

COPILOTO+, EL SISTEMA DE INTELIGENCIA ARTIFICIAL DESARROLLADO POR HUSBAY PARA LA PREDICCIÓN Y EL CONTROL DE FATIGA

Paulo Alcazar¹, Alex Conco², Carlos Herrera³ y Fremy Flores⁴

¹Superintendente de Productividad y Gestión Mina, UMC Constancia, Arequipa, Perú, paulo.alcazar@hubbayminerals.com

²Departamento de Costos y Presupuesto, UMC Constancia, Áncash, Perú, alex.conco@hubbayminerals.com

³Departamento de Control Mina, UMC Constancia, Arequipa, Perú, carlos.herrera.acuticona@hubbayminerals.com

⁴Ingeniero de Operaciones Mina Fremy Flores Chambilla, UMC Constancia, Puno, Perú, fremy.flores@hubbayminerals.com

RESUMEN

Siendo la inteligencia artificial una ciencia para elaborar sistemas automáticos con capacidades para emular e incluso superar la inteligencia y talento humano para tareas específicas y progresivamente a multitareas mediante un conjunto de modelos lógicos, físicos y matemáticos intercomunicados.

Las redes neuronales artificiales son un subconjunto del machine learning y están en el corazón de los algoritmos de Deep learning reflejando el comportamiento del cerebro humano, permitiendo así que las soluciones tecnológicas reconozcan patrones y resuelvan problemas comunes en los campos de la IA.

Este modelo matemático es capaz de aprender a través de un aprendizaje supervisado de patrones de conocimiento. Se investigó una solución que involucra cuatro tipos de sistemas. Estos sistemas son; el sistema de gestión de flotas (software de control de producción e indicadores de equipos), sistema de gestión de calidad de sueño (software de gestión de sueño por relojes inteligentes), sistema de anticolidión (software de control de anticolidión por alertas y registros de eventos potenciales de anticolidión entre equipos) y el sistema de alertas de fatiga (software de control de fatiga por alertas en cabina a través de reconocimiento facial).

En base a estas tecnologías descritas pretendemos realizar una solución que trabaje en sinergia con nuestros sistemas de control para poder incrementar su efectividad y evitar accidentes por fatiga y/o somnolencia.

PALABRAS CLAVE

Inteligencia artificial, Red neuronal, Minería, Seguridad, Producción.

ABSTRACT

Artificial intelligence is a science to develop automated systems with the capacity to emulate and even exceed

human intelligence and talent for specific tasks and progressively multitasking through a set of interconnected logical, physical and mathematical models.

Artificial neural networks are a subset of machine learning and are at the heart of deep learning algorithms by mirroring the behavior of the human brain, thus enabling technological solutions to recognize patterns and solve common problems in AI fields.

This mathematical model is capable of learning through supervised learning of knowledge patterns. A solution involving three types of systems was investigated. These systems are; the fleet management system (production control software and equipment indicators), the sleep quality management system (sleep management software for smart watches) and the fatigue alert system (fatigue control software for alerts in cabin through facial recognition).

Based on these technologies described, we intend to create a solution that works in synergy with our control systems in order to increase their effectiveness and avoid accidents due to fatigue and/or drowsiness

KEYWORDS

Artificial intelligence, Neural network, Mining, Security, Production

1. Introducción

El buscar la forma de que en una (UM) Unidad Minera pueda incrementar su producción junto al incremento de la seguridad es una de las principales tareas que los ingenieros de minas tienen en la actualidad, debido a esto cada vez se buscan nuevas técnicas para que se incremente la productividad generalmente esto no es acompañado del todo por indicadores de seguridad, el control de la seguridad y producción pueden resultar difíciles o muy repetitivas para los humanos.

