

People Analytics: A Strategic Tool to Optimize Organizational Well-being and Sustainability

Anna Gisselle Corrales Osorio¹; Eliezer Erazo¹; Henry Osorto²

¹Facultad de Postgrado, Universidad Tecnológica Centroamericana, UNITEC, Honduras, anna.corrales@unitec.edu,
eliezer.erazo@unitec.edu, henry.osorto@unitec.edu.hn

²Universidad Nacional Autónoma de Honduras, UNAH, Honduras, henry.osorto@unah.edu.hn

Abstract- *Controlling the costs associated with corporate healthcare utilization and employee absenteeism represents an increasing challenge for organizational sustainability, particularly in emerging economies. This study applies a People Analytics framework to examine the relationship between medical service utilization, work incapacity, and associated economic losses using monthly aggregated administrative data. The methodology combines exploratory data analysis, predictive modeling through Ridge regression with temporal validation, scenario analysis, and pre-post comparisons. Results reveal substantial temporal variability and a strong concentration of costs among a limited number of healthcare providers. The predictive model significantly outperforms a naïve temporal baseline, highlighting the importance of service utilization volume and temporal persistence of incapacity. In addition, the comparison between July and November 2025 shows reductions exceeding 30% in both incapacity hours and total economic loss. Overall, the findings demonstrate the value of People Analytics as an evidence-based tool to support preventive decision-making and enhance financial and operational sustainability.*

Keywords— *People Analytics; Organizational Well-being; Sustainability; Employee absenteeism; Business Intelligence.*

People Analytics: Una herramienta Estratégica para Optimizar el Bienestar Organizacional y la Sostenibilidad en el medio Empresarial

Anna Gisselle Corrales Osorio¹; Eliezer Erazo¹; Henry Osorto²

¹Facultad de Postgrado, Universidad Tecnológica Centroamericana, UNITEC, Honduras, anna.corrales@unitec.edu,
eliezer.erazo@unitec.edu, henry.osorto@unitec.edu.hn

²Universidad Nacional Autónoma de Honduras, UNAH, Honduras, henry.osorto@unah.edu.hn

Resumen- *El control de los costos asociados a la atención médica corporativa y al ausentismo laboral constituye un desafío creciente para la sostenibilidad organizacional, especialmente en contextos de economías emergentes. Este estudio aplica un enfoque de People Analytics para analizar la relación entre el uso de servicios médicos, la incapacidad laboral y la pérdida económica asociada, utilizando datos administrativos agregados a nivel mensual. La metodología combina análisis exploratorio de datos, modelación predictiva con regresión Ridge y validación temporal, análisis de escenarios y comparaciones pre-post. Los resultados muestran una elevada variabilidad temporal y una fuerte concentración del costo en un número reducido de proveedores médicos. El modelo predictivo presenta un desempeño sustancialmente superior a un baseline temporal ingenuo, evidenciando la relevancia del volumen de atenciones y de la persistencia temporal de la incapacidad. Asimismo, la comparación entre julio y noviembre de 2025 revela reducciones superiores al 30 % tanto en horas de incapacidad como en pérdida total. En conjunto, los hallazgos confirman el potencial del People Analytics como herramienta para apoyar decisiones preventivas y fortalecer la sostenibilidad financiera y operativa.*

Palabras clave- *People Analytics; Bienestar organizacional; Sostenibilidad; Ausentismo Laboral; Inteligencia de Negocios.*

I. INTRODUCCIÓN

El control de los costos asociados a la atención médica corporativa, las primas de seguros y las contribuciones a los sistemas de seguridad social se ha convertido en un desafío estratégico para las organizaciones, particularmente en contextos donde se busca equilibrar sostenibilidad financiera, productividad y bienestar de los colaboradores. En múltiples sectores, los esquemas de salud empresarial combinan la afiliación obligatoria al seguro médico social, la provisión de servicios mediante clínicas internas con capacidad y horarios limitados, y el acceso a redes privadas de atención externa disponibles las 24 horas. Si bien esta configuración garantiza cobertura y oportunidad de atención, también introduce incentivos que pueden favorecer la sobreutilización de servicios, el ausentismo en periodos críticos de la operación y el incremento sostenido de los costos asociados a primas y servicios privados.

La literatura latinoamericana destaca que los marcos regulatorios influyen de manera significativa en la gestión del ausentismo y los costos médicos. En el caso hondureño, la

coexistencia de clínicas internas y redes externas privadas plantea retos adicionales derivados de la heterogeneidad en los tiempos de atención, la variabilidad en los diagnósticos y criterios de incapacidad, y el uso intensivo de servicios privados durante picos de demanda operativa. El Reglamento de Incapacidad Temporal del Instituto Hondureño de Seguridad Social (IHSS, 2020) establece lineamientos estrictos para la certificación, el refrendo y el subsidio de incapacidades, lo que obliga a las empresas a mantener procesos formales de registro, verificación y archivo clínico. No obstante, el cumplimiento normativo por sí solo resulta insuficiente para gestionar de manera eficiente los costos y los efectos indirectos del ausentismo sobre la productividad.

En este contexto, la analítica de personas (People Analytics, PA) emerge como un enfoque analítico capaz de transformar grandes volúmenes de datos organizacionales dispersos en evidencia accionable para la toma de decisiones. A diferencia de los enfoques tradicionales de recursos humanos, centrados en indicadores descriptivos, el People Analytics integra información operativa (turnos, carga laboral, salario por hora), datos de salud ocupacional (consultas, diagnósticos, tipo de clínica, incapacidades), variables demográficas (edad, género) y métricas de desempeño (productividad, ausentismo), permitiendo analizar de manera conjunta fenómenos que, de otro modo, se examinan de forma aislada.

La principal contribución del People Analytics radica en su capacidad para generar trazabilidad analítica de la atención médica por empleado, motivo de consulta, área operativa y proveedor, fortaleciendo tanto los procesos de auditoría interna como el cumplimiento normativo. En sistemas de atención híbrida que combinan clínica interna, red externa y, crecientemente, modalidades de telemedicina, la analítica avanzada permite identificar patrones temporales de consulta, diagnósticos recurrentes asociados a condiciones laborales específicas, puntos críticos de sobrecarga operativa y perfiles de alto riesgo clínico u organizacional. Sin embargo, a pesar de su potencial, la evidencia empírica aplicada a contextos empresariales de economías emergentes sigue siendo limitada, particularmente en lo que respecta a la cuantificación conjunta del uso de servicios médicos, el ausentismo laboral y los costos por empleado.

Desde una perspectiva metodológica, el uso de modelos estadísticos avanzados como regresiones de conteo, modelos de datos de panel y análisis de series de tiempo permite aproximar los efectos de intervenciones específicas, tales como la implementación de esquemas de teletrabajo, políticas de derivación médica o rediseños contractuales con proveedores de salud. Asimismo, la incorporación de modelos predictivos posibilita transitar desde una gestión reactiva del ausentismo hacia enfoques preventivos, orientados a anticipar escenarios de alto impacto antes de que se materialicen en pérdidas de productividad o incrementos de costos.

