



UNIVERSIDAD
DE MÁLAGA



FACULTAD DE ESTUDIOS
SOCIALES Y DEL TRABAJO

FACULTAD DE ESTUDIOS SOCIALES Y DEL
TRABAJO

GRADO RELACIONES LABORALES Y RECURSOS
HUMANOS

TRABAJO FIN DE GRADO

*“DESARROLLO DE UNA APLICACIÓN DE
INTELIGENCIA ARTIFICIAL PARA LA
PLANIFICACIÓN ESTRATÉGICA DE LA
PLANTILLA”*

Autor: Antonio Roger Boris Wilkinson

Tutor: Roberto Ferrera Cordero

Septiembre de 2025

RESUMEN

El presente trabajo de fin de grado aborda el reto estratégico de la retención de talento mediante la aplicación de técnicas de people analytics. El objetivo principal es el diseño y desarrollo de una aplicación web interactiva que, mediante inteligencia artificial (IA), permita a los departamentos de Recursos Humanos anticipar y gestionar la rotación de personal de forma proactiva. Este proyecto destaca no solo por su resultado, sino también por su innovadora metodología de desarrollo, que se presenta como un caso de estudio. Empleando técnicas de prompt engineering, se ha construido una solución robusta en python y streamlit partiendo de una formación básica en programación, demostrando así la democratización en la creación de herramientas tecnológicas por parte de expertos de dominio. La aplicación integra un modelo de regresión logística para predecir con alta fiabilidad el riesgo de abandono de los empleados y un algoritmo de clustering k-means para segmentar la plantilla en perfiles de comportamiento homogéneos, facilitando la creación de estrategias de retención personalizadas. Adicionalmente, se incorporan técnicas de IA explicable (XAI) para desmitificar la "caja negra" de los modelos predictivos, ofreciendo una transparencia crucial para la toma de decisiones éticas y fundamentadas. El resultado, validado a través de un caso de uso práctico sobre la empresa ficticia 'Innovatech Solutions', es una herramienta funcional que ofrece un dashboard ejecutivo, análisis gráficos y un simulador de políticas "what-if", aportando una solución estratégica para la gestión del talento, especialmente valiosa para PYMES. De este modo, el trabajo valida una nueva forma de desarrollo tecnológico colaborativo entre expertos de dominio y la IA, acelerando la innovación en el ámbito de los recursos humanos.

PALABRAS CLAVE

Recursos humanos, people analytics, inteligencia artificial, retención de talento, machine learning, IA explicable (XAI), prompt engineering.

ABSTRACT

This final degree project addresses the strategic challenge of talent retention through the application of people analytics techniques. The main objective is the design and development of an interactive web application that, using artificial intelligence (AI), allows human resources departments to proactively anticipate and manage employee turnover. This project is notable not only for its outcome but also for its innovative development methodology, which serves as a case study. By employing prompt engineering techniques, a robust solution in python and streamlit has been built from a basic programming background, demonstrating the democratization of technological tool creation by domain experts. The application integrates a logistic regression model to reliably predict employee attrition risk and a k-means clustering algorithm to segment the workforce into homogeneous behavioral profiles, facilitating the creation of personalized retention strategies. Additionally, explainable AI (XAI) techniques are incorporated to demystify the "black box" of predictive models, providing crucial transparency for ethical and well-founded decision-making. The result, validated through a practical use case on the fictitious company 'Innovatech Solutions', is a functional tool featuring an executive dashboard, graphical analysis, and a "what-if" policy simulator, offering a strategic solution for talent management, particularly valuable for SMEs. Thus, this work validates a new form of collaborative technological development between domain experts and AI, accelerating innovation in the Human Resources field.

KEY WORDS

Human resources, people analytics, artificial intelligence, talent retention, machine learning, explainable AI (XAI), prompt engineering.

ÍNDICE

1.	INTRODUCCIÓN	5
1.1.	El capital humano como ventaja competitiva: el desafío de la retención de talento	5
1.2.	Limitaciones de la gestión tradicional de RRHH y la necesidad de un enfoque basado en datos	6
1.3.	Objetivos del trabajo: potenciar la toma de decisiones estratégicas en RRHH mediante IA	6
1.4.	Estructura de la memoria	7
2.	LA TRANSFORMACIÓN DIGITAL EN LA GESTIÓN DE PERSONAS	7
2.1.	El paradigma del people analytics: de la intuición al análisis predictivo	7
2.2.	La inteligencia artificial como aliado estratégico en recursos humanos	8
2.3.	Modelos de IA aplicados a la gestión del talento: fundamentos conceptuales	8
2.3.1.	Modelos de clasificación para la predicción del riesgo	9
2.3.2.	Modelos de clustering para la creación de perfiles	9
2.4.	Herramientas tecnológicas para la democratización del dato en RRHH	9
3.	DISEÑO DE UNA HERRAMIENTA DE IA PARA LA GESTIÓN ESTRATÉGICA DE LA PLANTILLA	10
3.1.	Metodología: un enfoque centrado en el usuario y el desarrollo asistido por IA	10
3.1.1.	El Rol del prompt engineering en la democratización del desarrollo	10
3.2.	Las variables clave en la gestión de personas: definición del conjunto de datos	11
3.3.	Funcionalidades clave de la herramienta	11
3.3.1.	Pestaña 1: dashboard principal y resumen ejecutivo	11
3.3.2.	Pestaña 2: análisis por segmentos	12
3.3.3.	Pestaña 3: consulta y simulación	13
3.3.4.	Pestaña 4: glosario y metodología	13
4.	APLICACIÓN PRÁCTICA Y ANÁLISIS DE RESULTADOS	14
4.1.	Escenario de aplicación: simulación de un caso de uso en una PYME	14
4.2.	Interpretación de los indicadores y gráficos desde una perspectiva de RRHH	14
4.2.1.	Análisis de los indicadores clave de rendimiento (KPIs)	14
4.2.2.	Análisis de las distribuciones de riesgo y perfiles	15
4.2.3.	Análisis de rankings y resumen ejecutivo: de los datos a la acción	16
4.3.	Discusión estratégica: ¿Qué acciones se derivan de los perfiles identificados?	18
4.3.1.	Análisis estratégico por perfiles de empleado (clusters)	18
4.3.2.	Análisis estratégico por departamento	20
4.4.	El Valor de la simulación para la optimización del presupuesto de retención en Innovatech	21

4.4.1.	Análisis individual detallado (XAI): Preparando la conversación con empleados de Innovatech	21
4.4.2.	Simulador de políticas 'what-if': Optimizando la inversión para Innovatech	22
4.5.	Centro de conocimiento: garantizando la autonomía de Innovatech	24
5.	CONCLUSIONES	24
5.1.	Conclusiones finales: Doble impacto de la IA en la estrategia de RRHH	24
5.2.	Limitaciones del estudio y de la herramienta desarrollada	26
5.2.1.	Limitaciones relativas a los datos	26
5.2.2.	Limitaciones del modelo de IA	26
5.2.3.	Limitaciones técnicas y de alcance de la herramienta	27
5.3.	Futuras líneas de trabajo y evolución de la herramienta	27
5.3.1.	Enriquecimiento del modelo predictivo	27
5.3.2.	Evolución hacia una herramienta de producción	28
6.	BIBLIOGRAFÍA	29
7.	ANEXOS	30
7.1.	Anexo I: manual de usuario de la aplicación	30
7.2.	Anexo II: Ejemplos de prompt engineering	32
7.3.	Anexo III: Listado completo de variables del dataset	33
8.	ÍNDICE DE ILUSTRACIONES	34

1. INTRODUCCIÓN

1.1. El capital humano como ventaja competitiva: el desafío de la retención de talento

En el entorno empresarial del siglo XXI, el capital humano se ha consolidado como el activo más valioso y un factor clave de diferenciación para las organizaciones (Savkovic et al., 2023). La capacidad para atraer, desarrollar y, fundamentalmente, retener el talento es un pilar estratégico para la sostenibilidad y el éxito competitivo (Agrawal et al., 2024). Sin embargo, la rotación de personal o employee churn se presenta como uno de los desafíos más persistentes y costosos para la gestión de recursos humanos. La salida de un empleado no solo genera costes directos de reclutamiento y formación, sino que también acarrea costes indirectos significativos como la pérdida de conocimiento institucional, la disminución de la productividad y un impacto negativo en la moral del equipo (Chung et al., 2023). Este problema es especialmente agudo en las pequeñas y medianas empresas (PYMES), donde la marcha de un solo individuo puede tener consecuencias desproporcionadas. La relevancia de este desafío es tal que, según encuestas recientes del

sector, la retención de talento es la principal preocupación para la mayoría de los profesionales de RRHH (Miguelés, 2024).

1.2. Limitaciones de la gestión tradicional de RRHH y la necesidad de un enfoque basado en datos

Tradicionalmente, la gestión de la rotación se ha abordado desde un enfoque reactivo, analizando las causas de la fuga de un empleado una vez que esta ya se ha producido. Herramientas como las entrevistas de salida, si bien son útiles, ofrecen una visión retrospectiva que limita la capacidad de anticipación. Este modelo, a menudo basado en la intuición, es insuficiente en un entorno que demanda agilidad y proactividad (Ramos Hernández et al., 2025). La irrupción de la inteligencia artificial (IA) y el *people analytics* está revolucionando esta área, permitiendo una transición desde la intuición hacia la predicción. La aplicación de modelos de *machine learning* (ML) ofrece la posibilidad de identificar patrones ocultos en los datos de los empleados para predecir futuros abandonos, permitiendo a los gestores de RRHH intervenir de manera proactiva (Rueda, 2023). Sin embargo, muchos de estos modelos avanzados funcionan como una "caja negra", lo que genera desconfianza y dificulta su adopción. Por ello, la tendencia actual no solo se centra en predecir, sino también en explicar el porqué de estas predicciones a través de la IA explicable (XAI), mitigando así la disyuntiva entre rendimiento predictivo y transparencia (Chaudhary et al., 2025; Heidemann et al., 2024).

