



ESCUELA DE NEGOCIOS
DEPARTAMENTO DE INGENIERÍA COMERCIAL

UNIVERSIDAD TÉCNICA
FEDERICO SANTA MARÍA

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
Escuela de Negocios Departamento de Ingeniería Comercial
MBA, Magister en Gestión Empresarial

AGREGANDO VALOR A LA INDUSTRIA MINERA MEDIANTE LA UTILIZACIÓN DE MACHINE LEARNING

Tesina de Grado presentada por

Iván Patricio Yutronic Núñez

Como requisito para optar al grado de

MBA, Magíster en Gestión Empresarial

Guía de Tesina Dr. Rodrigo Ortega B.

Noviembre de 2018

TITULO DE TESINA: **“AGREGANDO VALOR A LA INDUSTRIA MINERA
MEDIANTE LA UTILIZACIÓN DE MACHINE
LEARNING”**

AUTOR: **Iván Patricio Yutronic Núñez**

TRABAJO DE TESINA, presentando en cumplimiento parcial de los requisitos para el Grado de MBA, Magíster en Gestión Empresarial de la Universidad Técnica Federico Santa María.

OBSERVACIONES: _____

COMISIÓN DE TESINA: Dr. Rodrigo Ortega B.
 Dr. Luis Acosta E.
 Dr. Luis Cerna M.

Santiago, Noviembre 2018

Todo el contenido, análisis, conclusiones y opiniones vertidas en este estudio son de mi exclusiva autoría y responsabilidad.

Nombre: IVÁN PATRICIO YUTRONIC NÚÑEZ.

Fecha: 19 DE NOVIEMBRE 2018.

Resumen

La presente tesina evidencia la factibilidad técnica-económica de generar información relevante (patrones de comportamiento y modelos) para efectuar una oportuna toma de decisiones y optimizar el procesamiento de mineral alimentado al molino SAG, a partir del uso de grandes volúmenes de datos operacionales, confirmando la posibilidad de utilizar *Machine Learning* (ML) en el principal proceso de la planta concentradora de la minera Centinela.

Los resultados obtenidos con el modelo de ML han permitido desarrollar una carta de navegación basado en una matriz de rangos óptimos de operación para las variables críticas del molino SAG logrando maximizar el mineral procesado, reduciendo el consumo específico de energía y de bolas de acero, evitando además los eventos indeseados de alto torque y quiebres de parrillas.

El impacto económico del uso de la matriz de parámetros óptimos de operación del molino SAG alcanza los 19,4 MMUS\$/año. El menor consumo de medios de molienda, la reducción del consumo específico de energía CEE y las practicas operacionales totalizan un impacto de 6,9 MMUS\$/año, lo que significa que el proceso de molienda SAG logra ahorrar 26,3 MMUS\$/año.

La conformación de un equipo de profesionales que sean capaces de transformar datos en conocimiento se presenta como la principal debilidad para capturar los beneficios de manera sostenida en el tiempo, por lo que se recomienda crear una unidad de analítica avanzada (UAA) cuya evaluación económica muestra ser de alta rentabilidad e impacto para el negocio del grupo minero.

Este trabajo evidencia la madurez alcanzada por el ML, revelando la efectiva oportunidad de generar información relevante y mejorar la toma de decisiones en tiempo real, posicionando a los datos como un activo que agrega valor a las compañías, con relativamente bajos montos de inversión.

Índice

1. Introducción	3
2. Objetivos	5
2.1. Objetivo general.....	5
2.2. Objetivos específicos	5
3. Metodología de trabajo.....	6
4. Resultados.....	7
4.1. Estado del arte.....	7
4.2. Levantamiento de información, identificación de patrones y generación de conocimiento..	10
4.3. Métricas y evaluación de la prueba de concepto	14
4.3.1. Métricas de evaluación	14
4.3.2. Desempeño de la prueba de concepto	14
4.4. Análisis FODA – Uso de Machine Learning.....	20
4.4.1. Evaluación económica de implementación unidad analítica avanzado (UAA).....	23
5. Conclusiones y recomendaciones.....	24
6. Trabajos futuros y recomendaciones	26
7. Literatura y bibliografía.....	27
8. Anexo.....	29
8.1. Anexo 1 - Distribución de costos faena minera	29
8.2. Anexo 2 – Evaluación Económica Implementación Unidad de Analítica Avanzada (UAA)	30
8.3. Anexo 3 – Entorno de desarrollo - Plataforma como servicio PaaS.....	31

1. Introducción

En el plano internacional, durante las últimas dos décadas la industria minera ha tenido que enfrentar años difíciles, particularmente por las fluctuaciones de los precios de ventas de sus productos, los que, luego de haber alcanzado niveles récord, han sufrido un importante descenso a partir del año 2011 debido a la desaceleración económica de China y la menor demanda de metales de otros países en desarrollo (Lee y Prowse, 2014).

La producción de cobre en Chile no ha quedado ajena a los efectos de la economía mundial antes descritos, debiendo enfrentar importantes desafíos relacionados a alzas en sus costos de producción, disminución de las leyes del mineral en sus yacimientos y una fluctuación, con tendencia a la baja, de los precios de sus productos.

Este complejo escenario ha hecho que el grupo Antofagasta Minerals busque diferentes formas de hacer más eficientes sus procesos impulsando para ello un programa de competitividad y costos (PCC) cuyo objetivo es reducir los costos y aumentar la producción de cobre sin la necesidad de realizar grandes inversiones, sino que a través de la optimización del rendimiento de sus procesos mediante la incorporación de nuevas tecnologías.

Esta decisión de experimentar con nuevas tecnologías está siendo utilizada en otras industrias con muy buenos resultados, convirtiéndose cada día en una alternativa más viable y utilizada, gracias a que nos encontramos en una era de abundancia de datos, bajos costos de computación y acceso abierto a los equipos y la literatura, que permiten aprovechar el aprendizaje automático Machine Learning (ML) y otras formas de inteligencia artificial aplicada, siendo posible resolver problemas que anteriormente no era posible solucionar.

La gran abundancia de datos operacionales, que los procesos de las plantas concentradoras generan, se presenta como una oportunidad atractiva para desarrollar nuevas herramientas que den solución a problemas complejos. Estas soluciones solo pueden desarrollarse mediante analítica avanzada, capaz de identificar patrones y modelar el comportamiento de las variables críticas de los procesos productivos de cobre.

