibilidad, dentro de las posibilidades del modelo, estos se realizaban en tiempos que excedían la condición de tiempo impuesta.

##### PREDICTIBILIDAD CON 3 CAPAS OCULTAS

En este análisis se añade una tercera capa oculta a la red, de dimensión idéntica a la segunda capa. Es decir, son configuraciones de tipo 3-10-10 neuronas, o 3-20-20, etc.

#### 6.4.6.2. RED NEURONAL DE PREDICCIÓN DE DAÑO

Como ya se ha mencionado anteriormente, se utiliza el KPI Roll del camión para establecer el daño en el mismo. Para efectos de este trabajo se considera la existencia de daño desde un Roll igual o superior a 2.

La estrategia es encontrar por inspección una alternativa que presente una función de coste tal que la diferencia entre su entrenamiento y validación sea del orden de 2% o inferior, además de lograr un alto valor de MCC, y que se obtenga en un tiempo cercano a 5 segundos.

#### PREDICTIBILIDAD CON 1 CAPA OCULTA

Para este análisis se realizan pruebas con 1 capa neuronal oculta de 3, 7, 11 y 23 neuronas, las cuales se probaron a una misma cantidad de epochs (200 epochs), y a diferentes tamaños de batch (20, 32, 50 y 100).

#### PREDICTIBILIDAD CON 2 CAPAS OCULTAS

En esta etapa se analizó la configuración de una primera capa oculta de 7 neuronas y una segunda capa oculta de 10 y 20 neuronas. El tamaño de la primera capa fue elegido de manera arbitraria, con el objetivo de seguir explorando otras alternativas en caso de no lograr una solución satisfactoria, la cual fue lograda con la configuración de 7-20 neuronas. Se entiende por solución satisfactoria aquella que cumpla numérica y gráficamente las condiciones requeridas, las cuales son tener un grado de predictibilidad o MCC alto, una alta exactitud y precisión, además de un tiempo de entrenamiento del orden de 5 segundos. Mientras que gráficamente debe presentar una función de coste con una mínima diferencia entre el error de entrenamiento y el error asociado a la validación, además de mostrar resultados con poca variación al ejecutarse varias veces el mismo modelo, lo que representa cierto grado de estabilidad del resultado.

### 6.5. EVALUACIÓN ECONÓMICA

#### 6.5.1. DESCRIPCIÓN Y PARÁMETROS A UTILIZAR

Una vez definida la correlación entre posición del balde con esfuerzos en las suspensiones y ocurrencia de derrames ante un determinado ángulo de rampa, se evalúa el modelo comparando escenarios para casos sin derramen ruta, con 1 derrame y 2 derrames. Dichas evaluaciones serán para un caso base, con valores en régimen o cercanos al régimen operacional, y para un caso denominado “peor caso” donde tanto las variables económicas, como los incrementos en los costos cambian para presentar un peor escenario de operación.

Para generar estas evaluaciones económicas se realiza el desarrollo de un código en lenguaje Python, de tal forma que permita hacer uso de los datos entregados por las redes neuronales generadas, y así realizar una breve simulación de una mina. El código fuente de esta sección se puede encontrar en la sección de anexos.

Las simulaciones reflejan el comportamiento del carguío y transporte a nivel diario, durante 360 días al año. Se simulan 15 años, en 3 corridas de 5 años cada una. Los casos simulados son:

- Caso Base sin derrames
- Caso Base con 1 derrame
- Caso Base con 2 derrames
- Peor Caso sin derrames
- Peor Caso con 1 derrame
- Peor Caso con 2 derrames

Los parámetros a considerar para esta evaluación son los siguientes: Precio de libra de Cu, Precio del barril de petróleo WTI, Costo de Mantenimiento de equipos, Costo de Neumáticos. A su vez se consideran incrementos en los costos asociados tanto al daño generado por el carguío dinámico, como por el consumo de combustible provocado por el reinicio de la marcha de un camión, posterior a su detención ante un derrame en la ruta. Estos valores incrementales son porcentajes elegidos para conceptualizar la situación y no obedecen a algún estudio o información asociada.

### 6.5.2. PRECIO DEL CU

El precio del cobre para el caso base y para el peor caso fue determinado utilizando valores trimestrales, los cuales fueron calculados desde la información obtenida en la página [boletín.cochilco.cl](http://boletín.cochilco.cl).

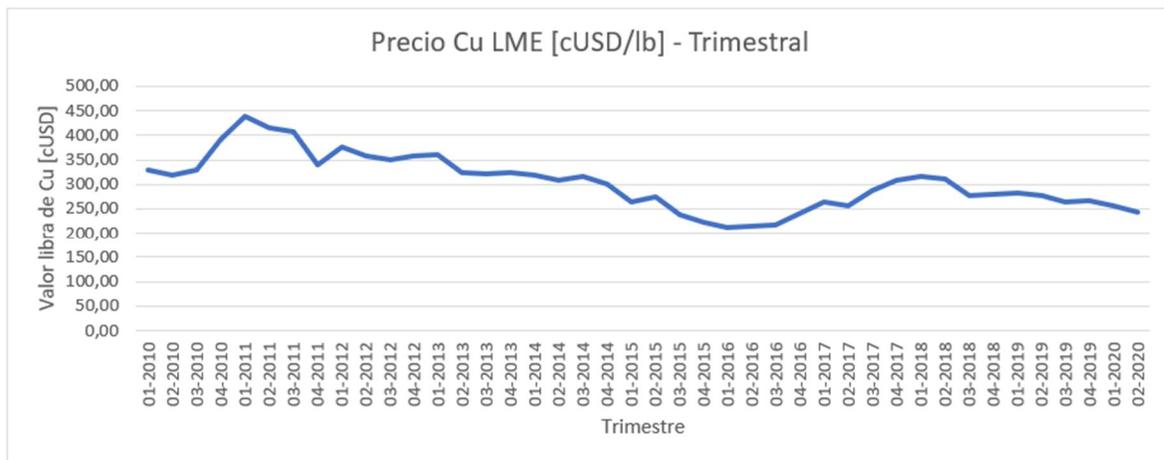


Gráfico 10-1: Precio Cu (trimestral) – LME. (Fuente: Cochilco)

Para el caso base se considera un valor de precio de cobre de 250 cUSD/lb, mientras que para el peor caso un valor de 200 cUSD/lb.

### 6.5.3. PRECIO DE PETROLEO

Para determinar los valores del costo del petróleo se utiliza la información mensual histórica del precio del barril de petróleo WTI, la cual fue obtenida desde la página web [investing.com](http://investing.com), y se determina el promedio de cada trimestre.

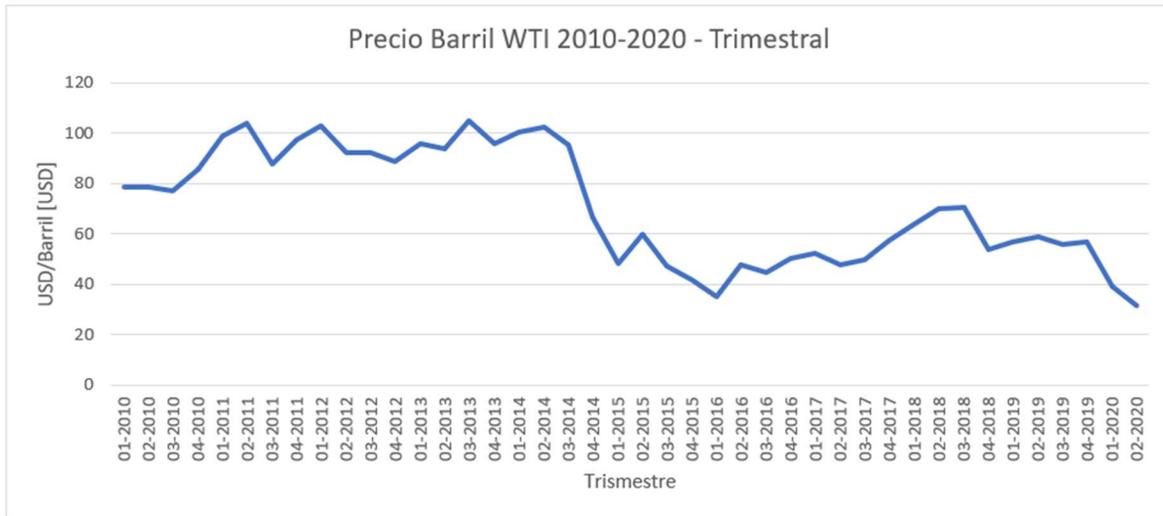


Gráfico 10-2: Precio trimestral de Petróleo WTI. (Fuente: investing.com)

El valor utilizado para el precio del barril de petróleo para el caso base es de 60 dólares, mientras que para el peor caso es de 70 dólares el barril.

#### 6.5.4. COSTO DE MANTENCIÓN

El costo de mantenimiento es de 59 [USD/hora] por camión para el caso base (Vidal, 2010). Para el peor caso se asume un aumento del 10% aproximadamente, resultando un valor de 65[USD/hora] por camión.

#### 6.5.5. COSTO DE NEUMÁTICOS

El costo de los neumáticos es de 65.000 USD por unidad y de una duración de 4688 horas. Estos valores se consideran para el caso base, mientras que para el peor caso se asume un aumento del 10% resultando 71.500 USD y una duración de 3.722 horas. (Blanco, 2016)

#### 6.5.6. VALORES DE INCREMENTOS DE COSTOS

Estos valores de incremento son aumentos en los costos asociados por daño mecánico, en el caso del mantenimiento y de los neumáticos; y por ocurrencia de derrame en el caso del petróleo. Estos valores son meramente conceptuales, por lo que requieren ser medidos en algún trabajo futuro.

El incremento del costo de mantención es el 1% del costo de mantención por ciclo, y se hace efectivo al existir daño por esfuerzo, es decir tener un valor de Roll superior a 2. Este valor va multiplicado por dicho daño al momento de calcular el costo de mantenimiento total. Para el peor caso este valor es de 2%.

Luego, si  $Roll > 2$ :

$$CMant_{ciclo} = CMant_{ciclo} * (1 + Incremento * Roll)$$

Igualmente, el incremento del costo de neumático es el 2% del costo del neumático por ciclo en el caso base, y del 5% en el peor caso. También aumenta su valor dentro del cálculo del costo de neumáticos según exista daño por carguío desbalanceado y de que magnitud es dicho daño.

Si  $Roll > 2$ :

$$C_{Neumatico_{ciclo}} = C_{Neumatico_{ciclo}} * (1 + Incremento * Roll)$$

El incremento del costo de petróleo es el 10% del costo de petróleo por ciclo para el caso base, y este costo aparece cuando existe un derrame en ruta. Representa el esfuerzo y gasto de combustible realizado al comenzar nuevamente el viaje una vez detenido en rampa por causa de un derrame. Para el peor caso el valor de este incremento es del 20%.

Si hay derrame en el ciclo:

$$C_{petroleo_{ciclo}} = C_{petroleo_{ciclo}} * (1 + Incremento)$$

Posteriormente se analiza el peor caso, pero con valores de 70% para todos los incrementos, en los casos sin derrame, y con 1 derrame.

Así también, posterior al análisis del peor caso con incrementos del 70%, se analiza el peor caso con un precio del cobre de 1 dólar la libra.

En síntesis, los valores utilizados para elaborar la evaluación económica son:

|                                    | Caso Base | Peor Caso |
|------------------------------------|-----------|-----------|
| Precio Cu [USD/Lb]                 | 2,5       | 2         |
| Precio Cu [USD/ton]                | 5511      | 4409      |
| Ley Cu [%]                         | 0,4       | 0,2       |
| Costo Mantenición [USD/hora]       | 59        | 65        |
| Costo Petroleo [USD/barril]        | 60        | 70        |
| Costo Neumáticos [USD/neumático]   | 65000     | 71500     |
| Duración Neumáticos [hr]           | 4688      | 3722      |
| Incremento Costo de neumático [%]  | 2%        | 5%        |
| Incremento Costo de petróleo [%]   | 10%       | 20%       |
| Incremento Costo de mantención [%] | 1%        | 2%        |

Tabla 10-1: Parámetros utilizados para la evaluación económica del caso base y del peor caso

## 7. RESULTADOS

### 7.1. SIMULACIÓN

#### 7.1.1 CASO BASE (SIN DERRAMES)

Para el caso base se ejecuta el modelo solo con las demoras programadas, los cuales corresponden a los periodos de colación y de cambios de turno. Por lo cual, cualquier pérdida de utilización efectiva corresponde a demoras en la cola de la pala, dado que para el modelo tanto las colas de las estaciones de derrame como también la cola en el chancador tienen valor cero.



Gráfico 8-1: Utilización efectiva del modelo sin derrames.

| UE Caso Base [%] |       |
|------------------|-------|
| Promedio         | 78,40 |
| Desviación Std.  | 1,03  |

Tabla 8-5: Promedio y desviación estándar de la utilización efectiva del caso sin derrames

El valor promedio de la utilización efectiva calculada en este caso es el referente para calcular la pérdida de utilización efectiva en los casos posteriores.

#### 7.1.2 CASO 1 DERRAME POR CICLO DE FLOTA (CADA 10 CAMIONES)

En este apartado se analizan los casos donde la frecuencia de bloqueo en las estaciones de derrame es de 10 entidades y solo en 1 estación de derrame por caso, con la intención de que se simule que ocurriría si hay 1 solo derrame por ciclo de flota. Al decir ciclo de flota se hace referencia a cada vez que los 10 camiones realizan un ciclo.

La primera ocurrencia de derrame será cuando pasen 5 unidades por la estación a estudiar, luego cuando pase la quinceava y así sucesivamente cada 10 unidades.

Para hacer referencia a la utilización efectiva se utiliza la sigla UE, mientras que para la pérdida de utilización efectiva por derrame se utiliza la sigla PUEPD, para la pérdida de tiempo por derrame,

o demora por derrame, se utiliza DPD y para la pérdida de utilización efectiva por minuto perdido se utiliza PUEPMP.

Los gráficos de Pérdida de tiempo por derrame y de pérdida de utilización efectiva por derrame asociados a cada uno de los casos se encuentran en el apéndice asociado a este capítulo, mientras que en este apartado se enseña los valores medios y el rango donde está el 80% de los casos de pérdida de tiempo por derrame con su respectiva pérdida de utilización efectiva.

### Estación 1

Para esta estación se tiene la siguiente información:

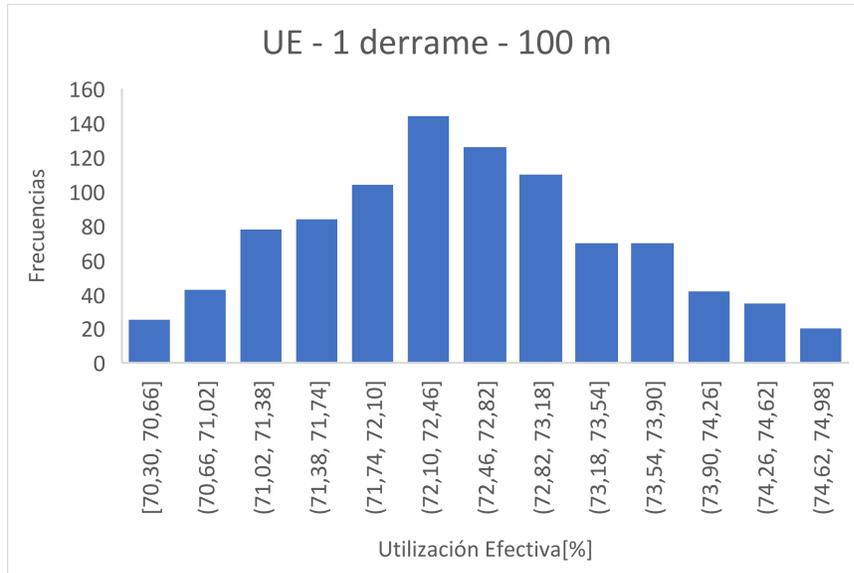


Gráfico 8-2: UE en el caso de 1 derrame por ciclo a 100 m.

| UE 1 Derrame - 100 m [%] |       |
|--------------------------|-------|
| Promedio                 | 72,40 |
| Desviación Std.          | 1,12  |

Tabla 8-6: UE en el caso de 1 derrame por ciclo de flota a 100 m

Luego, se procede a calcular cuanta pérdida de tiempo y de utilización efectiva hay en función a cada derrame, datos que serán utilizados luego en el apartado de evaluación económica.

| 1 Derrame 100 m |           |           |            |
|-----------------|-----------|-----------|------------|
|                 | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio        | 5,43      | 0,23      | 0,043      |
| Desviación Std. | 0,53      | --        | --         |
| 80% Superior    | 6,09      | 0,29      | 0,048      |
| 80% Inferior    | 4,64      | 0,17      | 0,037      |

Tabla 8-7: Resultados para el caso de 1 derrame a 100 metros

Estación 2

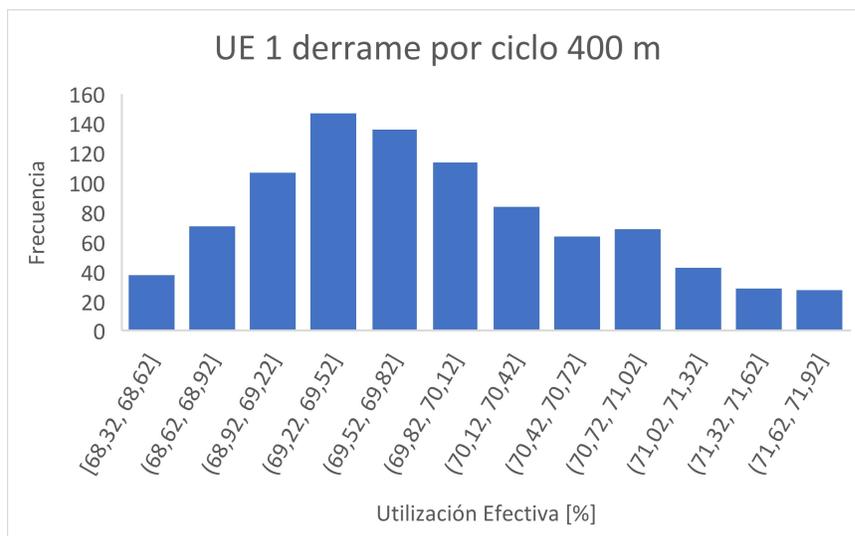


Gráfico 8-3: UE en el caso de 1 derrame por ciclo a 400 m.

| UE 1 Derrame - 400 m [%] |       |
|--------------------------|-------|
| Promedio                 | 69,87 |
| Desviación Std.          | 0,83  |

Tabla 8-8: UE en el caso de 1 derrame por ciclo de flota a 400 m

| 1 Derrame 400 m |           |           |            |
|-----------------|-----------|-----------|------------|
|                 | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio        | 6,89      | 0,35      | 0,051      |
| Desviación Std  | 0,49      | --        | --         |
| 80% Superior    | 7,45      | 0,40      | 0,053      |
| 80% Inferior    | 6,14      | 0,29      | 0,048      |

Tabla 8-9: Resultados para el caso de 1 derrame por ciclo de flota en 400 m.

Estación 3

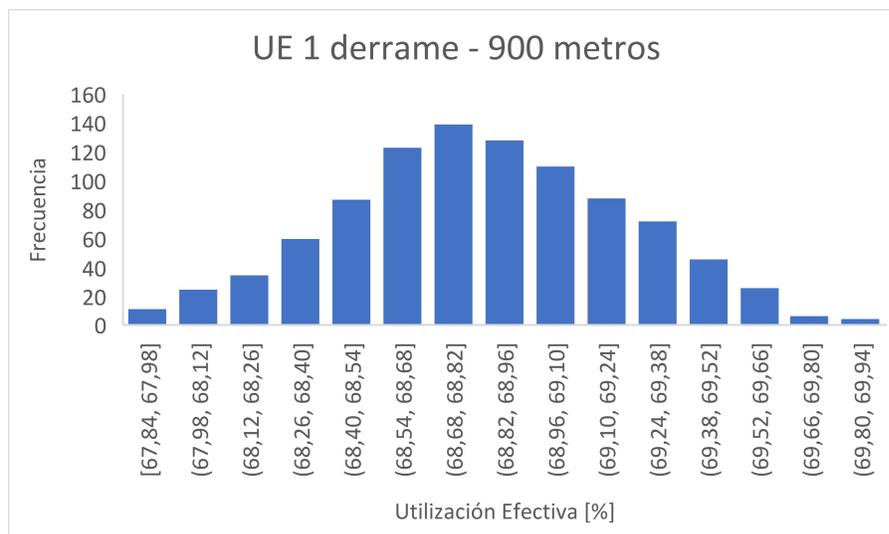


Gráfico 8-4: UE en el caso de 1 derrame por ciclo de flota a 900 m.

| UE 1 Derrame - 900 m [%] |       |
|--------------------------|-------|
| Promedio                 | 68,83 |
| Desviación Std.          | 0,39  |

Tabla 8-10: UE en el caso de 1 derrame por ciclo de flota a 900 m

| 1 Derrame 900 m |           |           |            |
|-----------------|-----------|-----------|------------|
|                 | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio        | 7,46      | 0,4       | 0,053      |
| Desviación Std  | 0,19      | --        | --         |
| 80% Superior    | 7,7       | 0,42      | 0,054      |
| 80% Inferior    | 7,2       | 0,38      | 0,052      |

Tabla 8-11: Resultados para el caso de 1 derrame por ciclo de flota en 900 m.

