

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE GRADO

ANÁLISIS DE AGENTES INTELIGENTES APLICADO A LA GESTIÓN DE PERSONAS EN LAS ORGANIZACIONES

Titulación: Doble Grado en Ingeniería en Tecnologías de la Telecomunicación y Administración y dirección de empresas

Mención: Telemática

Autor: ANTONIO CRISTIAN REGINA PUCCINI

Tutor: ITZIAR GORETTI ALONSO GONZÁLEZ, PETRA DE SAÁ PÉREZ

Fecha: 11 de julio de 2025

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE GRADO

ANÁLISIS DE AGENTES INTELIGENTES APLICADO A LA GESTIÓN DE PERSONAS EN LAS ORGANIZACIONES

HOJA DE EVALUACIÓN

Presidente/a:

Fdo.: _____

Vocal

Fdo.: _____

Secretario/a

Fdo.: _____

Fecha: 11 de julio de 2025

Resumen

El presente Trabajo de Fin de Grado aborda la aplicación de la Inteligencia Artificial (IA) en la gestión de personas desde una doble perspectiva: teórica y práctica. La primera parte consiste en un análisis exhaustivo de la literatura científica sobre el tema, centrándose en publicaciones desde el año 2020. Para ello, se aplicó una metodología mixta que combina un análisis bibliométrico y una revisión sistemática sobre un corpus de 226 artículos, utilizando herramientas de análisis de datos como VOSviewer y herramientas de IA como NotebookLM y Gemini. La segunda parte del trabajo se enfoca en el diseño y desarrollo de una solución de ingeniería: un agente de IA funcional concebido como una herramienta de asistencia a la investigación, capaz de automatizar la clasificación de artículos científicos.

El análisis de la literatura revela que la IA está redefiniendo las funciones de Recursos Humanos (RRHH) hacia una mayor personalización y optimización, aunque su adopción presenta desafíos significativos en dimensiones ético-algorítmicas, de gestión de datos y humano-organizacionales. Como respuesta práctica a la complejidad de realizar estos análisis, la segunda parte detalla la construcción de un Producto Mínimo Viable (MVP) de un agente de IA. Este prototipo, implementado en la plataforma de automatización n8n, utiliza un flujo de trabajo asíncrono para evaluar la relevancia de artículos basándose en sus metadatos y una rúbrica de evaluación estructurada. Las pruebas comparativas entre distintos Modelos de Lenguaje Extenso (LLM) validaron la robustez de la rúbrica, demostrando una consistencia moderada en sus calificaciones y una capacidad superior a la de una simple búsqueda por palabras clave.

En conclusión, este trabajo no solo sintetiza el estado del arte sobre la IA en la gestión de personas, identificándolo como un desafío sociotécnico, sino que también aporta una solución práctica y validada. El agente de IA desarrollado se posiciona como una herramienta eficaz para la criba de literatura académica, ofreciendo resultados cualitativos, justificables y más inclusivos que los métodos tradicionales. Finalmente, se presenta una hoja de ruta para la evolución futura del agente, que incluye la integración directa con bases de datos académicas y la implementación de arquitecturas de Generación Aumentada por Recuperación (RAG) para permitir un análisis de contenido más profundo y contextualizado.

Abstract

This Final Degree Project addresses the application of Artificial Intelligence (AI) in people management from a dual perspective: theoretical and practical. The first part consists of a comprehensive analysis of the scientific literature on the subject, focusing on publications since 2020. A mixed-methodology approach was applied, combining bibliometric analysis and a systematic review of a 226-article corpus, using data analysis tools like VOSviewer and AI tools like NotebookLM and Gemini. The second part of the project focuses on the design and development of an engineering solution: a functional AI agent conceived as a research assistance tool, capable of automating the classification of scientific articles.

The literature review reveals that AI is redefining Human Resources (HR) functions towards greater personalization and optimization, although its adoption presents significant challenges in ethical-algorithmic, data management, and human-organizational dimensions. As a practical response to the complexity of conducting such analyses, the second part details the construction of a Minimum Viable Product (MVP) of an AI agent. This prototype, implemented on the n8n automation platform, uses an asynchronous workflow to assess the relevance of articles based on their metadata and a structured evaluation rubric. Comparative tests among different Large Language Models (LLMs) validated the rubric's robustness, demonstrating moderate consistency in their ratings and a superior capability compared to simple keyword searches.