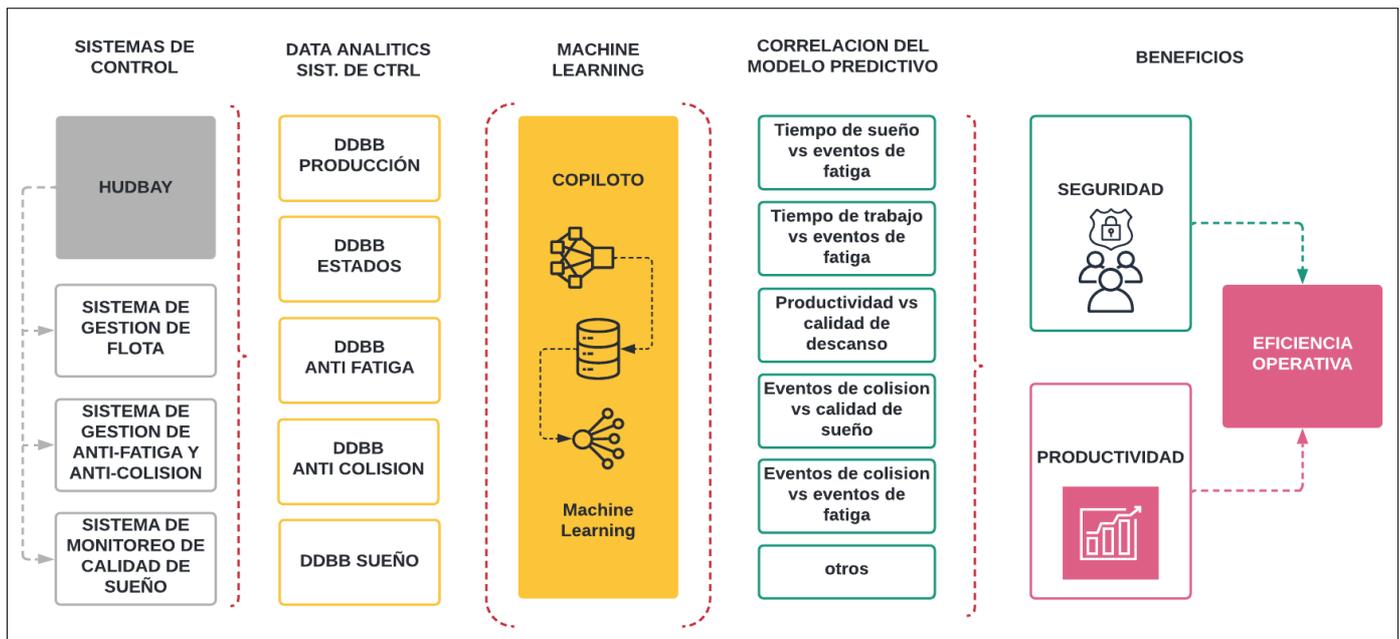


Figura 01 Diagrama que engloba las diferentes tecnologías de control y gestión en la UMC (Unidad Minera Constancia) para la generación de la solución COPILOTO+. Se distinguen cinco campos principales. Uno es el machine learning (ML) con algoritmos que deben ser alimentados con datos limpios y dentro de esto, el aprendizaje profundo con sistemas que, gracias a su mayor cantidad de capas, son capaces de hacerlo por sí solos. El otro es el modelo de correlación basado en datos, que consta de la verificación del comportamiento de los datos de forma relacional.

Es por esto que la Inteligencia Artificial (IA) en minería nace como un campo de estudio a partir del machine learning, ya que en esta última existen muchas vertientes como pueden ser redes neuronales, el deep learning o backpropagation.

Hudbay Perú comprometida con el desarrollo de innovaciones que permitan seguir siendo una operación productiva y sustentable. En esta línea de soporte se ha trabajado en una solución integral de control y gestión de fatiga en los operadores de acarreo, la cual identifica operadores fatigados de manera preventiva a partir de identificar anomalías en sus parámetros habituales en los tres sistemas de operación. A partir de este data-análisis se realizarán modelos predictivos los cuales nos brindarán una ventana de tiempo para actuar antes que el colaborador presente un incidente o accidente. Esta solución integral se convierte en una herramienta de soporte para la asignación y optimización de trabajos

El programa COPILOTO se implementó el 2018 para ser el soporte de los operadores de camiones gigantes, mediante reconocimiento facial se monitorea su estado de atención a partir de eventos de fatiga en cabina. La actual propuesta considera integrar todos los sistemas de control. encontrar correlaciones [figura 01] y desviaciones en otras variables cómo: productividad,

tiempo de descanso antes del inicio de turno, horas de trabajo acumuladas en el turno de trabajo, etc. El objetivo es que se pueda poner sobre aviso (con mayor anticipación) de un estado no habitual de un operador, y así se pueda tomar acciones preventivas.

2. Planteamiento del problema

2.1. Descripción del problema

Un promedio de 53 trabajadores muere en accidentes del sector minero cada año. En los últimos dos años han fallecido 84 empleados en unidades mineras o en actividades relacionadas con su trabajo. Por otro lado, desde el año 2000 suman más de mil las víctimas mortales en la minería (Convoca Deep Data, 2022). [figura 02].

Tecnología e innovación son dos de los conceptos centrales que marcan el camino de la minería en Perú, sector clave para el país y que en la actualidad enfrenta profundos desafíos de transformación para hacer más eficientes y automatizados sus procesos a fin de mejorar su productividad, seguridad y sustentabilidad.

La ausencia de tecnología con Inteligencia Artificial (IA), en las corporaciones nacionales, limita la competitividad respecto a corporaciones extranjeras, que exploran nuevas soluciones de negocio, optimizando ganancias y reduciendo pérdidas. (Gestión, 2016).



Figura 02 En los últimos 21 años, han muerto 1 118 trabajadores durante accidentes en el sector minero, un promedio de 53 fallecidos cada año y de cuatro cada mes. En el 2002 se reportó el mayor número de víctimas mortales, 73; seguido del 2005, con 69; y del 2010, con 66, según las estadísticas del Ministerio de Energía y Minas. Desde el 2011, las muertes estaban en descenso, hasta que se incrementaron en el 2021, con la mencionada cifra de 63 obreros fallecidos.

Los macrodatos también se pueden usar para el monitoreo en tiempo real de personas y máquinas en el sitio de la mina, para ayudar a mejorar la productividad, aumentar la seguridad y proteger el medio ambiente.

Cuanto más conectada está una mina, más eficiente y preparada estará para el futuro digital. (PresPeru, 2022).

2.1.1. Problema general

- ¿De qué manera el Sistema de Inteligencia Artificial COPILOTO+ ayuda al control de una producción segura?

2.1.2. Problema específico

- ¿De qué manera el Sistema de Inteligencia Artificial captura e identifica patrones de comportamiento de riesgo y producción?
- ¿De qué manera el Sistema de Inteligencia Artificial emula el razonamiento basado en conocimiento de hechos?

2.2. Objetivos de la investigación

2.2.1. Objetivo general

- Emular mediante el Sistema de Inteligencia Artificial la productividad y seguridad en la UMC.

2.2.2. Objetivo específico

- Capturar e identificar patrones de comportamiento de riesgo y productividad mediante el Sistema de Inteligencia Artificial.
- Emular el razonamiento basado en conocimiento de hechos mediante el Sistema de Inteligencia Artificial.

2.3. Justificación del problema

Este proyecto es motivado porque en Perú y en la minería una de las principales causas de accidentes es el factor humano en la operación de equipos, existen

diversas soluciones que monitorean y controlan la operación de los equipos, pero aún ninguna con un % alto de efectividad. Sumado a ello en ocasiones estas soluciones afectan la productividad de los equipos.

Se propone tecnología que aporte un valor agregado a la extracción de materias primas, obteniendo una operación más segura sin disminuir los indicadores de productividad a través del análisis de indicadores de riesgo relevantes tanto para la seguridad como productivos.