La adopción de nuevas tecnologías y su aplicabilidad a los procesos productivos de la industria minera cuentan con algunos importantes resultados a nivel mundial, lo que motiva y fomenta la necesidad de desarrollar pruebas de concepto (POC) que permitan verificar su viabilidad en los procesos más significativos de la cadena productiva de cobre y cuantificar su beneficio para el Grupo Minero Antofagasta Minerals.

Desde el punto de vista de costos, las plantas concentradoras del grupo minero son responsables de casi el 30% de los costos totales de la explotación y producción de cobre. La apertura de los costos relacionados con el proceso productivo de la planta concentradora muestra que el 55% de ellos está relacionado con los procesos de molienda y el 14% está asociado al proceso de flotación, lo cual define las prioridades para centrar los esfuerzos y realizar pruebas de concepto (POC) que permitan reducir la variabilidad de los procesos y utilizar la máxima capacidad de dichos activos.

Actualmente en la industria minera se han desarrollado algunas iniciativas innovadoras, que muestran los importantes beneficios de transformar la abundante cantidad de datos que generan los procesos productivos en soluciones y conocimiento utilizando Machine Learning (Elsevier Labs, 2017).

Recientemente, la revista Mining Journal en su edición de noviembre del año 2017, publicó el artículo “Machine learning magnifies value”, el cual describe el trabajo desarrollado en el proceso de molienda SAG de la minera Doña Inés de Collahuasi utilizando Machine Learning. Los resultados obtenidos utilizando algoritmos de ML muestran aumentos de rendimiento cercanos al 2% y una disminución del nivel de llenado de bolas cercana a 1,5 puntos porcentuales, logros que se traducen en un beneficio de 43 MMUS\$/año debido al mayor procesamiento de mineral por el molino SAG y la disminución de sus costos de operación.

Este tipo de resultados muestran que existe una oportunidad de aprovechar la gran cantidad de datos operacionales y desarrollar soluciones innovadoras a problemas complejos mediante la identificación de patrones de comportamiento y modelos que mejoren el comportamiento de las variables críticas aportando a la eficiencia operacional y la productividad en los procesos productivos de la industria minera utilizando Machine Learning.

Para el grupo minero Antofagasta Minerals los resultados obtenidos se presentan como una oportunidad para desarrollar soluciones innovadoras que contribuyan a disminuir la variabilidad de sus procesos y aumentar la capacidad de procesamiento de sus activos agregando conocimiento y valor a la compañía, lo cual motiva al desarrollar pruebas de concepto que permitan verificar y replicar los resultados obtenidos, identificar los requerimientos para alcanzarlos y cuantificar los beneficios sobre la cadena productiva a través de la evaluación de Kpi's adecuados.

2. Objetivos

2.1. Objetivo general

Verificar la factibilidad de utilizar Machine Learning en el proceso de molienda SAG de Antofagasta Minerals con el fin de disminuir su variabilidad y aumentar la capacidad de procesamiento de mineral.

2.2. Objetivos específicos

Revisar el estado del arte de la utilización de Machine Learning en la minería aplicado a los procesos de las plantas concentradoras de minerales.

Verificar la factibilidad técnica de utilizar grandes volúmenes de datos provenientes del subproceso de molienda SAG para generar información que permita identificar patrones de comportamiento y desarrollar modelos que optimicen su rendimiento.


Cuantificar el beneficio del uso de Machine Learning en el desempeño del proceso de molienda, en los resultados de la planta concentradora y su aporte al grupo minero.

Realizar un análisis FODA de la utilización e implementación de las herramientas de Machine Learning en los procesos productivos del grupo minero Antofagasta Minerals.

3. Metodología de trabajo

Este trabajo se sustenta en cuatro ejes principales, ver Figura 1. En el primero de ellos se desarrolla el estado del arte de las herramientas sobre Machine Learning en la minería, con especial énfasis en las soluciones aplicadas a sus principales procesos dando cuenta de la madurez alcanzada y el beneficio logrado al utilizar analítica avanzada.

El segundo eje permite verificar la capacidad de generar información y conocimiento a partir del análisis de grandes volúmenes de datos operacionales del proceso de molienda SAG abordando las principales etapas y criterios para lograr el levamiento de los datos, limpieza, preparación, procesamiento, modelado y la validación técnica operacional.



Fuente: Elaboración Propia

Figura 1: Metodología y cronograma de trabajo

El tercer eje cuantifica el impacto del uso de herramientas de Machine Learning determinando los beneficios asociados a la reducción de variabilidad del proceso y al aumento de capacidad de procesamiento de mineral teniendo en consideración la reducción de costos teniendo como referencia el proceso de molienda SAG.

El cuarto eje presenta los resultados del análisis FODA realizado y los hallazgos identificados, los cuales evidencian la necesidad de abordar algunos requerimientos para realizar la adecuada implementación de estas nuevas herramientas tecnológicas y promover su adopción definitiva.

4. Resultados

4.1. Estado del arte

Los principales desafíos que las compañías mineras deben enfrentar están relacionados con el agotamiento de minerales cercanos a la superficie y yacimientos con minerales de menor ley, aspectos que requerirán equilibrar sus gastos y mejorar su eficiencia de manera de extraer y procesar los minerales a un costo menor (Lee y Prowse, 2014; Deloitte, 2018).

Las operaciones mineras en todo el mundo son hoy, en promedio, un 28 % menos productivas que hace una década (McKinsey, 2015). Es así como durante el año 2010 el margen de beneficio neto fue del 25% para las cuarenta principales compañías mineras, mientras que, durante el año 2013, este indicador cayó al 2%, evidenciando el impacto antes mencionado y la lentitud de su regeneración (PwC, 2015).

Debido a que las compañías no pueden tener un impacto directo en los precios de venta de sus productos, ellas deben optimizar sus actividades a través de la disminución de los costos, a fin de contrarrestar las pérdidas y adecuarse a las nuevas condiciones de precios (MacKenzie, 2013). Sin embargo, tal como indica Lee y Prowse (2014): “La minería es una industria con grandes tradiciones donde el cambio es a veces muy gradual”, evidenciando que la principal causa es que la industria es reacia a la innovación, le cuesta adoptar nuevas tecnologías y se resiste a los cambios.