1.3. Objetivos del trabajo: potenciar la toma de decisiones estratégicas en RRHH mediante IA

El presente trabajo de fin de grado nace de la confluencia de estas dos realidades: la criticidad de la retención de talento y el potencial de la inteligencia artificial para optimizar su gestión. El objetivo general de este proyecto es el diseño y desarrollo de una herramienta tecnológica que sirva como aliado estratégico para los profesionales de recursos humanos, democratizando el acceso a técnicas de análisis predictivo.

Para alcanzar este fin, se han definido los siguientes objetivos específicos:

- Desarrollar un modelo de *machine learning* capaz de predecir la probabilidad de abandono de cada empleado basándose en variables clave.
- Implementar un modelo de *clustering* para segmentar la plantilla en perfiles homogéneos, permitiendo la personalización de las estrategias de retención.

- Construir una aplicación web interactiva y de fácil uso que visualice los resultados de los modelos, sin necesidad de conocimientos técnicos avanzados por parte del usuario.
- Proporcionar un marco de trabajo que permita a las organizaciones, especialmente a las PYMES, adoptar un enfoque proactivo y basado en datos para la gestión de su capital humano.

1.4. Estructura de la memoria

Se ha estructurado en cinco capítulos principales para guiar al lector de forma lógica a través del desarrollo del proyecto. El capítulo 1 introduce el contexto del trabajo, justificando la necesidad de herramientas de análisis de datos en la gestión de personas y definiendo los objetivos. El capítulo 2 establece el marco teórico, explorando el concepto de people analytics y las aplicaciones de la inteligencia artificial en recursos humanos. A continuación, el capítulo 3 detalla el proceso de diseño y desarrollo de la herramienta, explicando la metodología, la definición de las variables y las funcionalidades implementadas. El capítulo 4 presenta un caso de uso práctico, analizando los resultados que ofrece la aplicación y discutiendo su valor estratégico. Finalmente, el capítulo 5 recoge las conclusiones del trabajo, evalúa las limitaciones del proyecto y propone futuras líneas de mejora.

2. LA TRANSFORMACIÓN DIGITAL EN LA GESTIÓN DE PERSONAS

2.1. El paradigma del people analytics: de la intuición al análisis predictivo

El campo de los recursos humanos está experimentando una profunda transformación impulsada por la tecnología. El paradigma del people analytics, o analítica de personas, representa el cambio fundamental desde una gestión basada en la experiencia y la intuición hacia una toma de decisiones fundamentada en datos y evidencia empírica (Heidemann et al., 2024). Este enfoque permite a las organizaciones analizar grandes volúmenes de datos de sus empleados para descubrir patrones, predecir tendencias y optimizar procesos de gestión del talento. En lugar de simplemente reaccionar a los problemas, como la alta rotación, el people analytics ofrece las herramientas para anticiparlos. La capacidad de analizar datos históricos de los empleados que han abandonado la empresa, por ejemplo, permite identificar los factores de riesgo y construir

modelos predictivos que alerten sobre qué empleados actuales podrían estar en una situación similar (De Vos et al., 2024). Este salto cualitativo no solo mejora la eficiencia operativa, sino que posiciona a la función de RRHH como un socio estratégico capaz de aportar valor medible al negocio (Ramos Hernández et al., 2025).

2.2. La inteligencia artificial como aliado estratégico en recursos humanos

La inteligencia artificial (IA) es la tecnología que cataliza el potencial del *people analytics*, ofreciendo capacidades de análisis que superan con creces los métodos estadísticos tradicionales. La IA, y en particular el *machine learning* (ML), se ha convertido en un aliado estratégico para los departamentos de RRHH en múltiples áreas (Rueda, 2023). En el ámbito de la selección de personal, los algoritmos pueden analizar miles de currículums para identificar a los candidatos más idóneos de forma más eficiente y con menos sesgos que los procesos manuales. En la gestión del desempeño, la IA puede identificar patrones de rendimiento y sugerir planes de desarrollo personalizados.

En el contexto de este trabajo, dos aplicaciones de la IA son particularmente relevantes:

- **Predicción del riesgo de fuga (attrition risk):** Los modelos de ML pueden analizar una multitud de variables (demográficas, laborales, de rendimiento, etc.) para calcular una probabilidad de abandono individualizada. Esto permite a los managers focalizar sus esfuerzos de retención en aquellos empleados con mayor riesgo de abandono, optimizando recursos y tiempo (Agrawal et al., 2024).
- **Segmentación de la plantilla:** Mediante algoritmos de clustering, la IA puede agrupar a los empleados en segmentos o perfiles con características y necesidades similares. Esta segmentación permite a RRHH diseñar e implementar estrategias de retención mucho más específicas y efectivas que las políticas generalistas (Benabou et al., 2025). Sin embargo, la creciente complejidad de estos modelos a menudo los convierte en "cajas negras", lo que dificulta la confianza y adopción por parte de los profesionales. Por ello, el campo de la IA explicable (XAI) se vuelve fundamental, ya que busca ofrecer transparencia sobre cómo los modelos llegan a sus conclusiones, un aspecto clave para una gestión ética y responsable (Chaudhary et al., 2025).

2.3. Modelos de IA aplicados a la gestión del talento: fundamentos conceptuales

Los modelos de Machine Learning son el motor que impulsa el *people analytics*. Para los objetivos de este proyecto, se han empleado dos tipos de modelos con propósitos distintos

pero complementarios: modelos de clasificación para la predicción del riesgo y modelos de clustering para la segmentación de la plantilla.

2.3.1. Modelos de clasificación para la predicción del riesgo

Los modelos de clasificación son algoritmos de aprendizaje supervisado cuyo objetivo es predecir una etiqueta categórica. En el contexto de este trabajo, la tarea consiste en clasificar a cada empleado en una de dos categorías: "se irá" o "no se irá". La literatura académica ha explorado numerosos algoritmos para esta tarea, como las redes neuronales, los bosques aleatorios (Random Forest) o las máquinas de soporte vectorial (SVM) (De Vos et al., 2024). Para este proyecto, se ha optado por la regresión logística, una elección fundamentada en su robustez, eficiencia y, sobre todo, su alta interpretabilidad. A diferencia de modelos más complejos, la regresión logística permite entender fácilmente el peso y la dirección (positiva o negativa) de la influencia de cada variable en la probabilidad de abandono, lo cual es de gran valor para la toma de decisiones en RRHH (Guerranti & Dimitri, 2023). Diversos estudios comparativos la sitúan como un modelo de referencia con un rendimiento muy competitivo (Benabou et al., 2025).

2.3.2. Modelos de clustering para la creación de perfiles

A diferencia de la clasificación, el clustering o agrupamiento es una técnica de aprendizaje no supervisado. Su objetivo no es predecir una etiqueta predefinida, sino identificar grupos o "clusters" naturales dentro de los datos, agrupando a los empleados que compartan características similares. Para este TFG, se ha utilizado el algoritmo k-means, uno de los métodos de clustering más conocidos y eficaces. k-means agrupa los datos en un número predefinido (K) de clústeres, buscando minimizar la varianza dentro de cada grupo. El resultado es la creación de perfiles de empleado (ej. "alto desempeño", "en riesgo"), que permiten a la organización comprender la estructura de su plantilla y diseñar estrategias de gestión del talento mucho más focalizadas y efectivas.

2.4. Herramientas tecnológicas para la democratización del dato en RRHH

La implementación de estos modelos de IA se ha realizado utilizando un conjunto de tecnologías de código abierto que son estándar en el campo de la ciencia de datos. El lenguaje de programación python, junto con librerías como pandas para la manipulación de datos y scikit-learn para la implementación de los modelos de machine learning, constituye la base técnica del proyecto. Sin embargo, la tecnología clave para la democratización de los resultados es streamlit. Se trata de un framework de python que permite convertir scripts de análisis de datos en aplicaciones web interactivas con muy poco esfuerzo. Gracias a streamlit, los complejos resultados de los modelos de IA se

pueden presentar en forma de dashboards visuales, gráficos interactivos y simuladores fáciles de usar, haciendo que los insights sean accesibles para los profesionales de RRHH sin necesidad de que estos interactúen con el código o posean conocimientos técnicos avanzados.

3. DISEÑO DE UNA HERRAMIENTA DE IA PARA LA GESTIÓN ESTRATÉGICA DE LA PLANTILLA

3.1. Metodología: un enfoque centrado en el usuario y el desarrollo asistido por IA

El desarrollo de la presente herramienta se ha guiado por una metodología pragmática y ágil, centrada en dos pilares fundamentales: la utilidad para el usuario final (el profesional de RRHH) y la eficiencia en el proceso de creación mediante el uso de tecnologías de IA generativa.

3.1.1. El Rol del prompt engineering en la democratización del desarrollo

En lugar de seguir un ciclo de desarrollo de software tradicional, que exigiría un equipo con perfiles especializados en programación, diseño de interfaz y ciencia de datos, este proyecto ha adoptado un enfoque innovador basado en la colaboración con un modelo de lenguaje grande (LLM). La metodología se ha centrado en el prompt engineering, que puede definirse como la disciplina de diseñar y refinar las instrucciones (prompts) que se proporcionan a una IA para obtener los resultados deseados. Este enfoque ha permitido que un experto en la materia de RRHH, partiendo de una formación muy básica en programación, pueda actuar como arquitecto y desarrollador de la solución. A través de un diálogo iterativo con la IA, se han traducido los requisitos funcionales y las necesidades de negocio en código python funcional y robusto. Esta forma de colaboración hombre-máquina reduce significativamente la barrera técnica de entrada, demostrando que las competencias fundamentales para la creación de este tipo de herramientas pueden ser adquiridas de forma accesible. Por tanto, este proyecto no solo valida una herramienta de RRHH, sino que también sirve como caso de estudio sobre las nuevas formas de creación tecnológica, una idea que comienza a ser validada en la literatura académica (Kim & Chung, 2024).