La IA ofrece una gama de automatización de actividades, mejorando la seguridad, productividad, velocidad, calidad de producción del proceso de acarreo en la extracción y movimiento de material en minería durante las 24 horas continuas durante los 365 días al año.

La implementación de la IA en diferentes unidades de producción, desencadenará un crecimiento económico saludable sostenido, aumentando el producto bruto interno (PBI).

2.4. Delimitación del proyecto.

2.4.1. Delimitación espacial

El proyecto se desarrolló en la UMC (Unidad Minera Constancia), Chumbivilcas, Cusco - Perú, en coordinación con la empresa Hudbay Minerals.

2.4.2. Delimitación temporal

El proyecto se desarrolló en 4 años y medio aproximadamente, se inició en septiembre de 2018 hasta junio de 2022

2.4.3. Delimitación conceptual

El proyecto se realiza en función a la integración de sistemas de monitoreo en tiempo real y sus correlaciones, a través de la Inteligencia Artificial (IA) mediante modelos de aprendizaje supervisado de análisis de datos masivos.

3. Marco Teórico

3.1. Antecedentes de la investigación

Valencia T. A., & Quispe H. R. (2009). Modelos no Lineales de Redes Neuronales Artificiales Basadas en la Predicción de Series de Tiempo. Cusco: Universidad Nacional de San Antonio Abad del Cusco.

Joekes, S., Barbosa, S., & Robledo, W. (2005). Modelado y pronóstico de una serie de tiempo contaminada empleando redes neuronales y procedimientos estadísticos tradicionales.

Castillo, J. (2015). Concepto de la red neuronal con especial atención al Perceptrón Multicapa como elemento clasificador de patrones. 2017 editorial, Periódico El Comercio.

Cárdenas G, J. A. (2015). Pronósticos y comparación de una serie de tiempo con cambios estructurales mediante la red neuronal artificial de Retro propagación Resiliente y modelos no lineales. Lima - Perú: Universidad Nacional Mayor de San Marcos.

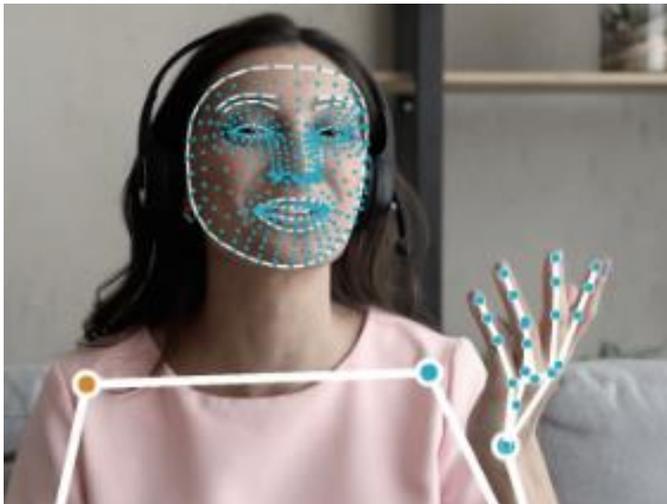


Figura 03 Reconocimiento facial, lectura de rasgos faciales con la Malla Facial (MediaPipe Face Mesh).

3.2. Bases teóricas

3.2.1. Reconocimiento Facial

El reconocimiento facial es una tecnología capaz de identificar o verificar a un sujeto [figura 03] a través de una o varias imágenes (estáticas o en movimiento), vídeo o cualquier elemento audiovisual de su rostro.

Generalmente, esta identificación es usada para acceder a una aplicación, sistema o servicio.

Es una forma de identificación biométrica que se sirve de medidas corporales, en este caso la cara y cabeza, para verificar la identidad de una persona. La tecnología recoge un conjunto de datos biométricos únicos de cada persona asociados a su rostro y expresión facial para identificar, verificar y/o autenticar a una persona. (electronicid.eu, 2011, / fase-Recognition / en).

3.2.2. Reconocimiento de sentimientos por rasgos faciales.

Se puede definir al reconocimiento facial de la expresión emocional como la capacidad de todos los individuos de reconocer formas básicas de expresión afectiva, la cual se muestra en los rostros de las personas y se constituyen por 6 emociones básicas (Russell, 1994, Saracco, 2012).

Este tipo de tecnología es utilizado para la generación de eventos de fatiga [figura 04] en camiones gigantes en la UMC



Figura 04 Verificación de eventos de fatiga por reconocimiento de rasgos faciales en el camión en producción CM16 - CAT793F – UMC.

El reconocimiento facial de la expresión emocional es la capacidad de todos los individuos de reconocer formas básicas de expresión afectiva, la cual aparece en los rostros de las personas. (ScarlettIglesias-Hoyos,2016)

3.2.3. Integración de sistemas

La integración de sistemas se define como el conjunto de elementos relacionados o que interactúan que permiten implantar y alcanzar la política y los objetivos de una organización, en lo que se refiere a aspectos diversos como pueden ser los de calidad, medio ambiente, seguridad y salud, u otras disciplinas de gestión. (Asociación Española de Calidad).

El hecho de tener todas las pequeñas partes que forman la empresa organizadas, interconectadas e integradas en una más grande supone una avalancha de productividad y, como bien es sabido, la productividad es beneficiosa para todos los estratos de una empresa (directivos, inversores, trabajadores).