Considerando lo descrito por Lee (2014) y MacKenzie (2013), queda en evidencia que la industria minera necesita un cambio en las formas de explotación y operación de sus yacimientos y procesos, de manera de mejorar su productividad mediante iniciativas innovadoras que permitan operar de una forma más eficiente sus procesos y aumentar sus ganancias, por lo que surge la posibilidad de generar valor a partir del uso de las grandes cantidades de datos que las industrias producen y del uso de herramientas de Machine Learning.

Machine Learning es una rama de la Inteligencia Artificial y está relacionada con uso inteligente de datos y la transformación en patrones complejos e información clave para la toma de decisiones. Es un paso más en la automatización de los procesos, ya que a través del uso de algoritmos se desarrollan modelos predictivos que cuentan con la capacidad de entrenarse y perfeccionarse de manera automática, sin intervención de un programador.

En la última década más organizaciones han ido reconociendo el valor que genera del uso de estos datos y en particular el utilizar herramientas de analítica avanzada para generar información que mejore la toma de decisiones.

En la minería se ha comenzado a observar un mayor nivel de consenso en que para avanzar hacia una industria más competitiva se requiere cambiar la forma tradicional de operar y controlar los procesos productivos, pasando de la actual situación en que los datos se almacenan en repositorios con la única intención de realizar, en algún futuro, un ejercicio de análisis *post mortem*, hacia la identificación de patrones de comportamiento, la generación de modelos y conocimiento confiable

que permitan predecir el comportamiento de eventos futuros y recomendar oportunamente una decisión a ejecutar.

Diversos ensayos, realizados por consultoras internacionales como EY (2017), Deloitte (2018), Gartner (2016), Wipro (2018), CISCO (2017), y McKinsey (2015), entre otras, evidencian las oportunidades y desarrollos realizados en los ámbitos de la innovación digital y la analítica avanzada, dando claras muestras de su impacto en la productividad y su importancia como una ventaja competitiva. En la Figura 2 se describe el posicionamiento tecnológico que han logrado algunas empresas relacionadas con la industria minera, sus distintos niveles de madurez y desarrollo alcanzado, dando cuenta de la evolución que ha adquirido la analítica avanzada y la potencialidad de su uso en los procesos minero -metalúrgicos del cobre.

Algunos ejemplos interesantes desarrollados en minería utilizando ML, son la implementación de analítica avanzada en las máquinas perforadoras de roca, lo que le permite tomar decisiones sin interacción humana sobre cómo proceder agilizando los procesos de extracción de mineral (Daugherty et al., 2015). Los sistemas de drones se comenzaron a utilizar para la exploración de nuevas áreas mineras con excelentes resultados logrando además un menor impacto ambiental (Fiscor, 2015). El desarrollo de herramientas de mantenimiento predictivo basado en el uso de patrones y alertas para diferentes los procesos y equipos, han mostrado ahorros de hasta el 12% en las revisiones programadas, al tiempo que se reducen los costos de mantenimiento en un 30% y se elimina el 70% de las fallas (Daugherty et al., 2015).

Rio Tinto es la compañía minera más tecnológica y actualmente está desarrollando un programa llamado Mine of the future, iniciativa que está implementando innovaciones en todas sus operaciones del mundo, particularmente en Australia, en donde utilizan perforadoras y camiones autónomos, drones y cuenta con centros integrados de operaciones (ROC), y próximamente lanzarán el primer tren autónomo de transporte pesado de todo el mundo para fines del año 2018, posicionándolos como líderes tecnológicos en minería.

De acuerdo a lo indicado por Stephen McIntosh (2016) quien es el encargado del crecimiento e innovación en Rio Tinto, los beneficios logrados con el desarrollo y uso de estas nuevas tecnologías son sustanciales tanto desde una perspectiva de seguridad como de productividad.

En este contexto, es posible indicar que la industria minera se encuentra en un punto de inflexión, en el que las nuevas tecnologías y el uso de herramientas de analítica avanzada como el Machine Learning pueden generar un cambio fundamental en la forma en que trabaja la minería, un cambio marcado por el aprovechamiento de los datos para reducir la variabilidad de los procesos, fomentar la toma de decisiones y mejorar la productividad.

La captura del valor de las innovaciones digitales representa un cambio fundamental en la visión, la estrategia, el modelo operativo y las capacidades, ya que la creación de valor en la minería cambiará de lo bien que se procesa el mineral a qué tan bien recopila, analiza y actúa con la información generada para procesar el mineral de la manera más productiva.

Se espera que en el futuro el mayor impacto provendrá de integrar estas tecnologías como un todo en la cadena de valor de la minería teniendo especial foco en cinco áreas: recursos mineros, optimización del flujo de minerales y equipos, anticipación de fallas, automatización y monitoreo

del desempeño en tiempo real de los resultados versus el plan de producción. Cada oportunidad es significativa en sí misma, sin embargo, el desafío en los años próximos será lograr el potencial de todas ellas e integrarlas para complementar y potenciar el beneficio.




Figura 2: Posicionamiento tecnológico Antofagasta Minerals

Esta nueva forma de abordar la minería será un cambio difícil, el cual solo será posible llevar a cabo con éxito si el liderazgo de la industria cree que existe un gran premio al final. Los análisis realizados (World Economic Forum, 2017), indica que el impacto económico potencial es de \$370 mil millones por año, lo cual representa el 17% del costo proyectado de la industria a nivel mundial en 2025.

En un clima de precios volátiles de los productos y fluctuaciones de la demanda, las empresas mineras están entrando en un período de cambio estructural que les permita rectificar los excesivos costos, mejorar la eficiencia del capital y reconstruir las relaciones con los inversionistas enfocándose más en la productividad, la gestión sostenible de los costos y el mayor valor para los accionistas.

En esa dirección el grupo minero Antofagasta Minerals ha decidido ingresar a la era digital y explorar el valor de incorporar nuevas tecnologías y analítica avanzada para analizar de manera más precisa los datos que provienen de sus procesos productivos (Big Data, 2015) realizando pruebas de concepto para verificar el potencial de éxito y estimar el beneficio de las implementaciones para así comenzar a transitar hacia un posicionamiento más avanzado como el de las empresas más reconocidas a nivel mundial.

4.2. Levantamiento de información, identificación de patrones y generación de conocimiento.

El fortalecimiento de los procesos más relevantes resultará ser clave para el cumplimiento de los compromisos productivos del Grupo Minero, por lo que reducir la variabilidad de los procesos y utilizar la máxima capacidad de los activos serán foco central.

