



Facultad de Ciencias Económicas y Empresariales
ICADE

Evaluación del desempeño mediante People Analytics: Implicaciones para el impacto en la gestión de recursos humanos y el crecimiento empresarial

Autor: Alejandra Charola González
Director: María Jesús Belizón Cebada

MADRID | Abril, 2025

Abstract

This study analyzes the impact of using People Analytics tools in performance evaluation and their relationship with both Human Resources Key Performance Indicators (HR KPIs) and Business Key Performance Indicators (Business KPIs). In an increasingly digitalized organizational environment, these tools enable a more structured, objective, and evidence-based management approach, which has driven their progressive adoption across various industries and countries. Through a literature review and a quantitative methodology based on data from the 2019 European Company Survey, three OLS models are developed incorporating control variables, HR indicators, and business indicators in order to understand to what extent the use of analytics has transformed the way employee performance is evaluated and managed.

Keywords

People Analytics, Performance evaluation, Human Resources Key Performance Indicators (HR KPIs), Business Key Performance Indicators (Business KPIs), Data analytics, OLS regression

Resumen

Este trabajo analiza el impacto del uso de herramientas de People Analytics en la evaluación del desempeño y su relación tanto con indicadores clave de recursos humanos (HR KPIs) como con indicadores de negocio (Business KPIs). En un entorno organizacional cada vez más digitalizado, estas herramientas permiten una gestión más estructurada, objetiva y basada en evidencias, lo cual ha impulsado su adopción progresiva en diversas industrias y países. A través de la revisión de la literatura y una metodología cuantitativa basada en datos de la European Company Survey 2019, se desarrollan tres modelos OLS que incorporan variables de control, indicadores de recursos humanos e indicadores de negocio con el fin de comprender hasta qué punto el uso de analytics ha transformado la forma en que se evalúa y gestiona el desempeño de los empleados.

Palabras clave

People Analytics, Evaluación del desempeño, Indicadores de recursos humanos (HR KPIs), Indicadores de negocio (Business KPIs), Analítica de datos, Regresión OLS

Tabla de contenido

1.	Introducción.....	4
1.1.	Contexto y justificación del tema.....	4
1.2.	Objetivos de la investigación.....	4
1.3.	Estructura del trabajo.....	4
2.	Marco Teórico.....	5
2.1.	El uso de la analítica de datos en la gestión de RRHH.....	5
2.2.	Impacto del uso de people analytics en indicadores de Recursos Humanos y de Negocio.....	14
3.	Metodología de Investigación.....	18
3.1.	Diseño de la Investigación.....	18
3.2.	Análisis Descriptivo.....	20
3.3.	Evaluación de los modelos.....	26
4.	Resultados de la Investigación.....	28
5.	Discusión.....	32
5.1.	Conclusión.....	32
5.2.	Implicaciones para las organizaciones.....	37
6.	Bibliografía.....	40

Tabla de ilustraciones

Figura 1:	Transformación digital en RRHH.....	6
Figura 2:	Transformación del mercado laboral Español.....	7
Figura 3:	Utilización de medios digitales en RRHH.....	10
Figura 4:	Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según la Antigüedad de la Empresa.....	20
Figura 5:	Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según su grupo de país de origen.....	21
Figura 6:	Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según su sector de actividad.....	22
Figura 7:	Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño en función de si la empresa utiliza ecommerce como canal de distribución.....	23
Figura 8	Tabla de Variables.....	24
Figura 9	Comparación ajuste de los modelos.....	27
Figura 10	Tabla comparativa importancia de las variables según el modelo.....	29

1. Introducción

1.1. Contexto y justificación del tema

En un entorno empresarial cada vez más dinámico y competitivo, la gestión eficaz del talento humano se ha convertido en un factor clave para el éxito organizacional. En este contexto, el uso de herramientas avanzadas de análisis de datos, conocidas como people analytics, ha ganado protagonismo como un medio para optimizar los procesos de evaluación y gestión del desempeño de los empleados. La creciente disponibilidad de datos y herramientas analíticas hace que comprender cómo estas herramientas afectan a la evaluación del desempeño no solo resulte crucial para la gestión de personas, sino también para el crecimiento sostenible y la competitividad de la empresa. Este trabajo busca aportar una visión cuantitativa sobre el impacto de people analytics en la evaluación del desempeño, identificando patrones y relaciones significativas entre la adopción de estas herramientas, las prácticas de evaluación, y los resultados de negocio.

1.2. Objetivos de la investigación

Este trabajo tiene como objetivo analizar el impacto del uso de people analytics en la evaluación del desempeño, centrándose en cómo esta herramienta influye tanto en la gestión de recursos humanos como en los resultados del negocio. A través de la revisión de indicadores clave de rendimiento y la implementación de modelos analíticos se busca comprender hasta qué punto el uso de analytics ha transformado la forma en que se evalúa y gestiona el desempeño de los empleados. La investigación evaluará tanto el impacto interno dentro del departamento de recursos humanos, como el efecto que estas evaluaciones tienen en el crecimiento y desarrollo del negocio en su conjunto.

1.3. Estructura del trabajo

Para llevar a cabo esta investigación, se comienza con una revisión de la literatura, en la que se analiza el uso actual de la analítica de datos en la gestión de recursos humanos y su adopción. A partir de este marco teórico, se plantean las hipótesis que guiarán el estudio. A continuación, se describe la metodología empleada y se presenta un análisis descriptivo de los datos utilizados. Por último, se discuten los resultados obtenidos, incluyendo la validación de las hipótesis, las implicaciones prácticas para las organizaciones, las limitaciones del estudio y futuras líneas de investigación.

2. Marco Teórico

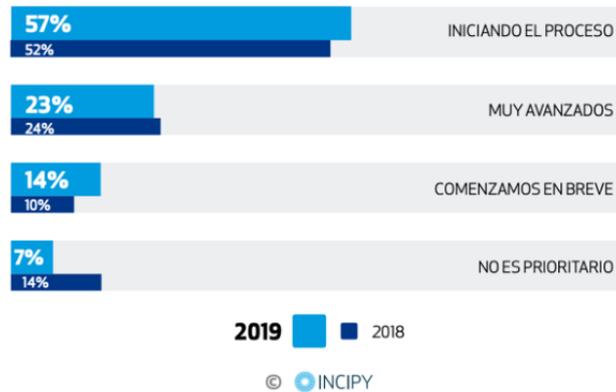
2.1. El uso de la analítica de datos en la gestión de RRHH

En la actualidad, el uso de analítica de datos se está extendiendo desde industrias como la agricultura de precisión, en la cual permite mejorar la productividad, optimizar el uso de recursos, y tomar decisiones más informada hasta el entorno empresarial en el que nos enfocaremos en el presente trabajo, concretamente su uso en la gestión de recursos humanos. En el ámbito empresarial, el uso de análisis de datos para recursos humanos se ha convertido en una herramienta de gran utilidad para no solo crear más valor de las personas si no para apoyar decisiones estratégicas e influir en la propia función de recursos humanos (Angrave et al., 2016). Además, la analítica de datos de las personas no debería estar limitada a la recolección de datos: es fundamental que las organizaciones establezcan métricas y análisis que contribuyan directamente a la ejecución de una estrategia. Esto requiere comprender como el talento impacta en el logro de los objetivos (Huselid, 2018).

Estudios como Minbaeva (2018) argumenta que contar con una infraestructura tecnológica adecuada es esencial para que los departamentos de recursos humanos (RRHH) desarrollen capacidades analíticas efectivas. Minbaeva argumenta que la calidad de los datos, las competencias analíticas y la capacidad estratégica para actuar son dimensiones fundamentales que las organizaciones deben construir como capacidades organizacionales. Por ello, la transformación digital de los departamentos de recursos humanos se convierte en un paso esencial para integrar herramientas analíticas y maximizar su impacto en la organización. Según un estudio sobre transformación digital en recursos humanos de Incipy, en España, alrededor del 80% de las empresas están afrontando el desafío de la transformación digital en el área de recursos humanos. De estas, el 57% ya ha comenzado el proceso, mientras que un 23% se encuentra en una etapa avanzada. Un 14% planea iniciar este cambio próximamente, y el porcentaje de quienes no lo consideran prioritario ha disminuido a la mitad, pasando del 14% al 7%. Estos datos reflejan de manera positiva que cada vez más empresas están tomando conciencia de la importancia de la transformación digital en la gestión organizacional y de personas y el temor por quedarse atrás (Ranera, 2020).

Figura 1: Transformación digital en RRHH

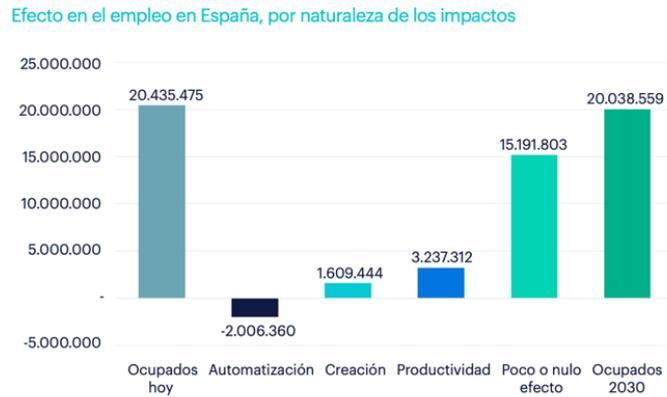
¿En qué momento de la transformación digital en RRHH os encontráis?



Fuente: Incipy

Por ejemplo, la creciente implementación de la inteligencia artificial en España está generando ciertas preocupaciones, especialmente por el impacto que podría tener en la pérdida de empleo. Se estima que cerca del 9,8% de los puestos de trabajo actuales, alrededor de 2 millones, podrían verse afectados por la automatización en la próxima década. Sin embargo, existen más aspectos positivos que favorecen su uso, por un lado, alrededor del 15,9% de los empleos actuales, unos 3,24 millones, podrían beneficiarse de un aumento significativo en su productividad gracias al uso de la IA, ayudando a los empleados a desempeñar sus tareas de forma más eficiente. Por otro lado, para la mayoría de los empleos, aproximadamente el 74,3%, no se espera que esta tecnología tenga un impacto directo en los próximos años. Aun así, el potencial de la IA va mucho más allá de los riesgos, ya que también se prevé que genere numerosos nuevos empleos. Según el informe de RandStad, se calcula que, en la próxima década, se crearán alrededor de 1,61 millones de empleos nuevos, resultado directo de los beneficios y avances que la inteligencia artificial puede aportar. Este equilibrio entre retos y oportunidades refleja la importancia de prepararse y adaptarse a los cambios que están por venir en un mundo cada vez más digitalizado (RandStad, febrero, 2024).