No obstante, la adopción intensiva del People Analytics también plantea desafíos éticos y regulatorios relevantes, especialmente cuando se utilizan datos sensibles de salud. La literatura reciente advierte sobre riesgos asociados a la privacidad, el consentimiento informado y la reproducción de sesgos en modelos predictivos, lo que hace indispensable el diseño de esquemas robustos de gobernanza de datos, auditoría de modelos y alineación con la normativa laboral y de seguridad social vigente.

A partir de estas consideraciones, este artículo propone un enfoque estructurado de People Analytics para diagnosticar la relación entre el uso de servicios médicos privados y públicos, el ausentismo laboral y los costos de salud por empleado en un contexto empresarial hondureño. El estudio emplea un Análisis Exploratorio de Datos (EDA) como fase inicial de descubrimiento, complementado con técnicas de modelación estadística y evaluación de impacto, así como con el desarrollo de modelos predictivos orientados a la prevención. De manera transversal, se abordan los aspectos éticos y de cumplimiento normativo vinculados al Instituto Hondureño de Seguridad Social y al Código de Trabajo, con el fin de garantizar que las recomendaciones de política respeten los derechos de los colaboradores y los marcos legales vigentes.

El objetivo general del estudio es demostrar que un marco de People Analytics aplicado a datos de salud ocupacional y operación permite identificar palancas de alto impacto para reducir costos innecesarios, mejorar el bienestar de los colaboradores, anticipar niveles de ausentismo y uso de servicios médicos, y proteger la productividad organizacional. Como contribución, el artículo articula una ruta metodológica replicable basada en EDA y modelación estadística, y propone una agenda de intervención respaldada en literatura reciente, con especial énfasis en contextos latinoamericanos y economías emergentes como Honduras.

II. REVISIÓN DE LITERATURA

Para el desarrollo de la revisión de literatura se consultaron bases de datos especializadas como Scopus, Google Scholar, Redalyc entre otras, de las cuales se obtuvieron bases de datos a las que se les aplicaron análisis bibliométricos con enfoques de análisis especializado con paquetes en R como *bibliometrix*, [1], o por medio de enfoques exploratorios propuestos en [2].

A. Contextualización de la evolución de la analítica de personas

El People Analytics (PA) ha experimentado una evolución significativa en las últimas décadas, transitando desde un enfoque predominantemente descriptivo, centrado en métricas tradicionales de recursos humanos, hacia un modelo analítico avanzado que incorpora técnicas de analítica predictiva, aprendizaje automático y sistemas de apoyo a la toma de decisiones [3], [4] [5], [6]. En sus etapas iniciales, el PA se enfocaba principalmente en el reporte de indicadores básicos como rotación, ausentismo y costos laborales; sin embargo, la literatura reciente documenta un cambio sustancial hacia su consolidación como un componente estratégico del capital humano con impacto directo en la sostenibilidad organizacional [7], [8].

En esta línea, diversos estudios han documentado cómo la integración de técnicas de aprendizaje automático y minería de datos permite superar las limitaciones de los enfoques tradicionales, facilitando la identificación temprana de patrones de ausentismo y la estimación de riesgos asociados a eventos de ausencia prolongada [9], [10]. Este tránsito hacia modelos predictivos se ha visto reforzado por la disponibilidad de registros administrativos y de salud ocupacional, que habilitan análisis longitudinales y segmentaciones más precisas del comportamiento laboral [11]. Esta evolución del PA ha sido ampliamente abordado en revisiones sistemáticas que evidencian cómo la analítica de personas ha dejado de ser una práctica emergente para convertirse en una herramienta clave en la gestión organizacional basada en datos [12]. En este contexto, el PA permite a las organizaciones tomar decisiones informadas y anticipar tendencias en el comportamiento de las personas, superando limitaciones previamente asociadas a la complejidad y variabilidad inherente al factor humano.

Algunos autores sostienen que el verdadero valor del People Analytics se materializa cuando los análisis se vinculan explícitamente con resultados de negocio, permitiendo cuantificar el impacto de las políticas organizacionales en variables como productividad, costos laborales, retención del talento y continuidad operativa [13]. Desde esta perspectiva, el PA deja de ser un ejercicio descriptivo para transformarse en un mecanismo de generación de valor estratégico. Esta orientación hacia el valor de negocio ha sido subrayada por investigaciones recientes que señalan que la adopción de prácticas de analítica de recursos humanos facilita una toma de decisiones más efectiva y un mejor alineamiento de las acciones de gestión con los resultados organizacionales [14]. Asimismo, estudios sobre adopción y aceptación de HR Analytics documentan una expansión de esta práctica en múltiples regiones, lo que refleja un creciente interés en integrar perspectivas digitales y analíticas dentro de la gestión de recursos humanos.

En términos operativos, el People Analytics contemporáneo se caracteriza por la integración de múltiples fuentes de información, que incluyen datos operativos, registros de salud ocupacional, evaluaciones de desempeño, encuestas organizacionales, métricas de productividad y mediciones de

clima laboral [15], [16]. Esta integración supera el uso aislado de indicadores tradicionales y permite la aplicación de análisis multivariados capaces de revelar patrones, relaciones y comportamientos que no son evidentes mediante métodos convencionales de análisis. La capacidad de combinar estas fuentes de información amplía significativamente el alcance analítico del PA y refuerza su utilidad para la toma de decisiones estratégicas.

B. Nuevo paradigma para los departamentos RRHH

El departamento de Recursos Humanos tradicional se enfoca en la operatividad y trabajo administrativo para que los engranajes funcionen, sin embargo, el introducir herramientas de analítica en el departamento da apertura a la tendencia de analizar los datos recolectados para generar valor a la empresa a través de la toma de decisiones basada en información fidedigna que desarrolle políticas establecidas sobre una base de datos que no sólo describe, sino que predice.

La literatura empírica coincide ampliamente en que el bienestar de los colaboradores constituye un determinante fundamental del desempeño organizacional [17]. Investigaciones desarrolladas por la Organización Mundial de la Salud (OMS, 2020) demuestran que los entornos laborales saludables contribuyen a la reducción del ausentismo, el presentismo y la rotación de personal, generando incrementos de productividad que, según diversos metaanálisis, pueden alcanzar hasta un 20%. Estos hallazgos subrayan la importancia de considerar el bienestar no solo como un componente social, sino también como un factor económico relevante para las organizaciones. Debido a estas causas, el departamento de Recursos Humanos deja de ser solamente un ente regulador y procesador, a un apoyo a la operación para que los números de las métricas de evaluación de clima laboral y otros se vean impactados de manera positiva para la empresa, creando rendimientos en productividad traduciendo todo esto en un retorno de inversión importante.