In conclusion, this project not only synthesizes the state-of-the-art on AI in people management, identifying it as a sociotechnical challenge, but also provides a practical and validated solution. The developed AI agent is positioned as an effective tool for screening academic literature, offering qualitative, justifiable, and more inclusive results than traditional methods. Finally, a roadmap for the agent's future evolution is presented, which includes direct integration with academic databases and the implementation of Retrieval-Augmented Generation (RAG) architectures to enable deeper and more contextualized content analysis.

Agradecimientos

En primer lugar, me gustaría expresar mi más sincero agradecimiento a mis tutoras. No solo por haberme propuesto un tema de investigación tan actual e interesante, sino también por su guía, paciencia y apoyo incondicional durante todo el desarrollo de este trabajo. Sus valiosas orientaciones han sido fundamentales, así como los desayunos compartidos de los viernes, que siempre aportaban una dosis extra de motivación.

Este camino no habría sido posible sin el pilar fundamental que es mi familia. Quiero dar las gracias a mis padres, a mi hermano y, cómo no, a mi perro, por haber estado a mi lado desde el primer día de carrera. Vuestro apoyo constante y vuestra confianza en mí han sido la fuerza que me ha impulsado a llegar hasta aquí; sin vosotros, no habría llegado tan lejos.

Por último, pero no por ello menos importante, quiero agradecer a mis amigos. Gracias por vuestro gran apoyo, por las risas, los ánimos en los momentos de agobio y por hacer de estos años una etapa inolvidable.

Tabla de contenido

| | |
|---|------------|
| Resumen | a |
| Abstract | b |
| Tabla de contenido | i |
| Índice de Tablas | iii |
| Índice de Figuras | iv |
| Introducción General al Proyecto y sus Partes. | 6 |
| PARTE 1: LA IA APLICADA A LA GESTIÓN DE PERSONAS: UN ENFOQUE DESDE LA ADMINISTRACIÓN Y DIRECCIÓN DE EMPRESAS. | 8 |
| Introducción | 8 |
| Capítulo 1. Fundamentos Teóricos: Conceptos clave. | 9 |
| Capítulo 2. Metodología | 12 |
| Capítulo 3. Resultados | 17 |
| 1. Resultados del Análisis Bibliométrico | 17 |
| 2. Resultados de la Revisión Sistemática de la Literatura. | 27 |
| Capítulo 4. Conclusiones | 35 |
| Parte 2. DISEÑO Y DESARROLLO DE UN AGENTE DE IA PARA EL ESTUDIO DE REFERENCIAS BIBLIOGRÁFICAS EN EL ÁMBITO DE LA GESTIÓN DE PERSONAS EN LAS ORGANIZACIONES | 38 |
| Capítulo 5. Introducción | 38 |
| Capítulo 6. Estado del arte: Fundamentos del Dominio de Aplicación y Arquitecturas Tecnológicas del MVP. | 40 |
| 1. Marco conceptual de la Gestión de Personas en las Organizaciones | 40 |
| 2. Fundamentos técnicos para el desarrollo de agentes de IA. | 43 |
| 2.1. Definiciones Clave y Evolución Histórica. | 44 |
| 2.2. Fundamentos de la IA Generativa y los Sistemas de Agentes | 48 |
| Capítulo 7. Diseño y Desarrollo de un Agente de IA para la Asistencia a la investigación. | 60 |