Para verificar la capacidad de generar información a partir de datos provenientes de los procesos industriales se realizó un levantamiento de las variables de operación del molino SAG de la planta concentradora de la compañía minera Centinela cuyo procesamiento anual alcanza los 25.000 [Ktms] y es una de las dos concentradoras del grupo minero AMSA.

El molino SAG es la operación unitaria más relevante de la planta concentradora y su principal objetivo es maximizar la capacidad de procesamiento de mineral alimentado manteniendo en control sus variables de operación a portando además estabilidad al proceso de flotación, lugar donde se logra la recuperación de las especies de interés.

El levantamiento realizado permitió recolectar casi tres años (2016 a 2018) de datos operacionales del proceso de molienda SAG, los cuales fueron filtrados con intervalos de un minuto utilizando para esto la herramienta PI System siendo almacenados para posteriormente realizar su limpieza y preparación.

El proceso de limpieza de los datos operacionales recopilados comienza con identificación de los cuartiles Q_1 y Q_3 , para posteriormente calcular el rango Inter cuartil ($I_q = Q_3 - Q_1$) y eliminar todos aquellos datos que se encuentren fuera rango de validez [$Q_1 - 1,5 I_q$; $Q_3 + 1,5 I_q$] datos que son denominados *outliers*. Aquellos datos que se encuentran dentro del validez corresponden a los datos utilizados en el procesamiento, los cuales generan dos grupos de datos válidos: el primero equivalente al 85% del total se utiliza en el modelado y el 15% restante para validar el modelo.

La Figura 3 muestra el comportamiento y la evolución en el tiempo de algunas de las variables operacionales del molino SAG observándose una dependencia temporal entre ellas (torque, porcentaje de sólido, velocidad de giro y el mineral procesado), evidenciando el potencial de identificar patrones de comportamiento y conocimiento.

La teoría del movimiento de carga al interior de un molino SAG, indica que existe una velocidad optima que maximiza la eficiencia de molienda, debido a que optimiza la forma del "riñón" y la trayectoria de las bolas de molienda permitiendo así aumentar la capacidad de procesamiento de mineral por el molino SAG, existiendo una relación directa con la velocidad de giro y la trayectoria de los elementos moledores, tal como se observa en la Figura 4.




Figura 3: Condiciones de operación Molino SAG

El modelo del molino SAG utilizando Machine Learning permitirá identificar las palancas que optimizar el procesamiento de minera, teniendo especial énfasis en el rango óptimo de las variables críticas de operación del molino SAG (velocidad de giro, nivel de carga y porcentaje de solido) a lo largo de la vida útil del revestimiento, así como también el impacto de la granulometría del mineral alimentado (*mine to mill* y la gestión del *stock pile*), iniciativas que se describen en la Figura 5.3.



Fuente: Yin. Z. Peng et al., 2017

Figura 4: Perfil de velocidad de rotación del molino



Figura 5: Identificación de oportunidades a desarrollar en el proceso de molienda SAG

El modelo desarrollado, corresponde a un modelo de red neuronal el cual incorpora variables operacionales del molino SAG (control y outputs) y otras que tienen relación con las características de mineral alimentado (dureza y granulometría del mineral) y vida útil de su revestimiento denominadas



Fuente: Elaboración Propia

Figura 6.




Fuente: Elaboración Propia

Figura 6: Modelo de red neuronal para estimación del procesamiento de mineral del Molino SAG variables

La Figura 7, muestra la predicción del mineral procesado por el molino SAG (variable de salida). Utilizando los datos de validación (15% de la data) se verifica que la bondad de ajuste del modelo es $R^2=0,62$, valor que resulta ser alto considerando la gran cantidad de datos, la naturaleza y dinámica del proceso de molienda.

Tipo de Variable	Variable
Restricciones aguas abajo	Cantidad de bombas “on”
	Nivel de sumidero
Restricciones aguas arriba	CV002 On/Off
	Cantidad de feeders usados
Estado de operación SAG	SAG RPM
	SAG % Sólido
	Presión SAG
	Estado liner SAG
Granulometria	% < 4 "
Mineralogía	AxB
Salida	SAG tph



Fuente: Elaboración Propia

Figura 7: Modelo de red neuronal para estimación del procesamiento de mineral del Molino SAG

La Figura 8 permite determinar el impacto sobre el rendimiento del mineral procesado y consumo de energía del molino SAG. Se observa que el mayor impacto sobre el procesamiento de mineral se obtiene cuando se logra determinar el rango óptimo de las variables de operación del molino

SAG a lo largo de la vida útil del revestimiento lo cual genera un aumento en el mineral procesado de 4,5% y un menor consumo energético avaluado en 7%, por lo que los esfuerzos se focalizarán en determinar la matriz de rangos de operación del molino para diferentes durezas de mineral considerando la vida útil del revestimiento.



Figura 8: Principales oportunidades identificada, estimación de impactos

4.3. Métricas y evaluación de la prueba de concepto

La efectividad del modelo descrito en el capítulo anterior, fue evaluada por su capacidad de optimizar el procesamiento de mineral identificando el rango óptimo de las variables críticas de operación del molino SAG a lo largo toda la campaña de vida del revestimiento, por lo que cuantificar de manera objetiva su desempeño ante las diferentes condiciones de operación se definieron las siguientes métricas de interés, las cuales darán cuenta de la reducción de costos y los aumentos producción logrados.

4.3.1. Métricas de evaluación

Los indicadores de desempeño para evaluar el modelo son los siguientes:

- Rendimiento SAG (tph).
- Consumo energético SAG.
- Eventos de torque SAG.


4.3.2. Desempeño de la prueba de concepto

El análisis de los datos históricos del molino SAG ha permitido identificar diferentes escenarios en los cuales opera este proceso lo cual queda reflejado en la Figura 9, la cual presenta un mapa térmico que describe el mineral procesado, % sólidos y presión, así como también la probabilidad de torque para cuando se tiene un escenario de liners de 0-1 mes, una dureza de mineral (Axb >32,5) y velocidad de 8,4 [rpm].

La utilización del modelo de ML y el análisis de este tipo mapas térmicos permiten identificar otras condiciones de operación para el molino SAG y logran mejorar en la capacidad de procesamiento de mineral y controlar los eventos de alto torque.

En la Figura 9 se observa que es posible aumentar el rendimiento del molino incrementando el porcentaje de sólidos (ir del punto 1 al punto 2) y posicionarse en una combinación de rangos de operación minimizando los eventos de alto torque (ver punto 3).