No existe ninguna empresa alrededor del mundo que cuente con áreas, departamentos o procesos totalmente independientes entre sí. Todo lo que suceda a una o varias partes, afecta a todo el proceso. Cada fracción lleva consigo una operación para que el producto o servicio llegue finalmente al consumidor o cliente. Por lo tanto, a mayor excelencia en cada

operación de cada parte o fase, mayor excelencia del proceso completo. (edsrobotics.com, 2021, integración-sistemas/es)

3.2.4. Herramientas correlación

Un análisis de correlación es un punto de partida importante para identificar las relaciones entre medidas, es importante aclarar que la correlación no tiene por qué significar causalidad, pero sí al revés, la causa tiene una relación con el efecto. (SOFIA. IS)

El coeficiente de correlación es una medida estadística que calcula la fuerza de la relación entre los movimientos relativos de dos variables. Los valores del coeficiente de correlación van de -1,0 a 1,0. Si un número calculado es mayor que 1,0 o menor que -1,0, esto indica que hubo un error en la medición de la correlación. Esto se debe a que una correlación de -1,0 muestra una perfecta correlación negativa, mientras que una correlación de 1,0 muestra una perfecta correlación positiva. Una correlación de 0,0 significa

que no hay relación entre el movimiento de las dos variables. (datascience.eu)

Los coeficientes de correlación se utilizan para medir la fuerza de la relación entre dos variables.

La correlación de Pearson es la que más se utiliza en estadística. Mide la fuerza y la dirección de una relación lineal entre dos variables. Los valores siempre oscilan entre -1 (fuerte relación negativa) y +1 (fuerte relación positiva). Los valores en 0 ó cerca de cero implican una relación débil o ninguna relación. Los valores del coeficiente de correlación inferiores a +0,8 o superiores a -0,8 no se consideran significativos.

3.3. Marco conceptual

3.3.1. Inteligencia artificial

La inteligencia artificial (IA) se define como la capacidad de máquinas para realizar tareas intelectuales normalmente realizadas por humanos.

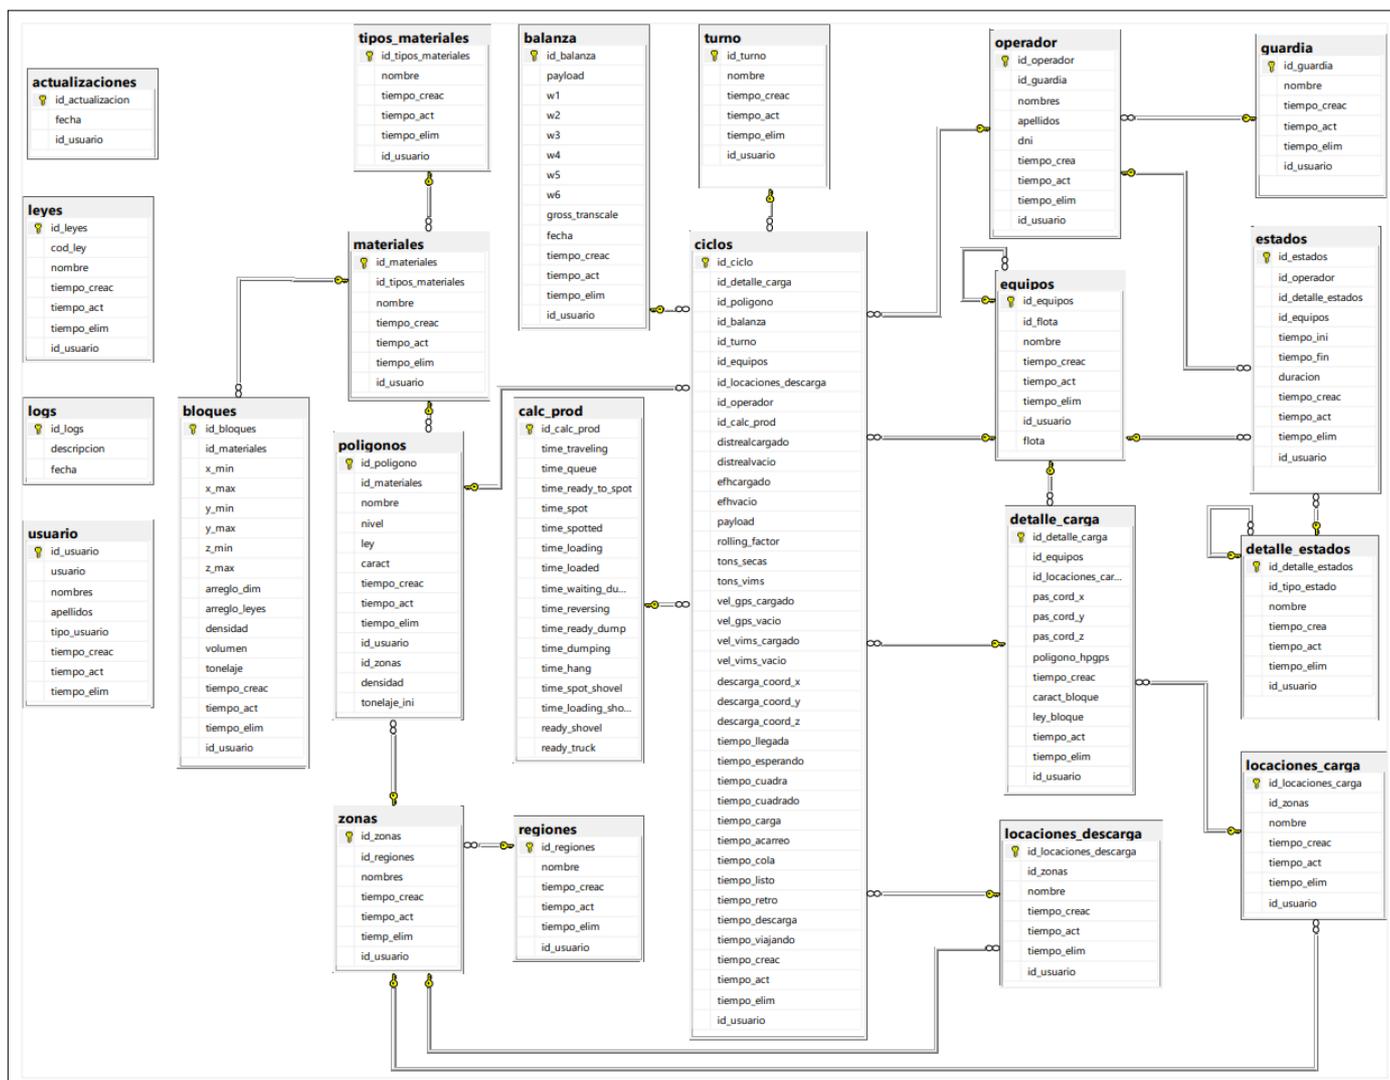


Figura 05 El diagrama E-R representa la estructura lógica de la base de datos COPILOTO, se han considerado diferentes entidades y atributos para el soporte de la solución tecnológica basada en el análisis datos masivos.