| | |
|---|---------------|
| 1. Fase 1: Análisis de metadatos y primeras categorizaciones..... | 63 |
| 2. Fase 2: Exploración de Enfoques Avanzados Basados en Contenido Completo | 73 |
| 3. Arquitectura propuesta para el MVP y flujo de trabajo de N8N. | 76 |
| 4. Hoja de ruta y evolución futura del agente | 80 |
| Capítulo 8. Conclusiones y resultados del Agente..... | 82 |
| Bibliografía Parte 1 (ADE). | 85 |
| Bibliografía Parte 2 (GITT)..... | 96 |
| Presupuesto..... | 104 |
| 1. Amortización y coste de recursos materiales..... | 104 |
| 1.1. Amortización del material hardware..... | 104 |
| 1.2. Coste del material software..... | 105 |
| 2. Trabajo tarifado por tiempo empleado | 105 |
| 3. Redacción de documentación..... | 106 |
| 4. Aplicación de impuestos y coste total | 107 |
| ANEXOS | - 1 - |
| 1. Parte 1: ADE | - 1 - |
| 1.1. Análisis de citación de documentos..... | - 1 - |
| 1.2. Análisis de acoplamiento bibliográfico | - 6 - |
| 2. Parte 2: GITT..... | - 17 - |
| 2.1. Prompt del agente calificador con rúbrica..... | - 17 - |

Índice de Tablas

| | |
|---|-------|
| <i>Tabla 1: Definiciones de IA</i> | 10 |
| <i>Tabla 2: Clústeres, Palabras Clave y Artículos</i> | 17 |
| <i>Tabla 3: Resumen de Aplicaciones de IA en las funciones de RRHH</i> | 28 |
| <i>Tabla 4: Principales Desafíos en la Implementación de IA en la Gestión de RRHH</i> | 31 |
| <i>Tabla 5: Principales Marcos Teóricos en la Investigación de IA en la Gestión de RRHH</i> | 33 |
| <i>Tabla 6: Hitos Históricos de la IA</i> | 46 |
| <i>Tabla 7: Resultados de Calificación Binaria por Modelo</i> | 65 |
| <i>Tabla 8: Distribución Temática por Modelo</i> | 66 |
| <i>Tabla 9: Interpretación de la puntuación para la sección "Temática General".</i> | 69 |
| <i>Tabla 10: Interpretación de la puntuación para las secciones de "Subgrupos".</i> | 69 |
| <i>Tabla 11: Tabla de amortización de recursos hardware</i> | 104 |
| <i>Tabla 12: Valores del factor de corrección en función a las horas trabajadas</i> | 106 |
| <i>Tabla 13: Presupuesto de Ejecución (Base para cálculo de documentación)</i> | 107 |
| <i>Tabla 14: Presupuesto Total del Proyecto</i> | 107 |
| <i>Tabla 15: Análisis de citación de documentos</i> | - 1 - |
| <i>Tabla 16: Análisis de acoplamiento bibliográfico</i> | - 6 - |

Índice de Figuras

| | |
|---|----|
| <i>Figura 1: Diagrama de flujo PRISMA del proceso de Selección de Artículos</i> | 15 |
| <i>Figura 2: Red de Coocurrencia de Palabras Clave sobre Inteligencia Artificial en la gestión de personas.</i> | 18 |
| <i>Figura 3: Red de citación de Documentos.</i> | 21 |
| <i>Figura 4: Red de acoplamiento bibliográfico</i> | 24 |
| <i>Figura 5: Esquema de un agente reactivo simple</i> | 52 |
| <i>Figura 6: Esquema de un agente reactivo basado en modelos</i> | 53 |
| <i>Figura 7: Esquema de un agente basado en objetivos</i> | 54 |
| <i>Figura 8: Esquema de un agente basado en utilidad</i> | 55 |
| <i>Figura 9: Esquema de un agente basado en aprendizaje</i> | 56 |
| <i>Figura 10: Ejemplo de agente en n8n</i> | 58 |
| <i>Figura 11: Estructura del Agente de IA para asistencia a la Investigación</i> | 62 |
| <i>Figura 12: Estructura visual de prompt con rúbrica</i> | 67 |
| <i>Figura 13: Distribución de Notas de Gemini</i> | 71 |
| <i>Figura 14: Distribución de Notas de ChatGPT</i> | 71 |
| <i>Figura 15: Gráfico de dispersión entre ChatGPT y Gemini</i> | 72 |
| <i>Figura 16: Agente de extracción de datos</i> | 74 |
| <i>Figura 17: Agente de Calificación Final</i> | 75 |
| <i>Figura 18: Arquitectura completa del MVP</i> | 76 |
| <i>Figura 19: Flujo de Trabajo del Agente Principal (Orquestador)</i> | 78 |
| <i>Figura 20: Flujo de Trabajo de Calificación Asíncrono</i> | 79 |