Estudios sectoriales complementan esta visión al señalar que los costos asociados al ausentismo laboral trascienden el pago directo de incapacidades médicas. Una proporción significativa de dichos costos se origina en efectos indirectos, como la redistribución de cargas de trabajo, la disminución en la calidad del servicio, el incremento de horas extra y el agotamiento del personal presente. De hecho, la evidencia indica que más del 60% del costo total vinculado a la salud laboral proviene de pérdidas de productividad, y no de gastos médicos directos. En este contexto, el People Analytics se presenta como una herramienta clave para cuantificar estos efectos mediante modelos que relacionan el uso de servicios médicos privados y públicos, los patrones de incapacidad y las variaciones en la productividad organizacional [18]. Revisiones recientes confirman que las intervenciones de bienestar resultan significativamente más efectivas cuando se diseñan de manera focalizada, se sustentan en evidencia empírica y se evalúan a través de diseños estadísticos rigurosos [19].

C. Sostenibilidad y Bienestar

Desde una perspectiva de sostenibilidad empresarial, el People Analytics se alinea de manera directa con los tres pilares del enfoque ESG: económico, social y de gobernanza. Dentro de este marco, el capital humano ha adquirido un rol estratégico, y el PA aporta herramientas analíticas que permiten identificar brechas de salud, equidad y desempeño, anticipar riesgos operativos derivados del ausentismo o del agotamiento laboral, diseñar políticas de bienestar basadas en evidencia y medir el impacto financiero de dichas intervenciones. La literatura más reciente ha ampliado el alcance del PA incorporando dimensiones de bienestar integral, salud mental y calidad de vida, reconociendo que el ausentismo no es únicamente un fenómeno operativo, sino también un reflejo de condiciones psicosociales y de salud subyacentes [20]. En este contexto, emergen propuestas de marcos integrados de inteligencia artificial para la salud ocupacional, que buscan alinear la analítica avanzada con objetivos de bienestar y sostenibilidad empresarial [21].

En [22] enfatizan que el aporte del People Analytics a la sostenibilidad radica en su capacidad para vincular métricas sociales, como el bienestar, el clima organizacional y la salud mental, con resultados económicos tangibles, tales como el retorno de inversión, la reducción de costos y la continuidad operativa, además de fortalecer estándares de gobernanza relacionados con la transparencia, la trazabilidad y la equidad.

Este vínculo entre analítica de personas y sostenibilidad adquiere especial relevancia en mercados emergentes, como el hondureño, donde los costos médicos y el ausentismo representan una proporción considerable del gasto operativo empresarial. En estos contextos, la capacidad de optimizar el uso de recursos de salud y gestionar el bienestar laboral mediante herramientas analíticas se convierte en un factor crítico para la competitividad y la estabilidad organizacional.

No obstante, el rápido avance del People Analytics ha generado importantes debates en torno a sus implicaciones éticas. Diversos autores advierten sobre riesgos asociados a la privacidad y el consentimiento, especialmente cuando se utilizan datos sensibles relacionados con la salud de los colaboradores, lo que exige garantías estrictas de confidencialidad, anonimización y minimización de la información. Asimismo, se ha señalado que los modelos predictivos pueden reproducir o amplificar inequidades laborales si no se someten a auditorías sistemáticas de sesgos, y que una datificación excesiva de la gestión del talento puede distorsionar la toma de decisiones y afectar la autonomía de los colaboradores. Frente a estos desafíos, la literatura coincide en la necesidad de implementar esquemas robustos de gobernanza de datos, que incluyan comités interdisciplinarios, mecanismos de auditoría de modelos, políticas claras de acceso y uso de la información, y una comunicación interna transparente.

En este sentido, la ética del People Analytics no se limita a la mitigación de riesgos, sino que incorpora un enfoque proactivo orientado a garantizar intervenciones más equitativas, decisiones organizacionales más objetivas y una gestión basada

en principios de justicia organizacional. La incorporación de criterios éticos fortalece la legitimidad del PA y contribuye a su aceptación por parte de los distintos actores organizacionales.

D. Síntesis de la revisión de literatura

En síntesis, la literatura internacional y regional converge en señalar que el People Analytics fortalece la capacidad de las organizaciones para tomar decisiones basadas en evidencia en materia de bienestar laboral, salud ocupacional y gestión de costos médicos. El bienestar de los colaboradores influye de manera directa en la productividad, y las intervenciones más efectivas son aquellas que integran tanto factores clínicos como operativos. La sostenibilidad empresarial requiere, por tanto, la articulación de indicadores ESG con analítica avanzada del capital humano, mientras que los riesgos éticos y legales asociados al uso intensivo de datos pueden mitigarse mediante esquemas robustos de gobernanza y políticas de transparencia. En el caso hondureño, el cumplimiento del marco normativo del IHSS, Código de trabajo de Honduras y la gestión adecuada del uso de redes médicas internas y externas se consolidan como variables críticas para el control de los costos corporativos y la sostenibilidad organizacional.

Desde el punto de vista metodológico, los estudios que se consultaron en la revisión de literatura pueden agruparse en cuatro enfoques principales. El primero corresponde a la predicción directa del ausentismo laboral mediante modelos supervisados de aprendizaje automático en las que se emplean algoritmos de clasificación y regresión para estimar la probabilidad de ausencias futuras, demostrando mejoras sustanciales respecto a modelos estadísticos tradicionales [23], [9], [24].

Un segundo enfoque se centra en la implementación práctica de modelos analíticos como herramientas de apoyo a la toma de decisiones. En [25] ilustran esta línea al integrar un modelo predictivo de ausentismo en una plataforma web interactiva, destacando la importancia de traducir los resultados analíticos en sistemas utilizables por gestores y responsables de recursos humanos. De manera complementaria, en [11] enfatizan la necesidad de que estos modelos contribuyan explícitamente a la eficiencia de costos y a la toma de decisiones estratégicas.

El tercer enfoque agrupa estudios orientados a la identificación de causas y factores determinantes del ausentismo, más allá de la predicción, en los que se aplican técnicas de clasificación y minería de datos para distinguir patrones causales, permitiendo segmentar a los empleados según perfiles de riesgo y tipos de ausencia [26], [27], [28]. En esta misma línea, en [29] subrayan la relevancia de la preparación de datos y la selección de variables como etapas críticas para garantizar la validez de los modelos.

Un cuarto enfoque amplía el análisis hacia la intervención y el bienestar organizacional, incorporando estudios sobre aplicaciones digitales de bienestar laboral [30], modelación del impacto de intervenciones ergonómicas [31] y esquemas de incentivos económicos para reducir el ausentismo [32]. Estos

trabajos evidencian una transición desde la analítica predictiva hacia estrategias de gestión activa del bienestar, alineadas con objetivos de sostenibilidad.