Estación 4

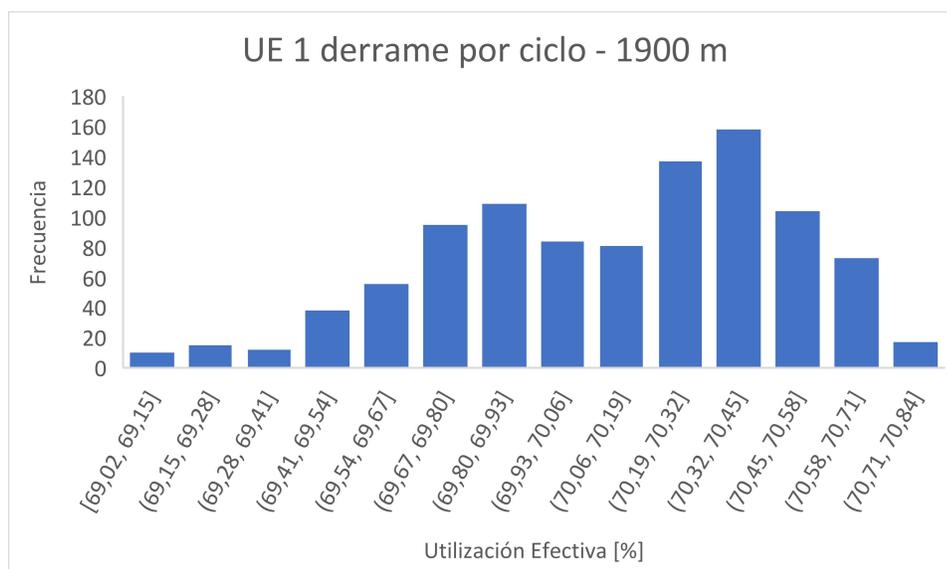


Gráfico 8-5: UE en el caso de 1 derrame por ciclo de flota a 1900 m.

| UE 1 Derrame - 1900 m [%] |       |
|---------------------------|-------|
| Promedio                  | 70,11 |
| Desviación Std.           | 0,38  |

Tabla 8-12: UE en el caso de 1 derrame por ciclo de flota a 1900 m

| 1 Derrame 1900 m |           |           |            |
|------------------|-----------|-----------|------------|
|                  | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio         | 6,74      | 0,34      | 0,050      |
| Desviación Std   | 0,30      | --        | --         |
| 80% Superior     | 7,09      | 0,37      | 0,052      |
| 80% Inferior     | 6,36      | 0,31      | 0,049      |

Tabla 8-13: Resultados para el caso de 1 derrame por ciclo de flota en 1900 m.

Estación 5

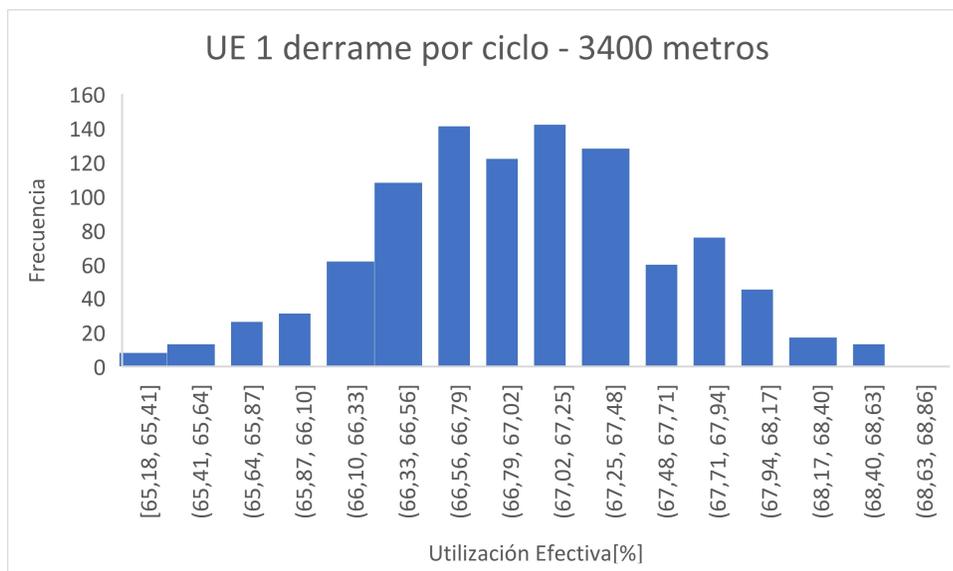


Gráfico 8-6: UE en el caso de 1 derrame por ciclo de flota a 3400 m.

| UE 1 Derrame - 3400 m [%] |       |
|---------------------------|-------|
| Promedio                  | 67,00 |
| Desviación Std.           | 0,65  |

Tabla 8-14: UE en el caso de 1 derrame por ciclo de flota a 3400 m

| 1 Derrame 3400 m |              |           |            |
|------------------|--------------|-----------|------------|
|                  | DPD<br>[min] | PUEPD [%] | PUEPMP [%] |
| Promedio         | 8,59         | 0,49      | 0,057      |
| Desviación Std   | 0,46         | --        | --         |
| 80% Superior     | 9,10         | 0,53      | 0,059      |
| 80% Inferior     | 7,93         | 0,44      | 0,056      |

Tabla 8-15: Resultados para el caso de 1 derrame por ciclo de flota en 3400 m.

### 7.1.3. CASO 2 DERRAMES POR CICLO DE FLOTA EN UNA MISMA ESTACIÓN

En estos casos la frecuencia de bloqueo en las estaciones de derrame es cada 5 entidades y solo en 1 estación de derrame por caso, esto simula la ocurrencia de 2 derrames por ciclo de flota. La primera ocurrencia de derrame será cuando pase 1 unidad por la estación a estudiar, luego cuando pase la sexta y así sucesivamente cada 5 unidades.

#### Estación 1

Para esta estación se tiene la siguiente información:

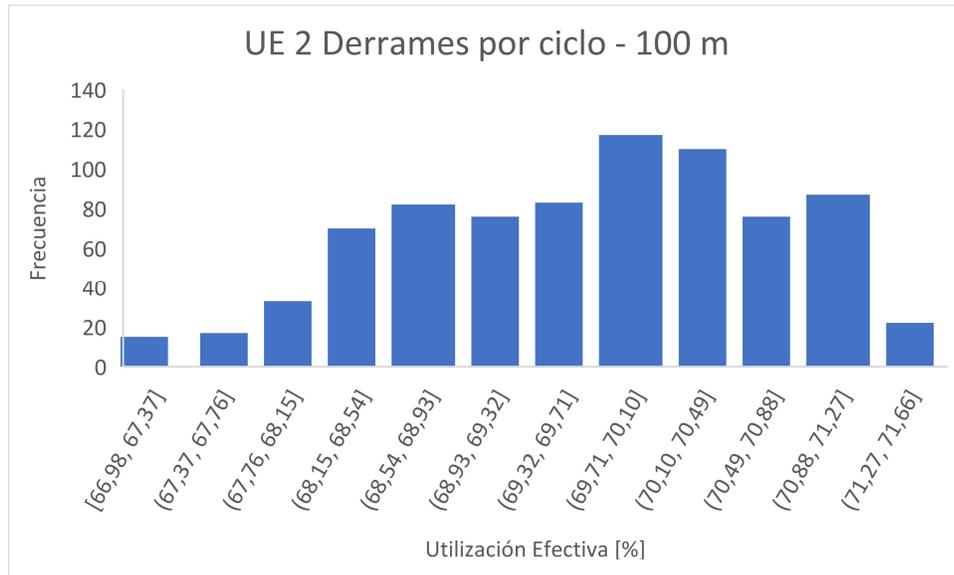


Gráfico 8-7: UE en el caso de 2 derrames por ciclo de flota a 100 m.

| UE 2 Derrames - 100 m [%] |       |
|---------------------------|-------|
| Promedio                  | 69,64 |
| Desviación Std.           | 1,03  |

Tabla 8-16: UE en el caso de 2 derrames por ciclo de flota a 100 m

| 2 Derrames 100 m |           |           |            |
|------------------|-----------|-----------|------------|
|                  | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio         | 3,49      | 0,18      | 0,052      |
| Desviación Std   | 0,30      | --        | --         |
| 80% Superior     | 3,87      | 0,21      | 0,055      |
| 80% Inferior     | 3,09      | 0,15      | 0,049      |

Tabla 8-17: Resultados para el caso de 2 derrames por ciclo de flota en 100 m.

Estación 2

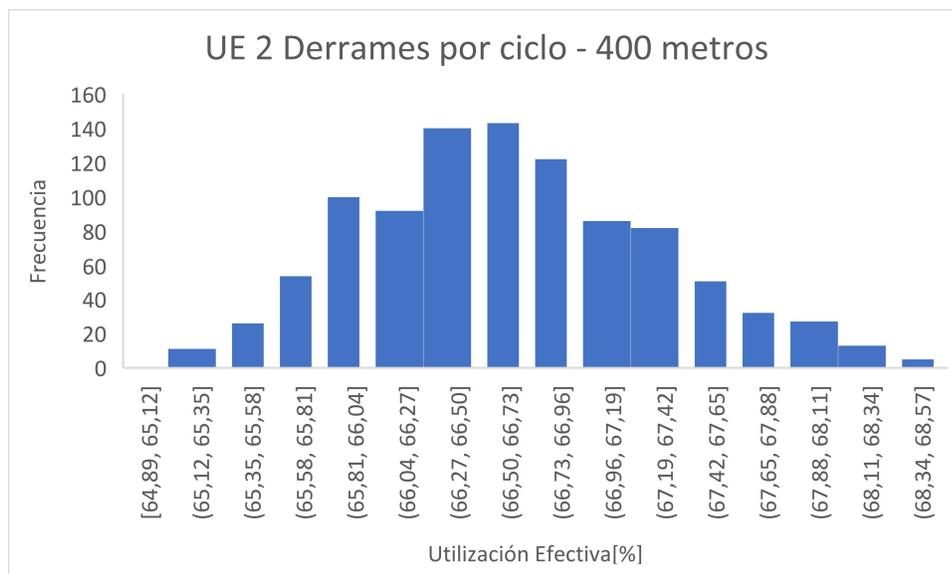


Gráfico 8-8: UE en el caso de 2 derrames por ciclo de flota a 400 m.

| UE 2 Derrames - 400 m [%] |       |
|---------------------------|-------|
| Promedio                  | 66,65 |
| Desviación Std.           | 0,66  |

Tabla 8-18: UE en el caso de 2 derrames por ciclo de flota a 400 m

| 2 Derrames 400 m |           |           |            |
|------------------|-----------|-----------|------------|
|                  | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio         | 4,42      | 0,25      | 0,057      |
| Desviación Std   | 0,20      | --        | --         |
| 80% Superior     | 4,65      | 0,27      | 0,059      |
| 80% Inferior     | 4,16      | 0,23      | 0,056      |

Tabla 8-19: Resultados para el caso de 2 derrames por ciclo de flota en 400 m.

Estación 3

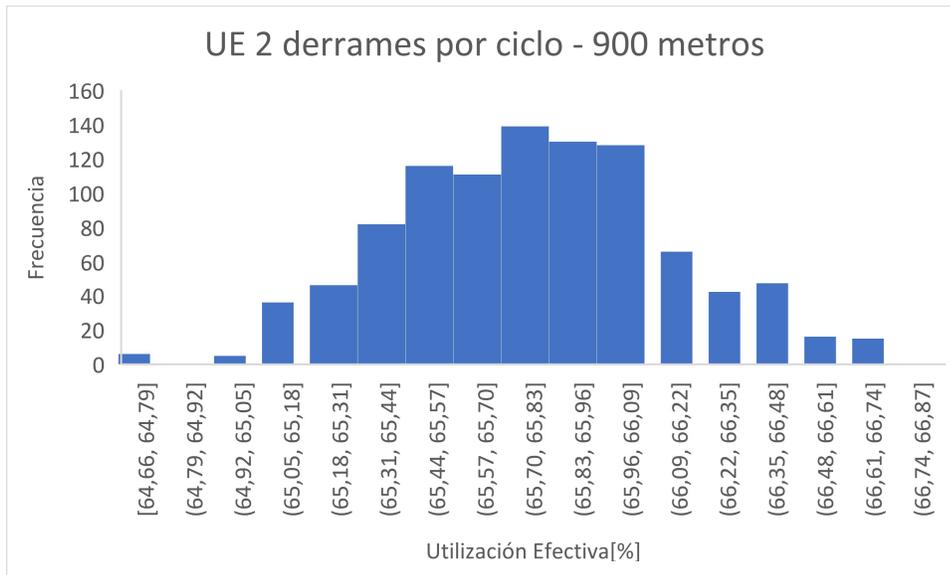


Gráfico 8-9: UE en el caso de 2 derrames por ciclo de flota a 900 m.

| UE 2 Derrames - 900 m [%] |       |
|---------------------------|-------|
| Promedio                  | 65,79 |
| Desviación Std.           | 0,38  |

Tabla 8-20: UE en el caso de 2 derrames por ciclo de flota a 900 m

| 2 Derrames 900 m |           |           |            |
|------------------|-----------|-----------|------------|
|                  | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio         | 4,66      | 0,27      | 0,059      |
| Desviación Std   | 0,09      | --        | --         |
| 80% Superior     | 4,77      | 0,29      | 0,060      |
| 80% Inferior     | 4,53      | 0,26      | 0,058      |

Tabla 8-21: Resultados para el caso de 2 derrames por ciclo de flota en 900 m.

Estación 4

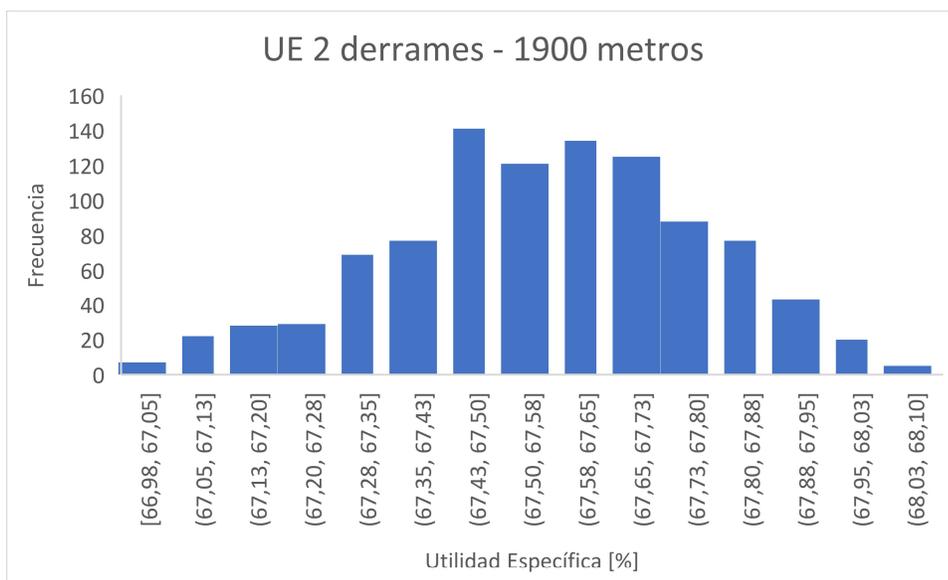


Gráfico 8-10: UE en el caso de 2 derrames por ciclo de flota a 1900 m.

| UE 2 Derrames - 1900 m [%] |       |
|----------------------------|-------|
| Promedio                   | 67,57 |
| Desviación Std.            | 0,21  |

Tabla 8-22: UE en el caso de 2 derrames por ciclo de flota a 1900 m

| 2 Derrames 1900 m |              |           |            |
|-------------------|--------------|-----------|------------|
|                   | DPD<br>[min] | PUEPD [%] | PUEPMP [%] |
| Promedio          | 4,12         | 0,23      | 0,056      |
| Desviación Std    | 0,13         | --        | --         |
| 80% Superior      | 4,28         | 0,24      | 0,057      |
| 80% Inferior      | 3,97         | 0,22      | 0,056      |

Tabla 8-23: Resultados para el caso de 2 derrames por ciclo de flota en 1900 m.

Estación 5

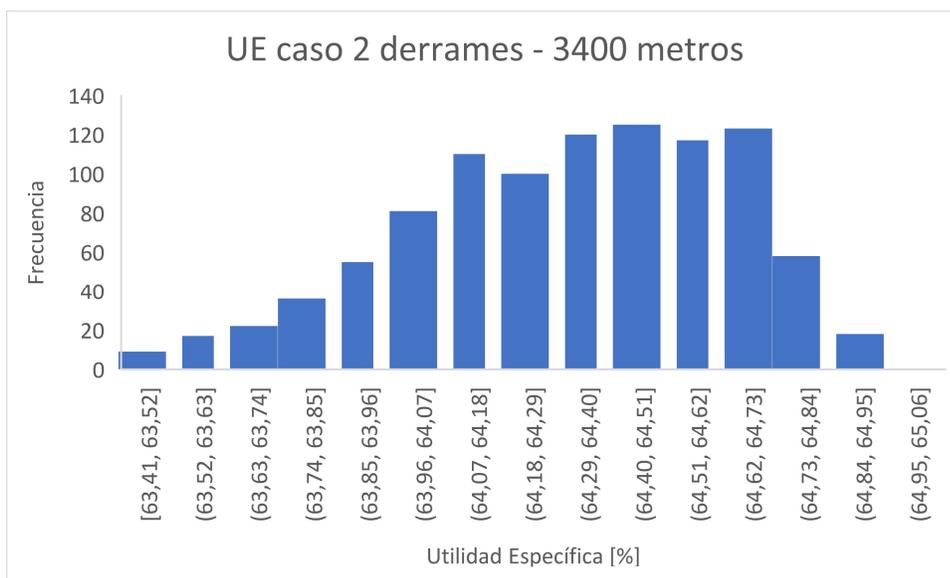


Gráfico 8-11: UE en el caso de 2 derrames por ciclo de flota a 3400 m.

| UE 2 Derrames - 3400 m [%] |       |
|----------------------------|-------|
| Promedio                   | 64,32 |
| Desviación Std.            | 0,32  |

Tabla 8-24: UE en el caso de 2 derrames por ciclo de flota a 3400 m

| 2 Derrames 3400 m |           |           |            |
|-------------------|-----------|-----------|------------|
|                   | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio          | 5,20      | 0,32      | 0,061      |
| Desviación Std    | 0,16      | --        | --         |
| 80% Superior      | 5,37      | 0,33      | 0,062      |
| 80% Inferior      | 4,93      | 0,30      | 0,061      |

Tabla 8-25: Resultados para el caso de 2 derrames por ciclo de flota en 3400 m.

### 7.1.4 CASO 2 DERRAMES POR CICLO DE FLOTA EN DISTINTOS LUGARES

En estos casos la frecuencia de derrame será cada 10 entidades por estación, comenzando luego de la primera unidad en la primera estación y de la sexta unidad que pase por la segunda estación. Quedando así configurados los derrames en la primera estación para las entidades 1, 11, 21, etc. Mientras que en la segunda estación los derrames serán luego de las entidades 6, 16, 26, etc.

*Estaciones 1 y 2 (100 m y 400 m)*

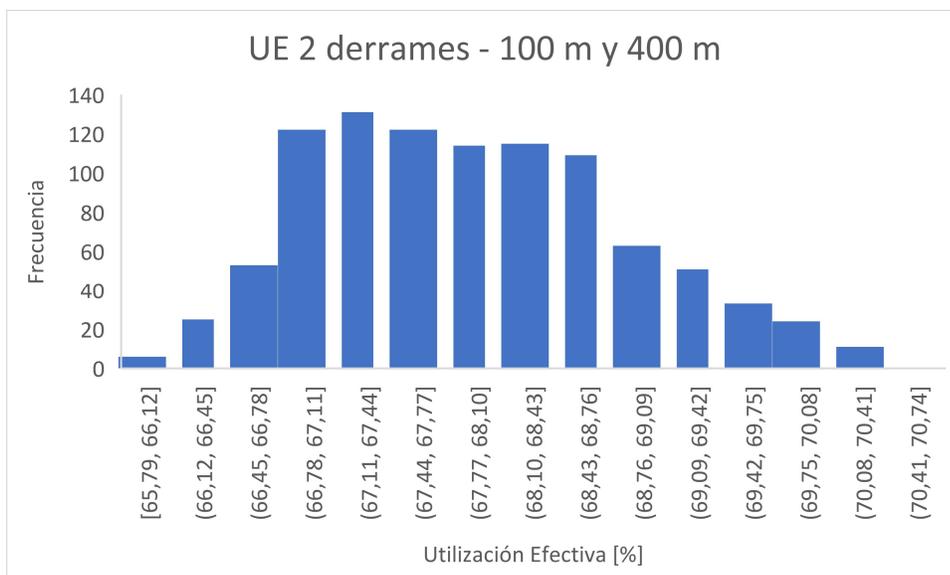


Gráfico 8-12: UE en el caso de 2 derrames por ciclo de flota a 100 y 400 metros.

| UE 2 Derrames - 100 m /400 m [%] |       |
|----------------------------------|-------|
| Promedio                         | 67,94 |
| Desviación Std.                  | 0,93  |

Tabla 8-26: UE en el caso de 2 derrames por ciclo de flota a 100 m y 400 m.

| 2 Derrames 100/400 |           |           |            |
|--------------------|-----------|-----------|------------|
|                    | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio           | 4,01      | 0,22      | 0,056      |
| Desviación Std     | 0,30      | --        | --         |
| 80% Superior       | 4,39      | 0,25      | 0,057      |
| 80% Inferior       | 3,63      | 0,19      | 0,053      |

Tabla 8-27: Resultados para el caso de 2 derrames por ciclo de flota en 100 m y 400 m.