3.2. Las variables clave en la gestión de personas: definición del conjunto de datos

La calidad de cualquier modelo de machine learning depende directamente de la calidad y relevancia de los datos utilizados para su entrenamiento. Para este proyecto, se ha utilizado el conocido dataset "IBM HR Analytics Employee Attrition & Performance", disponible públicamente en la plataforma kaggle. Este conjunto de datos es considerado un estándar de facto o benchmark en la literatura académica para la predicción de la rotación de personal, habiendo sido utilizado en numerosos estudios (Al Akasheh et al., 2023; De Vos et al., 2024). El dataset contiene 1.470 registros de empleados, cada uno descrito por 35 variables o atributos. Estas variables recogen un amplio espectro de información, incluyendo datos demográficos (ej. edad, género), condiciones laborales (ej. departamento, rol, salario mensual), factores de compromiso y satisfacción (ej. satisfacción laboral, satisfacción con el entorno) y el historial del empleado (ej. años en la compañía, años desde la última promoción). La variable objetivo del análisis es attrition (abandono), un campo binario que indica si el empleado ha dejado la empresa ("sí") o no ("no"). La riqueza y variedad de estas variables lo convierten en un recurso ideal para entrenar modelos capaces de capturar la complejidad multidimensional que subyace a la decisión de un empleado de permanecer o abandonar una organización.

3.3. Funcionalidades clave de la herramienta

La aplicación se ha diseñado con un enfoque modular, estructurada en cuatro pestañas principales para facilitar una navegación intuitiva y un análisis progresivo, desde una visión general hasta un estudio detallado. El flujo de trabajo del usuario comienza en la barra lateral, que actúa como panel de control principal. Aquí, el usuario tiene acceso a dos recursos fundamentales: un botón para descargar una plantilla de datos en formato excel, que sirve como guía para formatear correctamente los datos propios, y otro botón para descargar el manual de usuario en PDF. El paso más importante es la carga del fichero de datos de la empresa a través del cargador de archivos, que activa el procesamiento y la visualización de los resultados en las distintas pestañas. Cada una de estas pestañas responde a una necesidad específica del gestor de Recursos Humanos.

3.3.1. Pestaña 1: dashboard principal y resumen ejecutivo

Esta es la pantalla de inicio y el centro neurálgico de la aplicación. Su objetivo es ofrecer una visión macro e inmediata de la salud de la plantilla. Se compone de los siguientes elementos:

- **Indicadores clave de rendimiento (KPIs):** Cuatro tarjetas que muestran el número total de empleados analizados, el riesgo medio de abandono del grupo, el clima medio (valorado sobre 5) y el salario medio. Permiten un diagnóstico rápido de la situación general.
- **Distribución de perfiles:** Un gráfico de tarta que desglosa la plantilla según los cuatro perfiles de empleado identificados por el modelo de clustering. Este visual ayuda a entender la composición de la fuerza laboral (ej. "¿tenemos más empleados de 'alto desempeño' o de 'potencial crecimiento'?")
- **Distribución del riesgo de abandono:** Un gráfico de barras que clasifica a los empleados en tres niveles de riesgo (Bajo, Medio, Alto). Es una herramienta visual potente para detectar si el riesgo de fuga está concentrado en un grupo específico, lo que requeriría una acción urgente.
- **Ranking de empleados por riesgo:** Para facilitar la acción inmediata, se presentan dos listas: el top 5 de mayor riesgo, que señala a los individuos que requieren atención prioritaria, y el top 5 de menor riesgo, que identifica a los empleados más estables y comprometidos, de cuyas condiciones se puede aprender.
- **Resumen ejecutivo y conclusiones estratégicas:** Este es el componente más avanzado de la pestaña. Se trata de un informe dinámico, redactado en lenguaje natural, que interpreta automáticamente los datos mostrados. No solo describe los resultados, sino que identifica fortalezas, debilidades y ofrece recomendaciones estratégicas. Además, incluye un botón para exportar el resumen a un archivo .txt, facilitando su distribución en informes o correos electrónicos.

3.3.2. Pestaña 2: análisis por segmentos

Mientras que el dashboard principal ofrece una visión global, esta pestaña permite al usuario profundizar en el análisis comparativo entre diferentes grupos. El objetivo es identificar dónde se concentran los problemas y las fortalezas:

- **Análisis de perfiles de empleados (clusters):** Este módulo se divide en dos. A la izquierda, una visualización de clusters (PCA) muestra una representación gráfica de los

perfiles de empleado, permitiendo evaluar visualmente si los grupos están bien definidos. A la derecha, un resumen de perfiles identificados utiliza menús desplegables para cada perfil, mostrando sus métricas clave (riesgo medio, clima laboral) y la recomendación principal para ese segmento. Cada elemento cuenta con un análisis detallado que explica qué se está viendo y qué recomendaciones se derivan.

- **Análisis por departamento:** De forma similar, esta sección presenta dos gráficos de barras horizontales que clasifican los departamentos de la empresa según su clima laboral medio y su riesgo de abandono medio. Esta vista permite a los managers identificar de forma inmediata qué departamentos están funcionando bien y cuáles necesitan una intervención.

3.3.3. Pestaña 3: consulta y simulación

Esta pestaña dota al usuario de herramientas para pasar del análisis grupal al individual y a la planificación estratégica:

- **Análisis individual detallado (XAI):** Para combatir la opacidad de los modelos de IA, este módulo incorpora técnicas de IA explicable (XAI). El usuario puede seleccionar a un empleado concreto de una lista y la herramienta le proporcionará una ficha detallada con su probabilidad de abandono y, lo más importante, los factores clave que influyen en esa predicción (ej. "salario bajo", "pocas promociones"). Esta funcionalidad es crucial para que los managers puedan preparar conversaciones de retención personalizadas y basadas en datos reales.
- **Simulador de políticas 'what-if':** Esta es la funcionalidad más estratégica de la herramienta. Permite a los responsables de RRHH simular el impacto potencial de diferentes políticas de retención antes de su implementación. Mediante controles deslizantes, el usuario puede modelar escenarios y obtener una visualización gráfica del impacto de sus decisiones en el riesgo de abandono promedio, ayudando a optimizar la asignación de recursos.

3.3.4. Pestaña 4: glosario y metodología

Finalmente, esta pestaña actúa como un centro de conocimiento para asegurar que todos los usuarios, independientemente de su perfil técnico, puedan comprender la herramienta. Incluye un glosario que define los términos clave (KPI, XAI, Cluster, etc.) y un resumen

de la metodología que explica de forma sencilla los pasos que sigue la IA para generar los análisis, fomentando la confianza y la correcta interpretación de los resultados.

4. APLICACIÓN PRÁCTICA Y ANÁLISIS DE RESULTADOS

Acceso a la aplicación: <https://aplicacion-ia-planificacion-estrategica-antoniowilkinson-tfg.streamlit.app/>

4.1. Escenario de aplicación: simulación de un caso de uso en una PYME

Para demostrar el valor práctico de la herramienta, este capítulo simulará su aplicación en un escenario realista. Se asumirá el rol de un consultor de RRHH que presenta los resultados del análisis a la dirección de "Innovatech Solutions", una empresa ficticia del sector tecnológico. Para este análisis, se utilizará un dataset representativo de 150 empleados, que, aunque sintético, está construido sobre las variables y la lógica del conocido dataset de IBM, permitiendo así una demostración robusta y completa de todas las funcionalidades de la aplicación. El propósito de este caso de uso es doble. En primer lugar, servirá para ilustrar el flujo de trabajo completo que un responsable de Recursos Humanos seguiría, desde la carga de datos hasta la obtención de conclusiones estratégicas. En segundo lugar, permitirá analizar en profundidad los resultados generados por la aplicación, interpretándolos desde una perspectiva de gestión y extrayendo recomendaciones concretas y accionables. A lo largo de los siguientes apartados, se desglosarán los hallazgos de cada una de las pestañas de la herramienta aplicadas a este caso práctico.

4.2. Interpretación de los indicadores y gráficos desde una perspectiva de

RRHH

Una vez cargado el fichero con los datos anonimizados de los 150 empleados que componen la plantilla de "Innovatech Solutions", la aplicación procesa la información y presenta los resultados iniciales en el "Dashboard Principal". Esta pantalla está diseñada para ofrecer un diagnóstico macro e inmediato de la salud organizacional, permitiendo al equipo de gestión captar la situación general en un solo vistazo. A continuación, se analiza cada componente.

4.2.1. Análisis de los indicadores clave de rendimiento (KPIs)

Los cuatro indicadores principales, mostrados en la Figura 4.1, ofrecen una primera fotografía cuantitativa de la plantilla.

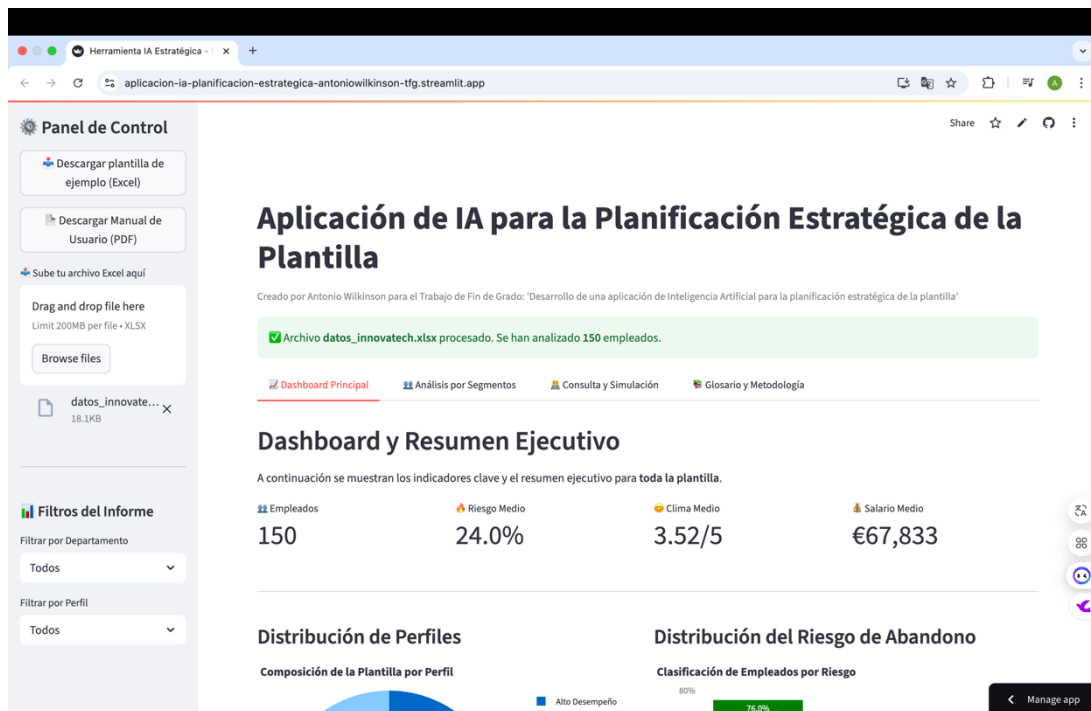


Figura 4.1: Captura de pantalla de la sección de KPIs del Dashboard, mostrando los valores de N° Empleados, Riesgo Medio, Clima Laboral y Salario Medio.