En términos de resultados, la evidencia empírica coincide en que los modelos basados en aprendizaje automático ofrecen una capacidad superior para identificar patrones de ausentismo y anticipar eventos de ausencia en comparación con enfoques descriptivos o puramente estadísticos [5], [10]. Asimismo, los estudios que incorporan análisis de causas aportan un valor adicional al permitir interpretar los resultados y diseñar intervenciones más focalizadas [26], [27].

Los trabajos centrados en bienestar y salud ocupacional amplían estos aportes al mostrar que la gestión del ausentismo debe integrarse con estrategias de promoción de la salud y de mejora del entorno laboral, ya sea mediante aplicaciones digitales [30], ajustes ergonómicos [31] o incentivos económicos [32]. En paralelo, estudios sobre utilización sanitaria de alto costo evidencian la relevancia de la analítica predictiva para la sostenibilidad financiera, al permitir identificar segmentos con mayor probabilidad de consumo intensivo de servicios de salud [33].

No obstante, la literatura también reconoce limitaciones recurrentes. Entre ellas destacan la dependencia de la calidad y completitud de los datos administrativos, los riesgos de sobreajuste en contextos con horizontes temporales cortos y los desafíos éticos asociados al uso de inteligencia artificial en entornos laborales. En este último punto, en [34] subrayan la necesidad de enfoques de inteligencia artificial explicable y centrada en el ser humano, especialmente cuando los modelos influyen en decisiones sensibles para los trabajadores.

III. MATERIALES Y MÉTODOS

A. Diseño de la investigación

Se desarrolló un estudio cuantitativo de carácter observacional y analítico, orientado a describir patrones de uso de servicios médicos corporativos, incapacidad laboral y costos asociados, así como a construir modelos predictivos para apoyar la toma de decisiones organizacionales. La unidad de análisis principal fue el período mensual t , utilizando agregaciones de los registros operativos y de salud ocupacional para construir indicadores de incapacidad y pérdida económica a nivel temporal (serie mensual).

B. Fuentes de información y estructura de los datos

Los datos provienen de registros administrativos de atención médica corporativa y ausentismo, que incluyen información de fechas de atención, número de atenciones, diagnósticos, días/horas de incapacidad, y variables derivadas de costos. A partir de estos registros se construyeron las siguientes variables mensuales:

- Horas de incapacidad (H_t): suma mensual de horas de incapacidad registradas.

- Pérdida total (L_t): indicador monetario mensual que integra pérdida por incapacidad y pérdida por atención médica.
- Número de atenciones (A_t): conteo mensual de atenciones médicas.
- Rezago de incapacidad (H_{t-1}): medida de persistencia temporal, definida como el valor de incapacidad del período inmediato anterior.

C. Preprocesamiento y preparación de los datos

Previo al análisis, se llevó a cabo un proceso sistemático de preprocesamiento de datos, que incluyó:

- Anonimización y minimización de información sensible.
- Tratamiento de valores faltantes mediante reglas de imputación consistentes con la naturaleza de cada variable.
- Codificación de diagnósticos médicos en categorías analíticas agregadas.
- Agregación temporal de los datos a nivel mensual mediante operaciones de suma y conteo.
- Cálculo de costos asociados a incapacidades utilizando un salario promedio por hora.

Formalmente, el ausentismo mensual en días laborales equivalentes se definió como:

$$D_{it} = \frac{H_{it}}{8},$$

donde H_{it} representa el total de horas de incapacidad del empleado i en el mes t .

Asimismo, el costo mensual asociado al ausentismo se estimó como:

$$C_{it} = D_{it} \times w_{it},$$

donde w_i corresponde al salario diario promedio del empleado.

D. Estrategia de análisis

El análisis de los datos se llevó a cabo en cuatro etapas:

1) *Análisis exploratorio de datos (EDA)*: Se realizó un análisis exploratorio para caracterizar la distribución temporal de los indicadores de incapacidad y pérdida económica, identificando meses con picos de pérdida total y variabilidad en la serie. Esta etapa incluyó visualizaciones mensuales de L_t y estadísticos descriptivos asociados.

2) *Comparación temporal*: Con fines descriptivos y de monitoreo, se estimó el cambio absoluto y relativo entre julio y noviembre de 2025 en: (i) horas de incapacidad (H_t) y (ii) pérdida total (L_t). Adicionalmente, se calculó el acumulado de horas de incapacidad en el período julio–noviembre de 2025 como medida de carga total del fenómeno.

3) Modelación predictiva con regularización (Ridge):

Para estimar el valor esperado de la incapacidad a partir de determinantes operativos y de persistencia temporal, se implementó un modelo de regresión Ridge. Considerando la estructura temporal, la validación se realizó con partición secuencial (*TimeSeriesSplit*), evitando el uso de información futura en el entrenamiento. La especificación general del modelo predictivo se expresa como:

$$\hat{H}_t = \alpha + \beta_1 A_t + \beta_2 H_{t-1} + \varepsilon_t,$$

Donde A_t representa el número de atenciones del mes t y H_{t-1} captura la persistencia temporal. Las covariables fueron estandarizadas mediante *StandardScaler*. El desempeño se evaluó usando error absoluto medio (MAE) y coeficiente de determinación (R^2), reportando resultados por fold y promedios. Como punto de referencia, se comparó el modelo Ridge contra un modelo base temporal ingenuo (*naive lag-1*).

4) *Análisis de escenarios (sensibilidad)*: Con el propósito de traducir la predicción en información útil para decisiones gerenciales, se estimaron escenarios contrafactuales de corto plazo. En particular, se simuló un incremento exógeno de $\Delta A = +10$ atenciones respecto al último período observado, manteniendo constantes las demás covariables, y se generó la predicción correspondiente $\hat{H}_t$. Este ejercicio se interpreta como análisis de sensibilidad y no como inferencia causal estricta.

E. Formulación de hipótesis analíticas

Dado el horizonte temporal limitado y el carácter observacional del estudio, las hipótesis se plantean como restricciones direccionales sobre la asociación esperada en el modelo predictivo:

El análisis se orienta a contrastar, de manera exploratoria, las siguientes hipótesis:

$H_0: \beta_1 = 0$ (el número de atenciones no se asocia con la incapacidad)

$H_1: \beta_1 > 0$ (el número de atenciones se asocia positivamente con la incapacidad).

Estas hipótesis se interpretan de manera exploratoria, complementando la evaluación principal basada en desempeño predictivo y consistencia temporal.