Figura 2: Transformación del mercado laboral Español



Fuente : RandStad

Tras este brece análisis introductorio, podemos concluir que a pesar de los avances evidentes en digitalización y analítica de datos en áreas como finanzas, operaciones o marketing (Angrave et al., 2016), el proceso de transformación digital en RRHH no ha hecho más que empezar y su desarrollo parece haber llegado más tarde y está progresando de manera más lenta en comparación con otras funciones empresariales. Estos datos reflejan que, si bien las empresas están empezando a reconocer la importancia de integrar la tecnología y la analítica en la gestión del talento, aún queda un largo camino por recorrer para alcanzar el nivel de madurez observado en otras áreas clave de la organización. La literatura apunta a que una infraestructura tecnológica y digital de RRHH es necesaria para que las empresas sean capaces de producir una analítica de RRHH más sofisticada y robusta, más allá de la elaboración de reportes o KPIs descriptivos.

Por ello, con el fin de sacar el máximo provecho a los datos disponibles, es importante realizar un cambio de análisis, que no solo reflejan datos históricos si no que pasen a análisis inferenciales y predictivos, que permitan anticipar cómo ciertos cambios en el talento pueden influir notablemente en los resultados del negocio. Este enfoque podría ayudar a las empresas a en lugar de ante los datos tomar una posición reactiva se preparen de forma proactiva (Huselid, 2018).

Para entender bien el concepto de ‘analytics’ y posteriormente sus usos en recursos humanos es esencial conocer el término de big data, el cual según el Cambridge Dictionary, “big data” se refiere a conjuntos de datos muy grandes que son producidos por las personas al utilizar internet. Sin embargo, la utilización de internet per se no es la forma de generar big data, sino

que este se compone de la recopilación de datos a través de diversas interacciones en medios digitales, que deja un rastro de información, como clics, búsquedas o tiempo de permanencia entre otros, los cuales una vez son capturados y procesados en grandes volúmenes y a alta velocidad, resultan en lo que conocemos como Big Data.

El acceso y gestión de grandes cantidades de datos en el ámbito de recursos humanos es crítico ya que se pueden encontrar tanto datos estructurados como no estructurados que abarcan temas desde datos personales (demográficos) de los trabajadores hasta algunos directamente relacionados con el historial de desempeño (Angrave et al., 2016).

Existen diversos tipos de datos que las organizaciones pueden utilizar en HRA, los cuales se agrupan en categorías clave que abarcan diferentes perspectivas analíticas. En primer lugar, los datos relacionados con conocimientos, habilidades y características de los empleados (KSAO's) incluyen competencias técnicas, experiencia laboral y aspectos demográficos, que permiten analizar el potencial y la capacidad de la fuerza laboral para responder a las demandas organizacionales. También se destacan los registros laborales, que incluyen información sobre horarios de trabajo, carga laboral y objetivos, facilitando la gestión eficiente de los recursos humanos, que junto con datos como los resultados de los empleados, la satisfacción, el compromiso y las percepciones, ofrecen una visión integral del bienestar y la motivación del talento. Por otro lado, los resultados de recursos humanos incluyen indicadores clave (HR KPIs) y métricas relacionadas con prácticas laborales, como ausentismo y antigüedad. En una escala más amplia, los resultados organizativos integran datos financieros y operativos, como costes laborales y márgenes de beneficio, permitiendo vincular la gestión de personas con los objetivos estratégicos del negocio. Finalmente, los datos externos, provenientes de redes sociales, condiciones climáticas o sitios web laborales, complementan el análisis al incorporar factores externos que influyen en la dinámica organizacional. Esta clasificación permite a las empresas no solo entender su entorno laboral, sino también construir modelos predictivos e inferenciales que mejoren la toma de decisiones y optimicen su estrategia de gestión de recursos humanos (Belizón et al, 2024).

En el contexto del big data, Huselid (2018) señala que una mayor variedad y volumen de datos permite realizar análisis más complejos, pero esto también presenta desafíos, como la necesidad de garantizar la fiabilidad y validez de las métricas. Esto es fundamental para asegurar que las decisiones basadas en datos sean precisas y éticas. Además, señala como una

de las áreas de crecimiento para el personal de recursos humanos es el desarrollo de capacidades analíticas avanzadas. Las organizaciones que invierten en desarrollar estas competencias tienen más posibilidades de mejorar el rendimiento de sus equipos, al contar con personal que sabe interpretar y actuar con una base en datos analíticos. Charlwood y Valizade (2019) expresan que, para los líderes de recursos humanos, es fundamental desarrollar habilidades en análisis de datos y colaborar con expertos en ciencia de datos. Señalan que los líderes deben comprender cómo aplicar modelos predictivos y cómo interpretar sus resultados dentro del contexto organizacional para tomar decisiones más informadas.

Al analizar y comprender estos datos, es posible abordar distintos tipos de problemas sobre los cuales profundizaré a continuación (Angrave et al., 2016).

Usos de Analítica de datos en RRHH

Retención de empleados

Uno de los principales retos que HRA busca abordar es la retención de talento. La retención de los empleados se define como las practicas llevadas a cabo por las organizaciones para mantener una fuerza laboral eficiente que satisfaga las necesidades operacionales (Yousuf & Siddqui, 2018). Las organizaciones a través de HRA, emplean análisis predictivos para identificar los factores que influyen en la rotación de personal y desarrollar estrategias efectivas para retener a los empleados más valiosos. Contar con la capacidad de predecir qué empleados son más propensos a abandonar la empresa resulta sumamente beneficioso, ya que permite destinar mayores recursos a retener a aquellos empleados estratégicos y, en caso contrario, reducir esfuerzos, lo cual contribuye a la disminución de costos. Algunos algoritmos de machine learning como, K-Nearest Neighbours o arboles de decisión han demostrado ser herramientas muy útiles para analizar factores y predecir la rotación. Factores como la justicia organizacional, el compromiso de los empleados, practicas sostenibles de gestión de recursos humanos o las oportunidades de aprendizaje parecen incrementar la retención de los empleados (Basnet, 2024). Además, Edwards et al. (2022) destaca la importancia de innovaciones en la atracción de personal, las estrategias como la formación pre-empleo, campañas de reclutamiento nacionales y la promoción de oportunidades de carrera son ejemplos de cómo las organizaciones pueden utilizar datos para mejorar su enfoque en la atracción del talento. Estas tanto para atraer a nuevos empleados como para retener a los existentes, se han vuelto cada vez más relevantes en un contexto de alta rotación laboral y escasez de mano de obra (Edwards et al., 2022).

Reclutamiento y selección

La utilización de HRA puede ser utilizada en los procesos de contratación, a través de su uso es más fácil que ciertos candidatos se adapten con más precisión a las necesidades de las vacantes. Candidatos más adaptados, desempeñarán mejor su role y por tanto contribuirán en mayor medida a la empresa. Además, el estudio de Edwards et al. (2022) destaca que las iniciativas de reclutamiento basadas en valores, como el "reclutamiento basado en valores" (values-based recruitment), son fundamentales para atraer y seleccionar a los candidatos adecuados. Este enfoque no solo se centra en las habilidades técnicas, sino también en la alineación de los valores del candidato con los de la organización, lo que puede aumentar la retención y satisfacción laboral.

Figura 3: Utilización de medios digitales en RRHH



Fuente: Incipy

Según el estudio realizado por Incipy, tal y como se muestra en la figura 3 las empresas cada vez más se sirven de medios digitales para llegar a una mayor audiencia y por tanto recibir un mayor número de candidaturas. Una vez reciben estas candidaturas, servirse de herramientas de análisis de datos ayudará a escoger al mejor candidato y optimizar el proceso de selección ya que existen fases de los procesos que no necesitarían ser supervisadas.

Compensación y beneficios

HRA ayuda a las empresas a optimizar sus estrategias de compensación y beneficios, analizando datos para asegurar que las ofertas sean competitivas y equitativas. El análisis del paquete retributivo y la comparación de empleados basadas en números, proporcionan una base sólida para la toma de decisiones objetivas. Esta herramienta permite examinar datos de salarios tanto del mercado como de la propia empresa, utilizando medidas de posición para guiar decisiones estratégicas.

Además, es fundamental considerar la ética en el uso de HRA, especialmente en la transparencia de los algoritmos utilizados para determinar compensaciones, ya que la falta de claridad puede generar desconfianza entre los empleados. En cuanto a la comparación de empleados, el HR Analytics facilita la determinación de la posición de cada trabajador dentro de la distribución salarial de la organización, por ejemplo empleando técnicas de clusterización para realizar comparaciones más precisas y equitativas. Además, el uso de analítica de datos en la compensación y beneficios permite a las organizaciones identificar tendencias y patrones en la satisfacción de los empleados con respecto a sus paquetes retributivos. La efectividad de HRA en la toma de decisiones de compensación depende de la participación activa de los gerentes, quienes son cruciales para interpretar los datos y aplicar los hallazgos de manera alineada con las necesidades organizacionales (Belizón, Majarín, & Aguado, 2024). La capacidad de medir y analizar datos de compensación permite a los líderes de recursos humanos no solo asegurar la competitividad salarial, sino también alinear estos beneficios con los objetivos estratégicos, lo que contribuye al éxito organizacional y al compromiso de los empleados (Huselid, 2018). Otro ejemplo es, mediante el análisis de encuestas de satisfacción y datos de rendimiento, las empresas pueden ajustar sus ofertas para alinearse mejor con las expectativas y necesidades de sus empleados, lo que puede resultar en un aumento de la moral y la productividad (Mathur, 2019). Además, el análisis de datos puede ayudar a identificar qué tipos de formación son más valorados por los empleados, permitiendo a las empresas personalizar sus ofertas de desarrollo y maximizar el retorno de inversión en sus programas de compensación y beneficios (Edwards et al., 2022).

Desempeño laboral

La función de evaluación del desempeño laboral es la función en la cual nos centraremos en el presente trabajo, los departamentos de recursos humanos tradicionalmente han empleado técnicas para valorar tanto el rendimiento como el potencial de desarrollo de sus empleados. Estas evaluaciones son esenciales no solo para definir el grado de alineación de los trabajadores con los objetivos organizacionales, sino también para identificar áreas de mejora y planificar su crecimiento profesional. El desempeño de los empleados se vincula con las responsabilidades asignadas y el nivel de precisión con el que se llevan a cabo. Muchos gerentes evalúan el rendimiento de sus empleados de forma anual, bianual o cuatrimestral. Según Armstrong (2014), el fin de la monitorización del desempeño es alinear los objetivos individuales con los de la organización. Este enfoque se basa en establecer metas claras y específicas que permitan evaluar los avances de la organización y de cada empleado de manera objetiva. Además, las estrategias modernas de gestión del desempeño promueven una cultura organizativa donde el reconocimiento y la retroalimentación son muy importantes. A través de herramientas como el feedback de 360 grados y el uso de sistemas integrados, las organizaciones pueden evaluar el impacto de las contribuciones individuales y diseñar estrategias basándose en sus correspondientes desempeños. Estos mecanismos no solo impulsan los resultados de la empresa en conjunto, sino que también incrementan la colaboración entre empleados y directivos, lo que impulsa un buen entorno de trabajo.