Estaciones 1 y 3 (100 m y 900 m)

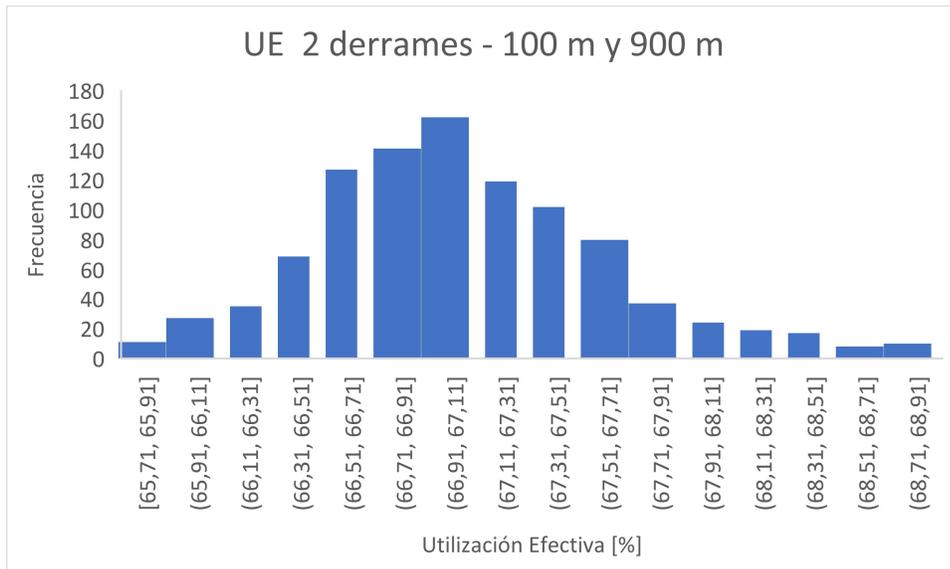


Gráfico 8-13: UE en el caso de 2 derrames por ciclo de flota a 100 y 900 metros.

| UE 2 Derrames - 100 m /900 m [%] |       |
|----------------------------------|-------|
| Promedio                         | 67,06 |
| Desviación Std.                  | 0,57  |

Tabla 8-28: UE en el caso de 2 derrames por ciclo de flota a 100 m y 900 m.

| 2 Derrames 100/900 |           |           |            |
|--------------------|-----------|-----------|------------|
|                    | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio           | 4,30      | 0,24      | 0,057      |
| Desviación Std     | 0,20      | --        | --         |
| 80% Superior       | 4,51      | 0,26      | 0,058      |
| 80% Inferior       | 3,98      | 0,22      | 0,056      |

Tabla 8-29: Resultados para el caso de 2 derrames por ciclo de flota en 100 m y 900 m.

Estaciones 1 y 4 (100 m y 1900 m)

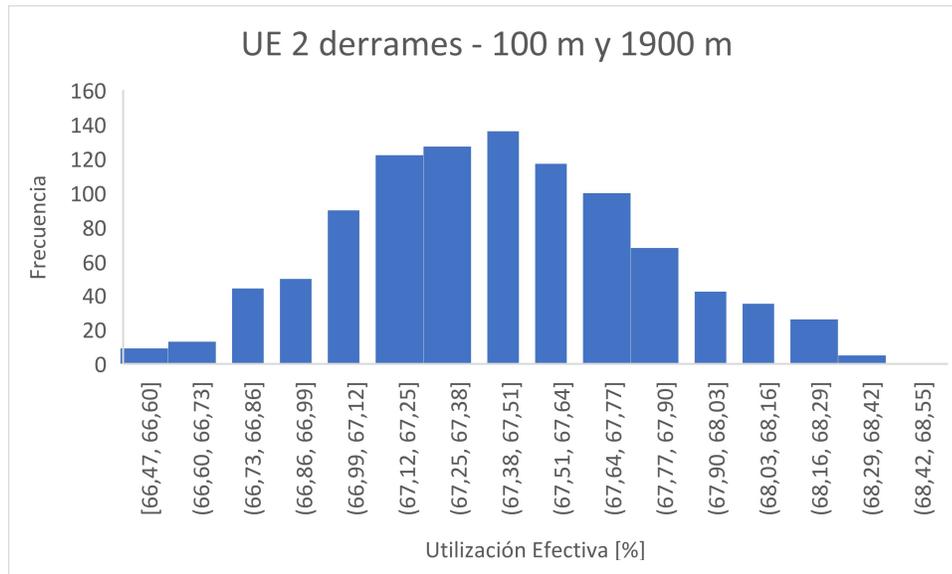


Gráfico 8-14: UE en el caso de 2 derrames por ciclo de flota a 100 y 1900 metros.

| UE 2 Derrames - 100 m /1900 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 67,42 |
| Desviación Std.                   | 0,38  |

Tabla 8-30: UE en el caso de 2 derrames por ciclo de flota a 100 m y 1900 m.

| 2 Derrames 100/1900 |           |           |            |
|---------------------|-----------|-----------|------------|
|                     | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,17      | 0,23      | 0,056      |
| Desviación Std      | 0,17      | --        | --         |
| 80% Superior        | 4,37      | 0,25      | 0,057      |
| 80% Inferior        | 3,95      | 0,22      | 0,055      |

Tabla 8-31: Resultados para el caso de 2 derrames por ciclo de flota en 100 m y 1900 m.

Estaciones 1 y 5 (100 m y 3400 m)

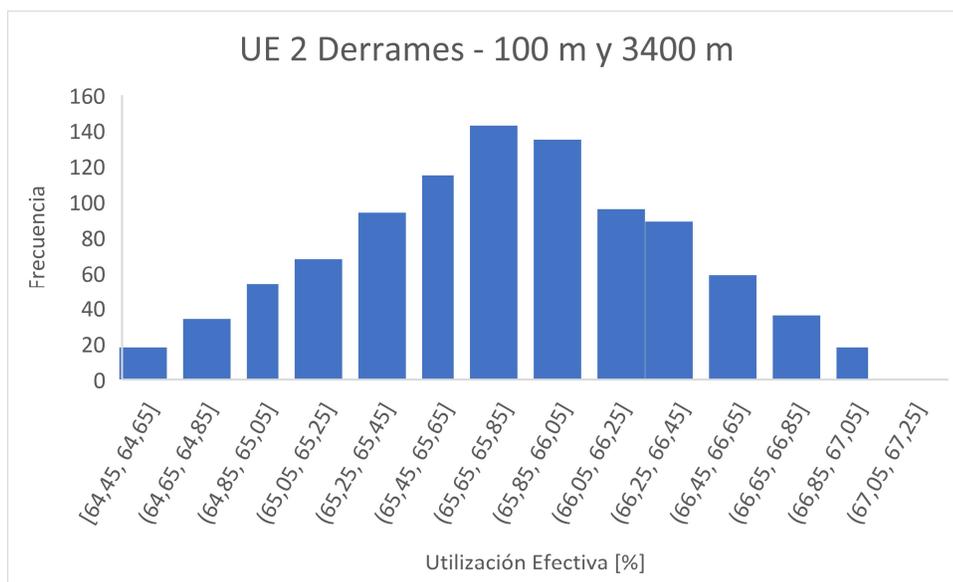


Gráfico 8-15: UE en el caso de 2 derrames por ciclo de flota a 100 y 3400 metros.

| UE 2 Derrames - 100 m /3400 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 65,77 |
| Desviación Std.                   | 0,55  |

Tabla 8-32: UE en el caso de 2 derrames por ciclo de flota a 100 m y 3400 m.

| 2 Derrames 100/3400 |           |           |            |
|---------------------|-----------|-----------|------------|
|                     | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,66      | 0,27      | 0,059      |
| Desviación Std      | 0,14      | --        | --         |
| 80% Superior        | 4,85      | 0,29      | 0,060      |
| 80% Inferior        | 4,48      | 0,26      | 0,058      |

Tabla 8-33: Resultados para el caso de 2 derrames por ciclo de flota en 100 m y 3400 m.

Estaciones 2 y 3 (400 m y 900 m)

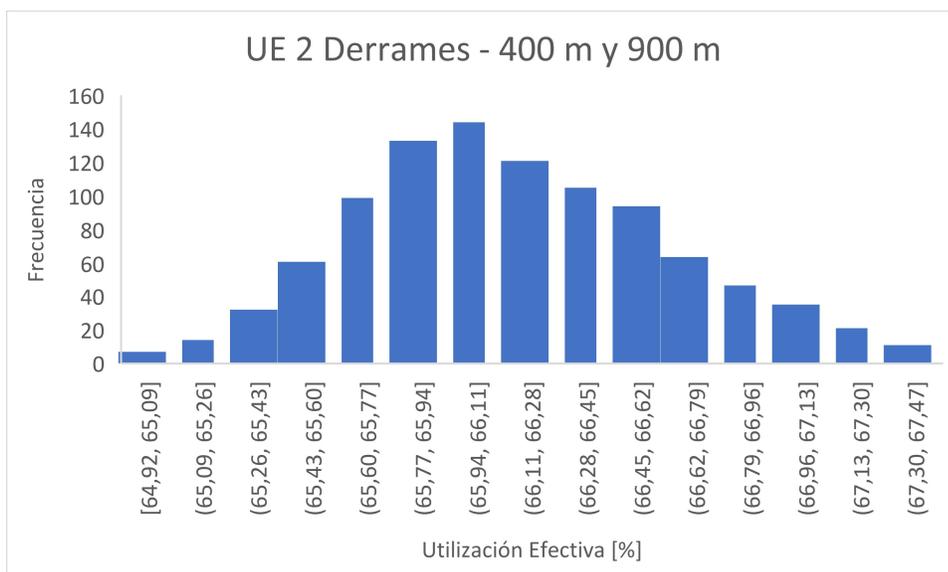


Gráfico 8-16: UE en el caso de 2 derrames por ciclo de flota a 400 y 900 metros.

| UE 2 Derrames - 400 m /900 m [%] |       |
|----------------------------------|-------|
| Promedio                         | 66,16 |
| Desviación Std.                  | 0,49  |

Tabla 8-34: UE en el caso de 2 derrames por ciclo de flota a 400 m y 900 m.

| 2 Derrames 400/900 |           |           |            |
|--------------------|-----------|-----------|------------|
|                    | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio           | 4,56      | 0,27      | 0,058      |
| Desviación Std     | 0,12      | --        | --         |
| 80% Superior       | 4,71      | 0,28      | 0,059      |
| 80% Inferior       | 4,40      | 0,25      | 0,057      |

Tabla 8-35: Resultados para el caso de 2 derrames por ciclo de flota en 400 m y 900 m.

Estaciones 2 y 4 (400 m y 1900 m)

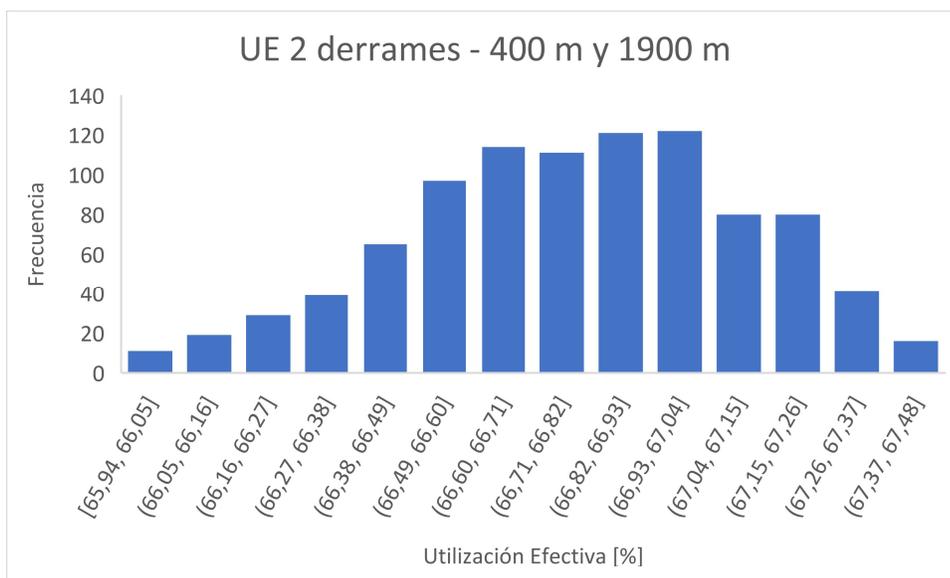


Gráfico 8-17: UE en el caso de 2 derrames por ciclo de flota a 400 y 1900 metros.

| UE 2 Derrames - 400 m /1900 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 66,79 |
| Desviación Std.                   | 0,31  |

Tabla 8-36: UE en el caso de 2 derrames por ciclo de flota a 400 m y 1900 m.

| 2 Derrames 400/1900 |           |           |            |
|---------------------|-----------|-----------|------------|
|                     | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,40      | 0,25      | 0,057      |
| Desviación Std      | 0,08      | --        | --         |
| 80% Superior        | 4,51      | 0,26      | 0,058      |
| 80% Inferior        | 4,30      | 0,24      | 0,057      |

Tabla 8-37: Resultados para el caso de 2 derrames por ciclo de flota en 400 m y 1900 m.

Estaciones 2 y 5 (400 m y 3400 m)

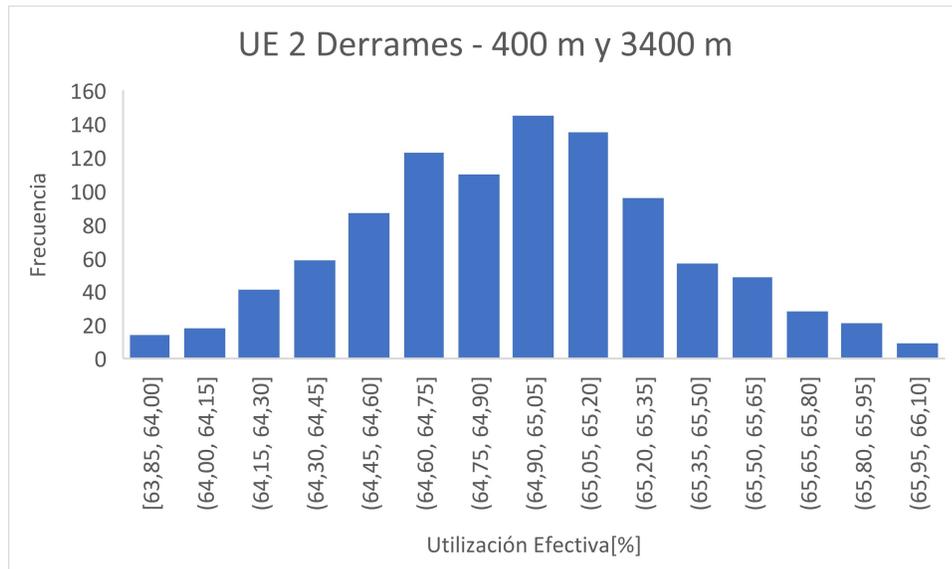


Gráfico 8-18: UE en el caso de 2 derrames por ciclo de flota a 400 y 3400 metros.

| UE 2 Derrames - 400 m /3400 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 64,94 |
| Desviación Std.                   | 0,43  |

Tabla 8-38: UE en el caso de 2 derrames por ciclo de flota a 400 m y 3400 m.

| 2 Derrames 400/3400 |              |           |            |
|---------------------|--------------|-----------|------------|
|                     | DPD<br>[min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,91         | 0,30      | 0,060      |
| Desviación Std      | 0,18         | --        | --         |
| 80% Superior        | 5,23         | 0,32      | 0,061      |
| 80% Inferior        | 4,72         | 0,28      | 0,059      |

Tabla 8-39: Resultados para el caso de 2 derrames por ciclo de flota en 400 m y 3400 m.

Estaciones 3 y 4 (900 m y 1900 m)

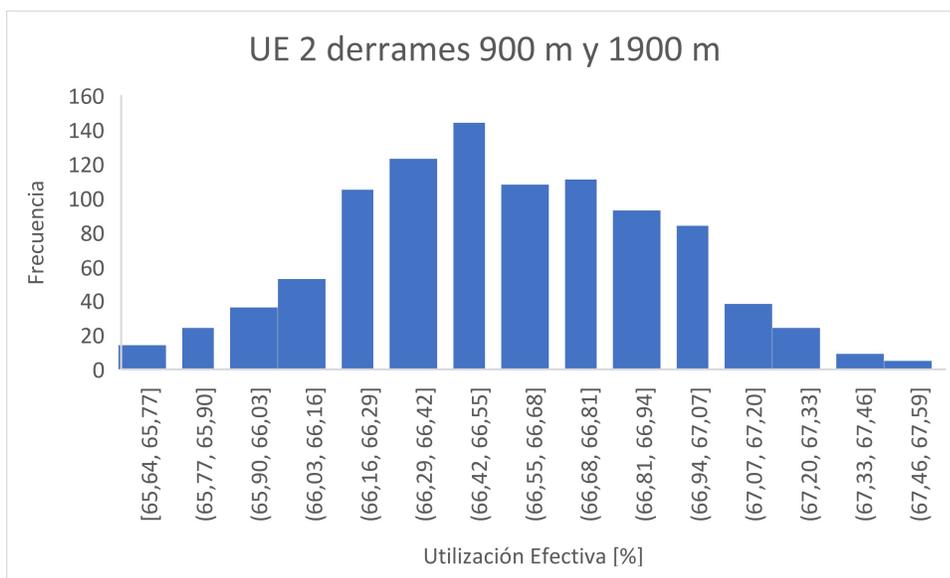


Gráfico 8-19: UE en el caso de 2 derrames por ciclo de flota a 900 y 1900 metros.

| UE 2 Derrames - 900 m /1900 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 66,56 |
| Desviación Std.                   | 0,37  |

Tabla 8-40: UE en el caso de 2 derrames por ciclo de flota a 900 m y 1900 m.

| 2 Derrames 900/1900 |           |           |            |
|---------------------|-----------|-----------|------------|
|                     | DPD [min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,46      | 0,26      | 0,058      |
| Desviación Std      | 0,09      |           |            |
| 80% Superior        | 4,58      | 0,27      | 0,058      |
| 80% Inferior        | 4,34      | 0,25      | 0,057      |

Tabla 8-41: Resultados para el caso de 2 derrames por ciclo de flota en 900 m y 1900 m.

Estaciones 3 y 5 (900 m y 3400 m)

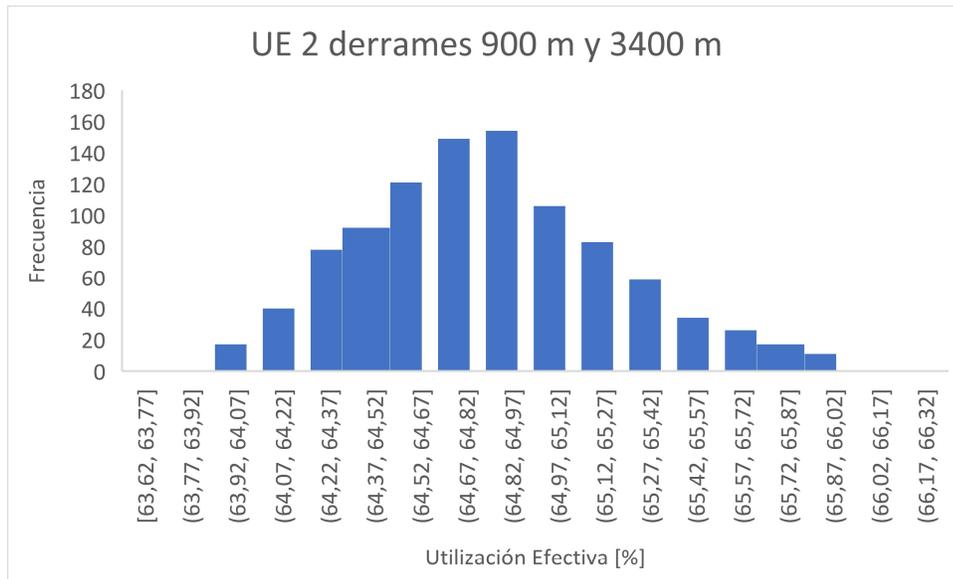


Gráfico 8-20: UE en el caso de 2 derrames por ciclo de flota a 900 y 3400 metros.

| UE 2 Derrames - 900 m /3400 m [%] |       |
|-----------------------------------|-------|
| Promedio                          | 64,83 |
| Desviación Std.                   | 0,43  |

Tabla 8-42: UE en el caso de 2 derrames por ciclo de flota a 900 m y 3400 m.

| 2 Derrames 900/3400 |              |           |            |
|---------------------|--------------|-----------|------------|
|                     | DPD<br>[min] | PUEPD [%] | PUEPMP [%] |
| Promedio            | 4,95         | 0,30      | 0,061      |
| Desviación Std      | 0,19         |           |            |
| 80% Superior        | 5,25         | 0,32      | 0,061      |
| 80% Inferior        | 4,75         | 0,28      | 0,059      |

Tabla 8-43: Resultados para el caso de 2 derrames por ciclo de flota en 900 m y 3400 m.

Estaciones 4 y 5 (1900 m y 3400 m)

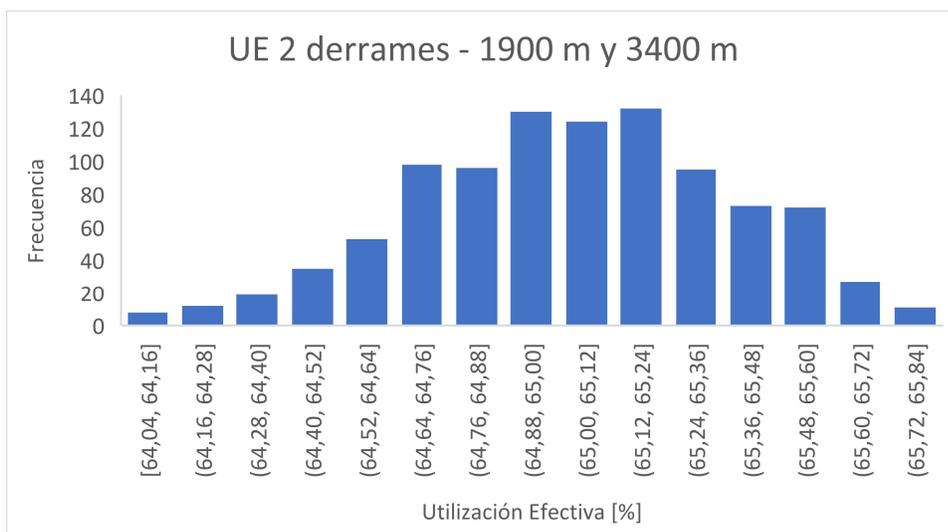


Gráfico 8-21: UE en el caso de 2 derrames por ciclo de flota a 1900 y 3400 metros.

| UE 2 Derrames - 1900 m /3400 m [%] |       |
|------------------------------------|-------|
| Promedio                           | 65,04 |
| Desviación Std.                    | 0,34  |

Tabla 8-44: UE en el caso de 2 derrames por ciclo de flota a 1900 m y 3400 m.

| 2 Derrames 1900/3400 |              |           |                   |
|----------------------|--------------|-----------|-------------------|
|                      | DPD<br>[min] | PUEPD [%] | PUEPMP<br>[%/min] |
| Promedio             | 4,87         | 0,29      | 0,060             |
| Desviación Std       | 0,14         |           |                   |
| 80% Superior         | 5,13         | 0,31      | 0,060             |
| 80% Inferior         | 4,73         | 0,28      | 0,059             |

Tabla 8-45: Resultados para el caso de 2 derrames por ciclo de flota en 1900 m y 3400 m.