Los resultados obtenidos con el modelo de Machine Learning han permitido identificar un perfil de velocidad óptima de operación para el molino SAG según el estado de sus liners, evidenciando que cuando el revestimiento está nuevo se debe operar a bajas velocidades de giro y al fin de su vida útil al máximo permitido.




Fuente: Elaboración Propia

Figura 9: Procesamiento de mineral según la velocidad del Molino SAG a lo largo de la vida útil de revestimiento

La Figura 10, muestra la evolución del rendimiento del molino del molino SAG y la velocidad de giro (líneas segmentadas roja y verde) para los tres periodos de la vida útil del liner. Estos resultados muestran que la velocidad real de operación del molino SAG excede la velocidad de giro propuesta por el modelo de ML como óptima, situación que afecta la capacidad de procesamiento de mineral durante los dos primeros periodos de vida útil del liner. El análisis permite verificar que la velocidad recomendada por el modelo de ML permite incrementar en 3% la capacidad de procesamiento del molino SAG.

Adicionalmente, la velocidad indicada por el modelo de Machine Learning ha permitido reducir el consumo específico de energía ([KWh/t]) en un 7%, ello debido a la menor potencia del molino y al mayor procesamiento de mineral logrado.



Fuente: Elaboración Propia

Figura 10: Procesamiento de mineral según la velocidad del Molino SAG a lo largo de la vida útil de revestimiento

La correcta definición del límite máximo de operación de la velocidad de giro del molino permitirá maximizar la capacidad de procesamiento del mineral. Es necesario tener presente que un revestimiento más nuevo posee mayor capacidad de levante del mineral y de medios de molienda, por lo que resulta indispensable lograr la adecuada ecualización de velocidad y vida útil del revestimiento, ya que el aumento por sobre el límite de la velocidad de giro genera efectos indeseados, como por ejemplo la proyección de bolas sobre el revestimiento. Esta situación genera una disminución de la probabilidad de que los medios molidores (bolas) impacten la carga de mineral, incrementando su consumo y una aumentando la probabilidad de fractura del revestimiento producto de la inadecuada proyección de bolas.

La Figura 11 muestra los resultados obtenidos luego de relacionar el comportamiento de las variables de operación del molino SAG. En ella se observa la presión (peso de la carga de mineral y bolas existentes al interior del molino SAG), velocidad de giro y niveles de procesamiento de mineral a lo largo de la vida útil del revestimiento, para un tipo de mineral y porcentaje de sólido.


Este resultado muestra que es posible desarrollar un mapa de operación del molino SAG y optimizar su capacidad de procesamiento de mineral teniendo en cuenta para ello el periodo de vida útil del revestimiento usado, la dureza del mineral alimentado a dicho equipo y una adecuada definición de rangos operacionales de las variables críticas tales como velocidad de giro del molino, porcentaje de sólido y presión de los descansos.

Esta herramienta que define la correcta operación no solo permite maximizar el rendimiento del mineral procesado en el molino SAG, sino que además controla y estabiliza el nivel de llenado de bolas, el cual es el principal insumo del proceso de molienda impactando de manera favorable a costos de operación a través de la reducción del consumo específico de energía y de medios de molienda impacto que se muestra en Figura 13.

El modelo de Machine Learning desarrollado, ha permitido desarrollar un mapa de operación del molino SAG el cual se presenta en la Figura 11. A partir del éste es posible construir una matriz

de recomendaciones de rangos óptimos de operación para las variables del molino SAG de acuerdo a lo presentado en la Figura 12.

La matriz de rangos óptimos de operación permite recomendar, para cada uno de los tres periodos de la campaña del revestimiento, valores óptimos, el control de las variables de operación del molino SAG que aseguren en todos los casos (dureza del mineral) la maximización del mineral procesado.



Fuente: Elaboración Propia

Figura 11: Mapa de operación del molino SAG durante la vida útil del revestimiento

El análisis de los valores que las variables de operación del molino SAG utiliza actualmente, versus las que el modelo ML, y que son presentadas como óptimas son diferentes en todos los escenarios descritos:

- En particular cuando se analiza el comportamiento de la velocidad de giro del molino, se observan importantes diferencias en los primeros dos periodos situación, lo que resulta preocupante ya que es en estas etapas donde mayor restricción de velocidad debe existir debido a que el revestimiento se encuentra con una alta capacidad de levante y proyección de bolas amenazando con generar fracturas sobre el revestimiento recién instalado con las consecuencias indeseadas de pérdida de continuidad operacional asociada a la detención no programada.

- Con respecto al porcentaje de sólido alimentado al molino SAG, se observa que la recomendación del modelo ML es operar a un nivel mayor lo cual mejora la eficiencia hídrica del proceso y promueve la fractura del mineral al interior del equipo.
- El análisis de la presión de los descansos del molino SAG, muestra que la recomendación del modelo ML es operar a una mayor presión que el actual valore utilizando, sobre todo cuando existe un mineral con Axb mayor, favoreciendo la capacidad de procesamiento de mineral.


Escenario		Puntos de setting óptimo según modelo ML								
Dureza (AxB)	Edad Liner (meses)	Velocidad (RPM)			% Sólidos			Presión (kPa)		
		Actual		Óptimo	Actual		Óptimo	Actual		Óptimo
AxB > 32,5	0-1	8,7	>	8,4	72	>	75	7960	>	8000
	1-3	8,7	>	8,5	72	>	75	7813	>	7900
	3-6	8,8	>	8,7	72	>	75	7556	>	7700
AxB < 32,5	0-1	8,6	>	8,5	72	>	72	7934	>	8000
	1-3	8,9	>	8,7	72	>	75	7744	>	7700
	3-6	8,7	>	8,7	72	>	75	7540	>	7600

Figura 12: Diagrama de operación del molino SAG durante la vida útil del revestimiento (Axb)

La Figura 13, presenta de manera gráfica el impacto económico de las iniciativas de Machine Learning y de las prácticas de operacionales relacionadas con el desarrollo del modelo de ML del molino SAG.

El impacto económico logrado con la determinación de la matriz de parámetros óptimos de operación del molino SAG alcanza los 19,4 MMUS\$.

Esta matriz promueve otros beneficios económicos, por ejemplo, menor consumo de medios de molienda y reducción del consumo específico de energía (CEE), los cuales se estiman en 4,1 MMUS\$ y 2,1 MMUS\$ respectivamente.