Anteriormente, existían métodos tradicionales comúnmente conocidos como 'orientados al pasado'. Algunos de estos métodos incluyen: el método de ranking, por el cual los empleados son clasificados de mejor a peor según sus méritos, este método presenta el inconveniente de que las razones detrás de la clasificación pueden estar sesgadas. O la escala de evaluación, que asigna puntuaciones a ciertas competencias de los empleados, como la iniciativa o la actitud, lo que permite realizar evaluaciones de manera simple y a bajo costo, aunque presenta un problema de subjetividad. En tercer lugar, el método de incidentes críticos se centra en evaluar el comportamiento de los empleados en eventos específicos que han tenido un impacto relevante, en lugar de su rendimiento diario. Por último, el ensayo narrativo permite que personas de mayor rango profesional redacten un informe detallado sobre los puntos fuertes y débiles del empleado. Aunque este análisis puede proporcionar una retroalimentación valiosa,

la opinión de un único evaluador puede estar sesgada, y el método requiere una inversión considerable de tiempo (Shaout & Yousif, 2014).

Aunque estas técnicas han sido empleadas durante años, estaban muy limitadas por la subjetividad del evaluador y por ofrecer un único punto de vista por parte de la persona que lo realizaba. Las técnicas modernas en cambio han permitido numerosas mejoras que ofrecen una mayor perspectiva del desempeño y amplían su utilidad.

Shaout y Yousif (2014) presentan distintos métodos de evaluación del desempeño que parecen superar algunas de estas barreras, conocidos como métodos modernos ‘orientados al futuro’. En primer lugar, el ‘Management by Objectives’ (MBO), este método ofrece una evaluación basada en el cumplimiento de unos objetivos previamente acordados entre el empleado y su evaluador, de esta forma ayudan a alinear los objetivos del empleado junto con los de la organización y fijar unas metas claras de desempeño que sean objetivamente evaluables. Ante el problema de la subjetividad, existen métodos como el de escalas de evaluación basadas en el comportamiento (BARS) que buscan asociar comportamientos a puntuaciones numéricas estandarizadas según ejemplos del desempeño esperado, de esta forma se tiene un desempeño requerido y la escala se realiza en función a ese comportamiento ideal. Shaout y Yousif (2014) ejemplifican este método con el caso de un doctor. En una escala del uno al cinco, un comportamiento de tres supondría que el doctor sea simpático con el paciente mientras que si se espera un desempeño de 5 se le pediría un alto grado no solo de simpatía si no también comportamientos empáticos y de entendimiento con el paciente. Otra técnica muy enriquecedora, pero algo más costosa es la evaluación 360 grados, gracias a este método se amplían los puntos de vista sobre un empleado ya que este es evaluado a distintos niveles, desde compañeros del mismo nivel a clientes o a supervisores, ofreciendo una visión integral del empleado. También existen empresas que han creado un sistema HRA (Human Resource Accounting) que concibe que los individuos son recursos de gran valor para una entidad y que basan su rendimiento en los ingresos económicos que producen para la compañía, esta valoración se fundamenta en un estudio de costos y beneficios, que tiene el poder de contribuir a la maximización del ROI también por la parte del capital humano (Shaout & Yousif, 2014).

La adopción de la analítica de RRHH representa un proceso complejo de legitimación, único dentro del ámbito de los recursos humanos, en parte debido a las dificultades que esta función ha tenido históricamente para demostrar su contribución directa al rendimiento organizacional.

A pesar del crecimiento en la literatura de analítica de RRHH, persisten desafíos fundamentales en la definición de sus objetivos y en la medición de sus indicadores clave de rendimiento (KPI), los cuales son significativamente más difíciles de evaluar en comparación con áreas como finanzas, operaciones o marketing ya mencionadas previamente (Belizón & Kieran, 2021).

Además, la analítica de RRHH requiere la participación de múltiples actores que no siempre son expertos en RRHH, lo cual añade un grado de complejidad, especialmente cuando cada etapa del proceso involucra diferentes competencias y habilidades. Estos proyectos, que abarcan desde la recolección de datos hasta el análisis y la implementación de estrategias, enfrentan también limitaciones en infraestructura y financiación, ya que el área de RRHH no suele recibir grandes inversiones en tecnología o infraestructura de datos (Belizón & Kieran, 2021).

Dada la naturaleza multidimensional de la analítica de RRHH, su legitimación no se reduce a un reconocimiento social dentro de la organización; en cambio, requiere también legitimidad cognitiva, sociopolítica y tecnológica. Este proceso puede entenderse mejor desde un enfoque de “legitimidad emprendedora,” en el que los actores de RRHH desarrollan su credibilidad en colaboración con diferentes interesados a través de un enfoque innovador que involucra habilidades, metodologías y recursos específicos. Asimismo, el modo en que los profesionales de RRHH interactúan y se conducen con otros departamentos en su búsqueda de legitimidad es crucial para el éxito de estos proyectos (Belizón & Kieran, 2021).

2.2 Impacto del uso de people analytics en indicadores de Recursos Humanos y de Negocio

Con este contexto en mente, mi investigación propone abordar cómo la analítica de datos aplicada a la evaluación del desempeño no solo impacta en el negocio, sino también en el propio departamento de recursos humanos, al facilitar un enfoque más estructurado y medible en la toma de decisiones. A continuación, presentaré las hipótesis clave que servirán de base para demostrar estas influencias y sus posibles implicaciones en el desempeño organizacional y la gestión de RRHH.

La implementación de People Analytics en las organizaciones permite la gestión de todo tipo de datos, lo que no solo mejora la precisión y constancia de los registros, sino que también la

calidad y centralización de los mismos (Angrave et al., 2016). Teniendo los datos centralizados, se facilita su análisis, comprensión y visualización (Belizón et al., 2023). A partir de estos análisis y del soporte analítico detrás de las decisiones se pueden sacar tendencias que influyen en el desempeño individual y en el trabajo en equipo lo que se puede extrapolar al desempeño de la empresa en su totalidad.

Además, la incorporación de la inteligencia artificial (IA) en la evaluación del desempeño ha revolucionado la medición de indicadores clave de recursos humanos (HR KPIs) y de negocio (Business KPIs). Herramientas basadas en IA permiten automatizar el análisis de grandes volúmenes de datos, proporcionando información en tiempo real sobre factores como productividad, compromiso y retención. Además, la implementación de modelos predictivos facilita la identificación de patrones y tendencias que, de otro modo, pasarían desapercibidos. Estas tecnologías no solo optimizan el seguimiento del rendimiento individual y organizacional, sino que también a través de modelos predictivos y análisis avanzados, facilita identificar áreas de mejora y oportunidades, alineando las acciones de recursos humanos con los objetivos organizativos.

En este contexto, people analytics no solo mejora la precisión de los datos, sino que también transforma la gestión del desempeño en un proceso más dinámico y orientado a resultados en la misma función de RRHH (Randstad, 2024). Aunque las herramientas de People Analytics han demostrado ser útiles para analizar datos relacionados con la fuerza laboral, ayudando a identificar patrones y métricas clave que reducen la subjetividad en la toma de decisiones, todavía falta evidencia de su impacto directo en los indicadores clave de recursos humanos (HR KPIs). Su uso ha sido particularmente efectivo en análisis históricos, pero su potencial para análisis predictivos sigue siendo limitado. Estudios como el de Angrave et al. (2016) destacan que la centralización y automatización de datos mejora la calidad y fiabilidad de los registros, optimizando procesos internos como el análisis de rendimiento, compromiso y retención (Angrave et al., 2016; Boudreau & Ziskin, 2011).

Como mencionado previamente people analytics también está transformando la forma en que las organizaciones toman decisiones relacionadas con la compensación y beneficios. Por un lado, mediante el análisis de datos retributivos internos y externos, es posible diseñar políticas salariales más competitivas, justas y alineadas con los objetivos estratégicos. Estas herramientas permiten identificar desigualdades, optimizar incentivos y personalizar beneficios según el perfil y las necesidades de los empleados, contribuyendo así al compromiso

y la retención del talento. Por otro lado, el seguimiento analítico del desempeño permite calcular con mayor precisión la retribución flexible que corresponde a cada empleado, funcionando además como un mecanismo de incentivo que refuerza el rendimiento individual.

Además, herramientas como las desarrolladas por The Wise Seeker refuerzan mi primera hipótesis ya que al poder evaluar el desempeño de manera objetiva, no solamente para medir resultados tangibles sino utilizando datos para medir competencias, habilidades y características personales mediante metodologías avanzadas como el modelo de los cinco grandes (Big Five), se mejora la precisión en la identificación de fortalezas y áreas de mejora lo que facilita la creación de planes estratégicos para el desarrollo del talento. Al centralizar y automatizar estas evaluaciones, no solo se optimizan procesos como el análisis de compromiso y retención, sino que también se fomenta un impacto directo en métricas clave, como la productividad y la satisfacción laboral (The Wise Seeker, 2022). En este sentido, planteo mis dos primeras hipótesis:

H1: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está correlacionado con la utilización de políticas de compensación variable.

H2: El uso de herramientas de People Analytics para la evaluación del desempeño está asociado con una mayor optimización de talento.

Aunque las herramientas de People Analytics han demostrado ser útiles para analizar a las personas dentro de una empresa y su influencia en el desempeño organizacional, la evidencia de un impacto directo en indicadores clave de negocio (business KPIs) sigue siendo limitada. De hecho, en 2024, solo existían cinco estudios que conseguían demostrar explícitamente una conexión entre la analítica de recursos humanos (HRA) y los indicadores claves de negocio (business KPIs) . Entre ellos, Aral et al. (2012) evidenciaron cómo la combinación de HRA, políticas de pago por desempeño y tecnología de la información incrementa la productividad empresarial. Xu y Li (2021) aplicaron modelos de optimización de programación de turnos, logrando reducir costos salariales e incrementar la satisfacción del personal. Simón y Ferreiro (2018) también aportaron conclusiones relevantes al conectar métricas de recursos humanos con indicadores de ventas en Inditex, fomentando la transferencia de buenas prácticas entre tiendas. Rasmussen y Ulrich (2015), por su parte, analizaron cómo el liderazgo y la efectividad operativa influyen en la satisfacción del cliente en plataformas petroleras. Y, por último,

Schiemann et al. (2018) utilizaron el marco de People Equity para demostrar el impacto del capital humano en la productividad, rotación de empleados y rentabilidad de una cadena de restaurantes. Aunque valiosos, estos estudios representan excepciones dentro de un campo todavía en desarrollo (Belizón et al., 2023).

Un ejemplo práctico de cómo las herramientas de People Analytics pueden influir en los indicadores clave de negocio (Business KPIs) es el índice Key Talent Indicator (KTI) desarrollado por The Wise Seeker. Este índice, que va del 0 al 100, mide cuanto se adaptan los empleados o candidatos a los perfiles ideales definidos por la empresa, teniendo en cuenta habilidades, competencias y características personales, es decir, midiendo tanto hard como soft skills. Gracias a esta herramienta, las organizaciones pueden identificar con mayor precisión al talento más adecuado que por el momento se asumirá que de forma consecuente será el que mejor desempeñará una determinada tarea con un impacto directo en la productividad y lo que se podría traducir en una reducción de costes por una mala contratación (The Wise Seeker, 2022). Es decir, el uso de estas métricas objetivas no solo aporta claridad a la gestión del talento, sino que también impacta directamente en el desempeño empresarial. En primer lugar, influye en la competitividad del negocio, al basar las decisiones de gestión del talento en datos objetivos, la organización optimiza el desempeño y desarrolla capacidades difíciles de imitar, reforzando su posición en el mercado. De hecho, estudios recientes demuestran que fortalecer las competencias de analítica de recursos humanos conduce a ventajas competitivas sostenibles (Minbaeva, 2018) Además, la evaluación del desempeño mediante People Analytics facilita la proyección de beneficios futuros, lo que supone actuar y tomar decisiones de forma proactiva, lo que se traduce en mejoras en el desempeño organizacional y en los resultados empresariales esperados (McCartney & Fu, 2022).