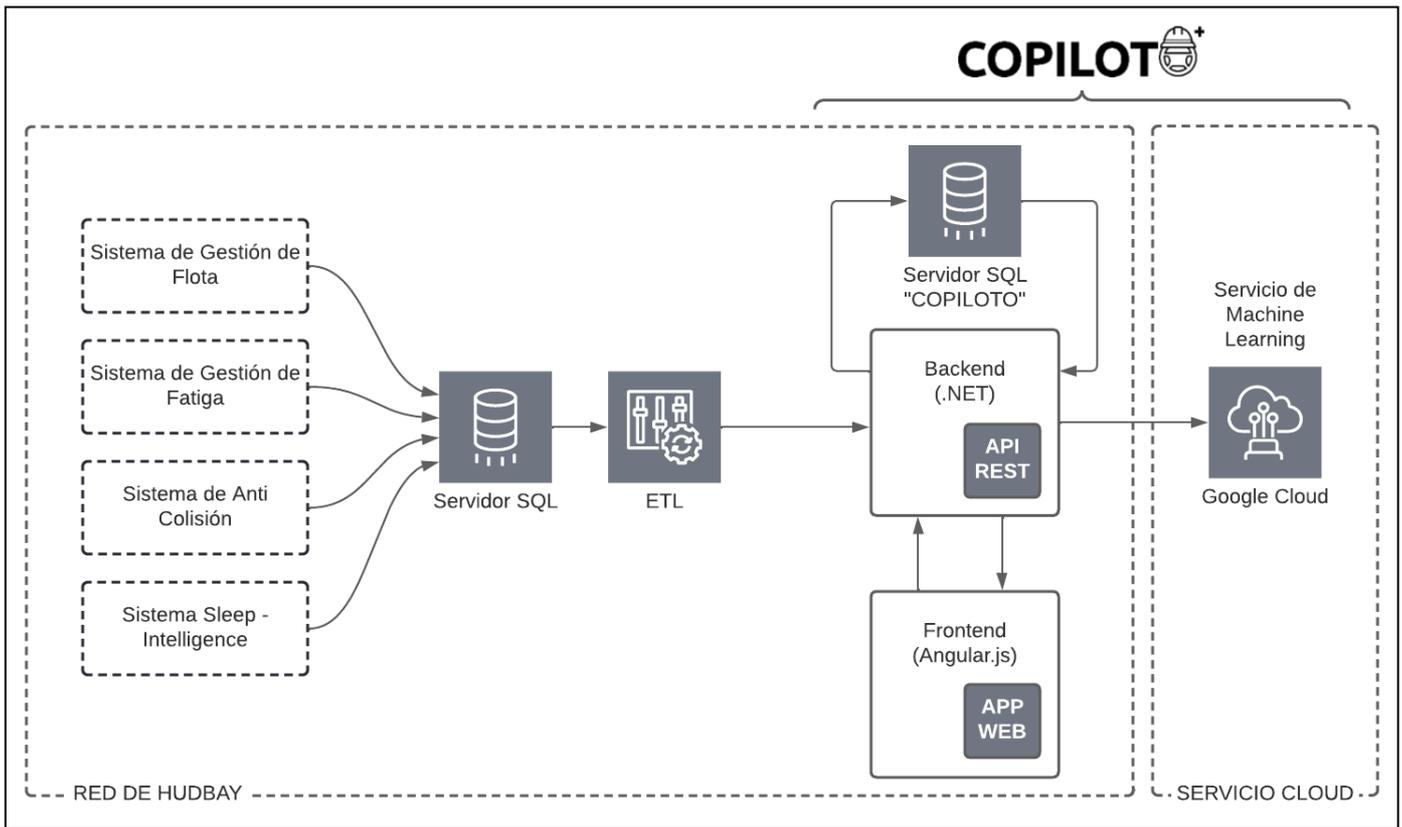


Figura 06 Arquitectura del proceso de integración de la solución COPILOTO, el servicio de Machine Learning (ML) se está generando en un servicio en la nube (Cloud) para contar con un mejor performance en la plataforma.

Este término se usa como un concepto general que abarca tanto el aprendizaje automático (ML) como el aprendizaje profundo (DL). Ambos conceptos pertenecen a un subcampo de la IA caracterizado mediante la creación de sistemas que son capaces de aprender, es decir generar sus propias reglas usando sólo datos.

Algunos autores distinguen entre ML y DL basándose en el hecho de que el primero implica la intervención humana para entrenar el algoritmo a través de la manipulación de datos (extracción y selección de las características más importantes), mientras que en la intervención humana de DL es mínima ya que no existe tal paso

Sin embargo, un enfoque más correcto es considerar DL una consecuencia de ML: los sistemas DL son sistemas ML, pero más profundos (de ahí el nombre). Es decir, consisten en muchas más capas, y estas capas

El diagrama de datos es usado para modelar y diseñar bases de datos relacionales, en términos de reglas de negocio y lógicas (en un modelo de datos lógicos) y en términos de la tecnología específica que se implementará (en un modelo de datos físicos).

El diagrama ER es un primer paso para determinar los requisitos de un proyecto de sistemas de información. Adicional a esto se usará modelar la base de datos de la solución COPILOTO+. Una base de datos

relacional tiene una tabla relacional equivalente y puede expresarse así potencialmente, según sea necesario.