Fuente: Elaboración Propia

Figura 13: Cuantificación de impactos económicos de la iniciativa ML

4.4. Análisis FODA – Uso de Machine Learning

El análisis del FODA muestra que existen cuatro fortalezas que se relacionan directamente con los procesos, siendo sin duda la disponibilidad de datos la mayor fortaleza, ya que con un adecuado análisis basado en nuevas herramientas tecnológicas existe una gran cantidad de oportunidades de aportar al fortalecimiento los procesos y al cumplimiento de los compromisos productivos del Grupo Minero Antofagasta Minerals.

Fortalezas	Debilidades
Disponibilidad de Datos	Especialistas / Data Science
Instrumentación	Grupo de interés
Infraestructura	Dificultad para recopilar datos
Automatización	Modelo operativo


Oportunidades	Amenazas
Generar conocimiento de los procesos	Poca experiencia Machine Learning en minería
Mejorar precisión de análisis	Resistencia a tecnologías en la industria
Estandarizar las prácticas	Falta de casos de éxito industria minera (credibilidad)
Automatizar los procesos	
Capacidad predictiva	
Mejorar toma de decisiones	
Visibilizar resultados	
Desarrollar de innovación	
Optimizar los procesos	

Fuente: Elaboración propia

Figura 14: Diagrama del análisis FODA realizado sobre el uso de ML en AMSA

Sin embargo, los resultados del análisis FODA indican que para implementar herramientas tecnológicas es necesario resolver algunas debilidades y abordar las amenazas identificadas en la Figura 14. El mayor desafío identificado es la inexistencia de un adecuado ecosistema tecnológico en el que coexistan especialistas que desarrollen este tipo de herramientas y soluciones (científicos de datos) que permitan transformar los datos en información que agregue valor a la compañía, capturando beneficios relacionados con reducción de variabilidad en los procesos y la maximización de la capacidad de los activos.

Es importante recalcar que la mejor tecnología no soluciona el problema si no se apoya en un equipo humano altamente calificado, el cual requiere contar diferentes habilidades para ser exitoso. En este sentido expertos en la materia (Gartner, 2016; Inc; Avantis PRISM, 2015) afirman que se requiere contar con un equipo que posea las habilidades, conocimientos y disciplinas descritas en la Figura 15.



Fuente: www.analyticstraining.in

Figura 15: Diagrama de Venn Data Science

El adecuado balance de las especialidades descritas en la Figura 15 resulta clave para garantizar el éxito de las actividades de Data Science (2015).

A modo de ejemplo se presenta la siguiente reacción química para describir las habilidades técnicas de un grupo de Ciencia de Datos.



Las habilidades técnicas fundamentales son: Ciencias de la Computación (CS), Matemáticas (M) y Conocimientos de Dominio (DE).

En el lado de los reactivos se encuentran los científicos de datos quienes tienen sus propias habilidades las que se deben equilibrar mediante una adecuada combinación de los integrantes para cumplir los requisitos de habilidades del equipo de Data Science, si esto no ocurre el equipo no tendrá el impacto deseado.

En el ejemplo anterior, requieren cuatro partes de conocimientos de informática, cinco partes de matemáticas y una parte de dominio. Dada la combinación de habilidades del personal, se necesitan cinco personas para equilibrar la ecuación, sin embargo, los requisitos de habilidades del equipo durante el desarrollo de los proyectos cambiarán por lo que se deberá volver a equilibrar la ecuación para asegurarse de que los reactivos se equilibren con los productos.

Tal como indica el ejemplo anterior, no existe una definición clara sobre la estructura organizacional requerida para realizar Data Science. Sin embargo, sí se sabe que se requieren profesionales altamente capacitados con perfiles específicos y que se requiere de una masa crítica de especialistas.

En este sentido, la empresa consultora internacional Mckinsey (año) en su estudio de requerimientos de la fuerza logra identificar los perfiles de trabajo y habilidades requeridos para desarrollar ciencia de datos en algunas industrias, ver Figura 16.

Este estudio revela que, en el caso particular de la industria minera las habilidades requeridas estarán relacionadas con aquellas altamente cognitivas y con mayor requerimiento las habilidades sociales, emocionales y tecnológicas.





Figura 16: Perfiles y habilidades requeridos para desarrollar ciencia de datos

Otra debilidad identificada es la existencia de un grupo de interés que patrocine estos temas de innovación, fomentando la implementación de nuevas plataformas y herramientas (historización masiva de datos y analítica avanzada) que permitan desarrollar soluciones que logren mejorar el desempeño de los procesos productivos a partir de la analítica avanzada de sus datos

Finalmente, la definición de un modelo operativo del equipo de ciencia de datos será fundamental para determinar la estructura organizacional que desarrollará estas actividades (unidad de análisis avanzado de datos). Este modelo estará determinado según la cantidad de datos, la complejidad y tamaño de los procesos y las características del negocio, debiendo por tanto cada organización definir el suyo, Figura 17. La adecuada selección de el arquetipo será esencial para lograr la gobernanza de los datos.

Las descripciones completas de cada modelo operativo se pueden encontrar en Booz et al. (2015), teniendo presente que se deben definir las características, roles y perfiles de los especialistas en Data Science (Mckinsey, 2018).



Fuente: McKinsey Global Institute, 2018

Figura 17: Modelos operativos de ciencia de datos

4.4.1. Evaluación económica de implementación unidad analítica avanzado (UAA)

Los requerimientos y montos involucrados para implementar una unidad de analítica avanzada (UAA) que desarrolle soluciones para el control de los procesos se presenta en la Tabla 1, los cuales están relacionados con servidores y licencias de software, consultorías especializadas para efectuar la analítica de datos en la nube y remuneraciones de 5 especialistas.

Descripción	Valor [MUS\$/año]
Data Lake 400 TB On Premise + Cloud (HW/SW)	145
Consultorías plataforma analítica en la nube	150
Líder Disciplina Data Science	160
Especialistas	500
Total	955

Tabla 1 Resumen de Gastos Unidad de Análisis Avanzado UAA

Considerando los resultados descritos en la Figura 13 y los montos indicados en la Tabla 1, se calcula el VAN del proyecto de creación de una unidad de análisis avanzado UAA, iniciativa que se evalúa con un horizonte de 5 años, ver Tabla 2. El proyecto es altamente rentable y genera un VAN de 77 MMUS\$.