Teniendo este contexto en mente, y considerando que los Business KPIs pueden medirse a través de la competitividad de la empresa en el mercado, así como por sus beneficios actuales y sus proyecciones futuras, se plantean las siguientes hipótesis con el objetivo de analizar si el uso de herramientas de People Analytics para la evaluación del desempeño está vinculado con una mejora en los resultados de negocio:

H3: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con la competitividad del negocio.

H4a: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con una mayor obtención de beneficios actuales.

H4b: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con una planificación de crecimiento favorable.

3. Metodología de Investigación

3.1. Diseño de la Investigación

Para la presente investigación se utilizarán datos secundarios provenientes de la European Company Survey (ECS) 2019, un estudio que recopila información de más de 20,000 empresas en los Estados miembros de la Unión Europea. El uso de esta base de datos es apropiado ya que incluye una pregunta sobre si el establecimiento/empresa, utiliza HR Analytics para la evaluación del desempeño de los empleados. Esta variable se tomará como variable dependiente durante el estudio. Además, esta base de datos contiene preguntas que proporcionan variables relacionadas con prácticas laborales, el uso de tecnología y la gestión de recursos humanos (Bechter et al., 2022).

En el análisis se han clasificado los países a los que pertenecen las observaciones de acuerdo con sus características institucionales y culturales, siguiendo la metodología planteada por Bechter et al. (2022). Esta clasificación se debe a que las características del entorno institucional, como las regulaciones laborales, las políticas gubernamentales, y las normativas de empleo, influyen directamente en cómo las empresas gestionan su talento. Asimismo, factores culturales como las preferencias nacionales por estilos de liderazgo o la aceptación de nuevas tecnologías también pueden afectar las decisiones organizativas.

En este sentido los países se dividieron en 4 grupos. En primer lugar, se identificaron las economías de mercado coordinadas (CME), que incluyen a Austria, Bélgica, Dinamarca, Finlandia, Alemania, Países Bajos y Suecia. Estas economías se caracterizan por una estrecha coordinación entre empresas, sindicatos y gobiernos en la regulación del mercado laboral y la gestión económica. Por otro lado, se clasificaron los países con economías de mercado liberales (LME), representadas por Reino Unido, Irlanda, Malta y Chipre, donde predominan las dinámicas de mercado con menor intervención estatal y estructuras menos coordinadas. Adicionalmente, también se formó un grupo de países para las economías de mercado estatistas, que incluyen a Grecia, España, Francia, Italia y Portugal, caracterizadas por una

mayor intervención gubernamental en la regulación económica; y el grupo de economías de Europa Central y del Este (CEECs), que abarca a Bulgaria, Croacia, Estonia, Hungría, Letonia, Lituania, Rumanía, Eslovaquia y Eslovenia. Es decir, de mayor a menor intervención estatal, los grupos se ordenarían de la siguiente manera: economías de mercado estatistas, economías de mercado coordinadas (CME), economías de Europa Central y del Este (CEECs) y, finalmente, economías de mercado liberales (LME). Además de la base de datos inicial se seleccionaron solamente aquellos establecimientos con más de 250 empleados ya que son más representativos a la hora de hablar del uso de herramientas de análisis de grandes cantidades de datos.

Con el fin de sacar conclusiones relevantes y que aporten valor, se realizaron dos estudios. Por un lado, un análisis descriptivo preliminar a partir de la descripción de los datos de la muestra; y en segundo lugar con el fin de validar o por el contrario rechazar las hipótesis planteadas, tres modelos OLS (Ordinary Least Squares), en español modelo de Mínimos Cuadrados Ordinarios, que es método de regresión lineal usado para estimar los coeficientes de dicha regresión. Este modelo es útil cuando se busca entender la relación entre una variable dependiente y una o más variables independientes. Su fórmula general se expresa de la siguiente forma:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \dots + \beta_k X_k + \varepsilon$$

Donde:

- Y: variable dependiente – En el caso de nuestra modelo sería la utilización de analytics para la evaluación del desempeño
- $X_1, X_2 \dots X_k$: variables independientes (los factores que afectan a Y). – En nuestro caso las distintas variables de control, indicadores de RRHH e indicadores de negocio.
- β_0 : intercepto.
- $\beta_1, \beta_2 \dots \beta_k$: coeficientes de regresión calculados por el modelo son valores, uno para cada variable independiente, que representan la fortaleza y el tipo de relación que tiene la variable explicativa con la variable dependiente.
- ε : término de error aleatorio

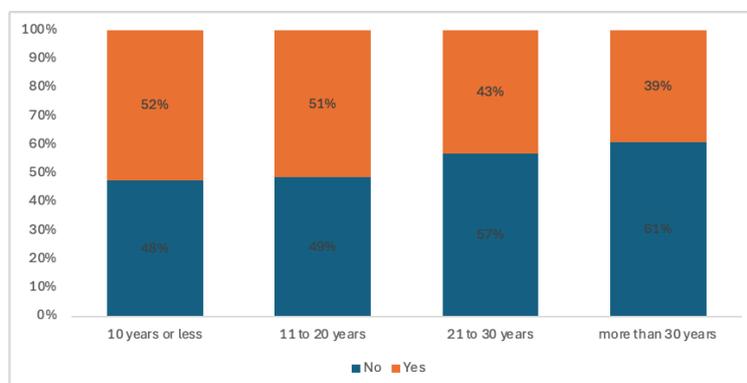
3.2 Análisis Descriptivo

En primer lugar, se realiza un análisis descriptivo de la muestra, prestando especial atención a las variables de control, ya que son fundamentales para interpretar correctamente los resultados del modelo. Estas variables incluyen el grupo de país, el uso o no de comercio electrónico, la antigüedad del establecimiento y su sector de actividad principal.

a. Por antigüedad del establecimiento

Los datos muestran que la adopción de herramientas de data analytics para la evaluación del desempeño varía según la antigüedad de las empresas, siendo más frecuente en las organizaciones más jóvenes. Tal y como se muestra en la figura 4, las empresas con 10 años o menos, más de la mitad (52%) ya utilizaban estas herramientas en 2019, año en que se realizó la encuesta, lo que se puede atribuir a que, desde su origen, han estado rodeadas de innovación y tecnología, y han visto como una obligación para mantenerse competitivas en el mundo digital la incorporación de herramientas de data analytics. Por ejemplo, avances como el cloud computing, que entre 2007 y 2009 comenzaron a consolidarse se consideran pilares fundamentales para la transformación digital. La nube permitió a las organizaciones almacenar sus datos y utilizar servicios sin necesidad de infraestructura física compleja, haciendo más accesible la adopción de data analytics. En contraste, las empresas con más de 30 años presentan un menor porcentaje de adopción (39%), probablemente debido a que suelen tener sistemas más tradicionales y resistentes al cambio, que pueden ralentizar la incorporación de nuevas tecnologías. Aun así, el hecho de que en 2019 el 43% del total de empresas de la muestra utilizara data analytics para la evaluación del desempeño refleja una transición importante hacia la digitalización.

Figura 4: Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según la Antigüedad de la Empresa

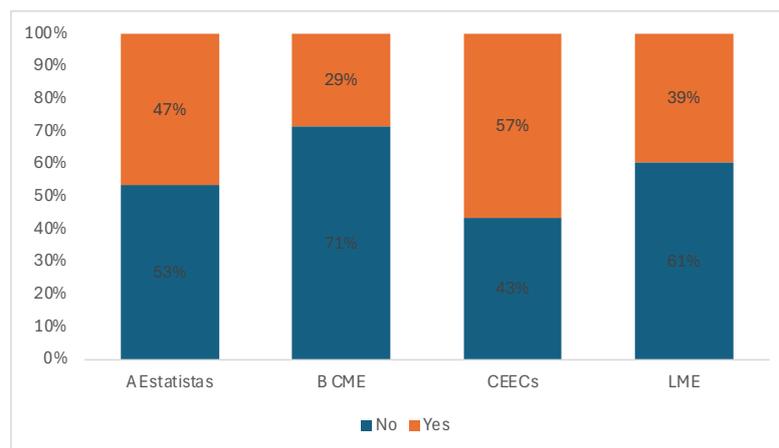


Fuente: Elaboración propia

b. Por países

En la figura 5 se muestra el porcentaje de adopción de herramientas de People Analytics para la evaluación del desempeño según el grupo de país de origen de las empresas. Se observa que los países del grupo CME (Coordinated Market Economies) presentan el nivel más bajo de utilización, con solo un 29% de empresas que utilizan estas herramientas, frente a un 71% que no lo hace. Por otro lado, el grupo con mayor porcentaje de adopción es el de las economías CEECs (Central and Eastern European Countries), con un 57% de adopción frente a un 43% que no utiliza estas herramientas. Este resultado podría interpretarse como un reflejo del proceso de modernización y transformación digital que muchas empresas de estos países están llevando a cabo. Las economías Estadísticas muestran una adopción equilibrada, con un 53% que no usa People Analytics y un 47% que sí lo hace. Esto puede deberse a que, aunque existe una fuerte intervención estatal que impulsa el control y el reporte, aún hay resistencia al cambio tecnológico en algunos sectores. Por último, los países del grupo LME (Liberal Market Economies) presentan una tasa de adopción del 39%, siendo el 61% restante empresas que no utilizan herramientas de análisis del desempeño. Este dato puede deberse a la autonomía empresarial típica de estos sistemas, donde las decisiones sobre innovación y digitalización pueden variar mucho entre empresas, sin una presión estatal homogénea que las empuje hacia la analítica de datos.