El riesgo medio de abandono se sitúa en un 24,0%, una cifra que demanda atención estratégica. El clima laboral medio es de 3,52 sobre 5, indicando un nivel de satisfacción aceptable pero con un claro margen de mejora. Finalmente, el salario medio de 67.833 € y el total de 150 empleados completan el contexto cuantitativo.


4.2.2. Análisis de las distribuciones de riesgo y perfiles

Los gráficos de distribución (ver Figura 4.2) revelan el hallazgo más significativo del análisis: una extrema polarización del riesgo. Un masivo 76% de los empleados (114 personas) presenta un riesgo “Bajo”. En el otro extremo, un 23,3% (35 empleados) se clasifica como de “Alto Riesgo”, siendo el riesgo “Medio” prácticamente inexistente (0,7%).

La distribución de perfiles complementa esta visión. Los segmentos de “Alto desempeño” (26,7%) y “Potencial Crecimiento” (26,7%) agrupan a la mayoría estable, mientras que los perfiles de “En riesgo” (24%) y “Bajo compromiso” (22,7%) concentran, con toda seguridad, a los 35 empleados en situación crítica.


Distribución de Perfiles

Composición de la Plantilla por Perfil



Distribución del Riesgo de Abandono

Clasificación de Empleados por Riesgo



Ver Análisis Detallado

¿Qué estamos viendo?: La proporción de cada perfil de empleado dentro del grupo seleccionado.

Análisis: El perfil más común en este grupo es 'Alto Desempeño'. Conocer la composición de la plantilla ayuda a enfocar las estrategias de RRHH.

Recomendaciones: Si un perfil de alto riesgo (como 'En Riesgo' o 'Bajo Compromiso') es mayoritario, se requieren acciones urgentes de retención.

Ver Análisis Detallado

¿Qué estamos viendo?: La clasificación de los empleados en tres niveles de riesgo y el porcentaje que representa cada grupo.

Análisis: Solo un 23.3% de los empleados está en 'Alto Riesgo', una situación mayormente controlada.

← Manage app

Figura 4.2 Captura de pantalla de los dos gráficos de distribución: el gráfico de barras de “Distribución del Riesgo de Abandono” y el gráfico de tarta de “Distribución de Perfiles”

4.2.3. Análisis de rankings y resumen ejecutivo: de los datos a la acción

Finalmente, la herramienta traduce el análisis en acción a través de sus componentes más estratégicos, mostrados en la Figura 4.3.

🔥 Top 5 Mayor Riesgo

Empleado ID: 45 (Ventas) - Riesgo: 100.0%

Empleado ID: 123 (Ventas) - Riesgo: 100.0%

Empleado ID: 31 (RRHH) - Riesgo: 100.0%

Empleado ID: 11 (Marketing) - Riesgo: 100.0%

Empleado ID: 93 (Marketing) - Riesgo: 99.9%

✅ Top 5 Menor Riesgo

Empleado ID: 140 (Producción) - Riesgo: 0.0%

Empleado ID: 37 (TI) - Riesgo: 0.0%

Empleado ID: 118 (TI) - Riesgo: 0.0%

Empleado ID: 64 (TI) - Riesgo: 0.0%

Empleado ID: 82 (TI) - Riesgo: 0.0%

Resumen Ejecutivo y Conclusiones Estratégicas

Diagnóstico General

El presente análisis cubre a 150 empleados de toda la plantilla. El riesgo de abandono promedio se sitúa en un 24.0%, mientras que el clima laboral medio es de 3.52 sobre 5. Estos indicadores generales sugieren un punto de partida para una evaluación más profunda.

Focos de Riesgo Principales

Se ha identificado que un 23.3% de la plantilla (35 personas) se encuentra en un nivel de riesgo 'Alto' (probabilidad de abandono > 70%). Esta es la cohorte que requiere atención más urgente.

- Departamento Crítico: El área de Ventas presenta el mayor riesgo medio de fuga, con una probabilidad promedio de 50.2%.
- Perfil más vulnerable: El perfil de empleado 'En Riesgo' es el que muestra la mayor tendencia al abandono en el grupo analizado (riesgo medio del 94.5%).

Fortalezas y Oportunidades

No todo son puntos débiles. Es crucial reconocer y aprender de las áreas de éxito:

- Departamento Ejemplar: Producción se destaca como el departamento con el menor riesgo de abandono (0.3%). Sería valioso analizar sus prácticas de gestión y clima.
- Mejor Clima Laboral: El departamento de TI goza del mejor clima laboral (4.79/5), un factor protector clave contra la rotación.

Conclusiones y Recomendaciones Estratégicas

1. **Acción de Choque (Corto Plazo):** Es imperativo implementar un plan de retención inmediato para los 35 empleados en alto riesgo. Priorizar entrevistas de permanencia ("stay interviews") en el departamento de Ventas para diagnosticar y actuar sobre las causas raíz.
2. **Análisis de Perfiles:** Investigar por qué el perfil 'En Riesgo' es particularmente propenso a la rotación. ¿Se debe a las condiciones del puesto, a la falta de desarrollo o a factores salariales? Utilice la pestaña *Análisis por Segmentos* para cruzar esta información.
3. **Capitalizar Fortalezas:** Analizar las políticas y el estilo de liderazgo del departamento de Producción para replicar sus buenas prácticas en otras áreas, especialmente en Ventas.
4. **Simulación de Políticas:** Antes de implementar cambios a gran escala (ej. aumentos salariales), utilice la pestaña *consulta y Simulación* para modelar su impacto en la probabilidad de abandono de los empleados clave. Esto permite optimizar la inversión en retención.

Exportar Resumen a .txt

Figura 4.3 Captura de pantalla de la parte inferior del dashboard, mostrando claramente las listas del "Top 5 de Mayor Riesgo" y "Top 5 de Menor Riesgo", junto al cuadro de texto del "Resumen Ejecutivo".

- Los Rankings de empleados son la funcionalidad que permite pasar del análisis macro a la gestión individual.

- El "Top 5 de Mayor Riesgo" es una llamada a la acción directa. Proporciona a los managers los nombres de los individuos que requieren una intervención inmediata, permitiéndoles preparar reuniones de retención personalizadas y proactivas.

- El "Top 5 de Menor Riesgo", a menudo infravalorado, es igualmente estratégico. Permite identificar patrones de éxito: ¿qué tienen en común estos empleados? ¿Pertencen a un mismo departamento o manager? Estudiar a este grupo puede revelar las mejores prácticas de liderazgo y compromiso de la organización, que luego pueden ser replicadas.

- El Resumen ejecutivo, por su parte, demuestra la capacidad de la IA para interpretar y sintetizar. El texto generado automáticamente conecta los puntos clave del análisis en una narrativa coherente, ofreciendo una conclusión clara y recomendaciones

iniciales. Para Innovatech, la conclusión sería: "La organización presenta una situación de riesgo polarizada. Existe un núcleo muy sólido (76%), pero también un grupo crítico de 35 empleados (23,3%) con alto riesgo de abandono, concentrados en los perfiles de 'En riesgo' y 'Bajo compromiso'. Se recomienda una intervención quirúrgica sobre estos colectivos." Esta funcionalidad ahorra tiempo y asegura que todos los stakeholders partan de una misma interpretación fundamentada en los datos.

4.3. Discusión estratégica: ¿Qué acciones se derivan de los perfiles identificados?

Una vez realizado el diagnóstico general en el dashboard principal, el siguiente paso lógico para un profesional de RRHH es profundizar en los datos para encontrar las causas raíz de los problemas y las palancas de acción más efectivas. Para ello, se utiliza la pestaña "Análisis por Segmentos" de la aplicación, que permite descomponer los datos por perfiles de empleado y por departamentos.

4.3.1. Análisis estratégico por perfiles de empleado (clusters)

La segmentación de la plantilla es uno de los resultados más valiosos del modelo de IA, ya que permite diseñar estrategias de retención personalizadas. La Figura 4.4 muestra un resumen de las métricas clave de cada perfil, revelando realidades muy distintas entre ellos.

Análisis por Segmentos (Perfiles y Departamentos)

Análisis de Perfiles de Empleados (Clusters)

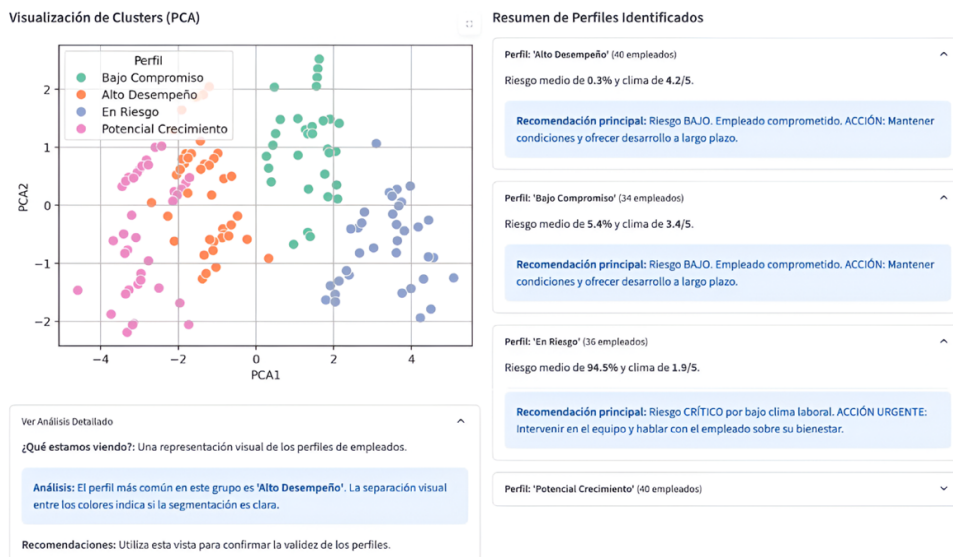


Figura 4.4 Captura de pantalla de la sección de "Análisis de Perfiles", donde se visualiza el gráfico PCA y las tarjetas desplegadas para cada uno de los cuatro perfiles identificados.