5.2. Algoritmo de toma de decisión.

Los modelos por implementar tienen la metodología de modelo supervisado de inteligencia artificial, por lo cual, para entrenar los modelos se requiere tener previamente la información de entrada (predictores) y de salida (predecir).

En la gráfica se detalla cuáles son las fuentes de información de las cuales se extraerá la información a predecir, por ejemplo, en el caso del clasificador se usará la información detallada que el supervisor agrega a cada evento.

En los lineamientos del modelo, se plantea que el despliegue de los modelos se realice de un contenedor en Docker, eso se encuentra alineado a los métodos actuales de despliegue, con lo cual no se tendrán problemas antes y después del despliegue. Adicionalmente, utilizaremos la técnica de “MLOps” para la supervisión de los modelos desplegados, para lo cual se requiere una conexión directa con el servidor donde se procederá al despliegue. Esto último sólo es válido si el cliente se orienta por la primera o la segunda alternativa. Para el caso de la tercera alternativa los servidores con Windows no cuentan con Docker para la puesta en producción de modelos. Los

scripts en Python correrán sobre el OS Windows Server así que los requerimientos de librerías serán fijas.

5.3 Modelo clasificador de eventos de fatiga

Este modelo se encarga de clasificar los eventos de fatiga de la tabla DB-Antifatiga.

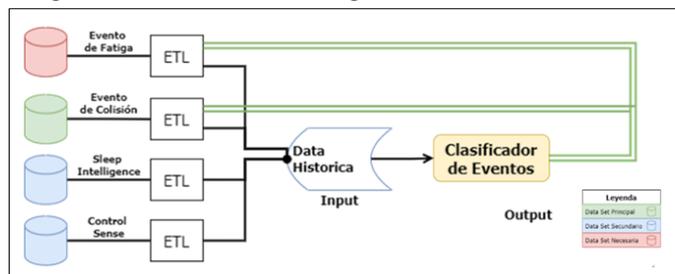


Figura 08 Diagrama de datos para la clasificación de los eventos generados en la solución.

Para el entrenamiento del modelo como parámetros de entrada se utiliza principalmente la información de la tabla DB-Antifatiga y de la tabla DB-Anticollision, adicionalmente se puede utilizar la información de las tablas DB-Sleep y DB-ControlSense. Como parámetros de salida tenemos la clasificación que se le da al evento según el testimonio del operador y el análisis posterior del evento.

Este modelo se ha entrenado y validado en el piloto que se entregó a Hudbay [figura 06], donde se demostró que se podían reducir el universo de eventos hasta en un 90% (donde dentro del 10% de eventos restantes se encuentran los eventos reales de fatiga),

optimizando el trabajo del supervisor al minimizar la cantidad de eventos a revisar.

5.4 Restricciones

El modelo va a clasificar cada vez que ocurra un evento de fatiga. Es importante detallar que el modelo necesita todas las variables asociadas al evento, si alguna variable tiene información fuera de rango o el valor que se tiene de la variable es nula, no se podrá hacer predicción sobre ese evento. Y quedará registrado en sistema log.

5.5 Modelo ranking de fatiga

Se desarrollará un modelo probabilístico por cada fuente de datos, donde los parámetros de entrada son independientes por cada modelo, pero el parámetro de salida es compartido entre los modelos y se extrae de la tabla DB-Antifatiga. Es necesario recalcar que los eventos confirmados de fatiga (<1% eventos) de la tabla DB-Antifatiga se pueden categorizar según el comentario del supervisor por evento, para poder categorizar los comentarios (nivel de fatiga 1- 5) se plantea utilizar un modelo NLP para automatizar la conversión de texto a nivel de fatiga, en caso de que la información no se pueda estructurar [figura 07] para el uso de algún modelo NLP, se hará la asignación a cada evento confirmado de manera manual (Esta asignación solo es necesaria para el entrenamiento de los modelos).

Posteriormente, se entrenará un modelo regresivo AP (Average Precisión) con el cual se espera combinar



Figura 07 La solución Copiloto es una herramienta de ayuda, acompañamiento y cuidado de los operadores de acarreo de la UMC el proyecto pretende integrar los sistemas más importantes para mejorar los índices de seguridad y producción.

Figura 10 Comparación grafica de resultados de los principales indicadores de los sistemas que involucran a la solución COPILOTO+.