Figura 5: Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según su grupo de país de origen



Fuente: Elaboración Propia

c. Por sector de actividad

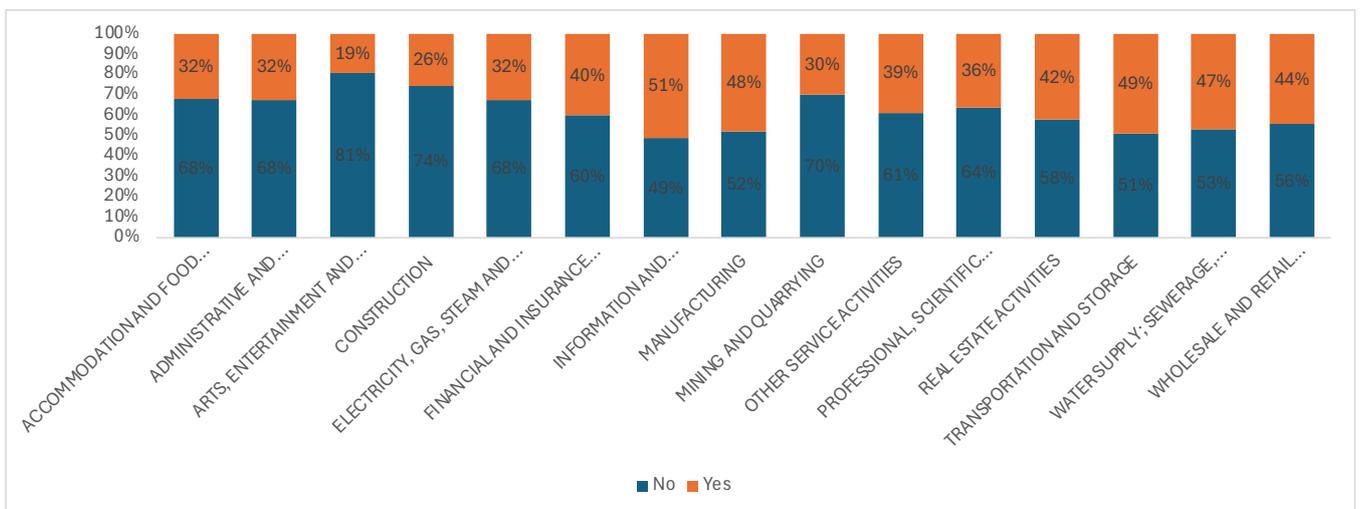
La adopción de herramientas de data analytics para evaluar el desempeño de los empleados varía considerablemente entre sectores, reflejando las características propias de cada industria. Como se muestra en la figura 6, los sectores más ligados a la tecnología y el manejo de datos, como información y comunicación (51%) y manufactura (48%), destacan como los más avanzados en este aspecto. Esto se debe a su necesidad de optimizar procesos y tomar decisiones basadas en datos.

Por otro lado, sectores como finanzas y seguros (40%) y actividades profesionales, científicas y técnicas (36%) también presentan niveles altos de adopción. Esto tiene sentido, ya que son industrias donde las decisiones informadas y la medición del desempeño son fundamentales para gestionar equipos y alcanzar objetivos organizacionales. Además, suelen contar con mayores recursos tecnológicos que facilitan la integración de estas herramientas

En contraste, sectores más tradicionales o con menor digitalización muestran menores niveles de adopción. Por ejemplo, el sector de arte, entretenimiento y recreación apenas alcanza un 19%, esto podría deberse a que estas industrias priorizan otras áreas o carecen de los recursos necesarios para implementar tecnologías avanzadas.

Finalmente, sectores como la construcción (26%) y minería y canteras (30%) también muestran una adopción limitada. Esto podría explicarse por su enfoque en operaciones técnicas y la menor importancia que suelen dar a la gestión del talento.

Figura 6: Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño según su sector de actividad

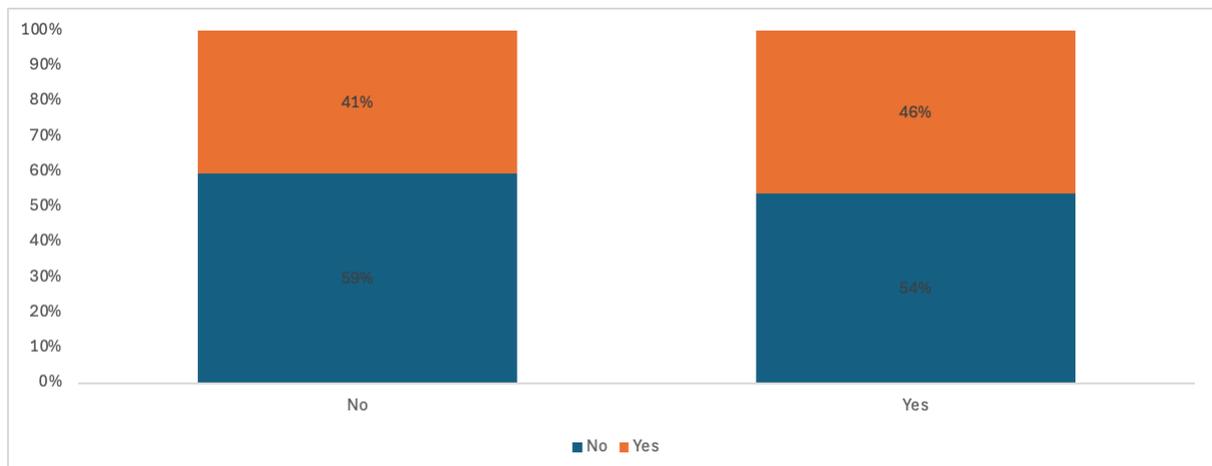


Fuente: Elaboración Propia

d. Según el uso de ecommerce

Al analizar la relación entre la adopción del comercio electrónico y el uso de herramientas de data analytics para evaluar el desempeño de los empleados, no se aprecia una asociación clara. Dentro de la muestra utilizada, aproximadamente el 70% de las empresas utilizan ecommerce frente al 30% que no lo utilizan. Dentro de estos grupos la adopción de people analytics para la evaluación del desempeño es bastante equilibrada. Estos datos reflejan que, aunque el uso de ecommerce podría asociarse a una mayor madurez digital, en nuestro análisis descriptivo preliminar no se traduce necesariamente en un uso de herramientas de analytics para la evaluación del desempeño.

Figura 7: Adopción de Herramientas de Data Analytics para la Evaluación del Desempeño en función de si la empresa utiliza ecommerce como canal de distribución



Fuente: Elaboración Propia

Una vez examinadas en profundidad las variables de control, la Figura 8 presenta un análisis detallado del resto de variables del modelo. En esta tabla, se incluye para cada variable su descripción, la clasificación según si pertenecen a variables de control, indicadores de recursos humanos o de negocio, su distribución de respuestas y el índice VIF asociado al último modelo, utilizado para evaluar el riesgo de multicolinealidad entre variables.

La interpretación del índice VIF se realiza de la siguiente manera:

- VIF =1 (No hay correlación con otras variables.)
- $1 < \text{VIF} < 5$ (Correlación moderada.)
- $\text{VIF} > 5$, (Alta correlación. Puede haber problemas de multicolinealidad.)
- $\text{VIF} > 10$ (Muy alta correlación. Es necesario revisar y posiblemente eliminar variables.)

La tabla muestra como este índice se encuentra en todos los casos por debajo del umbral crítico de 5, lo que indica una colinealidad aceptable, es decir, que las variables independientes no están excesivamente correlacionadas entre sí y, por tanto, no distorsionan la estimación de los coeficientes del modelo.

Figura 8 Tabla de Variables

Nombre	Clasificación	Descripción	Valores	VIF
countgroup	Control	Esta variable indica el país al que pertenece el establecimiento, clasificado en 4 grupos en función de la intervención estatal.	CEECs (29%) LME (7%) Estatistas (28%) CME (37%)	4,4 ¹⁾
smainact_d	Control	Esta variable indica la principal actividad que realiza el establecimiento.	Accommodation and food service activities (3,27%), Administrative and support service activities (7,37%), Arts, entertainment and recreation (2,96%), Construction (4,25%) Electricity, gas, steam and air conditioning supply (1,76%), Financial and insurance activities (3,37%), Information and communication (2,75%), Manufacturing (40,40%), Mining and quarrying (0,52%), Other service activities (6,17%), Professional, scientific and technical activities (5,03%), Real estate activities (0,99%), Transportation and storage (6,90%), Water supply; sewerage, waste management and remediation activities (1,66%), Wholesale and retail trade; repair of motor vehicles and motorcycles (12,60%)	3,15 ¹⁾
ecommerce	Control	Esta variable refleja si la empresa utiliza el comercio electrónico	Yes (69.87%) / No (30.13%)	1.12
Est_age	Control	Indica la edad del establecimiento	10 years or less (6.54%) , 11-20 (15.46%) years, 21-30 years (18.57%) or more than 30 (57.52%)	1.22
vpinper_d	RRHH KPI (H1)	En 2018, ¿cuántos empleados en este establecimiento recibieron una retribución variable adicional vinculada al desempeño individual según la evaluación de la dirección?	None at all (54%), Less than 20% (24%), 20% to 39% (6%), 40% to 59% (3%), 60% to 79% (2%), 80% to 99% (3%), All (5%)	1.47

vpgrpe_d	RRHH KPI (H1)	En 2018, ¿cuántos empleados en este establecimiento recibieron una retribución variable adicional vinculada al desempeño del equipo, grupo de trabajo o departamento?	None at all (65%), Less than 20% (17%), 20% to 39% (4%), 40% to 59% (2%), 60% to 79% (1%), 80% to 99% (2%), All (5%)	1.37
vpprsh_d	RRHH KPI (H1)	En 2018, ¿cuántos empleados en este establecimiento recibieron una retribución variable adicional vinculada a los resultados de la empresa o del establecimiento?	None at all (62%), Less than 20% (17%), 20% to 39% (3%), 40% to 59% (2%), 60% to 79% (1%), 80% to 99% (3%), All (9%)	1.25
sickleave	RRHH KPI (H2)	¿Cree que el nivel de bajas por enfermedad en este establecimiento es demasiado alto?	Yes (48%) /No (52%)	1.15
lowmot	RRHH KPI (H2)	En general, ¿qué tan motivados cree que están los empleados en este establecimiento?	Not at all motivated (1%), Not very motivated (18%), Fairly motivated (67%), Very motivated (12.76%)	1.35
findskill	RRHH KPI (H2)	¿Qué grado de dificultad tiene este establecimiento para encontrar empleados con las competencias requeridas?	Not at all difficult (2%), Not very difficult (26%), Fairly difficult (55%) , Very difficult (16%)	1.23
retainemp	RRHH KPI (H2)	¿Qué grado de dificultad tiene este establecimiento para retener a los empleados?	Not at all difficult (9%), Not very difficult (52%), Fairly difficult (34%), Very difficult (4%)	1.34
pmstratlp	Business kpi (H3)	Indica en una escala del 1-4 como de importante es ofrecer productos o servicios a precios más bajos que los de la competencia	Rango 1- 4 – Media (3.03)	1.39
pmstratbq	Business kpi (H3)	Indica en una escala del 1-4 como de importante es ofrecer productos o servicios de mejor calidad que los que ofrece la competencia	Rango 1- 4 - Media (1.87)	1.18
pmstratcust	Business kpi (H3)	Indica en una escala del 1-4 como de importante es personalizar productos o servicios para satisfacer requisitos específicos de los clientes	Rango 1- 4 Media (2.09)	1.23
pmstratnps	Business kpi (H3)	Indica en una escala del 1-4 como de importante es desarrollar regularmente productos, servicios o procesos que sean nuevos en el mercado	Rango 1- 4 - Media (2.75)	1.25
competmark	Business kpi (H3)	¿Qué tan competitivo diría que es el mercado de los principales productos o servicios que ofrece este establecimiento?	Not at all competitive (3%), Not very competitive (10%), Fairly competitive (44%), Very competitive (41%)	1.14
profit	Business kpi (H4a)	¿Obtuvo este establecimiento beneficios en 2018?	Yes, we made a profit (72%) No, we made loss (9%) We broke even (9%)	1.63
profplan	Business kpi (H4b)	¿Esperaba este establecimiento obtener beneficios en 2018?	Yes (80%) / No (10%)	1.57
chempfut	Business kpi (H4b)	En los próximos tres años, ¿cómo espera que cambie el número total de empleados en este establecimiento?	It will increase (36%) It will stay about the same (48%) It will decrease (15%)	1.18

1) Media entre el VIF de cada una de las respuestas ya que para el modelo se aplicará one hot encoding para esta variable tomando una respuesta como referencia.