## 7.2. DEEP LEARNING

### 7.2.1. DETERMINACIÓN RED DE PREDICCIÓN DE DERRAMES

#### PREDICTIBILIDAD CON 1 CAPA OCULTA

##### CAPA DE 3 NEURONAS

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,98                 | 80                       | 78,369               | 70            | 42,683     | 26,984                | 0,42767 |
| 20 b - 230 e | 77,98                 | 80                       | 78,369               | 71,429        | 42,683     | 11,438                | 0,42767 |
| 20 b - 100 e | 77,31                 | 77,78                    | 77,305               | 72,5          | 35,366     | 5,438                 | 0,38874 |
| 20 b -50 e   | 75,31                 | 74,67                    | 70,922               | indefinido    | 0          | 3,281                 | 0       |

Tabla 9-10: Predictibilidad para 1 capa oculta con 3 neuronas

##### CAPA DE 7 NEURONAS

Para el caso de 7 neuronas y 1 capa oculta se obtuvo la siguiente tabla:

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,75                 | 80                       | 78,369               | 71,429        | 42,683     | 25,859                | 0,42767 |
| 20 b - 230 e | 77,64                 | 80                       | 78,369               | 71,429        | 42,683     | 12,344                | 0,42767 |
| 20 b - 100 e | 76,75                 | 78,22                    | 77,305               | 71,429        | 36,585     | 5,906                 | 0,39013 |
| 20 b -50 e   | 76,86                 | 78,22                    | 75,887               | 85            | 20,732     | 3,453                 | 0,34023 |

Tabla 9-11: Análisis de predictibilidad para 1 capa oculta con 7 neuronas

##### CAPA DE 23 NEURONAS

Para el caso de 1 capa con 23 neuronas se obtuvo lo siguiente:

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,98                 | 79,56                    | 78,369               | 71,429        | 42,683     | 25,359                | 0,42767 |
| 20 b - 230 e | 77,64                 | 80                       | 78,369               | 71,429        | 42,683     | 11,594                | 0,42767 |
| 20 b - 100 e | 77,75                 | 80                       | 78,369               | 71,429        | 42,683     | 7,203                 | 0,42767 |
| 20 b -50 e   | 77,2                  | 79,56                    | 78,014               | 71,739        | 40,244     | 6,125                 | 0,41475 |

Tabla 9-12: Predictibilidad para 1 capa oculta con 23 neuronas

## PREDICTIBILIDAD CON 2 CAPAS OCULTAS

### PRIMERA CAPA OCULTA DE 3 NEURONAS

Los resultados obtenidos con 100 epochs son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 3-10 | 77,31                 | 80                       | 78,369               | 71,429        | 42,683     | 7,641                 | 0,42767 |
| 3-20 | 77,42                 | 80                       | 78,014               | 71,739        | 40,244     | 7,625                 | 0,41475 |
| 3-40 | 77,42                 | 80                       | 78,369               | 72,34         | 41,463     | 7,156                 | 0,42604 |

Tabla 9-13: Predictibilidad para distintas configuraciones en 100 epoch

Los resultados obtenidos con 50 epoch son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 3-10 | 77,98                 | 77,33                    | 76,596               | 73,529        | 30,488     | 3,625                 | 0,36243 |
| 3-20 | 76,64                 | 77,78                    | 77,305               | 71,429        | 36,585     | 4,031                 | 0,39013 |
| 3-40 | 76,53                 | 78,22                    | 77,305               | 71,429        | 36,585     | 5,797                 | 0,39013 |

Tabla 9-17: Predictibilidad para distintas configuraciones en 50 epoch

### PRIMERA CAPA OCULTA DE 7 NEURONAS

Los resultados obtenidos con batch tamaño 20 y 100 epoch son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 7-10 | 77,31                 | 80                       | 78,369               | 72,34         | 41,463     | 6,46                  | 0,42604 |
| 7-20 | 77,75                 | 79,56                    | 78,014               | 71,739        | 40,244     | 7,92                  | 0,41475 |
| 7-40 | 77,53                 | 80                       | 78,014               | 71,739        | 40,244     | 7,70                  | 0,41475 |

Tabla 9-18: Predictibilidad para distintas configuraciones en 100 epoch

Los resultados para una red de primera capa con 7 neuronas, batch de tamaño 20 y 50 epoch son los siguientes:

| Red | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de | MCC |
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------|-----|
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------|-----|

|      |       |       |        |        |        | Entren.<br>[s] |         |
|------|-------|-------|--------|--------|--------|----------------|---------|
| 7-10 | 76,64 | 77,78 | 77,305 | 71,429 | 36,585 | 3,375          | 0,39013 |
| 7-20 | 76,75 | 77,78 | 77,305 | 71,429 | 36,585 | 3,922          | 0,39013 |
| 7-40 | 76,86 | 78,67 | 78,014 | 72,727 | 39,024 | 4,188          | 0,41328 |

Tabla 9-19: Predictibilidad para distintas configuraciones en 50 epoch

## PREDICTIBILIDAD CON 3 CAPAS OCULTAS

### CON PRIMERA CAPA OCULTA DE 3 NEURONAS

Al igual que en el caso de 2 capas ocultas, se realiza este análisis para los casos de 100 y 50 epoch.

| Red     | Exactitud<br>Entren.<br>[%] | Exactitud<br>Validación [%] | Exactitud<br>Modelo<br>[%] | Precisión<br>[%] | Recall<br>[%] | Tiempo<br>de<br>Entren.<br>[s] | MCC     |
|---------|-----------------------------|-----------------------------|----------------------------|------------------|---------------|--------------------------------|---------|
| 3-10-10 | 77,75                       | 80                          | 78,369                     | 71,429           | 42,683        | 8,753                          | 0,42767 |
| 3-20-20 | 77,86                       | 80,44                       | 78,369                     | 71,429           | 42,683        | 8,578                          | 0,42767 |
| 3-40-40 | 78,2                        | 79,56                       | 78,369                     | 71,429           | 42,683        | 8,406                          | 0,42767 |

Tabla 9-20: Predictibilidad para distintas configuraciones en 100 epoch

| Red     | Exactitud<br>Entren.<br>[%] | Exactitud<br>Validación<br>[%] | Exactitud<br>Modelo<br>[%] | Precisión<br>[%] | Recall<br>[%] | Tiempo<br>de<br>Entren.<br>[s] | MCC     |
|---------|-----------------------------|--------------------------------|----------------------------|------------------|---------------|--------------------------------|---------|
| 3-10-10 | 77,31                       | 78,22                          | 77,66                      | 72,093           | 37,805        | 4,234                          | 0,40177 |
| 3-20-20 | 77,42                       | 80                             | 78,369                     | 71,429           | 42,683        | 4,703                          | 0,42767 |
| 3-40-40 | 77,98                       | 80                             | 78,369                     | 71,429           | 42,683        | 4,641                          | 0,42767 |

Tabla 9-21: Predictibilidad para distintas configuraciones en 50 epoch

### CON PRIMERA CAPA OCULTA DE 7 NEURONAS

| Red     | Exactitud<br>Entren.<br>[%] | Exactitud<br>Validación<br>[%] | Exactitud<br>Modelo [%] | Precisión<br>[%] | Recall [%] | Tiempo<br>de<br>Entren.<br>[s] | MCC     |
|---------|-----------------------------|--------------------------------|-------------------------|------------------|------------|--------------------------------|---------|
| 7-10-10 | 77,31                       | 80                             | 78,369                  | 71,429           | 42,683     | 7,359                          | 0,42767 |
| 7-20-20 | 77,98                       | 80                             | 78,014                  | 70               | 42,683     | 8,453                          | 0,41834 |
| 7-40-40 | 77,75                       | 80                             | 78,014                  | 70               | 42,683     | 8,406                          | 0,41834 |

Tabla 9-22: Predictibilidad para distintas configuraciones en 100 epoch

| Red     | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|---------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 7-10-10 | 77,09                 | 80                       | 78,369               | 71,429        | 42,683     | 4,453                 | 0,42767 |
| 7-20-20 | 76,75                 | 78,67                    | 78,014               | 72,727        | 39,024     | 4,406                 | 0,41328 |
| 7-40-40 | 78,2                  | 78,67                    | 78,369               | 73,333        | 40,244     | 5,203                 | 0,42464 |

Tabla 9-23: Predictibilidad para distintas configuraciones en 50 epoch

## 7.2.2. RED NEURONAL DE PREDICCIÓN DE DAÑO

### PREDICTIBILIDAD CON 1 CAPA OCULTA

Para el caso de 1 oculta capa de 3 neuronas se tienen los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC  |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|------|
| 20    | 71,37                 | 66,37                    | 69,98                | 72,71         | 85,37      | 13,73                 | 0,31 |
| 32    | 72,19                 | 68,15                    | 67,49                | 68,49         | 92,22      | 8,52                  | 0,19 |
| 50    | 69,63                 | 64,74                    | 69,74                | 72,07         | 86,11      | 5,79                  | 0,31 |
| 100   | 67,56                 | 62,52                    | 63,95                | 65,83         | 91,30      | 3,95                  | 0,09 |

Tabla 9-25: Predictibilidad para 1 oculta capa de 3 neuronas y 200 epoch

En el caso de 1 capa oculta de 7 neuronas se tienen los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC   |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-------|
| 20    | 77,27                 | 72,89                    | 73,88                | 79,31         | 80,00      | 13,28                 | 0,433 |
| 32    | 75,27                 | 72,59                    | 71,75                | 74,29         | 85,37      | 9,06                  | 0,359 |
| 50    | 75,23                 | 70,52                    | 72,34                | 76,56         | 81,67      | 5,46                  | 0,388 |
| 100   | 73,71                 | 69,78                    | 70,57                | 72,47         | 86,85      | 3,92                  | 0,326 |

Tabla 9-26: Predictibilidad para 1 capa oculta de 7 neuronas y 200 epoch

Para el caso de 1 capa oculta y 11 neuronas se obtuvieron los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 77,61                 | 75,11                    | 74,70                | 80,67         | 79,44      | 12,08                 | 0,4554 |
| 32    | 75,42                 | 72,45                    | 73,29                | 78,04         | 80,93      | 7,99                  | 0,4137 |

|     |       |       |       |       |       |      |        |
|-----|-------|-------|-------|-------|-------|------|--------|
| 50  | 75,60 | 73,63 | 73,76 | 78,29 | 81,48 | 6,11 | 0,4237 |
| 100 | 74,04 | 70,67 | 71,87 | 75,18 | 83,52 | 3,72 | 0,3683 |

Tabla 9-27: Predictibilidad para 1 capa de 11 neuronas y 200 epoch

La siguiente alternativa a analizar es la de 1 capa oculta con 23 neuronas:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 80,61                 | 80,30                    | 77,78                | 82,47         | 82,78      | 12,04                 | 0,5185 |
| 32    | 78,46                 | 76,15                    | 76,24                | 81,46         | 81,30      | 9,42                  | 0,4859 |
| 50    | 78,27                 | 76,15                    | 75,65                | 80,41         | 81,85      | 5,39                  | 0,4696 |
| 100   | 77,90                 | 76,59                    | 75,06                | 79,35         | 82,41      | 3,78                  | 0,4523 |

Tabla 9-28: Predictibilidad para 1 capa de 23 neuronas y 200 epoch

## ANÁLISIS DE PREDICTIBILIDAD CON 2 CAPAS OCULTAS

Para la alternativa de 10 neuronas en la segunda capa oculta se obtuvo lo siguiente:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 78,09                 | 76,00                    | 74,82                | 83,46         | 75,56      | 12,97                 | 0,4801 |
| 32    | 77,09                 | 74,82                    | 75,77                | 83,13         | 77,78      | 8,94                  | 0,4960 |
| 50    | 75,97                 | 72,59                    | 72,93                | 82,55         | 73,15      | 14,75                 | 0,4450 |
| 100   | 77,64                 | 75,70                    | 75,30                | 80,82         | 80,56      | 9,32                  | 0,4712 |

Tabla 9-29: Predictibilidad para red de 7-10 neuronas y 200 epoch

Para la configuración con 20 neuronas en la segunda capa oculta se obtuvieron los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 79,61                 | 77,78                    | 77,66                | 84,88         | 79,07      | 14,09                 | 0,5347 |
| 32    | 76,01                 | 72,89                    | 72,93                | 83,69         | 71,48      | 9,66                  | 0,4538 |
| 50    | 73,93                 | 70,22                    | 71,63                | 83,19         | 69,63      | 7,05                  | 0,4316 |
| 100   | 81,34                 | 80,89                    | 79,52                | 83,51         | 84,58      | 4,54                  | 0,5560 |

Tabla 9-30: Predictibilidad para red de 7-20 neuronas y 200 epoch

### 7.3. EVALUACIÓN ECONÓMICA

#### 7.3.1 RESULTADOS CASO BASE

|                                 | Sin Derrame | 1 Derrame   | 2 Derrames  |
|---------------------------------|-------------|-------------|-------------|
| Costo Anual Neumáticos [USD]    | 8.739.695   | 8.070.218   | 8.037.447   |
| Costo Anual Petróleo [USD]      | 4.771.717   | 4.166.484   | 4.173.830   |
| Costo Anual Mantenimiento [USD] | 2.991.696   | 2.583.537   | 2.569.946   |
| Ingreso Anual [USD]             | 232.717.032 | 201.341.589 | 200.440.017 |
| Utilidad Anual [USD]            | 216.213.924 | 186.521.350 | 185.658.794 |

Tabla: Costos, Ingreso y Utilidad Anual Caso Base

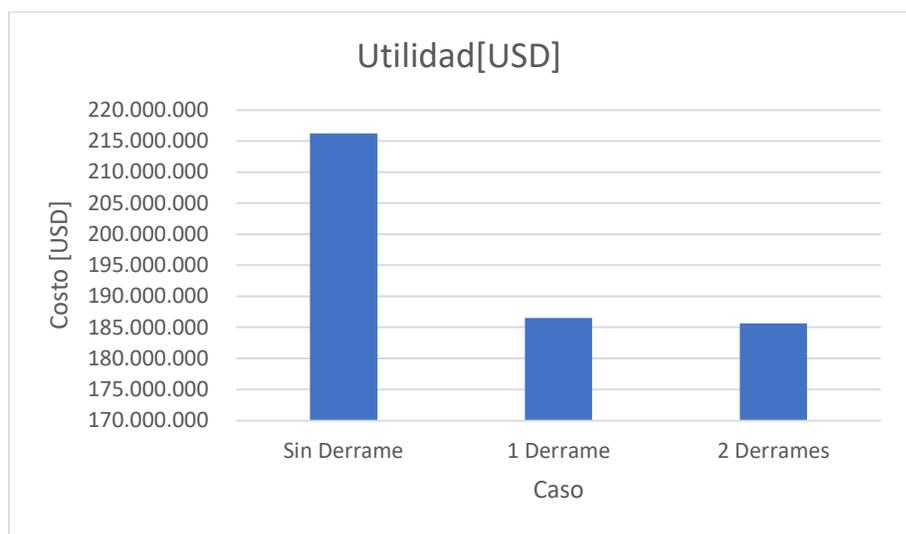


Gráfico: Utilidad del Caso Base

|                               | Sin Derrame | 1 Derrame | 2 Derrames |
|-------------------------------|-------------|-----------|------------|
| N viajes                      | 87.974      | 76.192    | 75.900     |
| C. Neumáticos por viaje [USD] | 55,01       | 54,73     | 54,51      |
| C. Petróleo por viaje [USD]   | 54,24       | 54,68     | 54,99      |
| C. Mantención por viaje [USD] | 34,01       | 33,91     | 33,86      |
| Ingreso por viaje [USD]       | 2.645       | 2.643     | 2.641      |
| Utilidad por viaje [USD]      | 2.458       | 2.448     | 2.446      |

Tabla: Costos, Ingreso y Utilidad media por viaje, Caso base

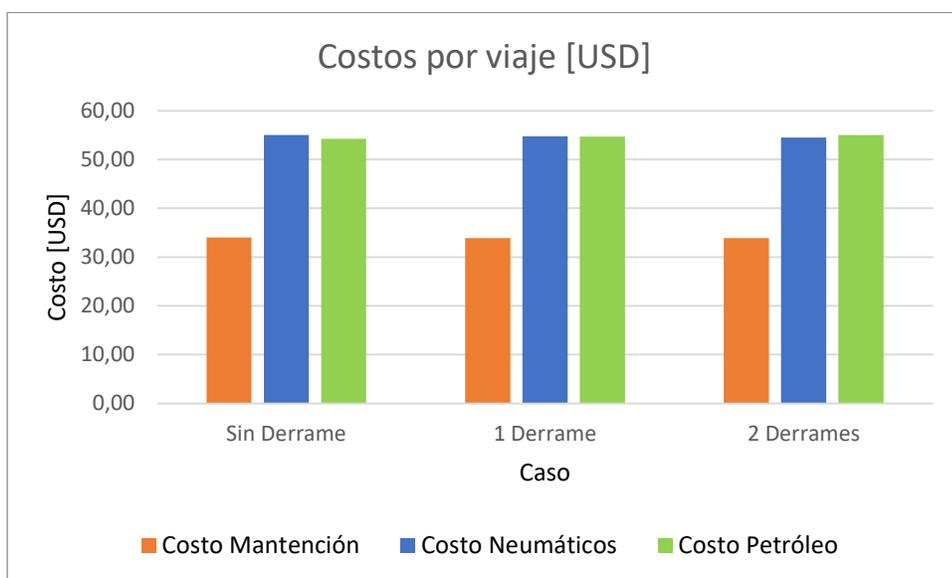


Gráfico: Costos por viaje Caso Base

|   | 1 Derrame   |
|---|-------------|
| Demora Total [min]                                  | 444.664     |
| Ingreso Sin Derrame[USD]                            | 232.717.032 |
| Ingreso 1 Derrame [USD]                             | 201.341.589 |
| Ingreso no percibido por minuto de demora [USD/min] | 70,56       |

Tabla: Ingreso no percibido por minuto de demora, Caso Base

|  | 1 Derrame |
|--|-----------|
| Mineral perdido por derrame al año [Ton]           | 11.738    |
| Merma de Ingreso anual por Mx derramado [USD]      | 207.008   |
| Aumento de utilidad anual al ingresar derrames [%] | 0,11      |

Tabla: Merma anual por mineral derramado

|                      | Caso 1 Derrame | Caso 2 Derrames |
|----------------------|----------------|-----------------|
| Ciclo sin derrame    | 1.380          | 1.165           |
| Ciclo con 1 derrame  | 6.053          | 2.346           |
| Ciclo con 2 derrames | -              | 3.883           |
| Total                | 7.433          | 7.394           |

Tabla: Cantidad de derrames por ciclo de flota al año, caso base

### 7.3.2. RESULTADOS PARA PEOR CASO

|                                 | Sin Derrame | 1 Derrame  | 2 Derrames |
|---------------------------------|-------------|------------|------------|
| Costo Anual Neumáticos [USD]    | 11.527.242  | 10.520.668 | 10.480.320 |
| Costo Anual Petróleo [USD]      | 5.566.426   | 4.897.540  | 4.943.155  |
| Costo Anual Mantenimiento [USD] | 3.384.674   | 2.921.885  | 2.912.719  |
| Ingreso Anual [USD]             | 93.093.263  | 80.474.636 | 80.332.944 |
| Utilidad Anual [USD]            | 72.614.921  | 62.134.544 | 61.996.750 |

Tabla: Costos, Ingreso y Utilidad Anual Peor Caso

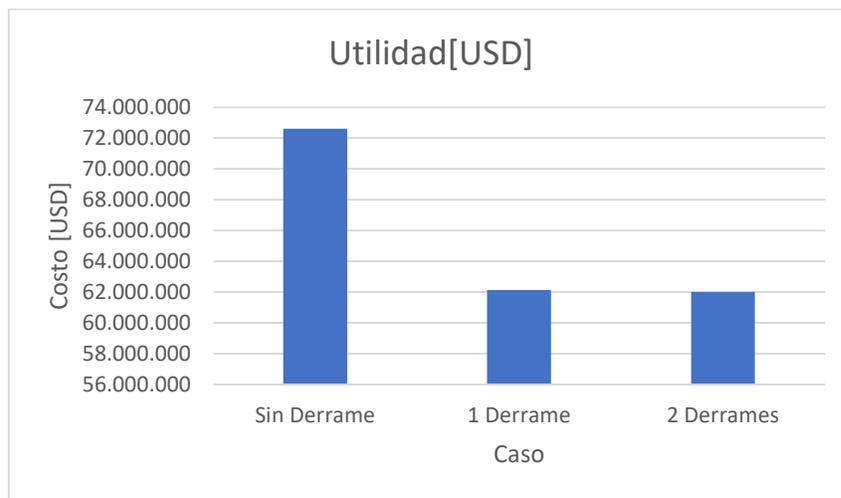


Gráfico: Utilidad del peor Caso

|                               | Sin Derrame | 1 Derrame | 2 Derrames |
|-------------------------------|-------------|-----------|------------|
| N viajes                      | 87.972      | 76.133    | 76.049     |
| C. Neumáticos por viaje [USD] | 86,70       | 86,96     | 86,53      |
| C. Petróleo por viaje [USD]   | 63,28       | 64,33     | 65,00      |
| C. Mantención por viaje [USD] | 38,47       | 38,38     | 38,30      |
| Utilidad por viaje [USD]      | 825         | 816       | 815        |