F. Métricas de desempeño y retorno de inversión

Se reportaron indicadores económicos mensuales, en particular L_t como pérdida total asociada a incapacidad y atención médica. El cálculo formal de retorno de inversión (ROI) requiere la definición explícita de una intervención, su costo y un esquema de evaluación de impacto. En esta etapa, el estudio utiliza comparaciones temporales y escenarios predictivos como aproximaciones descriptivas para identificar palancas de reducción de costos; la estimación de ROI se

propone como extensión futura condicionada a la disponibilidad de costos de intervención y una estrategia cuasi-experimental (por ejemplo, series de tiempo con intervención).

G. Consideraciones éticas y cumplimiento normativo

Todo el proceso analítico se desarrolló bajo principios éticos y de cumplimiento normativo. Se garantizó el uso responsable de los datos, la comunicación transparente sobre los fines analíticos del estudio y la incorporación de mecanismos de revisión de posibles sesgos. Asimismo, el análisis se ajusta a la normativa del IHSS, al Código de Trabajo de Honduras y a los principios de gobernanza de datos aplicables a estudios de salud ocupacional.

IV. RESULTADOS

A. Análisis descriptivo y evolución temporal de la incapacidad y los costos

Como etapa inicial del análisis, se desarrolló un análisis exploratorio de datos (EDA) orientado a caracterizar la evolución temporal del ausentismo laboral asociado a incapacidades médicas y su impacto económico. Este enfoque es consistente con la metodología planteada, la cual prioriza la identificación de patrones, tendencias y puntos críticos antes de la aplicación de modelos analíticos avanzados.

La Fig.1 presenta la evolución mensual de los días equivalentes de incapacidad (horas de incapacidad divididas entre ocho) para el periodo analizado. Se observa una variabilidad considerable entre meses, con valores sustancialmente más elevados a partir de mediados de 2024, lo que evidencia una presión creciente sobre la continuidad operativa. Este comportamiento sugiere la presencia de factores estructurales y operativos que trascienden eventos aislados, justificando la necesidad de intervenciones basadas en evidencia.




Fig. 1 EVOLUCIÓN MENSUAL DE LOS DÍAS EQUIVALENTES DE INCAPACIDAD.

De forma complementaria, la Fig. 2 muestra la evolución de la pérdida económica total mensual asociada a incapacidades y atenciones médicas. La trayectoria de esta variable guarda una relación directa con la incapacidad acumulada, lo que confirma que el ausentismo no solo constituye un problema operativo, sino también un determinante relevante del costo corporativo de la salud.




Fig. 2 EVOLUCIÓN MENSUAL DE LA PÉRDIDA TOTAL ASOCIADA A SALUD OCUPACIONAL

Por medio del análisis visual se evidencia que los picos de incapacidad coinciden con incrementos pronunciados en la pérdida económica. Esta asociación visual respalda la pertinencia del enfoque metodológico adoptado, que combina variables operativas y financieras para una evaluación integral del impacto del bienestar laboral.

B. Resultados del análisis descriptivo mensual

La Tabla 1 resume los principales indicadores mensuales derivados del EDA, incluyendo el número de registros, atenciones, horas de incapacidad, días equivalentes y pérdida económica total. Los resultados muestran que, en los meses de mayor carga operativa, se alcanzan niveles superiores a 500 días equivalentes de incapacidad mensual, acompañados de pérdidas económicas superiores a USD 15,000, lo que refuerza la magnitud del problema desde una perspectiva de sostenibilidad empresarial.

TABLA 1 RESUMEN MENSUAL DE INCAPACIDAD Y PÉRDIDA ECONÓMICA					
Mes	Registros	Atenciones	Horas incap.	Días equiv.	Pérdida total (USD)
2024-05	7	10,543,506	56	7	214.05
2024-06	790	1,201,326,695	3952	494	16,108.24
2024-07	899	1,367,523,513	4584	573	18,605.29
2024-08	696	1,063,453,933	3584	448	14,595.42
2024-09	796	1,214,266,165	4360	545	17,600.65

Estos resultados confirman que la carga de incapacidad presenta un comportamiento persistente en el tiempo, lo cual respalda la decisión metodológica de avanzar hacia comparaciones temporales estructuradas y análisis de impacto.

C. Concentración del costo por proveedor de salud

El análisis por proveedor revela una elevada concentración del costo total en un número reducido de clínicas. La Fig. 3 muestra que una sola clínica concentra una proporción dominante tanto de la pérdida económica como de los días equivalentes de incapacidad, lo que sugiere un alto potencial de optimización mediante estrategias de gestión diferenciada y rediseño de esquemas de derivación.

entre folds sugiere la conveniencia de complementar este enfoque con análisis de escenarios y evaluaciones de robustez, especialmente en contextos de alta volatilidad operativa.

E. Análisis de escenarios y sensibilidad del costo médico
Con el objetivo de evaluar la aplicabilidad práctica del modelo predictivo desarrollado, se realizó un análisis de escenarios orientado a examinar la sensibilidad de la pérdida total asociada a atención médica y ausentismo ante variaciones exógenas en el volumen de atenciones. Este ejercicio permite traducir los resultados del modelo estadístico en información accionable para la gestión organizacional, uno de los principales aportes del enfoque de People Analytics.

La Fig. 4 presenta la evolución mensual de la pérdida total, medida en términos monetarios, a lo largo del período de estudio. Se observa una variabilidad considerable entre meses, con la presencia de picos y caídas pronunciadas que sugieren patrones temporales y posibles efectos estacionales en el uso de servicios médicos y en los costos asociados. Esta heterogeneidad temporal refuerza la necesidad de enfoques analíticos que superen el análisis descriptivo y permitan anticipar escenarios de riesgo financiero.




Fig. 4 PÉRDIDA TOTAL MENSUAL ASOCIADA A ATENCIÓN MÉDICA Y AUSENTISMO

A partir del último período observado, se construyó un escenario de sensibilidad en el cual se simuló un incremento exógeno de diez atenciones médicas, manteniendo constantes las demás covariables incluidas en el modelo (características operativas y rezagos de incapacidad). La simulación fue evaluada utilizando el modelo Ridge previamente entrenado y validado mediante partición temporal (*TimeSeriesSplit*), lo que garantiza la coherencia del ejercicio con la estructura longitudinal de los datos.

Los resultados del escenario indican que un aumento moderado en el número de atenciones genera un incremento predecible en la pérdida total esperada. Este hallazgo pone de manifiesto la sensibilidad del costo corporativo frente a variaciones relativamente pequeñas en la demanda de servicios médicos, particularmente en contextos donde coexisten esquemas de atención interna y redes privadas externas. Desde




Fig. 3 TOP CLÍNICAS POR PÉRDIDA ECONÓMICA TOTAL

D. Aplicación de modelo predictivo
La Tabla 2 sintetiza el desempeño predictivo del modelo Ridge validado mediante particiones temporales, así como su comparación con un modelo base naïve. El modelo propuesto presenta una reducción sustancial del error absoluto medio y un poder explicativo elevado, manteniendo interpretabilidad a través de la contribución relativa de las covariables.