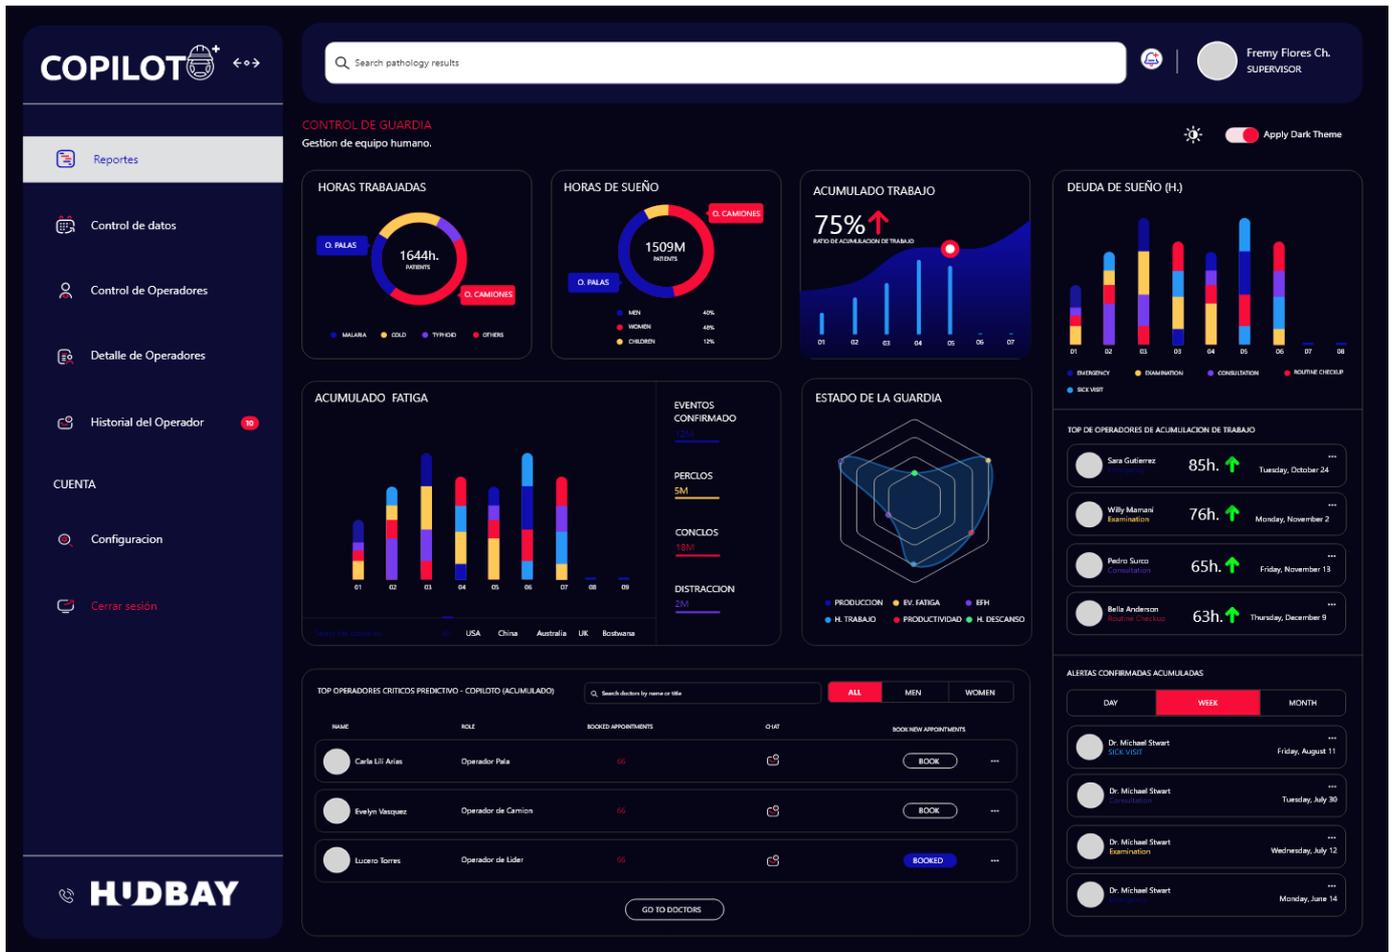
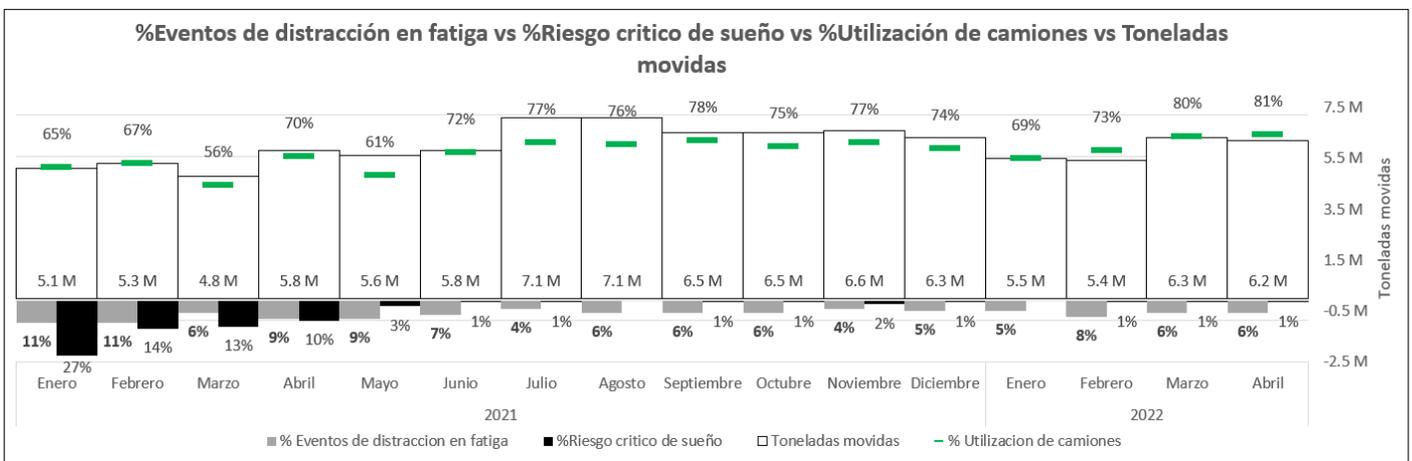


Figura 09 La plataforma COPILOTO es una solución integral que esta desarrollada en los ambientes de HBP, es utilizada por los lideres de despacho en el centro de control integrado de la UMC.

el resultado de cada fuente de datos, haciendo que el modelo sea robusto a la falta de información o caída de alguno de los sistemas. Adicionalmente, este tipo de flujo permite conocer las variables importantes (con mayor correlación con el nivel de fatiga) de cada tabla de manera independiente



Conclusiones

El trabajo ha requerido generar una solución que permita la relación de bases de datos desplegadas en MongoDB, PostgreSQL y MySQL, para luego proceder

aplicar modelos de *machine learning* a partir de la identificación de las variables más importantes.

Después, de integrar, comprender, estructuración de los datos para generar modelos predictivos, se optó

por el desarrollo de una herramienta multiplataforma en la infraestructura de HBP [figura 09].