Tabla: Costos, Ingreso y Utilidad media por viaje, Peor Caso

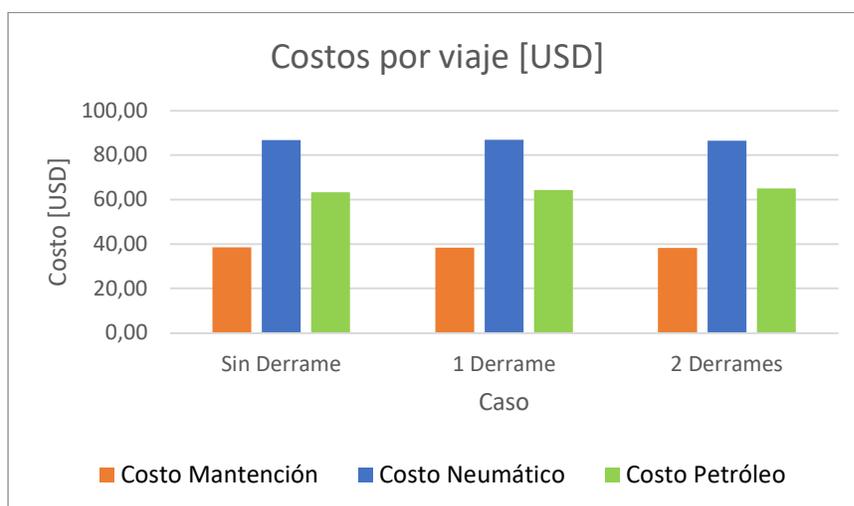


Gráfico: Costos por viaje, Peor Caso

### 7.3.3. RESULTADOS PEOR CASO, INCREMENTOS AL 70%

|                                 | Sin Derrame | 1 Derrame  |
|---------------------------------|-------------|------------|
| Costo Anual Neumáticos [USD]    | 22.372.174  | 19.501.308 |
| Costo Anual Petróleo [USD]      | 5.567.439   | 5.090.282  |
| Costo Anual Mantenimiento [USD] | 9.129.896   | 7.689.621  |
| Ingreso Anual [USD]             | 93.098.665  | 80.299.977 |
| Utilidad Anual [USD]            | 56.029.156  | 48.018.765 |

Tabla: Costos, Ingreso y Utilidad Anual Peor Caso, incrementos al 70%

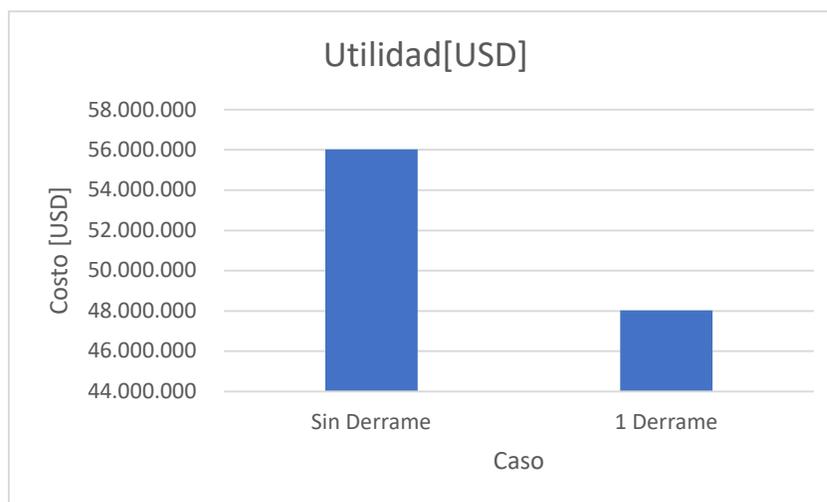


Gráfico: Utilidad Peor Caso, incrementos al 70%

|                                | Sin Derrame | 1 Derrame |
|--------------------------------|-------------|-----------|
| N viajes                       | 87.977      | 75.968    |
| C. Neumáticos por viaje [USD]  | 209,97      | 205,37    |
| C. Petróleo por viaje [USD]    | 63,28       | 67,01     |
| C. Mantenición por viaje [USD] | 103,78      | 101,22    |

|                          |     |     |
|--------------------------|-----|-----|
| Utilidad por viaje [USD] | 637 | 632 |
|--------------------------|-----|-----|

Tabla: Costos, Ingreso y Utilidad por viaje, Peor Caso con incrementos al 70%

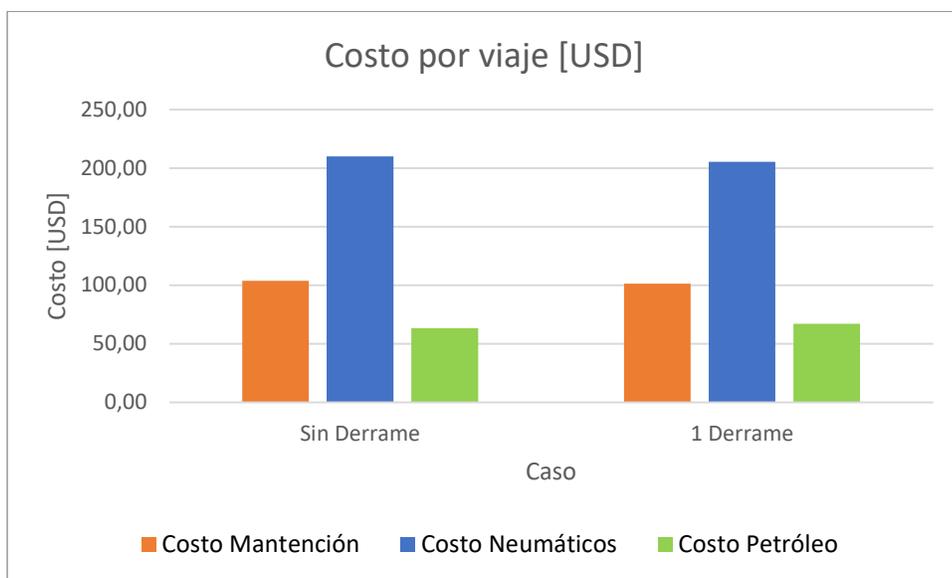


Gráfico: Costos por viaje, Peor Caso con incrementos al 70%

#### 7.3.4 RESULTADOS PEOR CASO, PRECIO DEL COBRE 1 USD/lb

|                                 | Sin Derrame | 1 Derrame  |
|---------------------------------|-------------|------------|
| Costo Anual Neumáticos [USD]    | 11.477.415  | 10.501.208 |
| Costo Anual Petróleo [USD]      | 5.566.918   | 4.894.581  |
| Costo Anual Mantenimiento [USD] | 3.374.612   | 2.920.001  |
| Ingreso Anual [USD]             | 46.556.988  | 40.218.769 |
| Utilidad Anual [USD]            | 26.138.043  | 21.902.979 |

Tabla: Costos, Ingreso y Utilidad Anual, Peor Caso, P Cu = 1

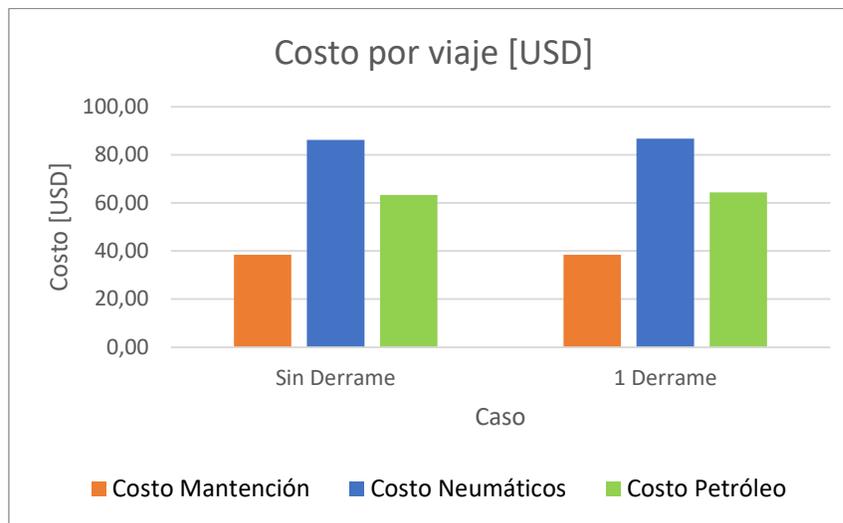


Gráfico: Costos por viaje, Peor Caso, P Cu = 1

## 8. ANÁLISIS

### 8.1. ANÁLISIS DE SIMULACIÓN

Luego de obtener los resultados de la simulación, se puede apreciar que la utilización efectiva es inversamente proporcional al tiempo perdido en los derrames, principalmente por la distancia donde ocurren respecto a la frente, que es la ubicación de los equipos de apoyo. Tal como se puede apreciar en el siguiente gráfico.

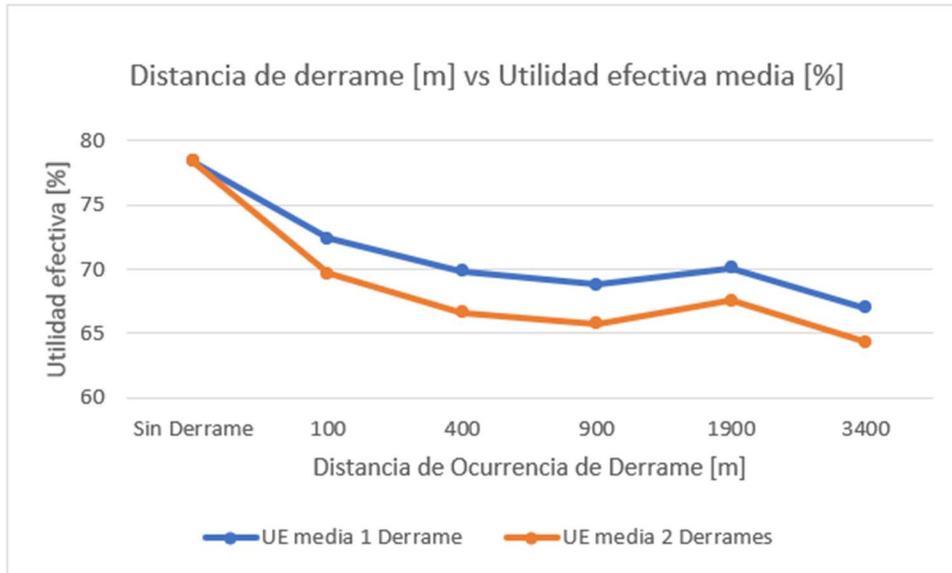


Gráfico 8-22: Utilización efectiva promedio por estación

Cabe destacar que la estación de 1900 metros presenta una discordancia respecto a la tendencia de los datos, la cual se debe a algún comportamiento propio del software de modelamiento respecto a los camiones que no están siendo utilizados por alguna entidad a transportar (carga mineral). El estudio de esta situación está desarrollado en el Anexo A del presente trabajo.

Dada la imposibilidad de que el punto ubicado a 1900 metros entregue datos concordantes con la tendencia global de los resultados, se toma la decisión de no utilizar esta estación en los reportes finales y recalcular los resultados obtenidos.

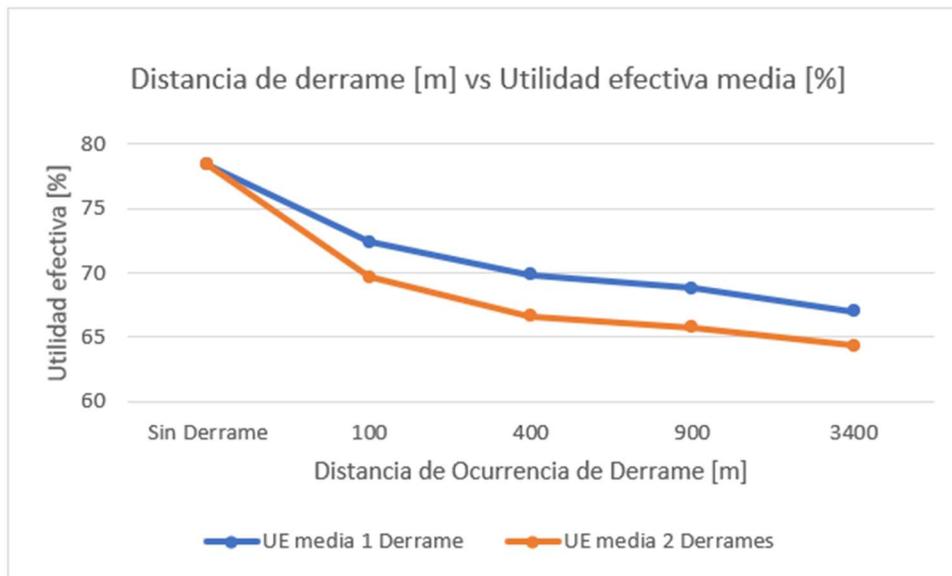


Gráfico 8-23: UE promedio por estación (Sin estación 1900)

Además de ser la utilización efectiva inversamente proporcional a la distancia recorrida por los equipos de limpieza, o distancia donde ocurren los derrames respecto a la frente, como ya se

mencionó, también lo es al volumen de derrames ocurridos, dado que para toda estación en la ruta la ocurrencia de 2 derrames por ciclo implica una utilización efectiva menor que la ocurrencia de solo 1 derrame por ciclo. En síntesis, la utilización efectiva es inversamente proporcional a las pérdidas operacionales.

| Derrame/ciclo | Ubicación Derrame [m] | Utilización efectiva media [%] | Desv. Estándar [%] |
|---------------|-----------------------|--------------------------------|--------------------|
| Sin Derrame   | -                     | 78,40                          | 1,03               |
| 1             | 100                   | 72,50                          | 1,02               |
| 2             | 100                   | 70,18                          | 1,25               |
| 1             | 400                   | 69,87                          | 8,62               |
| 1             | 900                   | 68,83                          | 0,44               |
| 2             | 100-400               | 67,94                          | 0,93               |
| 2             | 100-900               | 67,06                          | 0,57               |
| 1             | 3400                  | 67,00                          | 0,65               |
| 2             | 400                   | 66,65                          | 0,66               |
| 2             | 400-900               | 66,16                          | 0,49               |
| 2             | 900                   | 65,79                          | 0,38               |
| 2             | 100-3400              | 65,77                          | 0,55               |
| 2             | 400-3400              | 64,94                          | 0,43               |
| 2             | 900-3400              | 64,83                          | 0,43               |
| 2             | 3400                  | 64,32                          | 0,32               |

Tabla 8-46: Casos estudiados ordenados por Utilización efectiva media

Continuando con lo anterior, el caso donde hay un menor decremento de la utilización efectiva es en el caso de 1 derrame a 100 metros de la frente, representando así el mejor caso, mientras que el peor caso es el de 2 derrames a 3400 metros, tal como se puede apreciar en la tabla 8-46.

| N derrames | Ubicación [m] | 80% Inferior [min] | Promedio [min] | 80% Superior [min] |
|------------|---------------|--------------------|----------------|--------------------|
| 1          | 100           | 4,64               | 5,47           | 6,09               |
| 1          | 400           | 6,14               | 6,97           | 7,45               |
| 1          | 900           | 7,2                | 7,46           | 7,7                |
| 1          | 3400          | 7,93               | 8,70           | 9,1                |
| 2          | 100           | 3,09               | 3,54           | 3,87               |
| 2          | 400           | 4,16               | 4,44           | 4,65               |
| 2          | 900           | 4,53               | 4,66           | 4,77               |
| 2          | 3400          | 4,93               | 5,25           | 5,37               |
| 2          | 100-400       | 3,63               | 3,94           | 4,39               |
| 2          | 100-900       | 3,98               | 4,33           | 4,51               |

|   |          |      |      |      |
|---|----------|------|------|------|
| 2 | 100-3400 | 4,48 | 4,66 | 4,85 |
| 2 | 400-900  | 4,4  | 4,56 | 4,71 |
| 2 | 400-3400 | 4,72 | 4,87 | 5,23 |

Tabla 8-47: Tiempos de pérdidas operacionales promedio por derrame y por camión.

De los datos obtenidos se puede determinar un rango de pérdida de tiempo por derrame, que dentro de su extremo inferior bordea desde los 3,1 minutos hasta los 3,87 minutos, esto es para el 80% de los derrames en 100 metros y con frecuencia de 2 derrames por ciclo de flota. Mientras que en el otro extremo se obtienen demoras del orden de 7,93 minutos hasta 9,1 minutos para el 80% de los casos de 1 derrame por ciclo de flota en la estación de 3400 m.

Es contraintuitivo el resultado de que el caso de 2 derrames a 100 metros tenga un tiempo menor por derrame que el caso de 1 derrame a 100 metros, esto sucede debido a que la pérdida operacional en los casos de 2 derrames en el mismo lugar, la cual permite realizar la comparación, es menor que el doble de la pérdida operacional de los casos de 1 derrame.

Esto último provoca que, al dividir la pérdida operacional total entre la cantidad de derrames, resulte en que la pérdida operacional por derrame sea menor en los casos de 2 derrames en el mismo punto, que los casos de 1 derrame. En las siguientes dos tablas se analiza esta situación.

| Derrame/ciclo | Ubicación [m] | N viajes | Total Derrames | P.O. flota por derrame [min] | P.O. por camión [min] |
|---------------|---------------|----------|----------------|------------------------------|-----------------------|
| 1             | 100           | 251      | 25             | 54,72                        | 5,47                  |
| 1             | 400           | 242      | 24             | 69,67                        | 6,97                  |
| 1             | 900           | 238      | 24             | 74,58                        | 7,46                  |
| 1             | 3400          | 233      | 23             | 87,04                        | 8,70                  |
| 2             | 100           | 241      | 48             | 35,35                        | 3,54                  |
| 2             | 400           | 231      | 46             | 44,37                        | 4,44                  |
| 2             | 900           | 229      | 46             | 46,57                        | 4,66                  |
| 2             | 3400          | 223      | 44             | 52,52                        | 5,25                  |

Tabla 8-48: Pérdida Operacional por camión entregada por el modelo

| Derrame/ciclo | Ubicación [m] | N viajes | Total Derrames | P.O. flota por derrame [min] | P.O. por camión [min] |
|---------------|---------------|----------|----------------|------------------------------|-----------------------|
| 1             | 100           | 251      | 25             | 54,72                        | 5,47                  |
| 1             | 400           | 242      | 24             | 69,67                        | 6,97                  |
| 1             | 900           | 238      | 24             | 74,58                        | 7,46                  |
| 1             | 3400          | 233      | 23             | 87,04                        | 8,70                  |

|   |      |     |    |       |      |
|---|------|-----|----|-------|------|
| 2 | 100  | 164 | 32 | 53,03 | 5,30 |
| 2 | 400  | 150 | 30 | 68,03 | 6,80 |
| 2 | 900  | 140 | 28 | 76,50 | 7,65 |
| 2 | 3400 | 130 | 26 | 88,88 | 8,89 |

Tabla 8-49: Pérdida Operacional por camión en caso que fuese constante

Si bien en la tabla anterior, las pérdidas operacionales por camión (última columna) en los casos de 2 derrames no se ajustan con exactitud a los casos con 1 derrame, tienen una aproximación suficiente para asumir que por cada derrame en el mismo punto, independiente sea el caso de 1 derrame por ciclo o de 2 derrames por ciclo, se tiene una pérdida operacional por camión, en promedio, similar.

Resulta evidente al comparar ambas tablas anteriores, que la cantidad de viajes para los casos de 2 derrames con pérdidas operacionales constantes por camión son muy inferiores a las que resultan del modelo, así para que se cumpla dicha configuración se debería tener una mayor pérdida operacional por parte del sistema, lo cual no ocurre. Sin embargo, esto no implica que la pérdida operacional total en los casos de 2 derrames sea inferior a la pérdida operacional total en los casos de 1 derrame, como se ve a continuación.

| Derrame/ciclo | Ubicación [m] | Tiempo Disponible día [min] | Pérdida Operacional media [min] | N viajes | T ciclo camión medio [min] |
|---------------|---------------|-----------------------------|---------------------------------|----------|----------------------------|
| Sin Derrame   | 0             | 11520                       | 686                             | 272      | 35,74                      |
| 1             | 100           | 11520                       | 1368                            | 251      | 38,73                      |
| 1             | 400           | 11520                       | 1672                            | 242      | 40,17                      |
| 2             | 100           | 11520                       | 1697                            | 241      | 40,33                      |
| 1             | 900           | 11520                       | 1790                            | 238      | 40,84                      |
| 2             | 100-400       | 11520                       | 1893                            | 236      | 41,19                      |
| 2             | 100-900       | 11520                       | 1994                            | 233      | 41,72                      |
| 1             | 3400          | 11520                       | 2002                            | 233      | 41,72                      |
| 2             | 400           | 11520                       | 2041                            | 231      | 42,08                      |
| 2             | 400-900       | 11520                       | 2098                            | 230      | 42,26                      |
| 2             | 900           | 11520                       | 2142                            | 229      | 42,45                      |
| 2             | 100-3400      | 11520                       | 2143                            | 228      | 42,63                      |
| 2             | 400-3400      | 11520                       | 2240                            | 226      | 43,01                      |
| 2             | 900-3400      | 11520                       | 2251                            | 225      | 43,20                      |
| 2             | 3400          | 11520                       | 2311                            | 223      | 43,59                      |

Tabla 8-50: Casos ordenados según Pérdida operacional media de la flota.

Como se puede ver en la tabla anterior, el tiempo de ciclo aumenta en función a la cantidad de derrames y la distancia donde ocurren estos, debido al aumento de las pérdidas operacionales asociadas.