El desempeño del modelo predictivo basado en regresión Ridge evidencia una capacidad sustancial para anticipar el comportamiento de las horas de incapacidad laboral a partir de variables operativas y de historial reciente. La validación se realizó mediante un esquema de validación temporal, lo que garantiza que el entrenamiento y la evaluación respeten la naturaleza secuencial de los datos y reduzcan el riesgo de filtración de información futura.

TABLA 2 DESEMPEÑO PREDICTIVO E INTERPRETACIÓN DEL MODELO RIDGE CON VALIDACIÓN TEMPORAL			
Modelo	MAE $\mu \pm \sigma$	R^2 $\mu \pm \sigma$	Mejora MAE vs. baseline (%)
Ridge (TimeSeriesSplit)	17.06 $\pm$ 15.70	0.76 $\pm$ 0.16	-73.2

Notas: (1) Desempeño por fold (MAE / R^2): Fold 1 = 7.12 / 0.84; Fold 2 = 9.31 / 0.87; Fold 3 = 35.34 / 0.58. (2) Modelo base temporal (naive lag-1): MAE = 64.41, RMSE = 82.75. (3) Coeficientes promedio del Ridge (variables estandarizadas): N° de atención (β = 39.87; importancia relativa = 0.80) y rezago de días de incapacidad (β = 10.25; importancia relativa = 0.20). (4) Intercepto promedio del modelo: 552.88. (5) La validación se realizó mediante *TimeSeriesSplit* y las covariables fueron estandarizadas usando *StandardScaler*.

En conjunto, los resultados del modelo predictivo confirman que la analítica avanzada aplicada al capital humano permite no solo mejorar la precisión en la estimación del ausentismo futuro, sino también identificar palancas operativas clave para la gestión del bienestar y la sostenibilidad organizacional. La superioridad del modelo Ridge frente al baseline temporal, junto con la interpretabilidad de sus coeficientes, lo posiciona como una herramienta adecuada para apoyar decisiones preventivas, tales como la planificación de recursos médicos, la focalización de programas de bienestar y la anticipación de impactos financieros asociados a la incapacidad laboral. No obstante, la variabilidad observada

una perspectiva operativa, el resultado sugiere que el control del volumen de atenciones, así como la gestión temprana de casos recurrentes, puede tener efectos relevantes sobre la sostenibilidad financiera de la organización.

El análisis de escenarios complementa los resultados del modelo predictivo al evidenciar que la variable “número de atenciones” ejerce un peso significativo en la estimación de la pérdida total, en línea con los coeficientes obtenidos en el modelo Ridge estandarizado. De este modo, el escenario no solo confirma la consistencia interna del modelo, sino que también ilustra su potencial como herramienta de apoyo a la toma de decisiones, permitiendo evaluar de manera prospectiva el impacto económico de distintos cursos de acción.

Es importante destacar que este ejercicio no busca establecer relaciones causales estrictas, sino explorar escenarios plausibles bajo el supuesto de estabilidad estructural del modelo y del contexto operativo. No obstante, los resultados aportan evidencia empírica relevante para el diseño de políticas preventivas, tales como esquemas de teletriage, ajustes en los criterios de derivación médica o intervenciones focalizadas de bienestar dirigidas a segmentos con mayor probabilidad de uso intensivo de servicios de salud.

En conjunto, el análisis de escenarios refuerza el valor del enfoque de People Analytics al integrar modelación predictiva y evaluación económica, contribuyendo a una gestión más informada del bienestar laboral y de los costos médicos, y alineándose con objetivos más amplios de sostenibilidad organizacional.

F. Comparación pre-post: evolución de incapacidad y pérdida total

Entre julio y noviembre de 2025 se observa una reducción marcada tanto en las horas de incapacidad como en la pérdida total asociada a costos médicos y ausentismo (Tabla 3). En particular, las horas de incapacidad disminuyeron de 4,192 a 2,824, lo que representa una reducción absoluta de 1,368 horas y una contracción relativa de 32.63%. Este descenso ocurre dentro de un período acumulado de 16,832 horas de incapacidad, lo cual indica que, aun con una carga relevante de ausencias por incapacidad, la trayectoria hacia el final del período muestra una mejora operativa sustantiva.

TABLA 3
 COMPARACIÓN DE INDICADORES CLAVE ENTRE JULIO Y NOVIEMBRE DE 2025

Indicador	Pre	Post	Cambio absoluto	Cambio %
Horas de incapacidad	4,192	2,824	-1,368	-32.63
Días equivalentes	524	353	-171	-32.63
Pérdida total (USD)	16,715.59	11,341.97	-5,373.62	-32.15

De manera consistente, la pérdida total reportó una disminución desde USD 16,715.59 en julio de 2025 hasta USD 11,341.97 en noviembre de 2025, equivalente a una reducción absoluta de USD 5,373.62 (32.15%). La magnitud del cambio sugiere que los costos corporativos vinculados al uso de

servicios médicos y al ausentismo son altamente sensibles a variaciones en la dinámica de incapacidad, reforzando la relevancia de emplear métricas integradas (salud-operación-costos) para el monitoreo continuo.

Desde una perspectiva de People Analytics, estos resultados ofrecen dos implicaciones principales. Primero, la reducción conjunta de incapacidad y pérdida económica sugiere una mejora simultánea en el componente operativo (tiempo no trabajado) y en el componente financiero (costos directos e indirectos), lo que fortalece la lectura de sostenibilidad organizacional en el corto plazo. Segundo, el patrón observado valida la utilidad del enfoque analítico para identificar ventanas temporales críticas (picos) y períodos de mejora, aportando evidencia cuantitativa para orientar decisiones gerenciales (por ejemplo, ajustes en políticas de derivación, teletriage o intervenciones focalizadas de bienestar). No obstante, esta comparación pre-post debe interpretarse como evidencia descriptiva temporal; para atribuir cambios a intervenciones específicas sería necesario complementar el análisis con diseños de evaluación de impacto (p. ej., modelos de series de tiempo con intervención o esquemas cuasi-experimentales).

IV. DISCUSIÓN Y CONCLUSIONES

Los hallazgos empíricos confirman que la gestión de salud ocupacional y ausentismo representa un componente material de sostenibilidad financiera y continuidad operativa cuando se observa conjuntamente la dinámica de incapacidad y su traducción económica. En primer lugar, el análisis exploratorio mensual (Fig. 1 y Fig. 2) evidencia una variabilidad temporal marcada tanto en los días equivalentes de incapacidad como en la pérdida total asociada, con picos que coinciden en el tiempo. Esta co-movilidad respalda la decisión metodológica de integrar métricas operativas y monetarias, evitando interpretaciones aisladas del ausentismo como un fenómeno meramente administrativo.