A partir de estos datos, la discusión estratégica y las acciones recomendadas para cada grupo serían las siguientes:

- Perfiles "Potencial Crecimiento" y "Alto Desempeño": Estos dos grupos (80 empleados en total) constituyen el núcleo sólido y de futuro de la empresa. Su riesgo de abandono es prácticamente nulo (0,0% y 0,3% respectivamente) y disfrutan del mejor clima laboral (4,4/5 y 4,2/5).

- Acción Estratégica: Blindaje y potenciación. La prioridad es asegurar su permanencia a largo plazo mediante planes de carrera, proyectos desafiantes y una compensación competitiva. Son el vivero del futuro liderazgo de la empresa y deben ser tratados como el activo más valioso. La recomendación de la propia herramienta es clara: "Mantener condiciones y ofrecer desarrollo a largo plazo".

- Perfil "Bajo Compromiso" (34 empleados): A pesar de lo que su nombre podría sugerir, los datos muestran que este grupo es relativamente estable. Su riesgo de abandono es bajo (5,4%) y su clima laboral es aceptable (3,4/5).

- Acción Estratégica: Mantenimiento y monitorización. No requieren una intervención urgente, pero sí un seguimiento para asegurar que sus condiciones no se deterioren. El objetivo es entender qué les mantiene estables (quizás la conciliación, la seguridad laboral) y asegurarse de que no se deslicen hacia el perfil "En Riesgo".

- Perfil "En Riesgo" (36 empleados): Aquí se encuentra el epicentro del problema de rotación de la empresa. Este grupo presenta un riesgo de abandono crítico del 94,5% y un clima laboral insostenible de 1,9/5.

- Acción Estratégica: Intervención de choque. La recomendación de la herramienta es una "ACCIÓN URGENTE". Es imperativo "apagar este fuego" de inmediato. Esto implica hablar con cada empleado de este grupo para entender las causas raíz (salario, liderazgo, carga de trabajo, mal ambiente) y

aplicar soluciones contundentes, que pueden ir desde una revisión salarial hasta una mediación de conflictos o un cambio de equipo.

4.3.2. Análisis estratégico por departamento

El análisis departamental, mostrado en la Figura 4.5, confirma la concentración del problema.

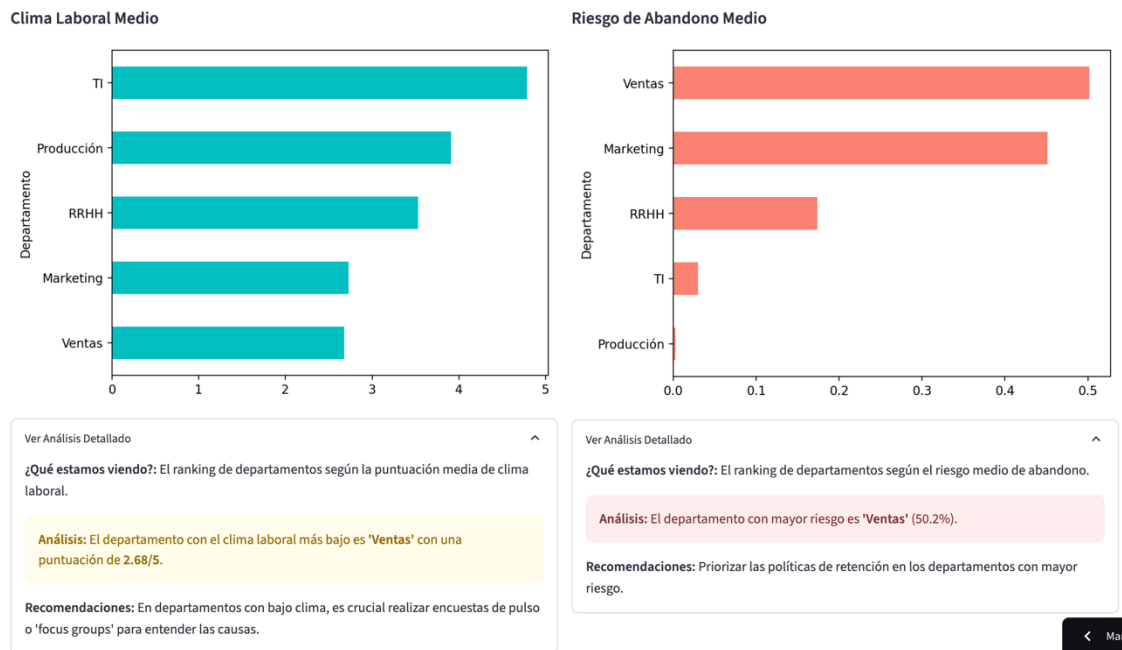


Figura 4.5 Captura de pantalla de los gráficos de barras horizontales que comparan el Riesgo de Abandono Medio y el Clima Laboral Medio entre los departamentos de Ventas, Marketing, RRHH, TI y Producción.

Los gráficos revelan una fractura clara en la organización:

- **Focos Rojos:** Ventas y marketing. Estos dos departamentos son los claros impulsores del riesgo en la compañía, con tasas de abandono altísimas (49% y 45% respectivamente) y el peor clima laboral (ambos por debajo de 3/5). Es muy probable que la mayoría de los 36 empleados del perfil "En Riesgo" pertenezcan a estas dos áreas.

- **Acción Estratégica:** Investigación focalizada. Es necesario realizar un diagnóstico profundo en ambos departamentos, analizando estilos de liderazgo, cargas de trabajo, sistemas de comisiones (en el caso de Ventas) y cultura de equipo.

- Casos de éxito: Producción y TI. En el extremo opuesto, estos departamentos son un modelo a seguir. Su riesgo de abandono es prácticamente inexistente (0% y 5%) y gozan del mejor clima laboral de la empresa, especialmente TI (casi 5/5).

- Acción estratégica: Identificar y replicar buenas prácticas. RRHH debe estudiar qué hacen diferente los líderes y equipos de TI y Producción. ¿Más flexibilidad? ¿Mejor reconocimiento? ¿Mayor autonomía? Identificar estas palancas de éxito permitirá crear un plan para exportarlas a los departamentos problemáticos.

4.4. El Valor de la simulación para la optimización del presupuesto de retención en Innovatech

Tras el diagnóstico inicial que identificó un núcleo de 35 empleados en situación crítica, el siguiente paso para la dirección de Innovatech es determinar las acciones más efectivas y con mayor retorno de la inversión. Las herramientas de simulación y análisis individual de la aplicación permiten pasar de la identificación del problema a la formulación de una solución estratégica y presupuestada.

4.4.1. Análisis individual detallado (XAI): Preparando la conversación con empleados de Innovatech

Para intervenir de forma efectiva, es crucial entender las causas raíz del riesgo de cada empleado. El módulo de IA explicable (XAI) permite a los managers de Innovatech preparar conversaciones de retención basadas en datos concretos, como se ilustra en la Figura 4.6 con el caso del empleado con ID 31.

Este caso es un ejemplo paradigmático del perfil "En Riesgo" que requiere una acción inmediata. La herramienta le asigna un riesgo de abandono del 100,0%, catalogándolo como "Riesgo CRÍTICO". La recomendación de la IA es una "ACCIÓN URGENTE: Intervenir en el equipo y hablar con el empleado sobre su bienestar". El análisis de los impulsores revela que los factores que disparan su riesgo son un historial de bajas en el último año, un exceso de horas extra y un mal clima laboral.

Esta funcionalidad dota a los líderes de Innovatech de la información necesaria para no tratar a todos por igual, sino para abordar los problemas específicos que están afectando a sus empleados más críticos.

Consulta Individual y Simulación de Políticas

Análisis Individual Detallado (XAI)

Selecciona un empleado para ver su ficha y los factores que determinan su riesgo.

Selecciona un ID de Empleado:

31

RIESGO DE ABANDONO (ID 31): 100.0%

RECOMENDACIÓN: Riesgo CRÍTICO por bajo clima laboral. ACCIÓN URGENTE: Intervenir en el equipo y hablar con el empleado sobre su bienestar.

¿Por qué tiene este nivel de riesgo?

● Factores que AUMENTAN el riesgo:

- Bajas Último Año
- Horas Extra
- Clima Laboral

● Factores que REDUCEN el riesgo:

- Departamento TI
- Tipo Contrato Temporal
- Departamento Ventas

Figura 4.6 Captura de pantalla del módulo XAI, mostrando la ficha de un empleado (ID 31), su riesgo crítico de abandono (100,0%) y los factores específicos que aumentan dicho riesgo.

4.4.2. Simulador de políticas 'what-if': Optimizando la inversión para Innovatech

La funcionalidad más estratégica para la dirección de Innovatech es el simulador, que permite cuantificar el impacto de posibles decisiones antes de aprobar el presupuesto. Partiendo del riesgo medio actual del 24,0%, se modelaron varios escenarios, cuyos resultados se visualizan en la Figura 4.7.