Desafortunadamente los tiempos de pérdida operacional por camión solo constituyen un valor referencial de cuanto es la demora por cada derrame propiamente tal. Es decir, no representan el tiempo de espera causado por el derrame y la limpieza de este, ni el efecto real del derrame en parte de la flota, sino un promedio distribuido en la flota completa sin importar si dicho derrame afectó el ciclo de un camión de la flota o no. Por ejemplo, un derrame puede afectar el tiempo de ciclo de 3 camiones al generarles pérdidas operacionales, sin embargo al determinar la pérdida operacional por camión se distribuye esta pérdida operacional en la flota completa.

No obstante, una mejor manera de determinar cuanto afecta la pérdida operacional por los derrames a la operación es utilizar la pérdida operacional y dividirla por el número de derrames, con esto se hace posible comparar esta pérdida operacional con la pérdida de utilización efectiva por cada derrame, llegando a una relación más consistente con la realidad, ya que denota cuan afectada se ve la flota por los derrames, y no cuan afectado se ve solo un camión de la flota.

| Derrame/ciclo | Ubicación [m] | UE [%] | Diferencia con UE ideal [%] | Nderrames | PUEPD [%] |
|---------------|---------------|--------|-----------------------------|-----------|-----------|
| 0             | Sin Derrame   | 78,40  | 0                           | 0         | 0         |
| 1             | 100           | 72,50  | 5,91                        | 25        | 0,2363    |
| 1             | 400           | 69,87  | 8,54                        | 24        | 0,3557    |
| 1             | 900           | 68,83  | 9,57                        | 24        | 0,3989    |
| 1             | 3400          | 67,00  | 11,40                       | 23        | 0,4958    |
| 2             | 100           | 70,18  | 8,22                        | 48        | 0,1712    |
| 2             | 400           | 66,65  | 11,75                       | 46        | 0,2554    |
| 2             | 900           | 65,79  | 12,62                       | 46        | 0,2743    |
| 2             | 3400          | 64,32  | 14,09                       | 44        | 0,3201    |
| 2             | 100-400       | 67,94  | 10,46                       | 48        | 0,2180    |
| 2             | 100-900       | 67,06  | 11,34                       | 46        | 0,2465    |
| 2             | 100-3400      | 65,77  | 12,63                       | 46        | 0,2746    |
| 2             | 400-900       | 66,16  | 12,24                       | 46        | 0,2661    |
| 2             | 400-3400      | 64,94  | 13,47                       | 46        | 0,2927    |
| 2             | 900-3400      | 64,83  | 13,57                       | 46        | 0,2950    |

Tabla 8-51: Determinación de Pérdida de utilización efectiva por derrame

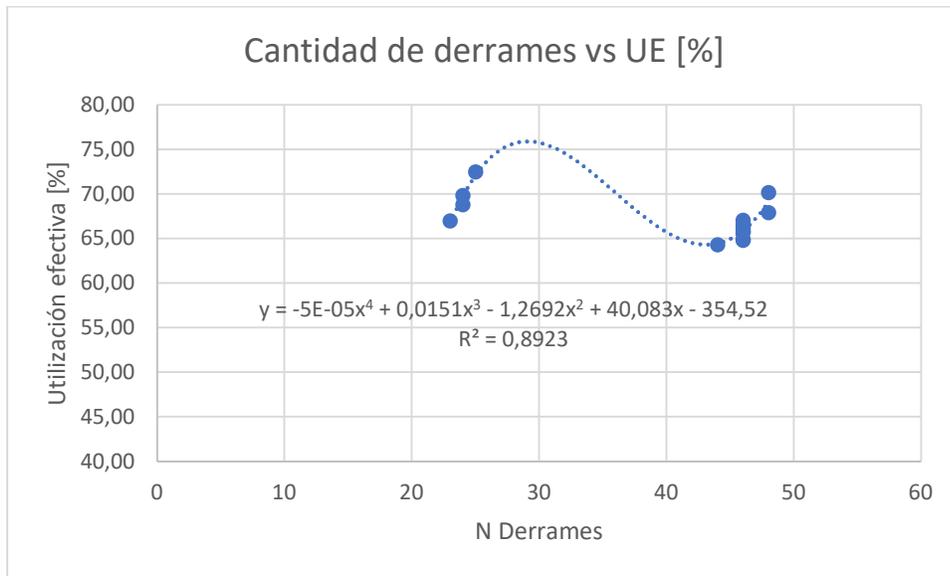


Gráfico 8-24: Cantidad de derrames vs Utilización efectiva

Del gráfico anterior es posible desprender la no linealidad de la relación entre la cantidad de derrames y la utilización efectiva de la flota en un día de operación. Luego se debe separar en dos grupos de datos y así poder obtener relaciones entre el tiempo de pérdida operacional y la pérdida de utilización efectiva debida a los derrames.

| Derrame/ciclo | Ubicación [m] | PUEPD [%] | P.O. Flota por derrame [min] |
|---------------|---------------|-----------|------------------------------|
| 0             | Sin Derrame   | 0         | 0,00                         |
| 1             | 100           | 0,2363    | 54,72                        |
| 1             | 400           | 0,3557    | 69,67                        |
| 1             | 900           | 0,3989    | 74,58                        |
| 1             | 3400          | 0,4958    | 87,04                        |
| 2             | 100           | 0,1712    | 35,35                        |
| 2             | 400           | 0,2554    | 44,37                        |
| 2             | 900           | 0,2743    | 46,57                        |
| 2             | 3400          | 0,3201    | 52,52                        |
| 2             | 100-400       | 0,2180    | 39,44                        |
| 2             | 100-900       | 0,2465    | 43,35                        |
| 2             | 100-3400      | 0,2746    | 46,59                        |
| 2             | 400-900       | 0,2661    | 45,61                        |
| 2             | 400-3400      | 0,2927    | 48,70                        |
| 2             | 900-3400      | 0,2950    | 48,93                        |

Tabla 8-52: Determinación Pérdidas de UE y operacional por derrame para cada caso.

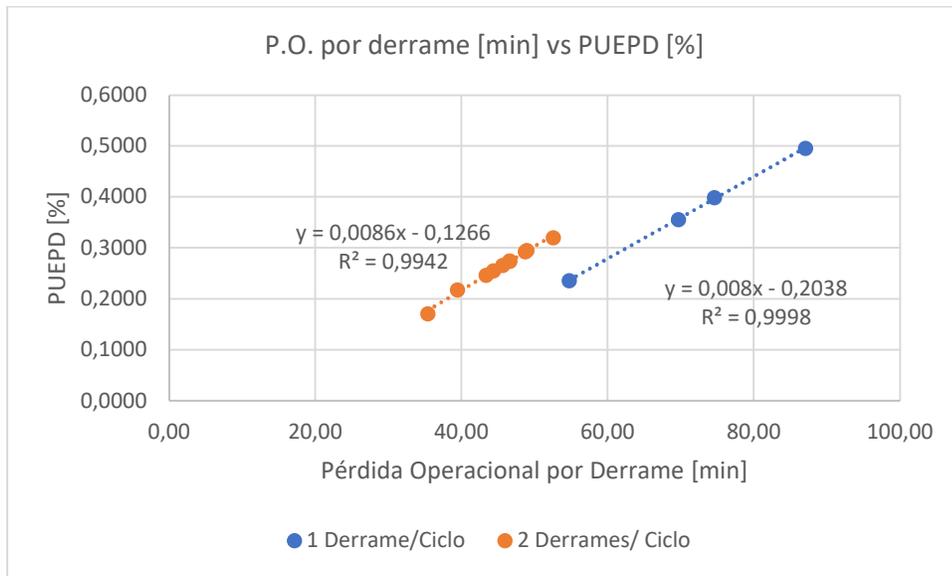


Gráfico 8-25: Relación por derrame entre Pérdida Operacional de la flota y Pérdida de UE

Por otra parte, al promediar tanto las pérdidas operacionales como las pérdidas de utilización efectiva por la cantidad de derrames, da como resultado dos grupos de datos, con una gran correlación. Esto evidencia que las pérdidas operacionales por derrame son directamente proporcionales a las pérdidas de utilización efectiva por derrame para ambos grupos de datos.

En otro aspecto de la operación, existe una clara sub utilización del equipo de carguío debido al incremento del tiempo de ciclo a causa de las pérdidas operacionales por derrames, lo que provoca mayor tiempo ocioso en la pala.

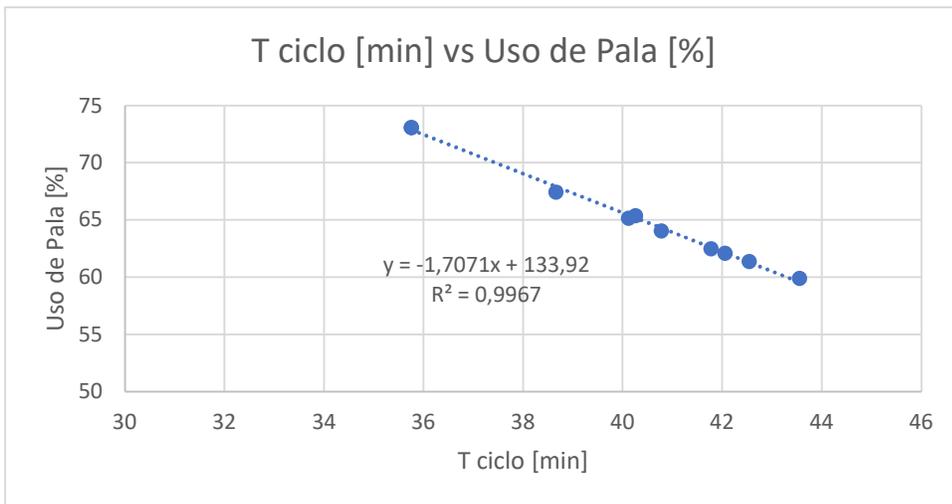


Gráfico 8-26: Relación entre utilización de la pala y el tiempo de ciclo.

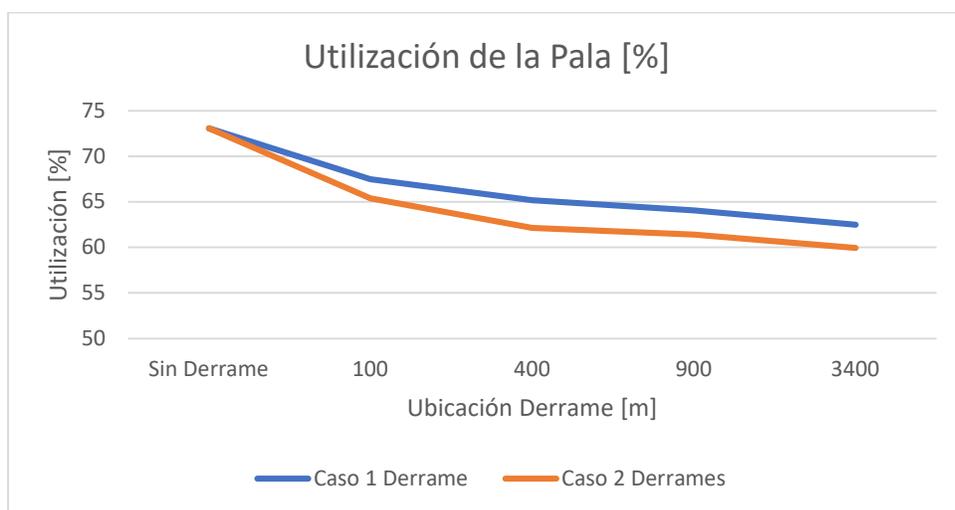


Gráfico 8-27: Comportamiento de la utilización de la pala según la ubicación de los derrames.

El número de viajes a planta, o ciclos realizados por cada camión, disminuye al existir derrames. Esto debido a las pérdidas operacionales que provocan que el tiempo de ciclo sea mayor, lo que afecta la cantidad de ciclos por hora, y consecuentemente la cantidad de ciclos por día. Esto incide de manera directa en los ingresos percibidos por la operación, provocando un comportamiento sub óptimo en este ítem.

## 8.2. DEEP LEARNING

### 8.2.1. ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 1 CAPA OCULTA

#### CAPA DE 3 NEURONAS

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,98                 | 80                       | 78,369               | 70            | 42,683     | 26,984                | 0,42767 |
| 20 b - 230 e | 77,98                 | 80                       | 78,369               | 71,429        | 42,683     | 11,438                | 0,42767 |
| 20 b - 100 e | 77,31                 | 77,78                    | 77,305               | 72,5          | 35,366     | 5,438                 | 0,38874 |
| 20 b -50 e   | 75,31                 | 74,67                    | 70,922               | indefinido    | 0          | 3,281                 | 0       |

Tabla 9-10: Análisis de predictibilidad para 1 capa oculta con 3 neuronas

Es posible apreciar que el Coeficiente de Matthews (MCC), que indica el grado de predicción o clasificación, adquiere un valor similar tanto para el caso de 500 epochs y de 230 epochs. Dado el tiempo de entrenamiento de ambos casos, que exceden ampliamente la condición inicial de ser menor a 10 segundos, y de la inexistencia de overfitting, se asume que es el valor máximo a alcanzar y por tanto objetivo para las futuras pruebas.

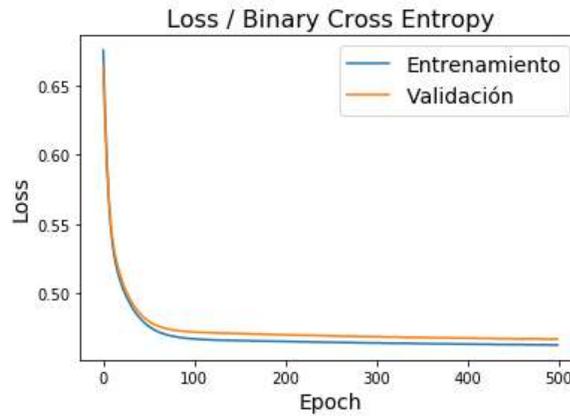


Gráfico 9-15: Función de Costo para el caso de 3 neuronas y 500 epochs.

### CAPA DE 7 NEURONAS

Para el caso de 7 neuronas y 1 capa oculta se obtuvo la siguiente tabla:

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,75                 | 80                       | 78,369               | 71,429        | 42,683     | 25,859                | 0,42767 |
| 20 b - 230 e | 77,64                 | 80                       | 78,369               | 71,429        | 42,683     | 12,344                | 0,42767 |
| 20 b - 100 e | 76,75                 | 78,22                    | 77,305               | 71,429        | 36,585     | 5,906                 | 0,39013 |
| 20 b -50 e   | 76,86                 | 78,22                    | 75,887               | 85            | 20,732     | 3,453                 | 0,34023 |

Tabla 9-11: Análisis de predictibilidad para 1 capa oculta con 7 neuronas

Nuevamente se obtiene el valor de 0,42767 para el MCC tanto en 500 epochs como en 230 epochs, pero el tiempo continúa excediendo la condición inicial.

### CAPA DE 23 NEURONAS

Para el caso de 1 capa con 23 neuronas se obtuvo lo siguiente:

| Batch/Epoch  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|--------------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 20 b - 500 e | 77,98                 | 79,56                    | 78,369               | 71,429        | 42,683     | 25,359                | 0,42767 |
| 20 b - 230 e | 77,64                 | 80                       | 78,369               | 71,429        | 42,683     | 11,594                | 0,42767 |
| 20 b - 100 e | 77,75                 | 80                       | 78,369               | 71,429        | 42,683     | 7,203                 | 0,42767 |
| 20 b -50 e   | 77,2                  | 79,56                    | 78,014               | 71,739        | 40,244     | 6,125                 | 0,41475 |

Tabla 9-12: Análisis de predictibilidad para 1 capa oculta con 23 neuronas

En la prueba de 1 capa oculta de 23 neuronas, con un batch de tamaño 20 y 100 epochs se logra obtener el MCC objetivo dentro del rango de tiempo solicitado.

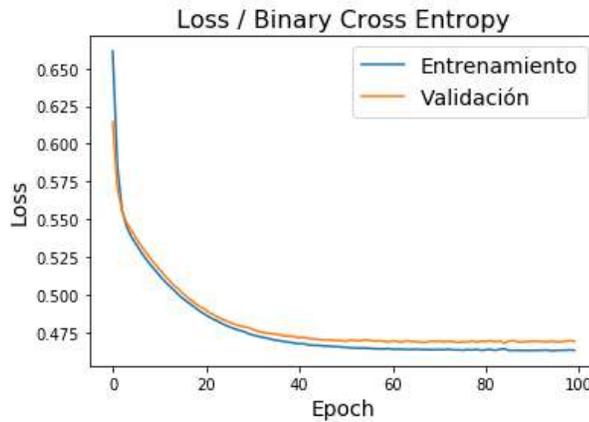


Gráfico 9-16: Función de Costo para el caso de 23 neuronas y 100 epochs.

Una vez llegado a este resultado, la búsqueda se orienta ahora en encontrar una configuración de parámetros e hiperparámetros que permita obtener un resultado similar a un menor tiempo, para eso se analiza la predictibilidad de una red neuronal con 2 y 3 capas ocultas, a diferentes epochs y distinto número de neuronas por capa.

## 8.2.2 ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 2 CAPAS OCULTAS

### ANÁLISIS CON PRIMERA CAPA OCULTA DE 3 NEURONAS

Los resultados obtenidos con 100 epochs son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 3-10 | 77,31                 | 80                       | 78,369               | 71,429        | 42,683     | 7,641                 | 0,42767 |
| 3-20 | 77,42                 | 80                       | 78,014               | 71,739        | 40,244     | 7,625                 | 0,41475 |
| 3-40 | 77,42                 | 80                       | 78,369               | 72,34         | 41,463     | 7,156                 | 0,42604 |

Tabla 9-13: Análisis de predictibilidad para distintas configuraciones en 100 epoch

En la tabla anterior, la columna red representa la configuración estudiada, por ejemplo 3-10 representa la red de primera capa oculta con 3 neuronas y la segunda capa oculta con 10 neuronas. El cambio en los valores de MCC se debe principalmente a pequeñas modificaciones en las predicciones, es por ello que se pueden considerar cercanos al valor máximo, obtenido en el caso de la configuración 3-10. Para ejemplificar estas pequeñas diferencias en las predicciones se muestra a continuación las distintas matrices de confusión asociadas a los distintos valores de MCC.

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | 186        | 14 |
|      | 1 | 47         | 35 |

Tabla 9-14: Matriz de confusión para el valor de MCC = 0,42767

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | 187        | 13 |
|      | 1 | 49         | 33 |

Tabla 9-15: Matriz de confusión para el valor de MCC = 0,41475

|      |   | Predicción |    |
|------|---|------------|----|
|      |   | 0          | 1  |
| Real | 0 | 187        | 13 |
|      | 1 | 48         | 34 |

Tabla 9-16: Matriz de confusión para el valor de MCC = 0,42604

Cabe recordar que los conceptos relativos a la matriz de confusión, asociados a la precisión de la predicción realizada por el modelo son: el “verdadero positivo”, ubicado en el recuadro inferior derecho de la matriz, y el “verdadero negativo” que está en el recuadro superior izquierdo.

Los resultados obtenidos con 50 epoch son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 3-10 | 77,98                 | 77,33                    | 76,596               | 73,529        | 30,488     | 3,625                 | 0,36243 |
| 3-20 | 76,64                 | 77,78                    | 77,305               | 71,429        | 36,585     | 4,031                 | 0,39013 |
| 3-40 | 76,53                 | 78,22                    | 77,305               | 71,429        | 36,585     | 5,797                 | 0,39013 |

Tabla 9-17: Análisis de predictibilidad para distintas configuraciones en 50 epoch

Al agregar una tercera capa oculta, las 3 alternativas presentadas con epoch 50 pueden mejorar eventualmente su MCC y a la vez lograr un tiempo inferior a las alternativas que ya cumplen los requisitos solicitados.

El MCC máximo con 2 capas ocultas y 3 neuronas en la primera capa, se obtiene para la configuración 3-10 neuronas con 100 epoch, tamaño de batch de 20 y en un tiempo de 7,64 segundos.

## ANÁLISIS CON PRIMERA CAPA OCULTA DE 7 NEURONAS

Los resultados obtenidos con batch tamaño 20 y 100 epoch son los siguientes:

| Red | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC |
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-----|
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-----|

|      |       |       |        |        |        |      |         |
|------|-------|-------|--------|--------|--------|------|---------|
| 7-10 | 77,31 | 80    | 78,369 | 72,34  | 41,463 | 6,46 | 0,42604 |
| 7-20 | 77,75 | 79,56 | 78,014 | 71,739 | 40,244 | 7,92 | 0,41475 |
| 7-40 | 77,53 | 80    | 78,014 | 71,739 | 40,244 | 7,70 | 0,41475 |

Tabla 9-18: Análisis de predictibilidad para distintas configuraciones en 100 epoch

Si bien las 3 alternativas se acercan al MCC máximo (0,42767), solo se considerarían en caso de que no exista una alternativa que ofrezca un tiempo inferior.

Los resultados para una red de primera capa con 7 neuronas, batch de tamaño 20 y 50 epoch son los siguientes:

| Red  | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 7-10 | 76,64                 | 77,78                    | 77,305               | 71,429        | 36,585     | 3,375                 | 0,39013 |
| 7-20 | 76,75                 | 77,78                    | 77,305               | 71,429        | 36,585     | 3,922                 | 0,39013 |
| 7-40 | 76,86                 | 78,67                    | 78,014               | 72,727        | 39,024     | 4,188                 | 0,41328 |

Tabla 9-19: Análisis de predictibilidad para distintas configuraciones en 50 epoch

Las 3 alternativas para 50 epoch tienen potencial de mejora en el MCC de añadir una tercera capa.