En segundo lugar, el análisis por proveedor (Fig. 3) muestra una concentración elevada del costo total en un número reducido de clínicas, con una clínica dominante en pérdida económica y días equivalentes de incapacidad. Este resultado sugiere una palanca clara de gestión: más que intervenir de forma homogénea, el enfoque de People Analytics permite priorizar estrategias diferenciadas sobre los nodos donde se concentra el costo (auditorías clínicas focalizadas, revisión de criterios de derivación y rediseño de acuerdos con proveedores). Desde la perspectiva de analítica aplicada, esta concentración es relevante porque permite transformar un problema difuso en un conjunto acotado de decisiones de alto impacto.

En tercer lugar, la modelación predictiva con regularización (Ridge) aporta evidencia de que una aproximación parsimoniosa y validada temporalmente puede anticipar el comportamiento de la incapacidad agregada. En la Tabla 2, el modelo Ridge validado con TimeSeriesSplit alcanza un desempeño promedio de $MAE \approx 17.06$ (± 15.70) y $R^2 \approx 0.76$ (± 0.16), superando de manera sustancial al baseline temporal

ingenuo (*naïve lag-1*) en términos de error. A nivel interpretativo, el peso relativo de las covariables estandarizadas sugiere que el número de atenciones del mes y la persistencia temporal de la incapacidad son señales operativas clave, consistentes con la lógica del modelo propuesto. No obstante, la variabilidad entre folds (Tabla 2) indica sensibilidad a periodos específicos, por lo que su uso debe entenderse como apoyo a monitoreo y prevención, y no como un mecanismo de inferencia causal.

El análisis de escenarios complementa la evidencia predictiva al traducirla en información accionable: al simular un aumento exógeno de atenciones ($\Delta A = +10$) sobre el último periodo observado, el modelo genera un cambio predecible en la pérdida esperada, ilustrando que variaciones moderadas en la demanda de atención pueden asociarse con impactos relevantes en la carga de incapacidad y en el costo total. Este ejercicio debe interpretarse como análisis de sensibilidad bajo supuestos de estabilidad estructural, útil para planificación (capacidad de atención, criterios de derivación, y priorización de casos recurrentes), sin atribuir efectos causales estrictos.

Finalmente, la comparación temporal julio–noviembre 2025 (Tabla 3) muestra una reducción simultánea de horas de incapacidad (−32.63%) y de pérdida total (−32.15%), lo que sugiere una mejora operativa y financiera en el corto plazo dentro del periodo observado. Sin embargo, dado el carácter observacional y descriptivo de esta comparación, el resultado debe interpretarse como evidencia de evolución temporal y no como evaluación atribuible a una intervención específica.

En conjunto, los resultados muestran que un marco de People Analytics aplicado a datos de salud ocupacional puede (i) cuantificar la magnitud y variabilidad temporal de la incapacidad y la pérdida económica asociada, (ii) identificar concentración de costos por proveedor como palanca de intervención prioritaria, y (iii) desarrollar un modelo predictivo parsimonioso con validación temporal que mejora sustancialmente el desempeño frente a un baseline ingenuo y habilita análisis de sensibilidad para la toma de decisiones. En contextos empresariales de economías emergentes, estos elementos contribuyen a fortalecer la gestión preventiva del ausentismo y la sostenibilidad financiera, siempre que se acompañen de gobernanza de datos, resguardos éticos y un enfoque explícito de no-causalidad en interpretaciones descriptivas y predictivas.

REFERENCES

- [1] M. Aria and C. Cuccurullo, "bibliometrix : An R-tool for comprehensive science mapping analysis," *Journal of Informetrics*, vol. 11, no. 4, pp. 959–975, 2017, doi: 10.1016/j.joi.2017.08.007.
- [2] H. Osorto, "Optimizing academic literature review using Textmining in R: An automated approach," in *Proceedings of the 23rd LACCEI International Multi-Conference for Engineering, Education and Technology (LACCEI): "Engineering, Artificial Intelligence, and Sustainable Technologies in service of society"*, Jul. 2025. [Online]. Available: <https://dx.doi.org/10.18687/LACCEI2025.1.1.1114>
- [3] M. M. Ahmed and A. Ismail Al-Alawi, "Efficient Hybrid Ensemble Learning Algorithms for Employee Absenteeism Prediction," in *2024 International Conference on Open Innovation and Digital Transformation (OIDT)*, Manama, Bahrain, 2024, pp. 1–10.
- [4] S. Sitters, K. O'Callahan, M. O'Callahan, M. Petersen, T. Clasper, and L. Sicely, "Evaluating the impact of artificial intelligence-driven self-rostering: A dual-site pilot in medical imaging," *Radiography (London, England : 1995)*, vol. 31, no. 6, p. 103150, 2025, doi: 10.1016/j.radi.2025.103150.
- [5] P. K. Kushwaha, A. Rana, S. Srivastava, A. Saifi, A. Tavish, and P. Chaturvedi, "Employee Absenteeism Prediction Using Machine Learning," in *2023 10th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, Gautam Buddha Nagar, India, 2023, pp. 116–121.
- [6] S. K. Pemmada and J. Nayak, "Prediction of Absenteeism at the Workplace: A Light Gradient Boosting Approach," in *Lecture Notes in Networks and Systems, Computational Intelligence in Pattern Recognition*, A. K. Das, J. Nayak, B. Naik, S. Vimal, and D. Pelusi, Eds., Singapore: Springer Nature Singapore, 2023, pp. 543–554.
- [7] M. S. Nawaz, M. Z. Nawaz, P. Fournier-Viger, and J. M. Luna, "Analysis and classification of employee attrition and absenteeism in industry: A sequential pattern mining-based methodology," *Computers in Industry*, 159–160, p. 104106, 2024, doi: 10.1016/j.compind.2024.104106.
- [8] A. Bressane and M. V. de Castro, "Workplace Well-Being Through Nature-Based Solutions: A Fuzzy Framework for Decision-Making," *Buildings*, vol. 15, no. 1, p. 117, 2025, doi: 10.3390/buildings15010117.
- [9] A. Rista, J. Ajdari, and X. Zenuni, "Predicting and Analyzing Absenteeism at Workplace Using Machine Learning Algorithms," in *2020 43rd International Convention on Information, Communication and Electronic Technology (MIPRO)*, Opatija, Croatia, 2020, pp. 485–490.
- [10] E. L. de Oliveira, J. M. Torres, R. S. Moreira, and R. A. F. de Lima, "Absenteeism Prediction in Call Center Using Machine Learning Algorithms," in *Advances in Intelligent Systems and Computing, New Knowledge in Information Systems and Technologies*, Á. Rocha, H. Adeli, L. P. Reis, and S. Costanzo, Eds., Cham: Springer International Publishing, 2019, pp. 958–968.
- [11] N. Lawrance, G. Petrides, and M.-A. Guerry, "Predicting employee absenteeism for cost effective interventions," *Decision Support Systems*, vol. 147, p. 113539, 2021, doi: 10.1016/j.dss.2021.113539.
- [12] S. Bottesch, C. Schwenke, M. Förster, and M. Klier, "Driving business value through people analytics: Literature review and research agenda from an information systems perspective," *Electron Markets*, vol. 35, no. 106, 2025, doi: 10.1007/s12525-025-00842-3.
- [13] T. Rasmussen and D. Ulrich, "Learning from practice: how HR analytics avoids being a management fad," *Organizational Dynamics*, vol. 44, no. 3, pp. 236–242, 2015, doi: 10.1016/j.orgdyn.2015.05.008.
- [14] R. Ramachandran, V. Babu, and V. P. Murugesan, "Human resource analytics revisited: a systematic literature review of its adoption, global acceptance and implementation," *BIJ*, vol. 31, no. 7, pp. 2360–2390, 2024, doi: 10.1108/BIJ-04-2022-0272.
- [15] J. Lee, H. Shin, and S. Cho, "A medical treatment based scoring model to detect abusive institutions," *Journal of biomedical informatics*, vol. 107, p. 103423, 2020, doi: 10.1016/j.jbi.2020.103423.
- [16] N. Bhattacharyya *et al.*, "Profiling Disease and Economic Burden in CRSwNP Using Machine Learning," *Journal of asthma and allergy*, vol. 15, pp. 1401–1412, 2022, doi: 10.2147/JAA.S378469.
- [17] R. Benni, M. M. Naik, N. A. Somankoppa, and M. M. Kittur, "Augmented Prediction of Employee Anxiety and Depression: an Ensemble Approach," in *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kamand, India, 2024, pp. 1–9.
- [18] S. Ghosh, "Health claim propensity model using Machine Learning," in *2023 16th International Conference on Developments in eSystems Engineering (DeSE)*, Istanbul, Türkiye, 2023, pp. 504–509.
- [19] R. Mosquera, I. G. Pérez Vergara, and O. E. Contreras-Pacheco, "A model based on PDCA and data mining approach for the prevention of occupational accidents in the plumbing activity in the construction