- Escenario 1: Mejora de formación. Al simular una reducción de riesgo del 24% gracias a planes de formación, el riesgo medio de la empresa bajaría al 18,2%. El análisis recomienda aplicar esta política en perfiles de "Potencial Crecimiento" o con bajo desempeño para potenciar su desarrollo.
- Escenario 2: Mejora salarial. Una intervención salarial para corregir inequidades (simulando una reducción de riesgo del 38% en los afectados) demuestra ser más potente, bajando el riesgo general al 14,9%. La recomendación es aplicarla en perfiles de "Alto Desempeño" para blindarlos o en perfiles "En Riesgo" para atajar una de las posibles causas raíz de su malestar.

- Escenario 3: Política combinada. La simulación revela que la estrategia más efectiva para Innovatech es una intervención quirúrgica. Aplicando una política combinada de formación y mejoras salariales en los grupos más críticos y valiosos, se consigue la mayor reducción del riesgo global, situándolo en un notable 9,1%.

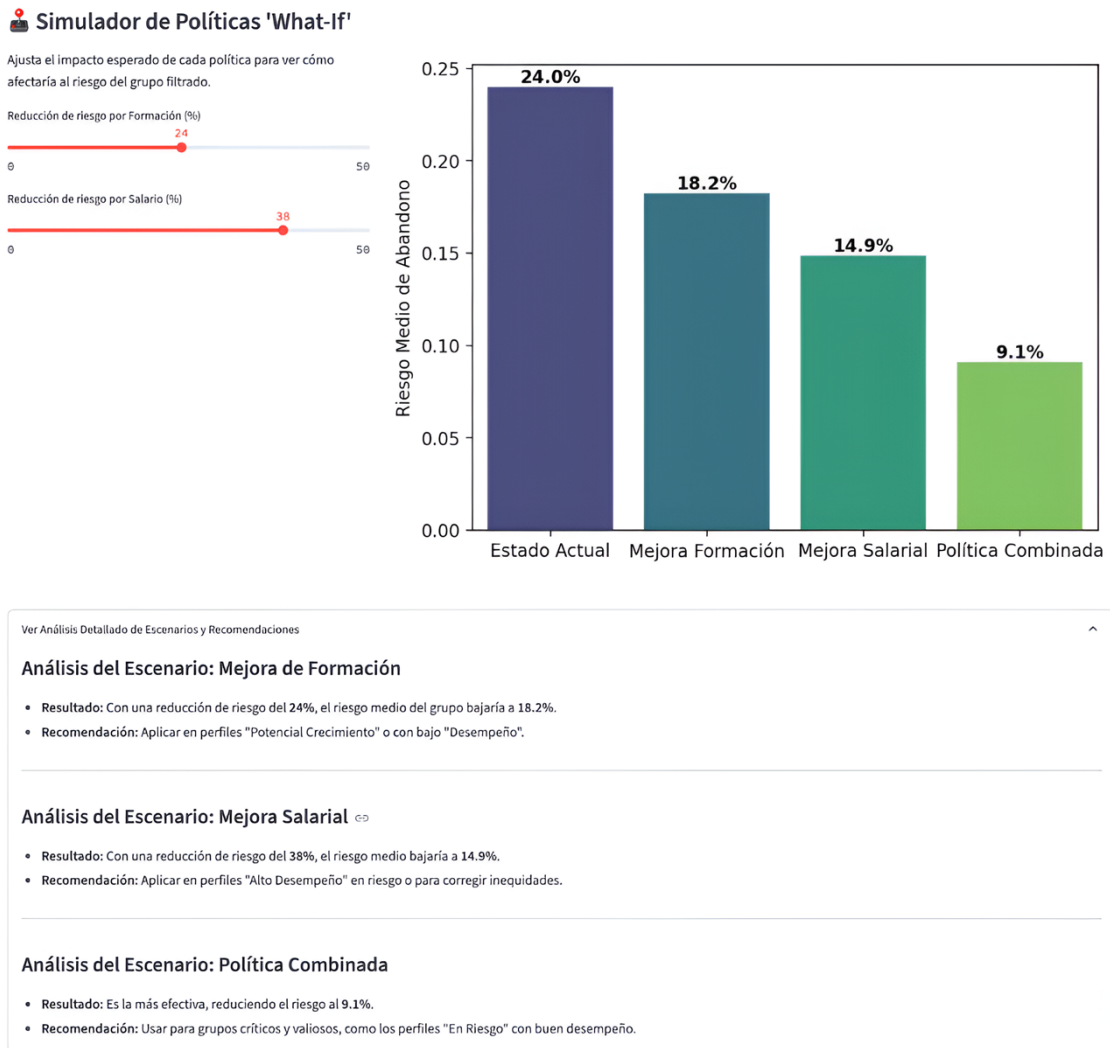


Figura 4.7 Interfaz del Simulador 'What-If'. Se aprecian los controles para modelar escenarios, el gráfico de barras que visualiza el impacto de cada política y el análisis textual con las recomendaciones para cada escenario.

Este análisis demuestra a la dirección de Innovatech que una inversión focalizada y basada en datos es significativamente más eficiente que una política generalista, permitiendo optimizar el presupuesto de retención y obtener un impacto mucho mayor.

4.5. Centro de conocimiento: garantizando la autonomía de Innovatech

Finalmente, como parte de la implementación de la herramienta en Innovatech, se destaca la importancia de la pestaña "Glosario y Metodología" (ver Figura 4.8). Su propósito es servir como un centro de conocimiento permanente para el equipo de RRHH y los máangers de la empresa.

Al asegurar que todos los usuarios comprenden los términos clave (KPI, XAI, etc.) y la metodología que sigue el modelo, se garantiza que la herramienta será utilizada de forma correcta y consistente a largo plazo. Esto fomenta la autonomía del equipo de Innovatech para interpretar los resultados y tomar decisiones fundamentadas sin depender de consultores externos, consolidando así una cultura de gestión basada en datos.

Glosario y Metodología

Glosario de Términos Clave

- **KPI (Key Performance Indicator):** Indicador Clave de Rendimiento. Son las métricas más importantes que resumen la situación general (ej. Riesgo Medio).
- **Probabilidad de Abandono:** Porcentaje que indica la probabilidad de que un empleado deje la empresa.
- **Perfil de Empleado (Cluster):** Grupo de empleados con características similares. En este análisis se identifican 4 perfiles principales:
 - **Alto Desempeño:** Empleados con buen rendimiento, pero que pueden estar en riesgo si no se sienten valorados o retados.
 - **Potencial Crecimiento:** Empleados leales y con buen clima, pero quizás con un desempeño que se puede potenciar.
 - **Bajo Compromiso:** Suelen ser empleados más jóvenes, con bajo clima y alto riesgo. Requieren una intervención para mejorar su integración.
 - **En Riesgo:** El grupo más crítico. Combinan varios factores negativos que disparan su probabilidad de abandono.
- **Impulsores Clave (Feature Importance):** Los factores o variables que más peso tienen para el modelo a la hora de hacer una predicción.
- **Explicabilidad (XAI):** Técnicas que permiten entender por qué el modelo ha tomado una decisión específica para un caso concreto.
- **Análisis de Componentes Principales (PCA):** Técnica de reducción de dimensiones usada para visualizar los clusters en un mapa 2D.
- **StandardScaler:** Proceso técnico para estandarizar las variables numéricas (como Salario y Edad) para que tengan la misma escala y peso en los modelos.

Metodología del Modelo - Paso a Paso

1. **Preparación de Datos:** Se transforman las variables categóricas (como Departamento) en un formato numérico que el modelo pueda entender (*One-Hot Encoding*).
2. **Escalado de Características:** Se aplica *StandardScaler* para que todas las variables tengan una importancia equitativa en los cálculos iniciales del modelo. Esto es crucial para algoritmos como K-Means.
3. **Modelo Predictivo:** Se utiliza un modelo de *Regresión Logística*, elegido por su robustez, rapidez y alta interpretabilidad.
4. **Modelo de Segmentación:** Se usa un algoritmo de *K-Means Clustering* para agrupar a los empleados en 4 perfiles distintos sin supervisión previa.

Figura 4.8 Captura de la pestaña "Glosario y Metodología". Esta sección sirve como centro de conocimiento, definiendo los términos técnicos clave y explicando los pasos del modelo de IA para garantizar la transparencia y la correcta interpretación de los resultados

5. CONCLUSIONES

5.1. Conclusiones finales: Doble impacto de la IA en la estrategia de RRHH

El presente trabajo de fin de grado ha culminado con éxito su objetivo: el desarrollo de una herramienta funcional de people analytics.

Por un lado, desde la perspectiva de la gestión del capital humano, este proyecto demuestra de forma práctica y tangible el valor de la inteligencia artificial como un aliado estratégico para los recursos humanos. La aplicación desarrollada no es un mero visualizador de datos, sino una herramienta de diagnóstico y decisión que permite a las organizaciones, especialmente a las PYMES, superar el enfoque reactivo tradicional en la gestión de la rotación. Como se ha evidenciado en el caso práctico del capítulo 4, la herramienta capacita al departamento de RRHH para:

1. Anticipar y cuantificar el riesgo de abandono de forma proactiva.
2. Focalizar los recursos de retención en los colectivos y departamentos que realmente los necesitan, optimizando el presupuesto.
3. Diseñar estrategias personalizadas basadas en perfiles de empleado, superando las políticas genéricas.
4. Ayudar a justificar decisiones estratégicas con datos y simulaciones de impacto (ROI), elevando el rol de RRHH a un plano de socio de negocio.

Por otro lado, desde la perspectiva de la innovación y el desarrollo tecnológico, este trabajo valida una nueva forma de crear soluciones tecnológicas. El proyecto sirve como caso de estudio que demuestra cómo, a través del prompt engineering y la colaboración con modelos de lenguaje avanzados, un experto de dominio —en este caso, en recursos humanos— puede convertirse en el arquitecto y constructor de sus propias herramientas sin necesidad de una formación extensiva en programación. Este enfoque democratiza el acceso a la tecnología y acelera la innovación, permitiendo que quienes mejor conocen los problemas de negocio sean quienes diseñen directamente sus soluciones. Se materializa así un cambio de paradigma, transitando desde un modelo donde los expertos especifican requisitos a los técnicos, hacia un modelo de co-creación hombre-máquina mucho más ágil y eficiente. Aunque la inteligencia artificial no es tan buena como será en el futuro, aun así sirve para aun crear valor tangible y ayuda a resolver problemas de negocio reales.