### 8.2.3. ANÁLISIS DE PREDICTIBILIDAD DE DERRAME CON 3 CAPAS OCULTAS

#### ANÁLISIS CON PRIMERA CAPA OCULTA DE 3 NEURONAS

Al igual que en el caso de 2 capas ocultas, se realiza este análisis para los casos de 100 y 50 epoch.

| Red     | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|---------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 3-10-10 | 77,75                 | 80                       | 78,369               | 71,429        | 42,683     | 8,753                 | 0,42767 |
| 3-20-20 | 77,86                 | 80,44                    | 78,369               | 71,429        | 42,683     | 8,578                 | 0,42767 |
| 3-40-40 | 78,2                  | 79,56                    | 78,369               | 71,429        | 42,683     | 8,406                 | 0,42767 |

Tabla 9-20: Análisis de predictibilidad para distintas configuraciones en 100 epoch

| Red | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC |
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-----|
|-----|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-----|

|         |       |       |        |        |        |       |         |
|---------|-------|-------|--------|--------|--------|-------|---------|
| 3-10-10 | 77,31 | 78,22 | 77,66  | 72,093 | 37,805 | 4,234 | 0,40177 |
| 3-20-20 | 77,42 | 80    | 78,369 | 71,429 | 42,683 | 4,703 | 0,42767 |
| 3-40-40 | 77,98 | 80    | 78,369 | 71,429 | 42,683 | 4,641 | 0,42767 |

Tabla 9-21: Análisis de predictibilidad para distintas configuraciones en 50 epoch

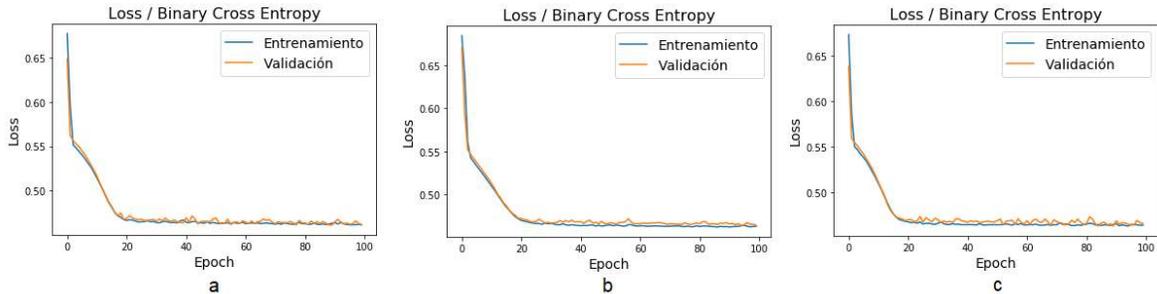


Gráfico 9-17: Función de Costo para 3-10-10 (a), 3-20-20 (b) y 3-40-40 (c) con 100 epoch

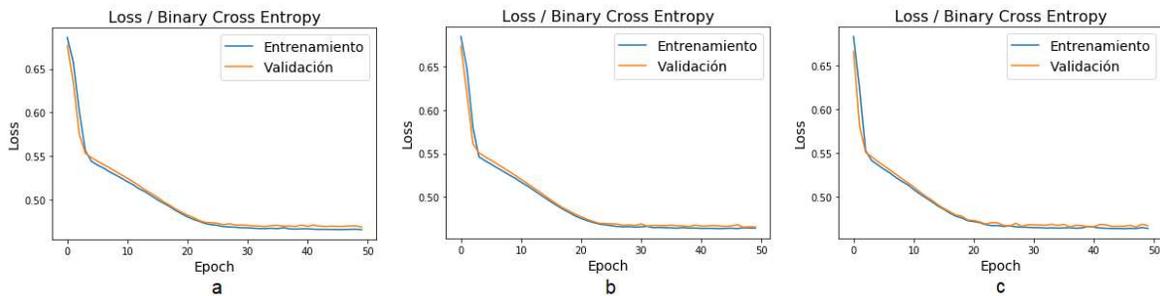


Gráfico 9-18: Función de Costo para 3-10-10 (a), 3-20-20 (b) y 3-40-40 (c) con 50 epoch

En los gráficos se puede apreciar que prácticamente no existe overfitting en estas configuraciones, y que tienen funciones de costo muy similares, mientras que en las tablas se enseñan valores similares de MCC. Luego, el factor por el cual decidir que configuración utilizar es el tiempo de entrenamiento, donde la configuración de tamaño de batch de 20 y 50 epochs logra el objetivo en menor tiempo que la configuración de 20 de batch y 100 epochs. Así, en este caso resulta prácticamente indiferente cual alternativa seleccionar entre la configuración 3-20-20 y 3-40-40 para 50 epochs y 20 de batch

### ANÁLISIS CON PRIMERA CAPA OCULTA DE 7 NEURONAS

| Red     | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|---------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 7-10-10 | 77,31                 | 80                       | 78,369               | 71,429        | 42,683     | 7,359                 | 0,42767 |

|         |       |    |        |    |        |       |         |
|---------|-------|----|--------|----|--------|-------|---------|
| 7-20-20 | 77,98 | 80 | 78,014 | 70 | 42,683 | 8,453 | 0,41834 |
| 7-40-40 | 77,75 | 80 | 78,014 | 70 | 42,683 | 8,406 | 0,41834 |

Tabla 9-22: Análisis de predictibilidad para distintas configuraciones en 100 epoch

| Red     | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC     |
|---------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|---------|
| 7-10-10 | 77,09                 | 80                       | 78,369               | 71,429        | 42,683     | 4,453                 | 0,42767 |
| 7-20-20 | 76,75                 | 78,67                    | 78,014               | 72,727        | 39,024     | 4,406                 | 0,41328 |
| 7-40-40 | 78,2                  | 78,67                    | 78,369               | 73,333        | 40,244     | 5,203                 | 0,42464 |

Tabla 9-23: Análisis de predictibilidad para distintas configuraciones en 50 epoch

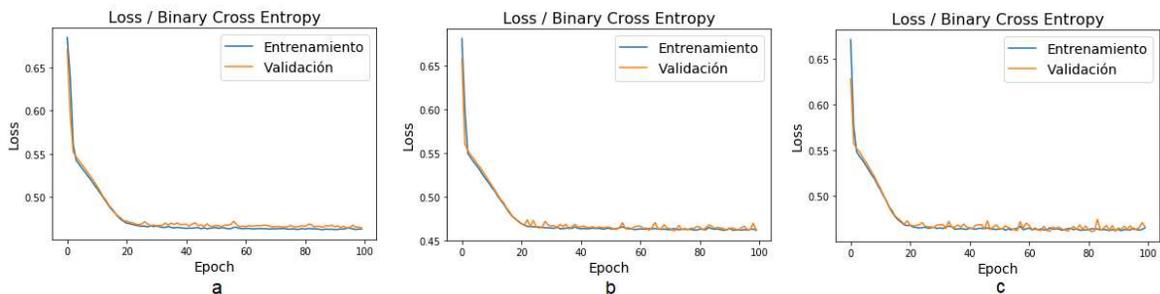


Gráfico 9-19: Función de Costo para 7-10-10 (a), 7-20-20 (b) y 7-40-40 (c) con 100 epoch

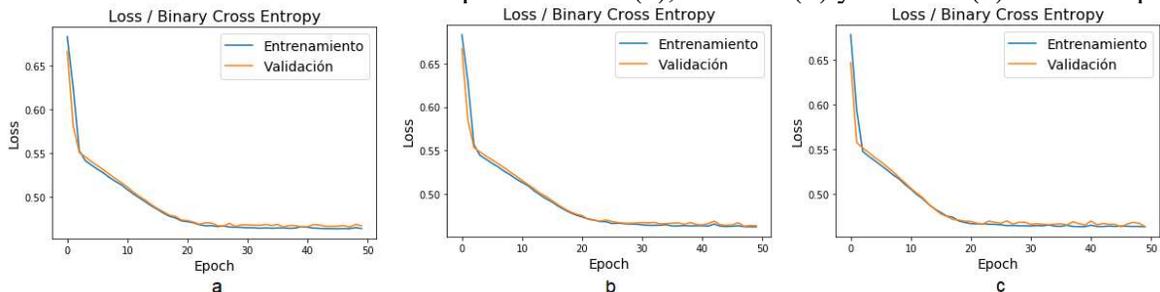


Gráfico 9-20: Función de Costo para 7-10-10 (a), 7-20-20 (b) y 7-40-40 (c) con 50 epoch

Todas las alternativas ofrecen MCC similares, pero la más atractiva es la de 7-10-10 en 50 epoch y con un batch de tamaño 20, puesto que alcanza el valor máximo de MCC a un tiempo menor que la configuración 7-10-10 a 100 epoch y batch de tamaño 20, la cual también logra el MCC máximo.

| RESUMEN |       |                 |         |                             |
|---------|-------|-----------------|---------|-----------------------------|
| Red     | Epoch | Tamaño de Batch | MCC     | Tiempo de entrenamiento [s] |
| 3       | 230   | 20              | 0,42767 | 11,44                       |
| 7       | 230   | 20              | 0,42767 | 12,34                       |
| 23      | 230   | 20              | 0,42767 | 11,59                       |
| 23      | 100   | 20              | 0,42767 | 7,20                        |
| 3-10    | 100   | 20              | 0,42767 | 7,64                        |
| 3-10-10 | 100   | 20              | 0,42767 | 8,75                        |
| 3-20-20 | 100   | 20              | 0,42767 | 8,58                        |
| 3-40-40 | 100   | 20              | 0,42767 | 8,41                        |
| 3-20-20 | 50    | 20              | 0,42767 | 4,70                        |
| 3-40-40 | 50    | 20              | 0,42767 | 4,64                        |
| 7-10-10 | 100   | 20              | 0,42767 | 7,36                        |
| 7-10-10 | 50    | 20              | 0,42767 | 4,45                        |

Tabla 9-24: Resumen de todas las alternativas que cumplen las condiciones solicitadas.

La tabla anterior es una tabla resumen con todas las alternativas que presentan el valor MCC máximo y el tiempo de entrenamiento asociado cercano o menor a 10 segundos. Las mejores alternativas son sin duda las que presentan las configuraciones 7-10-10, 3-20-20 y 3-40-40 todas con 20 de tamaño de batch y 50 epochs. La alternativa seleccionada para continuar es la 7-10-10 con 50 epochs y un batch de tamaño 20.

#### 8.2.4. ANÁLISIS DE PREDICTIBILIDAD DE DAÑO CON 1 CAPA OCULTA

La estrategia utilizada en esta red difiere de la anterior, donde los gráficos de la función de coste de entrenamiento y validación mostraban una evidente similitud en todo su co-recorrido, lo que provocaba la inexistencia de overfitting, mientras que para esta nueva red eso no sucede de manera tan clara. Esta estrategia aparece detallada en el apartado de Metodología.

Para el caso de 1 oculta capa de 3 neuronas se tienen los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-----|
|       |                       |                          |                      |               |            |                       |     |

|     |       |       |       |       |       |       |      |
|-----|-------|-------|-------|-------|-------|-------|------|
| 20  | 71,37 | 66,37 | 69,98 | 72,71 | 85,37 | 13,73 | 0,31 |
| 32  | 72,19 | 68,15 | 67,49 | 68,49 | 92,22 | 8,52  | 0,19 |
| 50  | 69,63 | 64,74 | 69,74 | 72,07 | 86,11 | 5,79  | 0,31 |
| 100 | 67,56 | 62,52 | 63,95 | 65,83 | 91,30 | 3,95  | 0,09 |

Tabla 9-25: Análisis de predictibilidad para 1 oculta capa de 3 neuronas y 200 epoch

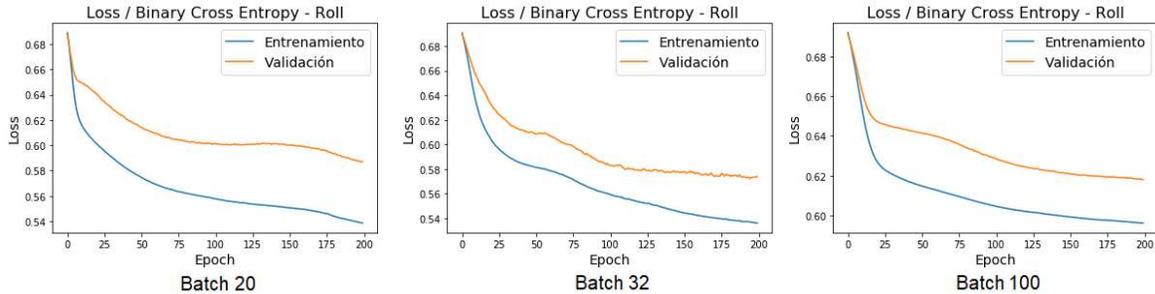


Gráfico 9-21: Ejemplos de funciones de coste para 1 capa oculta con 3 neuronas y 200 epoch

Es clara la diferencia entre el entrenamiento y la validación, lo que causa una predictibilidad deficiente, que se puede apreciar en los valores del MCC. Dicha diferencia eventualmente podría reducirse aumentando la cantidad de epochs en casos donde la gráfica sea como la del gráfico C, de 100 de tamaño de batch, esto debido a la pendiente que presentan las funciones de costo. Sin embargo, como se evidenció en la red de predicción de derrames, al aumentar el número de epochs se incurre también en un aumento de tiempo de entrenamiento, por lo que a priori no se considera por exceder el tiempo solicitado.

En el caso de 1 capa oculta de 7 neuronas se tienen los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC   |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|-------|
| 20    | 77,27                 | 72,89                    | 73,88                | 79,31         | 80,00      | 13,28                 | 0,433 |
| 32    | 75,27                 | 72,59                    | 71,75                | 74,29         | 85,37      | 9,06                  | 0,359 |
| 50    | 75,23                 | 70,52                    | 72,34                | 76,56         | 81,67      | 5,46                  | 0,388 |
| 100   | 73,71                 | 69,78                    | 70,57                | 72,47         | 86,85      | 3,92                  | 0,326 |

Tabla 9-26: Análisis de predictibilidad para 1 capa oculta de 7 neuronas y 200 epoch

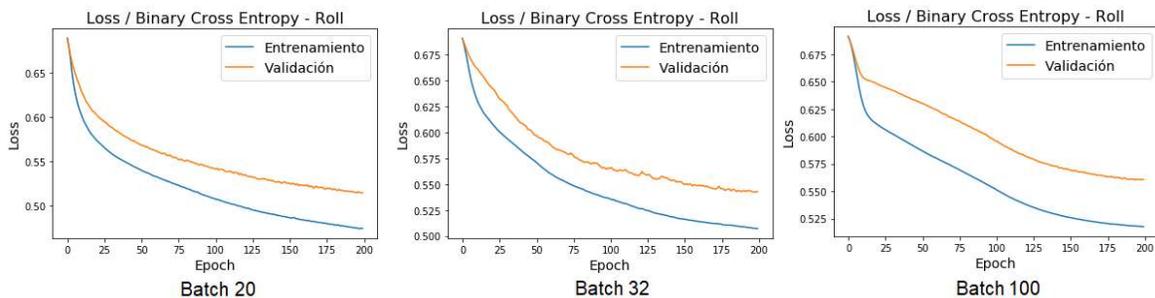


Gráfico 9-22: Ejemplos de funciones de coste para 1 capa con 7 neuronas y 200 epoch

Tal como el caso anterior, no hay ninguna alternativa que logre satisfacer las condiciones, presentando bajos valores de MCC para los casos donde se cumple con la condición del tiempo de entrenamiento.

Para el caso de 1 capa oculta y 11 neuronas se obtuvieron los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 77,61                 | 75,11                    | 74,70                | 80,67         | 79,44      | 12,08                 | 0,4554 |
| 32    | 75,42                 | 72,45                    | 73,29                | 78,04         | 80,93      | 7,99                  | 0,4137 |
| 50    | 75,60                 | 73,63                    | 73,76                | 78,29         | 81,48      | 6,11                  | 0,4237 |
| 100   | 74,04                 | 70,67                    | 71,87                | 75,18         | 83,52      | 3,72                  | 0,3683 |

Tabla 9-27: Análisis de predictibilidad para 1 capa de 11 neuronas y 200 epoch

La alternativa de batch tamaño 50 presenta a priori una posible solución, esto es si se considera que se trabajó con un MCC similar en la red de predicción de derrames. Sin embargo, al ver el gráfico de la función de coste asociada a esta alternativa resulta evidente que aún es una solución subóptima, y por lo tanto perfectible.

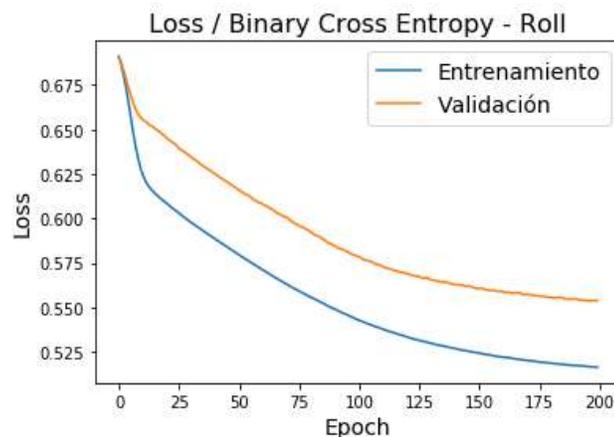


Gráfico 9-23: Función de coste para 1 capa de 11 neuronas, Batch 50 y 200 Epochs

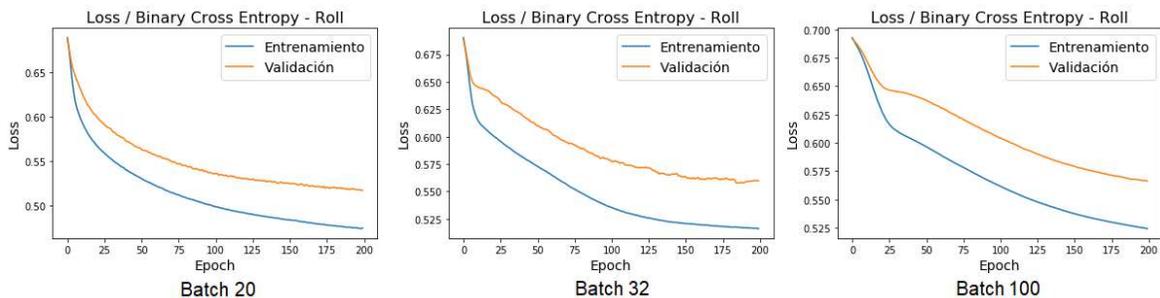


Gráfico 9-24: Ejemplos de funciones de coste para 1 capa con 11 neuronas y 200 epoch

La siguiente alternativa a analizar es la de 1 capa oculta con 23 neuronas:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 80,61                 | 80,30                    | 77,78                | 82,47         | 82,78      | 12,04                 | 0,5185 |
| 32    | 78,46                 | 76,15                    | 76,24                | 81,46         | 81,30      | 9,42                  | 0,4859 |
| 50    | 78,27                 | 76,15                    | 75,65                | 80,41         | 81,85      | 5,39                  | 0,4696 |
| 100   | 77,90                 | 76,59                    | 75,06                | 79,35         | 82,41      | 3,78                  | 0,4523 |

Tabla 9-28: Análisis de predictibilidad para 1 capa de 23 neuronas y 200 epoch

Según MCC y tiempo de entrenamiento las alternativas de tamaño de batch 50 y 100 presentan una posible solución. Aunque tal como refleja el siguiente gráfico, aún es posible lograr una mejor solución.

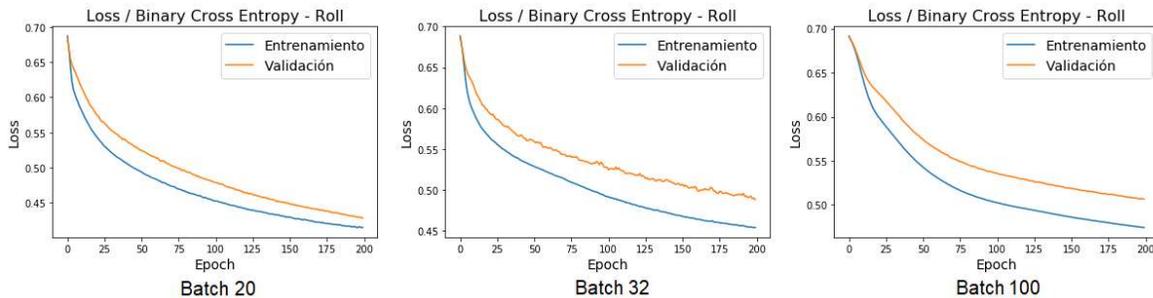


Gráfico 9-25: Ejemplos de funciones de coste para 1 capa con 23 neuronas y 200 epoch

### 8.2.5. ANÁLISIS DE PREDICTIBILIDAD DE DAÑO CON 2 CAPAS OCULTAS

Para la alternativa de 10 neuronas en la segunda capa oculta se obtuvo lo siguiente:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 78,09                 | 76,00                    | 74,82                | 83,46         | 75,56      | 12,97                 | 0,4801 |
| 32    | 77,09                 | 74,82                    | 75,77                | 83,13         | 77,78      | 8,94                  | 0,4960 |
| 50    | 75,97                 | 72,59                    | 72,93                | 82,55         | 73,15      | 14,75                 | 0,4450 |
| 100   | 77,64                 | 75,70                    | 75,30                | 80,82         | 80,56      | 9,32                  | 0,4712 |

Tabla 9-29: Análisis de predictibilidad para red de 7-10 neuronas y 200 epoch

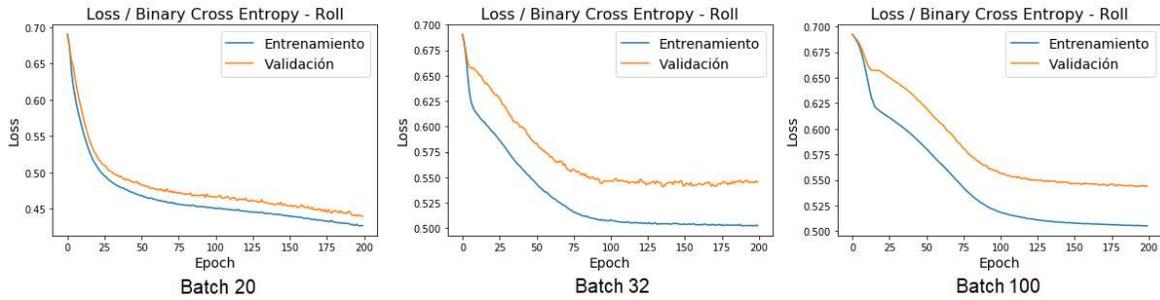


Gráfico 9-26: Ejemplos de funciones de coste para red de 7-10 neuronas y 200 epoch

Todas las alternativas presentadas quedan excluidas por no cumplir con el tiempo solicitado, además de que sus funciones de costo tienen una gran diferencia entre entrenamiento y validación.