INDICADOR	Valor [MMUS\$]
VAN	76.9

Tabla 2 VAN implementación de Unidad de Análisis Avanzado UAA

5. Conclusiones y recomendaciones

Este trabajo ha permitido verificar la factibilidad técnica de desarrollar un modelo para optimizar el proceso del molino SAG basado en redes neuronales a partir de la recopilación y análisis de grandes volúmenes de datos operacionales utilizando Machine Learning.

El modelo desarrollado que alcanzó un coeficiente de determinación (R^2) de 0,62, permite generar una matriz de rangos de operación óptimos para las variables críticas de operación (velocidad de giro, nivel de carga y porcentaje de solido) del molino SAG, en cada uno de los tres periodos más característicos de la campaña del revestimiento, considerando diferentes condiciones de dureza y granulometría del mineral.

Este resultado no solo permite optimizar la capacidad de procesamiento del mineral alimentado al Molino SAG, sino que además reduce la probabilidad de fractura de las parrillas y del revestimiento contribuyendo a la continuidad operacional del equipo, así como también a la disminución del consumo de bolas, principal insumo del proceso de molienda, impactando de manera favorable en los costos de operación.

El beneficio asociado al uso de los parámetros de operación determinados por la herramienta de analítica avanzada permite maximizar el mineral procesado por el molino SAG, reducir el consumo específico de energía y el consumo de bolas. El identificar un perfil de velocidad óptimo para el molino SAG durante toda la campaña del revestimiento permite reducir de los eventos indeseados de alto torque y estandarizar prácticas operacionales evitando los quiebres de parrillas y de revestimientos del molino.

La metodología de análisis puede ser desarrollada en las otras faenas mineras del grupo, generando un mayor conocimiento del proceso de molienda y un beneficio adicional en los otros tres molinos SAG relacionado con el incremento de la capacidad de procesamiento y una reducción del consumo específico de energía.

El impacto económico del uso de la matriz de parámetros óptimos de operación del molino SAG alcanza los 19,4 MMUS\$/año. El menor consumo de medios de molienda, la reducción del consumo específico de energía CEE y las prácticas operacionales totalizan un impacto de 6,9 MMUS\$/año, significa que el proceso de molienda SAG logra ahorrar 26,3 MMUS\$/año.

El presente trabajo permitió identificar la relevancia de los datos, los cuales mediante un adecuado análisis experto pueden ser transformados en información relevante para la toma oportuna de decisiones transformando al dato en una suerte de activo a considerar dentro de la organización.

El análisis experto de los datos y la correcta interpretación de los resultados e información generada dependerá de las habilidades y competencias de los especialistas en ciencia de datos por lo cual se debe invertir en profesionales que sean capaces de transformar estos datos en conocimiento, siendo clave reclutar profesionales que competentes en matemáticas, estadística, analítica, sistemas y del negocio, ya que como indica el dicho popular “información es poder”.

El análisis FODA evidencia que la principal debilidad para capturar de los beneficios antes descritos, sostenerlos en el tiempo y replicar en otros procesos y faenas del grupo minero radica en la falta de especialistas en ciencia de datos y la inexistencia de una unidad de analítica avanzada (UAA).

La evaluación económica del proyecto de creación de una unidad de analítica avanzada (UAA) al interior del grupo minero para realizar análisis, recomendaciones a la operación abordando de forma permanente estos temas muestra una alta rentabilidad.

Finalmente, se recomienda invertir en nueva instrumentación a fin de generar nuevos datos que permitan complementar los existente para mejorar la capacidad predictiva de los modelos desarrollados.

Este trabajo evidencia la madurez alcanzada por el Machine Learning, revelando la efectiva oportunidad de generar información relevante y mejorar la toma de decisiones en tiempo real posicionando al dato un activo que agrega valor a las compañías con bajos montos de inversión.

6. Trabajos futuros y recomendaciones

Los trabajos futuros estarán orientados a realizar Pruebas de Concepto en otros procesos de la compañía, de manera de generar una ventaja competitiva basada en el uso de los datos operacionales existentes y en el análisis de estos para mejorar la toma de decisiones y optimizar sus resultados.

Otro desafío a abordar, en el corto y mediano plazo, será lograr el escalamiento e integración de este tipo de soluciones identificándose las siguientes actividades a desarrollar las cuales están relacionadas con:

- Integrar los algoritmos a datos online para utilizarlos en tiempo real.
- Identificar otros procesos con capacidad para implementar Machine Learning.
- Generar una gobernanza para estas tecnologías al interior del grupo.
- Creación de una unidad de análisis avanzado de datos (UAA).

La creación de esta unidad permitirá realizar el análisis de los datos operacionales de los procesos productivos, generar conocimiento y resguardar de manera interna los elementos del proceso y el principal activo del futuro, agregando, así, valor al resultado de las compañías y del grupo minero.

7. Literatura y bibliografía

- BCG. (2017). *Competing in the Age of Artificial Intelligence*. Recuperado de: www.bcg.com
- BCG. (2018). *It's not a digital transformation without a digital culture*. Recuperado de: www.bcg.com
- Booz, Allen and Hamilton. (2015). *The Field Guide to Data Science*. Recuperado de: www.boozallen.com
- Carvajal, Costa, et al. (2017). *Machine learning magnifies value*. Meaning Journal (nov.20th).
- Csiro Mineral Resources. (2017). *Big Data improving the mineral processing*. Recuperado de: www.csiro.au
- Daugherty, P., et al. (2015). *Driving Unconventional Growth through the Industrial Internet of Things*. San Jose: Accenture Technology Labs.
- Deloitte. (2016). *Innovation in mining Australia 2016*. Recuperado de: www.deloitte.com
- Deloitte. (2016). *Tracking the trends 2016: The Top 10 issues mining companies will face in the coming year*. Recuperado de: www.deloitte.com
- Deloitte. (2018). *Tracking the trends 2018: The top 10 issues shaping mining in the year ahead*. Recuperado de: www.deloitte.com
- Elsevier Labs. (2017). *These Elsevier collaborations use machine learning to turn data into knowledge*. Recuperado de: www.elsevier.com
- Estado del Arte de Big Data. (2017). *Oportunidades industria 4.0 en Galicia*. Recuperado de: www.atiga.es
- EY. (2017). *Productivity in mining now comes the hard part*. Recuperado de: www.ey.com/miningmetals
- Fekete, J. (2015). *Big Data In Meaning Operations*. Master's Thesis Copenhagen Business School.
- Fiscor, S. (2015). "Drones, Drills and Determination". *Engineering and Mining Journal*. 216 (5), 30-33.
- Gartner. (2016). *2017 Planning Guide for data analytics*. Recuperado de: www.gartner.com
- GEOVIA. (2014). *Natural Resources: Special Report Mining Innovation*. Recuperado de: www.3ds.com/geovia
- Kane, G. (2017). *Digital disruption is a people problem*. MIT Sloan Management Review.
- KDnuggets. (2017). *How to build a successful advanced analytics*. Recuperado de: www.kdnuggets.com
- KIN. (2015). *Reinventing Mining: Creating Sustainable Value*. Recuperado de: www.kinglobal.org
- Lee, J. & Prowse, K. (2014). *Mining & Metals + Internet of Things: Industry opportunities and innovation*. Recuperado de: www.marsdd.com
- MacKenzie, A. (2013). *Special Report on Mining Innovation*. Melbourne Mining Club, London.