* Si el total de la incidencia no suma un 100% se debe a una parte residual de respuestas en blanco que no se tienen en cuenta en el análisis

Fuente: Elaboración Propia

3.3 Evaluación de los modelos

Con el objetivo de evaluar cuantitativamente las hipótesis planteadas, se desarrollaron tres modelos OLS incluyendo diferentes variables. El primer modelo incluyó únicamente variables de control: el grupo de país (countgroup), el sector de actividad principal (smainact_d), el uso de comercio electrónico (ecommerce) y la antigüedad del establecimiento (est_age). Estas variables de control se han seleccionado para aislar sus efectos antes de introducir las variables principales del estudio en modelos posteriores. En el segundo modelo se incorporaron indicadores de recursos humanos, como el ausentismo (sickleave), la motivación de los empleados (lowmot), la facilidad para encontrar (findskill) y retener talento (retainemp), además de 3 variables relacionadas con la estimación del pago variable de los empleados (vpinper_d, vprpe_d, vprsh_d). Finalmente, en el tercer modelo se añadieron variables de negocio: estrategias competitivas (pmstratlp, pmstratbq, pmstratcust, pmstratnps), percepción de competitividad del mercado (competmark), beneficio real y esperado (profit, profplan) y las expectativas sobre la evolución futura del número de empleados (chempfut).

Para evaluar el desempeño de los distintos modelos se utilizaron tres métricas cuyos resultados se muestran en la figura 9: accuracy, R-squared y F-statistic.

- **Accuracy:** también llamada precisión, mide el porcentaje de predicciones correctas que hace un modelo respecto al total de observaciones. Se calcula como:

$$Accuracy = \frac{\text{Número de predicciones correctas}}{\text{Número total de observaciones}}$$

Su interpretación va de 0 a 1 y cuanto mayor es la accuracy mejor predice el modelo, valores cercanos a 1 indican que el modelo clasifica bien la mayoría de los casos. Por lo que, en nuestro caso, a medida que se incluyen más variables, mejora la precisión.

- **R-squared:** también llamado coeficiente de determinación, indica qué porcentaje de la variabilidad de la variable dependiente puede explicarse por las variables independientes incluidas en el modelo. Se calcula como:

$$R^2 = 1 - \frac{\text{Suma de residuos al cuadrado (SSR)}}{\text{Suma total al cuadrado (SST)}}$$

Siendo:

- SSR el error entre los valores reales y los predichos por el modelo
- SST la variación total de la variable dependiente con respecto a su media.

Su valor va de 0 a 1, donde un R-squared cercano a 1 indica que el modelo explica muy bien los datos. Por el contrario, valores bajos reflejan que existen otros factores no considerados que influyen en la variable dependiente. En el ámbito de los recursos humanos, es habitual obtener R-squared bajos debido a la complejidad y subjetividad de los factores involucrados. Por tanto, los valores obtenidos en nuestros modelos pueden considerarse aceptables y coherentes con la literatura, observándose además una ligera mejora a medida que se incorporan más variables.

- **F-statistic:** esta métrica nos dice si el modelo en su conjunto es significativo, es decir, si al menos una de las variables independientes tiene un efecto sobre la variable dependiente. Se calcula como:

$$F = \frac{\text{Varianza explicada por el modelo}}{\text{Varianza no explicada por el modelo}}$$

Para saber si es aceptable, se compara con su p-valor asociado: si el p-valor es menor a 0.05 (o 0.01), entonces el modelo es estadísticamente significativo en su conjunto. En nuestros tres modelos, los p-values son extremadamente bajos, es decir es significativo en todos los casos, lo que confirma que el conjunto de variables introducidas aporta valor explicativo respecto a la variable dependiente.

Figura 9 Comparación ajuste de los modelos

Métrica	Modelo 1	Modelo 2	Modelo 3
Accuracy	0.6335	0.6449	0.6545
R-squared	0.086	0.089	0.104
F-statistic	9.282 (3.89e-26)	6.306 (8.52e-21)	5.120 (2.26e-19)

*Valor entre paréntesis representa el p-value asociado al estadístico F

4. Resultados de la Investigación

Además, se ha realizado un análisis de la importancia de cada variable independiente para identificar cuáles tienen un mayor impacto en la variable dependiente, la adopción de people analytics para evaluación del desempeño, y por tanto, son las más significativas tal y como se observa en la Figura 11.

Figura 10 Tabla comparativa importancia de las variables según el modelo

Variable	Coeficiente			Variacion	Tendencia	P-Value			Tendencia	Significancia		
	M1	M2	M3			M1	M2	M3		M1	M2	M3
ecommerce	0,0940	0,1029	0,0931	1%		0,0002	0,0001	0,0008		1%	1%	1%
est_age	-0,0421	-0,0434	-0,0282	33%		0,0006	0,0008	0,0427		1%	1%	5%
smainact_d_INFORMATION AND COMMUNICATION	0,1349	0,1209	0,0541	60%		0,0346	0,0870	0,4751		5%	10%	No significativo
smainact_d_CONSTRUCTION	-0,0916	-0,0718	-0,1113	21%		0,0843	0,2043	0,0625		10%	No significat	10%
smainact_d_MANUFACTURING	0,1161	0,1191	0,0729	37%		0,0000	0,0000	0,0142		1%	1%	5%
smainact_d_ELECTRICITY, GAS, STEAM AND AIR CON...	-0,0785	-0,1239	-0,1602	104%		0,3312	0,1684	0,1119		No significati	No significati	No significativo
smainact_d_WHOLESALE AND RETAIL TRADE; REPAIR ...	0,0657	0,0707	0,0247	62%		0,0587	0,0573	0,5386		10%	10%	No significativo
smainact_d_MINING AND QUARRYING	-0,0678	-0,0186	0,0468	169%		0,6329	0,9070	0,7844		No significati	No significati	No significativo
smainact_d_PROFESSIONAL, SCIENTIFIC AND TECHN...	0,0253	-0,0020	0,0354	40%		0,6044	0,9704	0,5740		No significati	No significati	No significativo
smainact_d_FINANCIAL AND INSURANCE ACTIVITIES	0,1206	0,0978	0,0640	47%		0,0428	0,1215	0,3544		5%	No significati	No significativo
smainact_d_ADMINISTRATIVE AND SUPPORT SERVICE ...	-0,0301	-0,0323	-0,0693	131%		0,4751	0,4687	0,1617		No significati	No significati	No significativo
smainact_d_ARTS, ENTERTAINMENT AND RECREATION	-0,1140	-0,1001	-0,0024	98%		0,0749	0,1420	0,9795		10%	No significati	No significativo
smainact_d_OTHER SERVICE ACTIVITIES	0,0149	0,0019	-0,0126	184%		0,7409	0,9674	0,8177		No significati	No significati	No significativo
smainact_d_TRANSPORTATION AND STORAGE	0,1171	0,1052	0,1029	12%		0,0060	0,0158	0,0259		1%	5%	5%
smainact_d_ACCOMMODATION AND FOOD SERVICE ACTI.	-0,0602	-0,0611	-0,1188	97%		0,3109	0,3229	0,0625		No significat	No significat	10%
smainact_d_WATER SUPPLY; SEWERAGE, WASTE MANAG...	0,0640	0,0653	0,1109	73%		0,4309	0,4405	0,2426		No significati	No significati	No significativo
smainact_d_REAL ESTATE ACTIVITIES	0,1324	0,1462	0,0750	43%		0,2400	0,1977	0,6023		No significati	No significati	No significativo
countgroup_LME	0,0576	0,0425	-0,0465	181%		0,1139	0,2925	0,3236		No significati	No significati	No significativo
countgroup_B CME	-0,0471	-0,0539	-0,1072	128%		0,0177	0,0356	0,0005		5%	5%	1%
countgroup_CEECs	0,2133	0,1962	0,1714	20%		0,0000	0,0000	0,0000		1%	1%	1%
countgroup_A Estadistas	0,1251	0,1326	0,0944	25%		0,0000	0,0000	0,0012		1%	1%	1%
vpinper_d		-0,0199	-0,0221	11%			0,0231	0,0161			5%	5%
vpgrpe_d		0,0069	0,0054	21%			0,4323	0,5597		No significati	No significativo	
vpprsh_d		0,0023	0,0027	16%			0,7333	0,7059		No significati	No significativo	
sickleave		-0,0169	-0,0056	67%			0,4918	0,8287		No significati	No significativo	
lowmot		0,0140	-0,0060	143%			0,5298	0,8060		No significati	No significativo	
findskill		0,0076	0,0014	81%			0,6779	0,9411		No significati	No significativo	
retainemp		0,0150	0,0144	4%			0,4301	0,4789		No significati	No significativo	
pmstratlp			0,0321					0,0124				5%
pmstratbq			-0,0070					0,6175				No significativo
pmstartcust			0,0194					0,1473				No significativo
pmstratnps			-0,0064					0,6119				No significativo
competmark			0,0533					0,0039				1%
profit			-0,0165					0,5021				No significativo
profplan			0,1215					0,0191				5%
chempfut			0,0252					0,1914				No significativo

Fuente: Elaboración propia

*Las variables marcadas en verde representan aquellas que son significativas en el tercer modelo

*Una tendencia creciente en el p-value significa que la variable pierde significancia

* La variacion se calcula para las variables control comparando M1 y M3 y para las de RRHH comparando M2 y M3

Al analizar los resultados de este primer modelo, se observa que tanto la variable `ecommerce` como `est_age` son significativas al 1%, lo que indica que tienen un impacto estadísticamente relevante sobre la variable dependiente. En concreto, `ecommerce` presenta un coeficiente de 0,094, lo que sugiere que la utilización del comercio electrónico está asociada a un mayor uso de herramientas de analytics para monitorizar el desempeño. Por su parte, `est_age` tiene un coeficiente de -0,042, lo que implica que, a mayor antigüedad del establecimiento, menor es la probabilidad de adoptar este tipo de herramientas. En relación con el grupo de país, las categorías CME, CEECs y Estadistas resultaron significativas con niveles de confianza del 5%, 1% y 1%, respectivamente. La interpretación de sus coeficientes, se analizan en comparación con las LME (liberal market economies), que se eligieron como categoría base para el one hot encoding. Así, las empresas situadas en países Estadistas (0,125) y en los CEECs (0,2133) presentan una mayor probabilidad de estar utilizando herramientas de People Analytics para la evaluación del desempeño, manteniendo constantes las demás variables del modelo. En cambio, el coeficiente negativo de -0,0471 de las economías CME indica una menor probabilidad de adopción frente a las LME.