Lista de acrónimos

- IA: Inteligencia Artificial
- RRHH: Recursos Humanos
- MVP: Producto Mínimo Viable
- LLM: Modelo de Lenguaje Extenso
- RAG: Generación Aumentada por Recuperación
- GITT: Grado en Ingeniería de Tecnologías de Telecomunicación
- ADE: Administración y Dirección de Empresas
- PRISMA: Preferred Reporting Items for Systematic reviews and Meta-Analyses
- JSON: JavaScript Object Notation
- ATS: Applicant Tracking System
- PwC: PricewaterhouseCoopers
- VoE: Voz del Empleado
- L&D: Formación y Desarrollo
- IDSS: Sistemas inteligentes de Soporte a la Decisión
- RGPD: Reglamento General de Protección de Datos
- TOE: Tecnología-Organización-Entorno
- UTAUT: Teoría Unificada de Aceptación y Uso de la Tecnología
- RBV: Visión Basada en Recursos
- DCV: Visión Basada en Capacidades Dinámicas
- STS: Teoría de Sistemas Sociotécnicos
- OSF: Teoría de Socialización Organizacional
- CVs: Currículums
- GPUs: Unidades de Procesamiento Gráfico
- GOFAI: Good Old Fashioned AI
- CPUs: Unidades de Procesamiento de Cálculo
- VRAM: Virtual Random Access Memory
- API: Interfaz de programación de aplicaciones
- SQL: Structured Query Language
- OCR: Reconocimiento Óptico de Caracteres
- GUI: Interfaz Gráfica de Usuario

Introducción General al Proyecto y sus Partes.

En el siglo XXI, tras los avances tecnológicos surgidos, las organizaciones se han ido adaptando al uso e integración de las tecnologías en su proceso de funcionamiento normal, y de entre todas las tecnologías la que está cobrando más fuerza en los últimos tres años es la inteligencia artificial (IA). Este avance promete grandes prestaciones, como el manejo, análisis e interpretación de grandes conjuntos de datos de manera rápida y con un margen de error asimilable. Aunque este área de conocimiento aún está en proceso de desarrollo y validación resulta de interés analizar y comprender cómo la aparición de IA, está afectando a los procesos de gestión de personas en las Organizaciones, con el auge de los agentes Inteligentes, también conocidos como agentes de IA.

Este Trabajo de Fin de Grado (TFG), desarrollado en el marco del doble grado en Ingeniería de Tecnologías de Telecomunicación (GITT) y Administración y Dirección de Empresas (ADE), aborda la creciente intersección entre la IA y la gestión de personas en las organizaciones.

Con este fin, el presente TFG persigue los siguientes objetivos generales:

- Analizar el estado del arte de la aplicación de la IA y en particular, los agentes de IA en la gestión de personas en las organizaciones identificando las principales tendencias y desafíos así como su impacto.
- Diseñar y proponer un agente de IA enfocado en una aplicación práctica dentro del ámbito de los RRHH. Por ello se investigarán las tecnologías existentes, definiendo sus requisitos técnicos y funcionales, y estableciendo una metodología para su potencial implementación y evaluación desde la perspectiva de la Ingeniería de Tecnologías de Telecomunicación.

Para alcanzar estos objetivos el trabajo se ha estructurado en dos partes complementarias:

La Parte I, que abarca los capítulos del 1 al 4, se centra, con un enfoque desde la Administración y Dirección de Empresas (ADE), en un estudio del estado del arte sobre el uso de la IA y los agentes de IA en la gestión de personas. A través de una revisión de la literatura científica, se analizará cómo estas tecnologías están transformando prácticas clave de recursos humanos (RRHH), como la selección, el reclutamiento, la compensación y la evaluación del rendimiento.