Se contará con un panel de control donde se identificarán anomalías en los indicadores por operador y el resultado del modelo predictivo. Esta información permitirá a los jefes de guardia la toma de decisiones basada en *Machine Learning* para la asignación y distribución de operadores por equipos.

El movimiento de material ha contado con un ascenso de 5.5MMt a 6.2MMT, junto con esto la utilización ascendió de 65% a 81% en la flota de camiones gigantes a la par los indicadores de eventos de distracción en fatiga se han visto reducido en 5% teniendo una mejor calidad de sueño por operador con el resultado de 1% de riesgo crítico de sueño en todos los operadores de camión. [figura 10].

El incremento de movimiento de tonelaje es acompañado con la reducción del índice de fatiga gracias

Uno de los casos más comunes comprobados en la etapa de prueba ha sido la correlación entre las horas de trabajo acumulado por un operador de acarreo, su tiempo de descanso acumulado en los últimos 4 días de turno ocasionan una predisposición a tener eventos de fatiga alineado a una baja es sus indicadores de productividad y un mayor número de eventos de anticolisión registrados.

Agradecimientos

Este contenido de investigación científica, escenifica el proceso de despliegue de polifacéticos procesos de inteligencia artificial aplicada a la seguridad, minería y productividad. Representa el ahínco y perseverancia de años de inversión para alcanzar los resultados que gratifican las conjeturas de este proyecto. Reconociendo el afán de cooperar para concluir esta etapa de investigación al equipo de Inteligencia de Negocios y al equipo de tecnología de la información de la Unidad Minera Constancia de Hudbay Minerals.

Agradecer al Ing. Augusto Fernando Montjoy Beteta por su apoyo durante el proceso de la investigación y presentación del proyecto.

Conflicto de intereses

Los autores declaran que no tienen conflictos de intereses.

Referencias

MECELLA M.; PERNICI B. Designing wrapper components for e-services in integrating heterogeneous systems, Edited by F.Casati,M.-C.Shan,D.Georgakopoulos.Received:30 October 2000 /Accepted:9 January 2001 Publishedonline:28 June 2001 –c Springer-Verlag 2001

GIAGLIS George M., Focus Issue on Legacy Information Systems and Business Process Change: On The Integrated Design and Evaluation of Business Processes And Information Systems, Brunel University George.Giaglis@brunel.ac.uk 1999.

ENSINK Brian; HAVEMAN Kimberly; SHRESTHA Mochan; SCHAVEY Todd, XML based adaptation of the composite approach for database integration - April 1999.

YANDONG (Steven) Deng; MALY Wojciech, System Integration: A Design Driven System Implementation Schema, Department of Electrical & Computer Engineering Carnegie Mellon University 5000 Forbes Ave. Pittsburgh, PA 15213, USA {yangdon, maly}@ece.cmu.edu.

Álvarez, D. y Guevara, M. (2009). Reconocimiento de expresiones faciales prototipo usando ICA. *Scientia Et Technica*, 15(41), 81–86.

Anguas-Wong, A. M. y Matsumoto, D. (2007). Reconocimiento de la expresión facial de la emoción en mexicanos universitarios. *Revista de Psicología*, 25(2), 277–293.

Arango, I., Brüne, M., Fresán, A., Ortega, V., Villanueva, J., Saracco,

R., et al. (2013). Recognition of facial expression of the emotions and their relation to attachment styles and psychiatric symptoms. *Salud Mental*, 36, 95–100.

Buck, R. (1984). *The communication of emotion*. New York: Guilford Press.

BERTRAND Enrique, Integración de información corporativa con Web Services http://es.sun.com/infospain/eventos/javaexpo2004/presentaciones/tracks3/SoftwareAG_WSInformationIntegration.pdf, – Software AG - Java Expo 2004.

Perfil profesional

Ingeniero de la Escuela Profesional de Ingeniería de Minas de la Facultad de Ingenierías de la Universidad Nacional Jorge Basadre Grohmann - Tacna.
MBA - CENTRUM PUCP Graduate Business School y EADA Business School Barcelona
Nombre del autor: Paulo Alcazar
Cargo: Jefe de Costos y Presupuesto Mina – Encargado del Área de productividad y gestión mina.
Empresa: Hudbay Minerals
Correo electrónico: paulo.alcazar@hudbayminerals.com
Teléfono / Celular: +51 952 313 317
Dirección: Arequipa - Perú

Perfil profesional

Ingeniero de Minas, Titulado de la Universidad Nacional Santiago Antúnez de Mayolo, miembro ordinario del Colegio de Ingenieros del Perú - sede Lima, CIP:

170276. Con un posgrado de Gestión Minera en la Universidad Nacional de Ingeniería
Nombre del coautor (1): Alex Conco
Cargo: Supervisor de Productividad y de Gestión Mina
Empresa: Hudbay Minerals
Correo electrónico: alex.conco@hudbayminerals.com
Teléfono / Celular: +51 986 938 462
Dirección: Carhuaz - Perú

Perfil profesional

Egresado en Ingeniería de Minas (Dic-2014), Diplomado en Minería Subterránea y Medio Ambiente
Nombre del coautor (2): Carlos Herrera
Cargo: Ingeniero de Operaciones Mina II
Empresa: Hudbay Minerals
Correo electrónico: carlos.herrera.acuticona@hudbayminerals.com
Teléfono / Celular: +51 944 675 269
Dirección: Arequipa - Perú

Perfil profesional

Ingeniero de Operaciones Mina en UMC, Scrum Master y Magíster en proceso en Análisis e Interpretación de datos en la Universidad Internacional de la Rioja – España.
Nombre del coautor (3): Fremy Flores Chambilla
Cargo: Ingeniero de Operaciones Mina I
Empresa: Hudbay Minerals
Correo electrónico: fremy.flores@hudbayminerals.com
Teléfono / Celular: +51 999 21 5757
Dirección: Puno - Perú