- sector," *Work (Reading, Mass.)*, vol. 78, no. 2, pp. 399–410, 2024, doi: 10.3233/WOR-230112.
- [20] A. Dias *et al.*, "The impact of disease changes and mental health illness on readapted return to work after repeated sick leaves among Brazilian public university employees," *Frontiers In Public Health*, vol. 10, p. 1026053, 2022, doi: 10.3389/fpubh.2022.1026053.
 - [21] M. V. Popa *et al.*, "An Integrated AI Framework for Occupational Health: Predicting Burnout, Long COVID, and Extended Sick Leave in Healthcare Workers," *Healthcare (Basel, Switzerland)*, vol. 13, no. 18, 2025, doi: 10.3390/healthcare13182266.
 - [22] S. Zeidan and N. Itani, "HR analytics and organizational effectiveness," *International Journal on Emerging Technologies*, vol. 11, no. 2, 683–688, 2020.
 - [23] A. K. Das, J. Nayak, B. Naik, S. Vimal, and D. Pelusi, Eds., *Computational Intelligence in Pattern Recognition*. Singapore: Springer Nature Singapore, 2023.
 - [24] B. Hu, "The Application of Machine Learning in Predicting Absenteeism at Work," in *2021 2nd International Conference on Computing and Data Science (CDS)*, Stanford, CA, USA, 2021, pp. 270–276.
 - [25] G. Nath, Y. Wang, A. Coursey, K. K. Saha, S. Prabhu, and S. Sengupta, "Incorporating a Machine Learning Model into a Web-Based Administrative Decision Support Tool for Predicting Workplace Absenteeism," *Information*, vol. 13, no. 7, p. 320, 2022, doi: 10.3390/info13070320.
 - [26] I. Fosić and A. Živković, "Classifying Relevant Causes of Employee Absenteeism Using Machine Learning," in *2023 46th MIPRO ICT and Electronics Convention (MIPRO)*, Opatija, Croatia, 2023, pp. 1347–1352.
 - [27] E. A. Berón, D. Mejía, and O. D. Castrillón, "Principales causas de ausentismo laboral: una aplicación desde la minería de datos," *Inf. tecnol.*, vol. 32, no. 2, pp. 11–18, 2021, doi: 10.4067/S0718-07642021000200011.
 - [28] D. Alzu'bi, M. El-Heis, A. R. Alsoud, M. Almahmoud, and L. Abualigah, "Classification model for reducing absenteeism of nurses at hospitals using machine learning and artificial neural network techniques," *Int J Syst Assur Eng Manag*, vol. 15, no. 7, pp. 3266–3278, 2024, doi: 10.1007/s13198-024-02334-7.
 - [29] A. Al-Rasheed, "Identification of important features and data mining classification techniques in predicting employee absenteeism at work," *IJECE*, vol. 11, no. 5, p. 4587, 2021, doi: 10.11591/ijece.v11i5.pp4587-4596.
 - [30] G. Cameron *et al.*, "Real-World Usage of a Digital Employee Wellbeing Platform: k-Means Clustering Analysis," in *2024 IEEE International Conference on E-health Networking, Application & Services (HealthCom)*, Nara, Japan, 2024, pp. 1–4.
 - [31] M. S. Sohrabi, H. Khotanlou, R. Heidarimoghdam, I. Mohammadfam, M. Babamiri, and A. R. Soltanian, "Modeling the Impact of Ergonomic Interventions and Occupational Factors on Work-Related Musculoskeletal Disorders in the Neck of Office Workers with Machine Learning Methods," *Journal Of Research In Health Sciences*, vol. 24, no. 3, e00623, 2024, doi: 10.34172/jrhs.2024.158.
 - [32] M. S. Eddin and H. El-Amine, "Optimal Incentive-based Plans to Reduce Absenteeism," *Management And Labour Studies*, vol. 50, no. 3, pp. 306–319, 2025, doi: 10.1177/0258042X251341125.
 - [33] E. A. Seyam, "Predicting High-Cost Healthcare Utilization Using Machine Learning: A Multi-Service Risk Stratification Analysis in EU-Based Private Group Health Insurance," *Risks*, vol. 13, no. 7, p. 133, 2025, doi: 10.3390/risks13070133.
 - [34] N. Mollaei, C. Fujao, L. Silva, J. Rodrigues, C. Cepeda, and H. Gamboa, "Human-Centered Explainable Artificial Intelligence: Automotive Occupational Health Protection Profiles in Prevention Musculoskeletal Symptoms," *International Journal Of Environmental Research And Public Health*, vol. 19, no. 15, 2022, doi: 10.3390/ijerph19159552.