La Parte II, que se desarrolla en los capítulos del 5 al 7, se orienta desde la Ingeniería de Tecnologías de Telecomunicación (GITT) al diseño y desarrollo de un agente de IA. La función principal de este agente es analizar referencias bibliográficas dentro del ámbito de la gestión de personas en la organización, basándose en palabras clave de interés o en una rúbrica específica. Esta sección abarcará la investigación de tecnologías existentes, el diseño conceptual del agente, la definición de sus requisitos y la propuesta de una metodología para su implementación y evaluación en un entorno de prueba.

Cabe destacar que, para mantener la rigurosidad académica, se seguirán las normativas de citación indicadas por las respectivas titulaciones(ADE y GITT). De este modo, la Parte I (ADE) empleará el formato de citas APA 7th, mientras que la Parte II (GITT) utilizará el formato IEEE. Consecuentemente, cada parte contará con su propia bibliografía específica y su correspondiente anexo, asegurando la diferenciación de las partes y el cumplimiento de los estándares de cada área.

PARTE 1: LA IA APLICADA A LA GESTIÓN DE PERSONAS: UN ENFOQUE DESDE LA ADMINISTRACIÓN Y DIRECCIÓN DE EMPRESAS.

Introducción

En esta primera parte del TFG, se profundizará en el análisis de la literatura científica y académica referente a la implementación de la IA y, más concretamente, los agentes de IA, en el ámbito de la gestión de Personas en las Organizaciones. El objetivo es comprender el impacto actual y potencial de estas tecnologías en las prácticas de RRHH y en la estrategia en torno a su utilización.

Para acotar este análisis y asegurar su actualidad, el estudio se centrará en artículos científicos publicados a partir del año 2020, con una previsión de que la mayoría de la literatura relevante se encuentre en inglés. El estudio cubrirá el espectro general de las prácticas tradicionales de RRHH donde la IA y los agentes de IA tienen o podrían tener aplicación, buscando una visión amplia. El enfoque se dirigirá hacia aspectos conceptuales, estratégicos, organizativos y éticos, reservando los detalles técnicos más específicos de las tecnologías para la Parte II de este TFG.

La metodología que guiará esta revisión combinará un análisis bibliométrico inicial, para obtener una visión general de la producción científica, con una posterior revisión sistemática de la literatura. Este proceso, que se apoyará en herramientas de IA para optimizar la gestión de la información, incluirá la formulación de la pregunta de investigación y el establecimiento de criterios rigurosos de búsqueda y selección. El Capítulo 2 ofrecerá un desglose exhaustivo de estas fases metodológicas. Posteriormente, el Capítulo 3 se centrará en presentar los resultados, detallando tanto los hallazgos del análisis bibliométrico y la revisión sistemática, así como las contribuciones de los trabajos más relevantes para culminar en una síntesis del estado del arte y un comentario de las principales conclusiones en el Capítulo 4.

Capítulo 1. Fundamentos Teóricos: Conceptos clave.

La gestión de personas constituye un pilar fundamental en la estrategia de cualquier organización. Los empleados, junto con los clientes, son uno de los grupos de interés más significativos, por lo que atender a sus necesidades y optimizar los procesos en los que participan es crucial. En el siglo XXI, la transformación digital ha llevado a las organizaciones a integrar nuevas tecnologías en su funcionamiento diario. Entre ellas, la IA ha emergido con fuerza, prometiendo revolucionar la manera en que se manejan, analizan e interpretan grandes volúmenes de datos con rapidez y precisión. Aunque la IA es un campo en constante evolución, su impacto en la gestión de personas ya es tangible (Al Qahtani & Alsmairat, 2023). Este estudio se enfoca en analizar cómo la IA, y especialmente cómo el reciente auge de los agentes de IA está influyendo en los procesos clave de RRHH. La pregunta central que guía esta parte del estudio es: ¿Cómo afecta la adopción de agentes de IA en los procesos clave de RRHH?