En cuanto al sector de actividad, varios sectores presentan una relación significativa con el uso de herramientas de People Analytics para la evaluación del desempeño. Con un nivel de significancia del 10% destacan construcción, comercio mayorista y minorista, y artes y recreación; al 5% el sector financiero y de seguros; y al 1% manufactura y transporte y almacenamiento. En cuanto a la interpretación de sus coeficientes, comparado con el sector de referencia (information and communication), los sectores con un mayor uso de estas herramientas son manufactura (0,11), venta mayorista y minorista (0,0657), financiero y de seguros (0,1206), y transporte y almacenamiento (0,1171), mientras que en sectores como construcción (-0,0916) y artes y entretenimiento (-0,1140) la adopción es menor.

Pasando a analizar el segundo modelo en el que se incorporan variables de recursos humanos, resulta interesante analizar como varían los coeficientes y significancias de nuestro modelo inicial. La mayoría de las variables de control se mantienen significativas, lo que refuerza su relevancia en la explicación del uso de People Analytics. Sin embargo, tres variables pierden significancia: construcción, finanzas y seguros y artes y entretenimiento, esta última con un p-value de 0,142. Además, el sector de transporte y almacenamiento experimenta una leve pérdida de significancia, pasando de ser significativa al 1% a serlo al 5%. Por otro lado, todas las variables confirman la dirección de su relación con la variable dependiente, aunque con

algunas variaciones en sus coeficientes. En cuanto a las variables nuevas incorporadas en este modelo sobre indicadores de recursos humanos, ninguna resulta ser significativa a excepción de la utilización de retribución flexible basada en el desempeño individual (*vpinper_d*) cuya significancia es del 5% y presenta una relación negativa con la variable dependiente, siendo su coeficiente de -0,0199.

Por último, al incorporar al último modelo las variables de negocio de competitividad y beneficios se ve que algunas se mantienen estables mientras otras varían respecto al modelo anterior. Las variables *ecommerce*, el sector de transporte y almacenamiento, CEECs, Estadistas y retribución flexible basada en el desempeño individual mantienen el nivel de significancia respecto al anterior modelo. Por otro lado, la edad del establecimiento y el sector manufacturero pierden significancia, pasando de ser significativas al 1% al 5%, mientras que el sector de venta mayorista y minorista deja de ser significativa, habiéndolo sido anteriormente al 10%. En cambio, las variables correspondientes a sector de construcción y servicios de alojamiento y de comida ganan significancia estadística, pasando de no ser significativas a serlo al 10%, y el grupo de países CME aumenta su significancia, mejorando del 5% al 1%. Respecto a sus coeficientes todos mantienen la misma dirección, pero cambia la importancia que se le da en el modelo. Si comparamos la variación de los coeficientes de las variables de control entre el primer modelo y el último, la variable *ecommerce* es la que más estable se mantiene, que apenas ha aumentado un 1%. En contraste, destacan las variaciones en el sector de servicios de alojamiento y de comida, cuyo coeficiente se incrementa en sentido negativo un 97%, pasando de -0,0602 a -0,1188, y el de las economías CME, que también intensifican su efecto negativo con un aumento del 128%, pasando de -0,0471 al -0,1072. El resto de los coeficientes presentan variaciones más moderadas: entre un 10% y un 25% para CEECs, economías estadistas, transporte y almacenamiento y construcción, y entre un 26% y un 40% para edad del establecimiento e industria manufacturera. *Vpinper_d*, única variable de recursos humanos que resulta significativa, presenta una variación en sentido negativo del 11%, calculada como la diferencia entre su coeficiente en el segundo y el tercer modelo.

En relación con las nuevas variables incorporadas sobre indicadores de negocio, destacan como significativas las variables de competitividad sobre la importancia de tener precios bajos y la competitividad del mercado en el que operan, al 5% y 1% respectivamente. Por otro lado, entre las variables relacionadas con beneficios, únicamente *profplan* resulta significativa al 5%. En todos los casos, los coeficientes asociados con estas son positivos, lo que sugiere una relación directa con la utilización de herramientas de People Analytics.

5. Discusión

5.1. Conclusión

A continuación, se presenta la discusión de los principales resultados obtenidos en relación con las hipótesis formuladas, tratando de manera paralela las limitaciones del estudio y propuestas para futuras investigaciones.

H1: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está correlacionado con la utilización de políticas de compensación variable. (HR KPIs).

Los resultados del modelo 3 llevan a una aceptación parcial de la H1, la compensación variable basada en el desempeño individual (V_{pinper}) presenta una correlación significativa negativa con el uso de People Analytics para la evaluación del desempeño, mientras que los pagos variables basados en grupos, incluso en el desempeño de la organización (V_{pgrpe} , V_{pprsh_d}) no resultan significativos. Este resultado sugiere que las organizaciones que utilizan People Analytics tienden a depender menos de bonificaciones individuales, una posible explicación es que la objetividad que aporta People Analytics puede suponer un énfasis excesivo en recompensas extrínsecas individualistas, lo que puede resultar contraproducente (fomentando competencia malsana y reduciendo la colaboración), por lo que las empresas avanzadas en analítica optarían por motivadores alternativos centrados en el desarrollo y la retroalimentación continua en lugar de bonos individuales. La falta de significancia de los incentivos grupales puede sugerir que las retribuciones variables basadas en desempeños dependen más de factores macro (rentabilidad, cultura organizativa) que, de sistemas analíticos, por lo que no se aprecia una relación clara con People Analytics. Cabe señalar que al ser un estudio transversal no se puede inferir causalidad; además, factores contextuales (industria, país) o la forma de medir las variables podrían influir en la relación observada. En conjunto, aunque la literatura anticipaba sinergias positivas entre People Analytics y la retribución variable, la evidencia empírica aún es incipiente en este ámbito. Como futuras líneas de investigación, nuestros hallazgos sugieren que el uso de People Analytics podría conllevar un replanteamiento de los sistemas de incentivos, primando un enfoque integral de la gestión del desempeño por encima de la recompensa individual.

H2: El uso de herramientas de People Analytics para la evaluación del desempeño está asociado con una mayor optimización de talento

La hipótesis H2 planteaba que el uso de herramientas de People Analytics en la evaluación del desempeño se asociaría con una mayor optimización del talento; sin embargo, los resultados del estudio no evidencian ninguna relación estadísticamente significativa con los indicadores analizados (ausentismo, motivación, dificultad para encontrar y retener talento). Una posible explicación es que dichas métricas están fuertemente influenciadas por factores de clima laboral y bienestar organizacional, más que por la metodología de evaluación del desempeño en sí.

Asimismo, cabe destacar que la “optimización del talento” es un concepto muy amplio que podría requerir integrar People Analytics en diversos procesos de RR.HH. (selección, desarrollo, incentivos etc.), lo que el hecho de que nuestro modelo lo haya medido solamente en función de la evaluación del desempeño es una limitación de nuestro análisis que abre una futura línea de investigación en relación al uso de people analytics en todas las áreas de RRHH. De hecho, estudios previos señalan que la analítica de RR.HH. produce beneficios claros solo cuando se combina con prácticas complementarias alineadas con la estrategia (por ejemplo, sistemas de incentivos adecuados). En conjunto, estos factores podrían explicar la falta de significancia observada, coincidente con lo señalado en la literatura, que advierte que la evidencia de impactos directos de People Analytics en indicadores de talento sigue siendo limitada.

H3: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con la competitividad del negocio.

Los resultados de la investigación apoyan parcialmente la hipótesis H3, al mostrar que el uso eficaz de herramientas de People Analytics se asocia con ciertos factores clave de competitividad empresarial. En mercados altamente competitivos, el rendimiento tanto individual como colectivo se convierte en un elemento crucial para destacar frente a otros competidores. Esta presión por diferenciarse impulsa a muchas organizaciones a adoptar herramientas de people analytics que les aseguren así la productividad y eficiencia de sus trabajadores, dos elementos directamente vinculados a la obtención de ventajas competitiva. De forma particular, destaca la relación significativa con las empresas que siguen estrategias de liderazgo en costes, es decir, aquellas que compiten ofreciendo precios bajos. En estos casos,

los márgenes de beneficio suelen ser muy ajustados, por lo que cualquier mejora o por el contrario empeoramiento en la eficiencia operativa tiene un impacto significativo. Para estas compañías, People Analytics representa una herramienta estratégica para identificar ineficiencias y maximizar el rendimiento de su plantilla, asegurando así sus márgenes positivos. En cambio, la falta de significancia en empresas orientadas a la innovación, por ejemplo, aquellas que priorizan el desarrollo de nuevos productos o servicios podría explicarse por un enfoque distinto: en estos entornos, los esfuerzos suelen concentrarse en I+D y en fomentar una cultura creativa más abierta al ensayo y error. Por tanto, el rendimiento individual a corto plazo puede ser menos relevante que el potencial a futuro, algo que supone una limitación para sacar conclusiones a partir de nuestro modelo cuyo alcance se limita a un año concreto.

H4a: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con una mayor obtención de beneficios actuales.

Los resultados obtenidos no respaldan la hipótesis H4a, ya que no se ha encontrado una relación significativa entre el uso de herramientas de People Analytics para la evaluación del desempeño y la obtención de beneficios (profit). Este hallazgo, podría explicarse desde varias perspectivas. En primer lugar, es importante señalar la ya mencionada limitación de nuestro estudio en términos temporales, los datos analizados corresponden a un único año, lo que limita la posibilidad de identificar causalidad o relaciones de impacto a medio y largo plazo. Además, las herramientas de People Analytics, especialmente aquellas centradas en la evaluación del desempeño, suelen generar beneficios indirectos y sostenidos en el tiempo, como reducción de errores o aumento del compromiso, cuyos efectos financieros pueden tardar en materializarse. Además, el hecho de que una empresa haya obtenido beneficios en un año determinado puede estar condicionado por múltiples factores externos que no se hayan tenido en cuenta en esta investigación como el contexto económico o decisiones estratégicas pasadas que puedan estar teniendo repercusión en los resultados presentes. En resumen, la ausencia de significancia en esta variable pone de manifiesto la necesidad de estudios longitudinales que permitan capturar su verdadero impacto en la rentabilidad empresarial a lo largo del tiempo.

H4b: El uso eficaz de herramientas de People Analytics para la evaluación del desempeño está positivamente correlacionado con un crecimiento favorable.

Los resultados del modelo validan parcialmente la hipótesis H4b, mostrando que el uso de herramientas de People Analytics para la evaluación del desempeño se correlaciona de forma significativa con el crecimiento. Por un lado, las empresas que prevén obtener beneficios en el futuro suelen mostrar una mayor predisposición a invertir en herramientas como People Analytics, ya que la planificación de sus resultados requiere analizar el desempeño pasado para tomar decisiones más informadas y acertadas de cara al futuro.