- Mason, L. et al. (2011). *Vision 2040: Mining, Minerals and Innovation – A vision for Australia's mineral future*. Institute for Sustainable Futures (UTS, Sydney, Australia) and Curtin University (Perth, Australia).
- McKinsey. (2011). *Big data: The next frontier for innovation, competition and productivity*. McKinsey Global Institute. Recuperado de: www.mckinsey.com
- McKinsey. (2015). *How digital innovation can improve mining productivity*. McKinsey Global Institute. Recuperado de: www.mckinsey.com
- McKinsey. (2016). *The age of analytics: competing in a data-driven world*. Recuperado de: www.mckinsey.com
- McKinsey. (2017). *What's now and next in analytics AI and automation*. McKinsey Global Institute. Recuperado de: www.mckinsey.com
- McKinsey. (2018). *An agenda for the talent-first CEO*. Recuperado de: www.mckinsey.com
- McKinsey. (2018). *Skill Shift Automation And The Future Of The WorkForce*. McKinsey Global Institute. Recuperado de: www.mckinsey.com
- Microsoft Azure. (2018). *¿Qué es PasS? Plataforma de servicio*. Recuperado de: <https://azure.microsoft.com/es-es/overview/what-is-paas/>
- PwC. (2015). *Total revenue of the top mining companies worldwide from 2002 to 2014 (in billion U.S. dollars)*. Recuperado de: www.statista.com
- Wilson, H., et al. (2017). *The jobs that artificial intelligence will create*. MIT Sloan Management Review vol. 58.
- World Economic Forum. (2017). *Digital Transformation Initiative: Mining And Metals Industry*. Recuperado de: www.weforum.org

8. Anexo

8.1. Anexo 1 - Distribución de costos faena minera




Figura 18: Distribución porcentual de costos faena minera y procesos planta concentradora

8.2. Anexo 2 – Evaluación Económica Implementación Unidad de Analítica Avanzada (UAA)

Los requerimientos y montos involucrados para implementar una unidad de analítica avanzada (UAA) que desarrolle soluciones para el control de los procesos se presenta en la Tabla 1, los cuales están relacionados con:

- Servidores y Licencias de Software:
 - Plataforma como servicio (PaaS) desarrollo e implementación en la nube.
 - Incluye infraestructura (servidores, almacenamiento y redes) y middleware, herramientas de desarrollo, sistemas de administración de bases de datos.
- Consultorías especializadas para efectuar la analítica de datos en la nube:
 - Definir requerimientos de análisis de datos en nube y herramientas tecnológicas.
 - Contraparte técnica de licitaciones y adjudicaciones de contratos de servicios.
- Remuneraciones de especialistas:
 - Considera la remuneración de cinco (5) profesionales.

Descripción	Valor [MUS\$/año]
Data Lake 400 TB On Premise + Cloud (HW/SW)	145
Consultorías plataforma analítica en la nube	150
Líder Disciplina Data Science	160
Especialista 1 – Computer Science	120
Especialista 2 – Mathematics & Statistics	120
Especialista 3 – Business Domain Senior	140
Especialista 4 – Business Domain Junior	120
Total	955

Tabla 3 Resumen de Gastos Unidad de Análisis Avanzado UAA

Considerando los resultados descritos en la Figura 13 y los gastos necesarios de incurrir para crear una unidad de análisis avanzado UAA indicados en la Tabla 1 se tiene que el VAN y TIR para la iniciativa con un horizonte de 5 años es la descrita en Tabla 2.

INDICADOR	Valor [MMUS\$]
VAN	76.9
TIR	-28,48 %

Tabla 4 VAN y TIR implementación de Unidad de Análisis Avanzado UAA

8.3. Anexo 3 – Entorno de desarrollo - Plataforma como servicio PaaS

Plataforma como servicio (PaaS) es un entorno de desarrollo e implementación completo en la nube, con recursos que permiten entregar todo: desde aplicaciones sencillas basadas en la nube, hasta aplicaciones empresariales sofisticadas habilitadas para la nube. Es posible comprar los recursos que necesita a un proveedor de servicios en la nube, a los que accede a través de una conexión segura a Internet, pero solo paga por el uso que hace de ellos.

Al igual que IaaS, PaaS incluye infraestructura (servidores, almacenamiento y redes), pero también incluye middleware, herramientas de desarrollo, servicios de inteligencia empresarial (BI), sistemas de administración de bases de datos, etc. PaaS está diseñado para sustentar el ciclo de vida completo de las aplicaciones web: compilación, pruebas, implementación, administración y actualización.

PaaS permite evitar el gasto y la complejidad que suponen la compra y la administración de licencias de software, la infraestructura de aplicaciones y el middleware subyacentes, las herramientas de desarrollo y otros recursos. Es posible administrar las aplicaciones y los servicios que desarrolla y, normalmente, el proveedor de servicios en la nube administra todo lo demás.



Figura 19: Modelos operativos de ciencia de datos

Ventajas de PaaS:

- Reduce tiempo de programación.
- Agregar más funcionalidad de desarrollo sin incorporar más personal.
- Desarrollar para varias plataformas (incluidos los dispositivos móviles) con más facilidad.
- Usar herramientas sofisticadas a un precio asequible.
- Colaboración en equipos de desarrollo distribuidos geográficamente.
- Administrar el ciclo de vida de las aplicaciones con eficacia.