Para abordar esta cuestión, resulta imprescindible delimitar primero el concepto de gestión de RRHH, un término que ha sido definido desde diversas perspectivas por múltiples autores. Por ejemplo, Schermerhorn (2001) la describe como el proceso de incrementar y desarrollar una fuerza de trabajo inteligente con el fin de ayudar a la empresa a alcanzar sus metas, incluyendo la misión, visión y objetivos varios. Por su parte, Storey (2004) la considera un método de gestión de empleados que busca mantener una fuerza de trabajo habilidosa y dedicada a través de varias técnicas estructurales, culturales y personales para otorgar a la organización una ventaja competitiva. Finalmente, Boselie et al. (2005) la conciben como una colección de sistemas o prácticas de RRHH interconectadas entre sí. Tomando estas consideraciones, para este trabajo se entiende la gestión de RRHH como el conjunto de prácticas y políticas necesarias para dirigir los aspectos de los puestos de las personas en la organización, incluyendo el reclutamiento, la selección, la formación, las remuneraciones y la evaluación del desempeño. En este contexto, la irrupción de la IA plantea tanto oportunidades como desafíos significativos. Por ello, esta primera parte del trabajo se centrará en la identificación y análisis de los enfoques y modelos de gestión de personas impactados por estas tecnologías, a fin de construir un marco conceptual sólido y detectar las principales tendencias, junto con los desafíos metodológicos y éticos más significativos.

Comenzando por entender qué es la IA, en la tabla 1 se presentan algunas definiciones y acepciones.

Tabla 1: Definiciones de IA

Fuente: elaboración propia

| Autor | Definición |
|-------------------------------------|---|
| (Mccarthy et al., 2006) | Hacer que una máquina se comporte de maneras que se llamarían inteligentes si un ser humano se estuviera comportando como tal. |
| (Dwivedi et al., 2021) | Inteligencia no humana diseñada para completar actividades y tareas específicas. |
| (Rich, 1983) | El estudio de cómo hacer que los ordenadores hagan cosas para las cuales los humanos son mejores por el momento. |
| (Adams et al., 2012) | Un sistema diseñado para el aprendizaje y la replicación de la cognición humana y las capacidades intelectuales, hasta el punto de potencialmente superar el rendimiento humano. |
| (Thierer et al., 2017) | La exhibición de inteligencia por parte de una máquina cercana o superior a las capacidades humanas. |
| (Huang & Rust, 2018; Robbins, 2020) | Un conjunto de instrucciones informáticas basadas en algoritmos, programadas para aprender y adaptarse por sí mismas a un entorno determinado. |
| (Rodgers, 2019a; Rodgers 2019b) | Una tecnología que intenta simular el razonamiento humano en ordenadores y otros tipos de máquinas. |
| (Ren et al., 2018) | La imitación del procesamiento de la información del pensamiento humano mediante algoritmos de aprendizaje automático, permitiendo que la máquina realice trabajos que pueden hacer los humanos, lo cual constituye la base de la inteligencia computacional. |

Tal y como se desprende de la definiciones, aunque el concepto de IA ha evolucionado sigue manteniendo un núcleo común. Las definiciones iniciales, como la de Mccarthy et al. (2006) o Rich (1983), se centraban en la capacidad de las máquinas para imitar o igualar el comportamiento humano inteligente. Con el tiempo, el enfoque se desplazó hacia la capacidad de la IA para superar el rendimiento humano (Adams et al., 2012; Thierer et al., 2017) y simular el razonamiento (Rodgers, 2019a; Rodger, 2019b). Las definiciones más contemporáneas, sin embargo, ponen el énfasis en el aprendizaje y la adaptación autónoma. En este sentido, la definición aportada por Huang & Rust, (2018); Robbins (2020), que la describen como un conjunto de algoritmos programados para "aprender y adaptarse por sí mismos a un entorno determinado", es la que captura la esencia de los sistemas de IA modernos, que no solo ejecutan tareas, sino que evolucionan a través de la experiencia y los datos.