En contraste, la variable *chempfut*, que refleja la expectativa de cambio en el tamaño de la plantilla, no muestra significancia estadística. Esto puede deberse a que las decisiones sobre contratación o reducción de personal suelen estar influidas por factores externos, como las condiciones del mercado laboral, políticas públicas o cambios sectoriales, y no necesariamente por procesos de evaluación del desempeño.

Además, las variables de control utilizadas en el modelo nos confirman que el uso de People Analytics para la evaluación del desempeño puede verse influido por diversas características estructurales y contextuales de las empresas. Por un lado, las empresas más antiguas tienden a ser más conservadoras y reticentes a modificar sus métodos tradicionales de gestión. Su confianza en prácticas establecidas a lo largo del tiempo podría considerarse como una barrera frente a la implantación de herramientas tecnológicas a las que no están habituados sus empleados. Siguiendo este contexto empresas más acostumbradas a entornos digitales como aquellas que utilizan el comercio electrónico como canal de distribución, muestran una correlación con el uso de people analytics. Su familiaridad con entornos digitales y su necesidad de adaptarse constantemente al cambio facilita la integración de sistemas avanzados de evaluación del rendimiento, en línea con una cultura organizativa orientada a la evaluación de grandes cantidades de datos. Además, el sector de actividad también juega un papel relevante, en general mientras que los sectores tecnológicos tienden a adoptar con mayor facilidad este tipo de herramientas, sectores más tradicionales, como la construcción o la manufactura, muestran una resistencia mayor al cambio tecnológico. Por último, el entorno regulatorio y geográfico también es determinante. Empresas localizadas en regiones con marcos normativos más estrictos, como países estatistas de la Unión Europea, se ven prácticamente obligadas a implementar soluciones de People Analytics para cumplir con

requisitos establecidos, que pueden exigir la elaboración de reportes detallados incluyendo datos sobre la gestión del talento.

Por último, si bien el estudio ha permitido identificar numerosos hallazgos relevantes sobre la relación entre el uso de herramientas de People Analytics y diversos indicadores tanto de recursos humanos como de negocio, es importante reconocer sus limitaciones generales. El diseño del análisis es de naturaleza transversal y se basa en una variable dependiente binaria que únicamente refleja si la empresa utiliza o no People Analytics para evaluar el desempeño. Esto impide establecer relaciones de causalidad o captar la intensidad o calidad de dicha utilización. En cuanto al resto de variables, algunas presentan una distribución de respuestas no homogénea, por lo que sería conveniente aplicar un muestreo estratificado. Además, el enfoque sobre el desempeño como única dimensión analizada de RRHH podría resultar restrictivo, dado que el impacto del People Analytics puede extenderse a otras áreas clave como la retención, el compromiso o el desarrollo del talento. Incorporar métricas adicionales permitiría una visión más integral de sus efectos. Por otro lado, la muestra del estudio se limita a empresas ubicadas en Europa, lo que acota la generalización de los resultados. En un contexto globalizado, donde las prácticas de gestión del talento varían significativamente entre regiones, sería recomendable ampliar el alcance geográfico en futuras investigaciones para capturar una diversidad más representativa de enfoques organizativos y marcos regulatorios.

5.2. Implicaciones para las organizaciones

Aunque People Analytics se ha convertido en una herramienta clave para no quedar rezagado en un entorno cada vez más digitalizado (especialmente en grandes organizaciones que gestionan volúmenes masivos de datos), su verdadero potencial solo se alcanza cuando se utiliza de manera adecuada. En este sentido, es responsabilidad de las organizaciones aprovechar al máximo sus capacidades para obtener ventajas competitivas reales. Por ello, a continuación, se plantean algunas implicaciones clave para una implementación efectiva de People Analytics en las organizaciones.

Decisión estratégica: desarrollo interno vs. subcontratación

Una de las primeras decisiones clave que deben tomar las organizaciones es si desarrollar internamente sus sistemas de People Analytics o subcontratar soluciones ya existentes en el mercado. El desarrollo interno ofrece un mayor control, personalización y la posibilidad de monetizar la herramienta en el futuro. Sin embargo, requiere recursos técnicos, tiempo y una inversión considerable. Subcontratar, por su parte, permite una implementación más rápida, aunque puede ser menos flexible. La elección debe alinearse con la estrategia y las capacidades de la empresa y de sus empleados.

Aplicación integral a lo largo de todo el *employee journey*

Para maximizar su valor, People Analytics debe aplicarse a todo el ciclo de vida del empleado, y no limitarse únicamente a la evaluación del desempeño. Desde la fase de selección y onboarding, hasta la gestión del desarrollo, la promoción y las entrevistas de salida, el análisis de datos puede generar insights valiosos. Esto permite tomar decisiones basadas en evidencia en cada punto crítico del *employee journey*, mejorando la experiencia del empleado en su conjunto y optimizando de esta forma la gestión del talento.

Capacitación de la plantilla para el uso eficaz de las herramientas

Contar con herramientas de análisis de datos sin que los empleados sepan utilizarlas correctamente reduce completamente su utilidad. Es fundamental ofrecer formación continua a los equipos de recursos humanos, managers y otros usuarios clave. Esta capacitación debe enfocarse tanto en habilidades técnicas como en la interpretación de los resultados.

Migración de datos históricos a nuevos sistemas

La transición hacia nuevas plataformas analíticas conlleva el reto de integrar correctamente los datos históricos. Una migración eficiente asegura la continuidad del análisis y evita perder información valiosa del pasado. Este proceso requiere planificación, validación y limpieza de los datos antiguos para que sean compatibles con los nuevos sistemas.

Protección de datos y cumplimiento normativo

El uso de People Analytics implica el tratamiento de datos sensibles sobre empleados, lo que exige una gestión rigurosa de la privacidad y la seguridad. Las organizaciones deben asegurarse de cumplir con normativas como el RGPD (en Europa) u otras leyes locales de protección de datos. Esto implica establecer protocolos claros sobre el almacenamiento, acceso y uso de la información, así como fomentar una cultura organizacional que respete la confidencialidad.

Interpretación y toma de decisiones

Disponer de grandes volúmenes de datos no es suficiente si no se sabe interpretar ni traducir en decisiones prácticas. La clave está en combinar los resultados de los modelos analíticos con el conocimiento profundo del negocio que tienen los responsables de RRHH y la dirección. Los datos son una base objetiva, pero requieren ser contextualizados y evaluados críticamente para que la toma de decisiones sea realmente efectiva y alineada con los objetivos estratégicos.

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

Por la presente, yo, Alejandra Charola Gonzalez, estudiante de ADE + Business Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Evaluación del desempeño mediante People Analytics: Implicaciones para el impacto en la gestión de recursos humanos y el crecimiento empresarial", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
10. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
11. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
12. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 9 de abr. de 25

Firma:



6. Bibliografía

Angrave, D., Charlwood, A., Kirkpatrick, I., Lawrence, M., & Stuart, M. (2016). HR and analytics: Why HR is set to fail the big data challenge. *Human Resource Management Journal*, 26(1), 1-11. <https://doi.org/10.1111/1748-8583.12090>

Armstrong, M. (2014). *Armstrong's handbook of human resource management practice* (13^a ed.). Kogan Page.

Basnet, S. (2024). The impact of AI-driven predictive analytics on employee retention strategies. *International Journal of Research and Review*, 11(9), 50-65. <https://doi.org/10.52403/ijrr.2>

Bechter, B., Brandl, B. & Lehr, A. (2022) The role of the capability, opportunity, and motivation of firms for using human resource analytics to monitor employee performance: A multi-level analysis of the organisational, market, and country context. *New Technology, Work and Employment*, 37, 398–424. <https://doi.org/10.1111/ntwe.12239>

Belizon, M.J., Majarín, D. & Aguado, D. (2023) Human resources analytics in practice: A knowledge discovery process. *European Management Review*, 1–19. <https://doi.org/10.1111/emre.1260>

Belizón, M. J., & Kieran, S. (2021). Human resources analytics: A legitimacy process. *Human Resource Management Journal*, 1–30. <https://doi.org/10.1111/1748-8583.12417>

Belizon, M.J., Majarín, D.& Aguado, D. (2024) Human resources analytics in practice: A knowledge discovery process. *European Management Review*, 21(3), 659–677. <https://doi.org/10.1111/emre.12605>

Boudreau, J. W., & Ziskin, I. (2011). The future of HR and effective organizations. *Organizational Dynamics*. <https://doi.org/10.1016/j.orgdyn.2011.07.003>

Cambridge University Press. (s. f.). Big data. *Cambridge Dictionary*. Recuperado de <https://dictionary.cambridge.org/es/diccionario/ingles-espanol/big-data>

Charlwood, A., & Valizade, D. (2019). *Predictive Analytics and Data Science: A Guide for HR Analytics Leaders*. HR Analytics ThinkTank.

Edwards, D, Trigg, L, Carrier, J, Cooper, A, Csontos, J, Day, J, Gillen, E, Lewis, R and Edwards, A. 2022. A rapid review of innovations for attraction, recruitment and retention of social care workers, and exploration of factors influencing turnover within the UK context. *Journal of Long- Term Care*, (2022), pp. 205–221. DOI: <https://doi.org/10.31389/jltc.130>

Huselid, M. A. (2018). The science and practice of workforce analytics: Introduction to the HRM special issue. *Human Resource Management*, 57(3), 679-684. <https://doi.org/10.1002/hrm.21916>

Johnson, R. D., Lukaszewski, K. M., & Stone, D. L. (2016). The evolution of the field of human resource information systems: Co-evolution of technology and HR processes. *Communications of the Association for Information Systems*, 38

Mathur, S. (2019). Artificial Intelligence: Redesigning Human Resource Management, Functions and Practices. *Human Resource: People, Process Technology*, (April 2019)

McCartney, S., & Fu, N. (2022). Bridging the gap: why, how and when HR analytics can impact organizational performance. *Management Decision*, 60(13), 25–47. <https://doi.org/10.1108/MD-12-2020-1581>

Minbaeva, D. B. (2018). Building credible human capital analytics for organizational competitive advantage. *Human Resource Management*, 57(3), 701-713.

Randstad Research. (noviembre, 2024). *Informe sobre inteligencia artificial y recursos humanos*. Randstad.

Randstad Research. (febrero, 2024). *IA y Mercado de trabajo en España. Una aproximación cuantitativa y cualitativa a los efectos futuros de una tecnología revolucionaria*. Randstad.

Ranera, M. (2020) Transformación digital en RRFF, 5º estudio en España. https://www.incipy.com/wp-content/uploads/2020/02/5%C2%BA_ESTUDIO-transformation_Digital_RRHH_Cast_WEB_AF.pdf

Shaout, A., & Yousif, M. K. (2014). *Performance Evaluation – Methods and Techniques: Survey*. International Journal of Computer and Information Technology, 3(5), 966-979.

The Wise Seeker. (2022). *Propuesta estratégica C-Level 9.0*. The Wise Seeker.

Yousuf, S., & Siddqui, D. (2018). Factors Influencing Employee Retention: A Karachi Based Comparative Study on IT and Banking Industry. *International Journal of Human Resource Studies*, 9(1), Pages 42-62. doi:<http://dx.doi.org/10.5296/ijhrs.v9i1.14111>