En síntesis, este TFG no solo aporta una solución concreta a uno de los mayores desafíos de RRHH —la retención de talento—, sino que también ilumina un nuevo camino sobre cómo la inteligencia artificial está redefiniendo los procesos de creación e innovación en el ámbito empresarial.

5.2. Limitaciones del estudio y de la herramienta desarrollada

Con el fin de mantener el rigor académico y ofrecer una visión completa del alcance del proyecto, es fundamental reconocer las limitaciones inherentes tanto al estudio como a la herramienta resultante. Este ejercicio de autocrítica no resta valor a los resultados obtenidos, sino que los contextualiza adecuadamente. Las principales limitaciones se pueden agrupar en tres categorías:

5.2.1. Limitaciones relativas a los datos

- Fuente y naturaleza de los datos: El estudio se ha basado en un conjunto de datos público y estandarizado (IBM HR Analytics de Kaggle), que si bien es un referente en la materia, es de naturaleza sintética. La aplicación práctica del capítulo 4 es, por tanto, una simulación robusta, pero los resultados y su precisión podrían variar al aplicar el modelo sobre datos reales, específicos y potencialmente más complejos de una empresa particular.

- Alcance de las variables: El modelo predictivo se construye a partir de las 35 variables disponibles en el dataset. Sin embargo, la rotación de personal es un fenómeno multifactorial que puede estar influenciado por variables no recogidas en este estudio, como el tiempo de desplazamiento al trabajo, la satisfacción directa con el mánager, la cultura de feedback o las condiciones del mercado laboral externo.

5.2.2. Limitaciones del modelo de IA

- Elección de algoritmos: Para este proyecto se optó por modelos de regresión logística y k-means, priorizando la interpretabilidad y la facilidad para explicar los resultados (XAI). Si bien estos modelos han demostrado ser eficaces, existen algoritmos más complejos (ej. redes neuronales profundas, gradient boosting) que podrían, potencialmente, ofrecer un grado de precisión predictiva ligeramente superior, aunque a costa de una mayor opacidad ("caja negra").

- Naturaleza estática del modelo: El modelo ha sido entrenado en un punto concreto en el tiempo. En un entorno real, la herramienta debería incorporar un sistema de reentrenamiento periódico para adaptarse a los cambios en el comportamiento de los empleados y en las dinámicas de la empresa, una funcionalidad que excede el alcance de este prototipo.

5.2.3. Limitaciones técnicas y de alcance de la herramienta

- Prototipo funcional, no sistema de producción: La aplicación desarrollada con streamlit es un prototipo funcional de alto valor, pero no un software listo para ser desplegado en producción a gran escala. Carece de funcionalidades empresariales críticas como la gestión de múltiples usuarios con diferentes roles y permisos, protocolos de seguridad avanzados o la integración directa y automática con las bases de datos de RRHH de una empresa.
- Dependencia de la calidad del prompt: La metodología de desarrollo asistido por IA, si bien es una de las fortalezas del proyecto, también implica una dependencia de la habilidad del experto para formular los prompts adecuados y de las capacidades del modelo de lenguaje utilizado en el momento del desarrollo.

5.3. Futuras líneas de trabajo y evolución de la herramienta

El presente trabajo sienta las bases para futuras investigaciones y desarrollos que podrían expandir significativamente el alcance y la potencia de la herramienta. Las propias limitaciones identificadas en la sección anterior se convierten en una hoja de ruta para la evolución del proyecto. A continuación, se proponen las líneas de trabajo más relevantes:

5.3.1. Enriquecimiento del modelo predictivo

- Integración de nuevas fuentes de datos: La futura evolución de la herramienta debería permitir la integración con fuentes de datos internas de la empresa, como los sistemas de registro de jornada (para analizar el presentismo o las horas extra reales), las encuestas de pulso o satisfacción, o las evaluaciones de desempeño para obtener una visión de 360 grados del empleado.
- Modelos de series temporales: Para superar la naturaleza estática del modelo actual, se podría investigar la aplicación de modelos de series temporales que analicen la evolución del riesgo de un empleado a lo largo del tiempo, detectando tendencias y puntos de inflexión en su compromiso.
- Análisis de texto no estructurado: Incorporar modelos de procesamiento del lenguaje natural (NLP) para analizar datos no estructurados, como los comentarios en las encuestas de clima o las entrevistas de salida, podría revelar insights cualitativos muy valiosos que actualmente no se están aprovechando.

5.3.2. Evolución hacia una herramienta de producción

- **Desarrollo de un backend robusto:** Es crucial migrar la lógica de la aplicación a un backend más potente. El uso de frameworks como django o fastAPI en python facilitaría la gestión de múltiples usuarios, roles y permisos de forma nativa. Esto permitiría implementar protocolos de seguridad avanzados, como el control de acceso basado en roles (RBAC), para asegurar que cada usuario acceda únicamente a la información que le compete, garantizando la confidencialidad de los datos de los empleados.
- **Integración y automatización:** El valor de la herramienta se podría multiplicar al conectarla directamente con las bases de datos de RRHH de la empresa (como SAP o Workday) a través de APIs. Esta integración directa podría eliminar la carga manual de datos, prevenir errores y asegurar que los análisis se basasen en información en tiempo real. Adicionalmente, se debería establecer un sistema de reentrenamiento automático del modelo para que este se ajuste a los nuevos patrones de comportamiento en la plantilla, combatiendo la degradación de su precisión (model drift) sin necesidad de intervención manual.
- **Expansión de funcionalidades:** Sobre esta base tecnológica sólida, la herramienta puede crecer para convertirse en una suite integral de people analytics. Sería posible añadir nuevos módulos que aborden otros desafíos clave de RRHH, como un panel para la predicción del desempeño, una utilidad para la optimización de la selección de personal que identifique a los candidatos con mayor potencial de permanencia, o una herramienta de análisis de la brecha salarial para promover la equidad retributiva en la organización. Profundización en la IA explicable (XAI).
- **Simuladores Individuales:** El siguiente paso lógico para el simulador "what-if" es evolucionar de una herramienta de análisis global a una de gestión personalizada. Se debe desarrollar una funcionalidad que permita a un mánager o a un HR business partner seleccionar a un empleado específico y simular el impacto de acciones concretas sobre su riesgo de abandono individual. Por ejemplo, la interfaz permitiría plantear escenarios como: "Si a este empleado le asigno un nuevo proyecto (+5% de carga de trabajo) pero le apruebo una subida salarial del 10%, ¿cómo varía su probabilidad de abandono en los próximos 6 meses?". El sistema no solo devolvería un nuevo score de riesgo, sino que

también explicaría qué factores (el aumento salarial, en este caso) han mitigado el impacto negativo de otros. Esto transforma la herramienta en un potente aliado para la toma de decisiones del día a día, la preparación de negociaciones salariales y la personalización de planes de retención, basando la gestión de personas en datos predictivos y no solo en la intuición.

6. BIBLIOGRAFÍA

Agrawal, P., Ghangale, S., Dhar, B. K., y Nirmal, N. (2024). Strategic management of employee churn: Leveraging machine learning for sustainable development and competitive advantage in emerging markets. *Business Strategy & Development*, 7(4), e70039.

Al Akasheh, M., Malik, E. F., Hujran, O., y Zaki, N. (2023). A decade of research on data mining techniques for predicting employee turnover: A systematic literature review. *Expert Systems with Applications*, 238, 121794.

Benabou, A., Touhani, F., y Sabri, M. A. (2025). Predicting Employee Turnover Using Machine Learning Techniques. *Acta Informatica Pragensia*, 14(1), 112-127.

Chaudhary, M., Gaur, L., Chakrabarti, A., Singh, G., Jones, P., y Kraus, S. (2025). An integrated model to evaluate the transparency in predicting employee churn using explainable artificial intelligence. *Journal of Innovation & Knowledge*, 10, 100700.

Chung, D., Yun, J., Lee, J., y Jeon, Y. (2023). Predictive model of employee attrition based on stacking ensemble learning. *Expert Systems With Applications*, 215, 119364.

De Vos, S., Bockel-Rickermann, C., Van Belle, J., y Verbeke, W. (2024). Predicting Employee Turnover: Scoping and Benchmarking the State-of-the-Art. *Business & Information Systems Engineering*.

Guerranti, F., y Dimitri, G. M. (2023). A Comparison of Machine Learning Approaches for Predicting Employee Attrition. *Applied Sciences*, 13(1), 267.

Heidemann, A., Hülter, S. M., y Tekieli, M. (2024). Machine learning with real-world HR data: mitigating the trade-off between predictive performance and transparency. *The International Journal of Human Resource Management*, 35(14), 2343-2366.

Kim, S., y Chung, J. Y. (2024). 대형 언어 모델을 활용한 기업데이터 분석: ChatGPT를 활용한 직원 이직 예측 [Leveraging LLMs for Corporate Data Analysis: Employee Turnover Prediction with ChatGPT]. *Knowledge Management Research*, 25(2), 19-47.

Miguelés, R. (2024, 17 de febrero). ¿Inteligencia artificial en Recursos Humanos para seleccionar candidatos?: la mitad en México está de acuerdo. *CE Noticias Financieras*.

Ramos Hernández, R. R., Ramos Hernández, G. J., y Cueva Rodríguez, M. (2025). Optimización del desempeño organizacional mediante sistemas de inteligencia artificial: enfocado en gestión de recursos humanos. *IMPULSO*, 5(9), 237-249.

Rueda, F. J. (2023). *La Revolución de la Inteligencia Artificial en Recursos Humanos*. Jornadas Sarteco.

Savkovic, M., Ciric Lalic, D., Vuckovic, T., Gracanin, D., y Vujicic, M. (2023). *Agilidad Organizativa, Resiliencia del Proyecto y Prácticas Laborales de Alto Rendimiento: Una Receta para el Éxito del Proyecto*.