Para la configuración con 20 neuronas en la segunda capa oculta se obtuvieron los siguientes resultados:

| Batch | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|-------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 20    | 79,61                 | 77,78                    | 77,66                | 84,88         | 79,07      | 14,09                 | 0,5347 |
| 32    | 76,01                 | 72,89                    | 72,93                | 83,69         | 71,48      | 9,66                  | 0,4538 |
| 50    | 73,93                 | 70,22                    | 71,63                | 83,19         | 69,63      | 7,05                  | 0,4316 |
| 100   | 81,34                 | 80,89                    | 79,52                | 83,51         | 84,58      | 4,54                  | 0,5560 |

Tabla 9-30: Análisis de predictibilidad para red de 7-20 neuronas y 200 epoch

El caso de la red de 7-20 neuronas con tamaño de batch 100 y con 200 epochs resulta ser la configuración elegida, pues con un coeficiente de Matthews de 0,556 en un tiempo de 4,54 segundos logra satisfacer las condiciones exigidas.

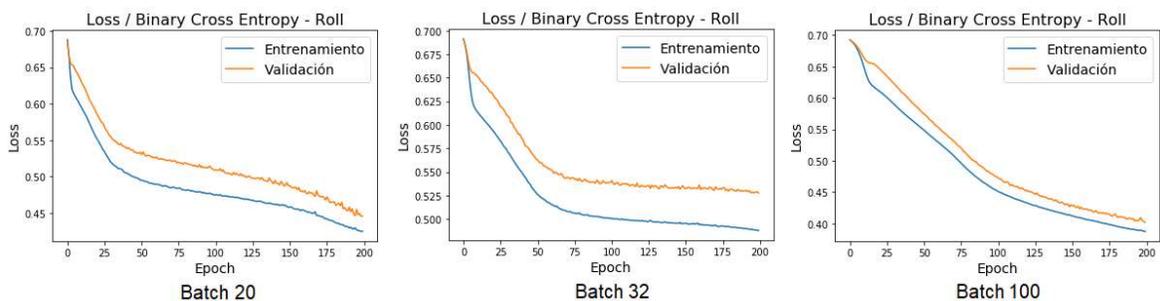


Gráfico 9-27: Ejemplos de funciones de coste para red de 7-20 neuronas y 200 epoch

En la siguiente tabla se muestra los resultados de distintas ejecuciones del algoritmo de predicción de daños para la configuración de 7-20 neuronas, con 100 de tamaño de batch y 200 epochs.

| Prueba | Exactitud Entren. [%] | Exactitud Validación [%] | Exactitud Modelo [%] | Precisión [%] | Recall [%] | Tiempo de Entren. [s] | MCC    |
|--------|-----------------------|--------------------------|----------------------|---------------|------------|-----------------------|--------|
| 1      | 81,98                 | 81,33                    | 81,92                | 84,87         | 87,22      | 4,20                  | 0,6046 |
| 2      | 79,98                 | 80                       | 77,66                | 83,05         | 81,67      | 5,06                  | 0,5194 |
| 3      | 79,76                 | 78,67                    | 76,24                | 82,29         | 80         | 4,19                  | 0,4912 |
| 4      | 83,65                 | 83,56                    | 82,27                | 83,85         | 89,44      | 4,69                  | 0,6087 |

Tabla 9-31: Resultados para predicción de daños, con 7-20 neuronas, 100 de tamaño de batch y 200 epochs.

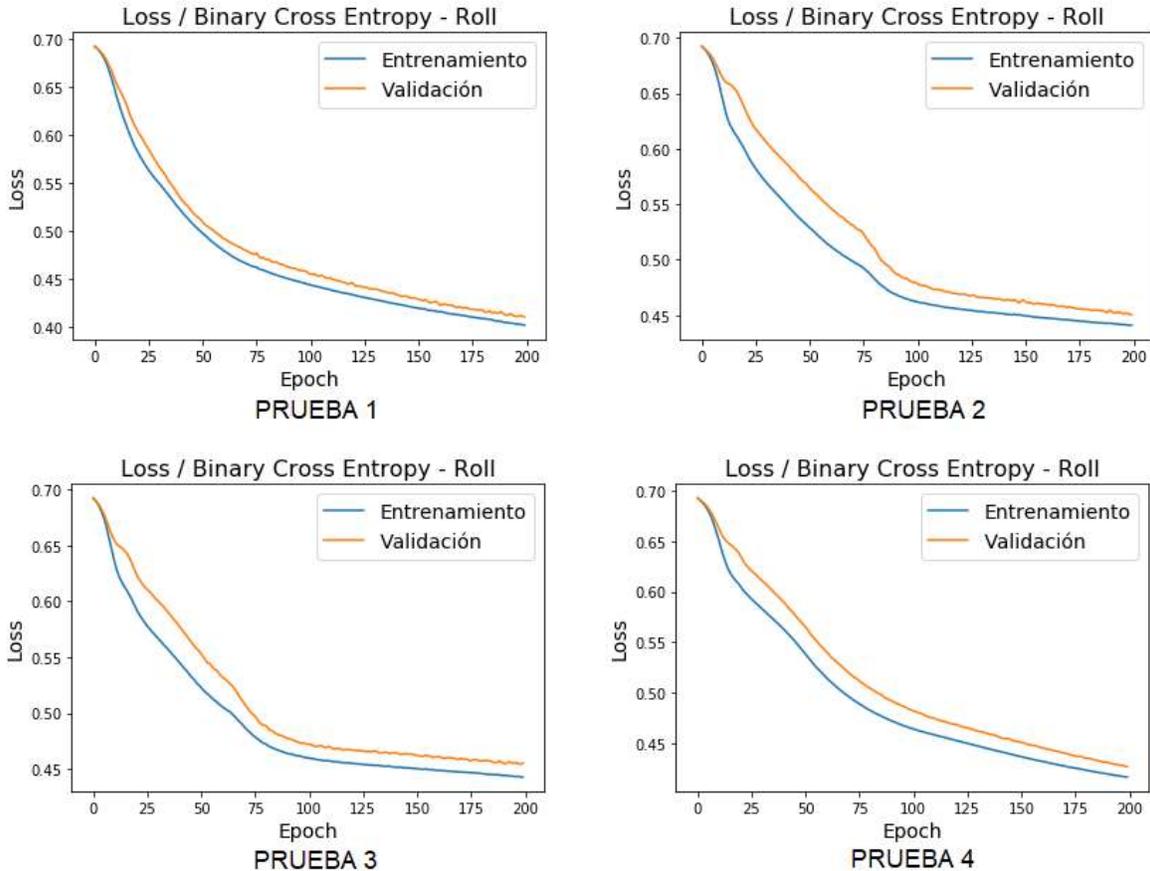


Gráfico 9-28: Funciones de costo para el caso con 7-20 neuronas, 100 de tamaño de batch y 200 epochs.

### 8.3. ANÁLISIS DE EVALUACIÓN ECONÓMICA

Tanto para el caso base como para el peor caso las utilidades de los casos sin derrame son superiores a la de los casos que presentan derrames:

|                            | Caso Base   | Peor Caso  |
|----------------------------|-------------|------------|
| Utilidad Sin Derrame [USD] | 216.213.924 | 72.614.921 |
| Utilidad 1 Derrame [USD]   | 186.521.350 | 62.134.544 |
| Utilidad 2 Derrames [USD]  | 185.658.794 | 61.996.750 |

Tabla: Utilidad para los casos analizados

Al comparar los costos e ingresos promediándolos por la cantidad de viajes a planta en cada caso, se descubre que los valores son muy similares en los costos del camión por cada viaje, y por ende la utilidad generada por cada viaje es similar en los casos con y sin derrames. Esto hace que el factor diferenciador entre los casos con derrames y sin derrame sea la mayor cantidad de viajes a planta que existen en el caso sin derrame, versus los casos con derrames.

|                                | Sin Derrame | 1 Derrame | 2 Derrames |
|--------------------------------|-------------|-----------|------------|
| N viajes                       | 87.974      | 76.192    | 75.900     |
| C. Neumáticos por viaje [USD]  | 55,01       | 54,73     | 54,51      |
| C. Petróleo por viaje [USD]    | 54,24       | 54,68     | 54,99      |
| C. Mantenición por viaje [USD] | 34,01       | 33,91     | 33,86      |
| Ingreso por viaje [USD]        | 2.645       | 2.643     | 2.641      |
| Utilidad por viaje [USD]       | 2.458       | 2.448     | 2.446      |

Tabla: Costos, Ingreso y Utilidad media por viaje, Caso base

|                 | Caso Base | Peor Caso |
|-----------------|-----------|-----------|
| Viajes caso SD  | 87.974    | 87.972    |
| Viajes caso 1 D | 76.192    | 76.133    |
| Viajes Caso 2D  | 75.900    | 76.049    |

Tabla: Cantidad de Viajes anuales a planta en cada caso

|                 | Caso Base | Peor Caso |
|-----------------|-----------|-----------|
| Viajes caso SD  | 244,37    | 244,37    |
| Viajes caso 1 D | 211,65    | 211,48    |
| Viajes Caso 2D  | 210,83    | 211,25    |

Tabla: Cantidad de viajes diarios (360 días trabajados por año)

A priori se podría deducir que esta similitud de valores en los costos es debida a que los incrementos determinados de manera conceptual no fueron lo suficientemente altos como para generar una clara diferencia, es por ello que se analiza aumentar estos valores incrementales hasta que equivalgan el 70% del costo de cada item por ciclo. Por ejemplo, si en un ciclo normal el costo de petróleo es de 100 USD/ciclo, ahora sería de 170 USD/ciclo. Este aumento de incrementos de costo se aplica a la configuración del “peor caso”, tanto para el caso sin derrame como el de 1 derrame, obteniendo lo siguiente:

|                               | Sin Derrame | 1 Derrame |
|-------------------------------|-------------|-----------|
| N viajes                      | 87.977      | 75.968    |
| C. Neumáticos por viaje [USD] | 209,97      | 205,37    |

|                              |        |        |
|------------------------------|--------|--------|
| C. Petróleo por viaje [USD]  | 63,28  | 67,01  |
| C. Mantenión por viaje [USD] | 103,78 | 101,22 |
| Utilidad por viaje [USD]     | 637    | 632    |

Tabla: Costos por viaje para el caso de incrementos de 70%

Si bien son valores similares, se aprecia que por cada viaje sin derrame, en promedio, el costo de neumáticos y de mantención es ligeramente mayor que el caso de 1 derrame, mientras que el petróleo es mayor en el caso de 1 derrame. Estos costos seguirían la lógica que para evitar derrames se debe incurrir en daños al equipo de transporte, sin embargo este trabajo de título no se enfoca en el cálculo de estos factores, incorporándolos como un valor conceptual. Se recomienda a futuro estudiar como es el comportamiento real de los costos ante la ocurrencia de derrames.

Otro detalle a considerar es que en los casos tanto de 1 derrame y 2 derrames existen ciclos que poseen menos derrames. Es decir, en los casos de 2 derrames por ciclo de flota, existen ciclos con 0 y con 1 derrames. Esto provoca que haya similar cantidad de viaje en los casos de 1 derrame y de 2 derrames, puesto que el programa realizado donde se calculó la evaluación económica considera tiempos distintos por cada derrame según sea el caso, tal como muestra el análisis de resultados de la simulación en Promodel, donde se obtienen dos grupos distintos de datos, los de 1 derrame y los de 2 derrames.

El problema es en el caso de 2 derrames, ya que al dividir por derrame individual se obtienen demoras menores por derrame (del orden de 35 a 52 minutos) con respecto al caso de 1 derrame por ciclo (del orden de 55 a 87 minutos). En caso de que todos estos ciclos fuesen de 2 derrames por ciclo no habría problema, pues seguiría la lógica de tener mayor pérdida operacional por ciclo de flota, ya que la suma de la pérdida operacional de los dos derrames, aún siendo menores individualmente, es mayor en promedio a la pérdida operacional de los derrames en el caso de 1 derrame por ciclo. Estos valores son en relación al tiempo de operación día de la flota, es decir el tiempo cronológico multiplicado por la cantidad de camiones.

|                      | Caso 1 Derrame | Caso 2 Derrames |
|----------------------|----------------|-----------------|
| Ciclo sin derrame    | 1.380          | 1.165           |
| Ciclo con 1 derrame  | 6.053          | 2.346           |
| Ciclo con 2 derrames | -              | 3.883           |
| Total                | 7.433          | 7.394           |

Tabla: Cantidad de ciclos para casos de 1 derrame y 2 derrames, caso base

## 9. CONCLUSIONES

Los derrames afectan la utilización efectiva de la flota, esto debido al incremento en las pérdidas operacionales, lo cual operativamente se traduce en la espera del camión que enfrenta el derrame, mientras se ejecuta la limpieza de la ruta, como también los desajustes que estos derrames provocan en la fluidez del circuito, reflejándose en demoras mayores en la cola de la pala y del chancador, esto respecto a una operación sin derrames, afectando así no solo al camión que enfrenta al derrame, sino que a la flota completa.

La sola ocurrencia de 1 derrame por cada ciclo de una flota completa de 10 camiones merma la utilización efectiva de la flota desde un 78,4%, que es la utilización efectiva en el escenario sin derrame entregada por la simulación; a una utilización efectiva entre 70,5% y 67% aproximadamente. Este rango está en función de la distancia del derrame en relación a los equipos de apoyo, los cuales para este trabajo están ubicados en la frente de extracción. En caso de que sean 2 derrames por ciclo, esta utilización efectiva desciende a un rango entre 67 y 64,32%.

Dadas las pérdidas operacionales, el tiempo de ciclo de transporte se ve afectado notoriamente pasando de 35,7 minutos en el caso sin derrame a unos 43,6 minutos en el caso de 2 derrames por ciclo a 3400 metros de la frente de explotación. Y así mismo se reduce la utilización de la pala en función al aumento del tiempo de ciclo de los camiones, siendo aproximadamente de un 73% para el caso sin derrames (35,7 minutos de ciclo), y bajando a un 60% para el caso de 2 derrames a 3400 metros (43,6 minutos de ciclo).

Por lo tanto el evitar derrames, desde el punto de vista operativo, resulta beneficioso debido a que al haber más tiempo involucrado en tareas propias del carguío y transporte implica un mayor número de viajes a planta, 272 viajes en promedio en el caso sin derrames versus 241 en el caso de 1 derrame por ciclo de flota, lo que se traduce en mayores ingresos en comparación a los casos donde hay ocurrencia de derrames, los cuales ven disminuido su tiempo de utilización en tareas productivas, es decir su utilización efectiva, a causa de las pérdidas operacionales mencionadas anteriormente, y con ello hay una evidente disminución en el número de viajes a planta, y en consecuencia menores ingresos.

La simulación genera dos conjuntos de datos no lineales entre sí, pero claramente identificables: los del modelo de 1 derrame por ciclo y los del modelo de 2 derrames por ciclo. La pérdida de utilización efectiva en función a los minutos de pérdida operacional para el caso de 1 derrame por ciclo sigue la siguiente fórmula:  $y = 0,008x - 0,2038$ , mientras que la función asociada a 2 derrames por ciclo corresponde a  $y = 0,0086x - 0,1266$ , ambas funciones con  $x =$  pérdida operacional por derrame [min] e  $y =$  pérdida de utilidad efectiva por derrame [%]. Estas fórmulas se utilizan a su vez en el modelo generado en Python para determinar la evaluación económica.

Con el dataset entregado fue posible configurar dos redes neuronales artificiales de tipo perceptrón multicapa que entregaran una etiqueta binaria, En la primera red la etiqueta fue la ocurrencia o no ocurrencia de derrames en ruta, desde 3 características, o información de entrada, que eran la ubicación de 3 paladas respecto a la tolva; para el caso de la segunda red lo que se busca es predecir la ocurrencia de daño en la estructura del camión y en los neumáticos debido al carguío dinámico.

Se generaron 2 redes, la cuales entregaron una precisión de 73% en entrenamiento y 72% en etapa de prueba para el caso de Roll=2. Mientras que para el caso de Roll=3 la red generada fue de una precisión de entrenamiento de 83% y de 85% de validación. Demostrando que también es posible predecir la ocurrencia de daño por medio de los valores del roll, sin embargo, esta precisión puede aumentar igualmente al caso anterior con un dataset de mayor volumen. Cabe destacar que para la evaluación económica se utilizó el roll=2, esto para que haya un mayor volumen de casos de existencia de daño

Se establece entonces que el carguío dinámico es una buena herramienta a desarrollar y perfeccionar, con el objetivo de prevenir derrames y pérdidas operacionales asociadas, para así disponer de mayor tiempo operativo y mayores ingresos.

## 10. TRABAJOS FUTUROS

Como alternativas de trabajo futuro se presentan las siguientes:

- 1) Analizar la influencia en la operación, y posteriormente en el aspecto económico, de la disposición espacial de los equipos de apoyo dentro de la faena. En otras palabras, estudiar si es conveniente tener a los equipos de apoyo:
  - a) Cerca del frente de carguío
  - b) “Patrullando” la ruta
  - c) Detenidos a una distancia equidistante entre dos puntos con mayor ocurrencia de derrames
  - d) Detenidos en la vecindad próxima del último derrame ocurrido
- 2) Realizar un análisis en terreno de los tiempos asociados a los eventos de derrames, estos son el lapso de tiempo que pasa entre la ocurrencia del derrame, el llamado a los equipos de apoyo, la llegada de los equipos de apoyo, la ejecución de la limpieza y restablecimiento normal de la ruta. Además de considerar como se ven afectados los demás equipos de transporte de la flota ante diversos tiempos de derrame.
- 3) Analizar la utilidad de la implementación de sensores traseros en los camiones para alertar en caso de que el equipo derrame mineral. Esto eventualmente sería de gran utilidad, pues informaría en línea de la ocurrencia de este derrame, y no cuando otro operador o equipo autónomo lo detecta posteriormente. Con esto habría un tiempo menor de interrupción del circuito de transporte, lo que implica mayor fluidez de este.

4) En el aspecto de la generación de la red neuronal artificial, esta podría entrenarse con un dataset de mayor dimensión y con un mayor número de características, tales como:

- Información sensorial de los 4 sectores de amortiguación del equipo
- Distintos ángulos de reposo de material y distintos ángulos de rampa.
- Condición actual del motor e infraestructura del equipo
- Estado de las componentes motrices del equipo, saber cuánto afectaría una exigencia en rampa.
- Temperatura y estado de los neumáticos (desgaste, tracción, etc)

Esto con el objetivo de que la posición de la baldada sea tomada con mayor información técnica y económica, en vías de una visión global de la operación.

5) Realizar el análisis con información de una sola faena para obtener resultados con mayor precisión. Además de conocer en mayor detalle los costos ligados al desgaste de los neumáticos, consumo de combustible y labores de mantenimiento, las cuales son distintas en cada faena dadas las condiciones del suelo, clima, tipo de equipos, tamaño de flota, programa de mantenimiento, etc.

6) Estudiar alternativas tecnológicas para facilitar la tarea de los operadores de pala al momento de cargar, como es por ejemplo el uso de cámaras que permitan visualizar la carga, sistemas de referencia posicional del balde respecto a la tolva, uso de realidad aumentada (AR) y el uso de digital twins para la labor del carguío.

## 11. BIBLIOGRAFÍA

GOODFELLOW, I. "et al", 2016. "Deep Learning", Cambridge, MIT Press, 800p.

CHOLLET, F., "Deep Learning with Python", Shelter Island, Manning Publications, 384p.

CHICCO, D., JURMAN, G., 2020. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. BMC Genomics 21 (6)

BOUGHORBEL S, "el al", 2017. Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric, PLoS ONE 12(6)

CHAMANARA, A., 2013. Enhancing mine haul truck KPIs via payload balance. Tesis de Doctorado en Ingeniería de Minas, Edmonton, Universidad de Alberta, Departamento de Ingeniería Civil y Medioambiental. 165p.

HENZE, J., 2015. Haul Truck Payload Modelling Using Strut Pressures, Tesis de Master of Science en Ingeniería de Minas, Edmonton, Universidad de Alberta, Departamento de Ingeniería Civil y Medioambiental. 119p.

BONZI, J., 2016. Propuestas de mejora de la utilización efectiva en base a disponibilidad de la flota de carguío y transporte en Minera Los Pelambres, Memoria de Ingeniería de Minas, Santiago, Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Ingeniería de Minas, 135p.

PARREIRA, J., 2013. An Interactive Simulation Model to Compare an Autonomous Haulage Truck System with Manually-Operated System, Tesis de Doctorado en Ingeniería de Minas, Vancouver, Universidad de British Columbia, 228p.

VIDAL, M., 2010. Estudio del cálculo de flota de camiones para una operación minera a cielo abierto, Tesis de Ingeniería de Minas, Lima, Pontificia Universidad Católica del Perú, Facultad de Ciencias e Ingeniería, 66p.

BLANCO, J., 2016. Incremento de la vida útil de neumáticos para reducir costos de operación en camiones Caterpillar 797F en Toromocho-Chinalco Perú, Tesis de Ingeniería Mecánica, Huancayo, Universidad Nacional del Centro del Perú, Facultad de Ingeniería Mecánica, 110p.

COCHILCO, 2020, Precios de los Metales e Inventarios [en línea] <[https://boletin.cochilco.cl/estadisticas/grafico.asp?tipo\\_metal=1](https://boletin.cochilco.cl/estadisticas/grafico.asp?tipo_metal=1)> [Consulta: 15 de Junio 2020]

INVESTING.COM, 2020. Datos históricos Futuros petróleo crudo WTI [En Línea]  
<<https://es.investing.com/commodities/crude-oil-historical-data>> [Consulta: 15 Junio 2020]