7. ANEXOS

7.1. Anexo I: manual de usuario de la aplicación

Versión: 1.1 Autor: Antonio Roger Boris Wilkinson

1. Introducción y objetivo de la herramienta

1.1. ¿Qué problema resuelve?

Esta aplicación ha sido diseñada para transformar la gestión de recursos humanos, pasando de un enfoque reactivo a uno proactivo y estratégico. La herramienta utiliza inteligencia artificial para predecir el riesgo de abandono de los empleados y para segmentar la plantilla en perfiles con características similares, permitiendo así aplicar estrategias de retención personalizadas y eficientes.

1.2. ¿A quién va dirigida?

Esta herramienta está pensada para directores y técnicos de recursos humanos, así como para líderes de equipo y managers, siendo especialmente útil para PYMES y empresas que no disponen de los recursos para realizar este tipo de investigaciones. Funciona como

un acompañamiento a la gestión diaria, permitiendo detectar tendencias y riesgos que de otra manera pasarían desapercibidos.

2. Guía Rápida: Cómo empezar

2.1. Requisitos del sistema para utilizar la aplicación solo se necesita un navegador web moderno (Chrome, Firefox, Edge, Safari) y conexión a internet.

2.2. Pasos Iniciales

El uso es muy intuitivo. El primer paso es preparar los datos, para lo cual se recomienda encarecidamente descargar la plantilla de ejemplo desde la barra lateral para evitar errores de formato. El segundo paso es subir el fichero ya preparado en el cargador de la barra lateral. Una vez procesado, el tercer y último paso es explorar los resultados que la aplicación generará automáticamente en sus cuatro pestañas.

3. Explorando el dashboard

3.1. Pestaña 1: Dashboard principal

Esta es la vista de resumen ejecutivo. Muestra los indicadores clave (KPIs) de un vistazo, como el número de empleados, el riesgo medio de abandono, el clima laboral y el salario medio. También contiene gráficos principales que visualizan la proporción de cada perfil de empleado y la distribución del riesgo (Bajo, Medio, Alto). Para una acción más directa, incluye un ranking del top 5 de empleados con mayor y menor riesgo, y finalmente, un resumen ejecutivo redactado por la IA con las conclusiones y recomendaciones estratégicas, el cual se puede exportar.

3.2. Pestaña 2: Análisis por segmentos

Esta pestaña permite profundizar en las diferencias entre grupos. Incluye un análisis de perfiles que compara el riesgo y clima para cada uno de los 4 perfiles de empleado, y un análisis por departamento que muestra gráficos de barras comparando estas mismas métricas entre las diferentes áreas de la empresa.

3.3. Pestaña 3: Consulta y simulación

Esta sección permite pasar del análisis grupal al individual. El análisis individual (XAI) permite seleccionar a un empleado para entender los factores clave que influyen en su riesgo. El simulador 'what-if' es una herramienta interactiva para modelar el impacto que tendrían ciertas políticas (mejoras en formación, salario, etc.) sobre el riesgo de abandono general.

3.4. Pestaña 4: Glosario y metodología

Es el centro de conocimiento de la aplicación, donde se definen los términos técnicos más importantes y se explica de forma sencilla la metodología que utilizan los modelos de inteligencia artificial para generar los análisis.

4. Requisitos del fichero de datos (.xlsx)

4.1. Columnas obligatorias

Para que la aplicación funcione, el fichero .xlsx debe contener exactamente las siguientes 12 columnas: Edad, Antigüedad, Desempeño, Salario, Formación_Reciente (1 para sí, 0 para no), Clima_Laboral, Departamento (texto), Riesgo_Abandono (1 para sí, 0 para no), Horas_Extra, Bajas_Último_Año, Promociones_2_Años (1 para sí, 0 para no), y Tipo_Contrato (texto).

4.2. Formato del fichero

El tipo de archivo debe ser microsoft excel (.xlsx).

7.2. Anexo II: Ejemplos de prompt engineering

Dado que una de las aportaciones clave de este trabajo es la metodología de desarrollo asistido por IA, se presentan a continuación tres ejemplos de los *prompts* (instrucciones) utilizados para generar partes fundamentales del código de la aplicación. Estos ejemplos ilustran el diálogo iterativo entre el experto de dominio y el modelo de lenguaje para construir la solución.

Prompt 1: Creación de la estructura inicial de la aplicación:

"Necesito crear una aplicación web con streamlit en python. La aplicación debe tener una barra lateral (sidebar) titulada 'panel de control'. Dentro de esta barra, quiero un cargador de archivos que solo acepte ficheros .xlsx y un botón para descargar un manual de usuario en PDF. La interfaz principal debe estar organizada en cuatro pestañas: 'Dashboard Principal', 'Análisis por Segmentos', 'Consulta y Simulación' y 'Glosario y Metodología'. Genera el código base para esta estructura."

Prompt 2: Implementación de los modelos de machine learning:

"Vamos a definir la función principal de análisis. Cuando el usuario suba un fichero Excel, esta función debe leerlo con Pandas, realizar un preprocesamiento básico (eliminar columnas innecesarias y manejar valores nulos si los hubiera) y luego entrenar dos modelos de Scikit-learn:

1. Un modelo de regresión logística para predecir la columna 'Attrition'.
2. Un modelo de k-means para segmentar a los empleados en 4 clusters basados en las variables numéricas más relevantes. La función debe devolver los modelos entrenados y el dataframe con los resultados de la predicción y el cluster asignado a cada empleado."

Prompt 3: Generación del módulo de IA explicable (XAI)

"Para la pestaña 'Consulta y Simulación', necesito implementar la funcionalidad de IA explicable. Crea una función que, al seleccionar un ID de empleado de una lista desplegable, utilice la librería SHAP. Esta función debe:

1. Cargar el modelo de regresión logística ya entrenado.
2. Calcular los valores SHAP para el empleado seleccionado.
3. Identificar y mostrar los 3 principales factores que más contribuyen a aumentar su riesgo de abandono y los 3 que más contribuyen a reducirlo. Presenta el resultado de forma clara y visual."

7.3. Anexo III: Listado completo de variables del dataset

El estudio se basa en el dataset "IBM HR Analytics Employee Attrition & Performance", que contiene 35 variables. A continuación, se detallan todas ellas:

Nombre de la Variable	Descripción
Age	Edad del empleado.
Attrition	Variable objetivo: si el empleado ha dejado la empresa (Sí/No).
BusinessTravel	Frecuencia de los viajes de negocios.
DailyRate	Tarifa salarial diaria.
Department	Departamento del empleado.
DistanceFromHome	Distancia del domicilio al trabajo.
Education	Nivel educativo (1-5).
EducationField	Campo de estudio.
EmployeeCount	Contador de empleados (valor constante).
EmployeeNumber	Número de identificación único del empleado.
EnvironmentSatisfaction	Satisfacción con el entorno laboral (1-4).
Gender	Género del empleado.
HourlyRate	Tarifa salarial por hora.

JobInvolvement	Nivel de implicación en el trabajo (1-4).
JobLevel	Nivel del puesto en la jerarquía (1-5).
JobRole	Rol o puesto específico del empleado.
JobSatisfaction	Satisfacción con el puesto de trabajo (1-4).
MaritalStatus	Estado civil del empleado.
MonthlyIncome	Ingreso mensual.
MonthlyRate	Tarifa salarial mensual.
NumCompaniesWorked	Número de empresas en las que ha trabajado anteriormente.
Over18	Si el empleado es mayor de 18 años (valor constante).
OverTime	Si el empleado realiza horas extra (Sí/No).
PercentSalaryHike	Porcentaje de aumento salarial del último año.
PerformanceRating	Calificación del desempeño (1-4).
RelationshipSatisfaction	Satisfacción con las relaciones interpersonales (1-4).
StandardHours	Horas de trabajo estándar (valor constante).
StockOptionLevel	Nivel de opciones sobre acciones.
TotalWorkingYears	Años totales de experiencia laboral.
TrainingTimesLastYear	Número de formaciones recibidas el último año.
WorkLifeBalance	Percepción del equilibrio entre vida laboral y personal (1-4).
YearsAtCompany	Años de antigüedad en la empresa actual.
YearsInCurrentRole	Años en el puesto actual.
YearsSinceLastPromotion	Años desde la última promoción.
YearsWithCurrManager	Años con el mánager actual.

8. ÍNDICE DE ILUSTRACIONES

Figura 4.1: Captura de pantalla de la sección de KPIs del Dashboard, mostrando los valores de N° Empleados, Riesgo Medio, Clima Laboral y Salario Medio. 15

Figura 4.2 Captura de pantalla de los dos gráficos de distribución: el gráfico de barras de “Distribución del Riesgo de Abandono” y el gráfico de tarta de “Distribución de Perfiles”	16
Figura 4.3 Captura de pantalla de la parte inferior del dashboard, mostrando claramente las listas del “Top 5 de Mayor Riesgo” y “Top 5 de Menor Riesgo”, junto al cuadro de texto del “Resumen Ejecutivo”.....	17
Figura 4.4 Captura de pantalla de la sección de "Análisis de Perfiles", donde se visualiza el gráfico PCA y las tarjetas desplegadas para cada uno de los cuatro perfiles identificados.....	18
Figura 4.5 Captura de pantalla de los gráficos de barras horizontales que comparan el Riesgo de Abandono Medio y el Clima Laboral Medio entre los departamentos de Ventas, Marketing, RRHH, TI y Producción.....	20
Figura 4.6 Captura de pantalla del módulo XAI, mostrando la ficha de un empleado (ID 31), su riesgo crítico de abandono (100,0%) y los factores específicos que aumentan dicho riesgo.....	22
Figura 4.7 Interfaz del Simulador 'What-If'. Se aprecian los controles para modelar escenarios, el gráfico de barras que visualiza el impacto de cada política y el análisis textual con las recomendaciones para cada escenario.	23
Figura 4.8 Captura de la pestaña "Glosario y Metodología". Esta sección sirve como centro de conocimiento, definiendo los términos técnicos clave y explicando los pasos del modelo de IA para garantizar la transparencia y la correcta interpretación de los resultado	24