Una vez establecida esta comprensión de la IA como una tecnología adaptativa, y para profundizar en su aplicación en la gestión de personas, es pertinente clarificar el concepto central de este estudio que es el de agentes Inteligentes. Inicialmente, estos se concebían como programas informáticos capaces de operar de forma autónoma para alcanzar objetivos predeterminados (Wooldridge, 2013). Sin embargo, con la evolución de la IA, su comprensión se ha refinado. Actualmente, un Agente Inteligente se define de forma más específica como una entidad de software que puede realizar tareas con diversos grados de autonomía, recibiendo entradas (comandos o información del sistema) y produciendo salidas que retroalimentan y optimizan el sistema en el que operan (OECD, 2024).

Aplicados al ámbito de los RRHH, estos sistemas, que van más allá de la IA general, se caracterizan por su capacidad para percibir el entorno organizacional, tomar decisiones o asistir en ellas, e interactuar de forma autónoma con empleados o candidatos.

Estrechamente vinculado al alcance de este trabajo, se encuentran las Prácticas de RRHH que son objeto de transformación por la IA. Estas prácticas, tal como señalan Wall & Wood (2005), comprenden actividades fundamentales como el reclutamiento de nuevos empleados, su contratación efectiva, la gestión continua de su desempeño y su desarrollo profesional dentro de la organización. Un gran número de estas prácticas comparten un enfoque específico en la retención del talento y en el mantenimiento de niveles satisfactorios de compromiso y bienestar entre los empleados, aspectos donde la IA puede ofrecer nuevas herramientas y enfoques.

No obstante, no se debe obviar que la implementación de la IA en la gestión de personas no está exenta de consideraciones cruciales sobre la ética, a la hora de definir los principios morales y los valores que deben guiar el diseño, desarrollo y despliegue de sistemas de IA en el contexto laboral para asegurar un trato justo y respetuoso. Estos principios éticos varían de un autor a otro, pero se pueden resumir en los explicados por Floridi et al. (2018), los cuáles comprenden la beneficencia, autonomía, justicia y explicabilidad.

Además, dado que este TFG pretende analizar el impacto de la IA en la gestión de personas, es fundamental abordar el concepto de bienestar del empleado (employee wellbeing) en el contexto de la adopción tecnológica. Este es un concepto multidimensional y complejo para el que no existe una única definición; por ejemplo, Stefana et al. (2021) lo describen como el resultado de la unión de factores diversos, incluyendo la satisfacción con el puesto de trabajo, la conciliación laboral y la salud física y psicológica. Para obtener una comprensión más profunda del bienestar es útil examinar también conceptos estrechamente ligados que definen sus componentes esenciales. Uno de ellos es la calidad de vida laboral (QWL), que Mosisa et al. (2022) definen como la medida en que los empleados pueden satisfacer sus necesidades personales a través de su experiencia en el trabajo. Otro pilar fundamental es la satisfacción laboral, que aborda la dimensión emocional y evaluativa de la experiencia del empleado. Este constructo ha sido definido de varias maneras: desde una "visión emocional positiva del trabajo" (Marin-García et al., 2011) hasta las "actitudes y emociones de los empleados hacia el lugar de trabajo" (Department of Applied Economics and Management, National I-Lan University, Taiwan et al., 2018). En conjunto, estas perspectivas demuestran que el bienestar del empleado es un estado integral que se nutre tanto de la satisfacción con las tareas y el entorno como de la capacidad del trabajo para contribuir a una vida personal plena.

Capítulo 2. Metodología

Dada la naturaleza del tema abordado en este TFG, se ha optado por un enfoque metodológico mixto para la revisión de la literatura. Este enfoque combina un análisis bibliométrico inicial con una revisión sistemática posterior, proceso en el cual se ha incorporado el uso de agentes de IA como apoyo fundamental. El análisis bibliométrico se llevará a cabo predominantemente mediante métodos replicables, buscando seguir, en la medida de lo posible, las directrices PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses) (Page et al., 2021) para asegurar la transparencia y la calidad del procedimiento siguiendo una serie de fases claras, concisas y replicables (Da Silva et al., 2022).

Para la ejecución de este enfoque metodológico, se emplearon herramientas especializadas en cada fase. En la etapa de análisis bibliométrico y mapeo conceptual, la herramienta principal fue VOSviewer para generar las visualizaciones de redes. Para profundizar en la interpretación, los grafos generados se exportaron en formato JSON¹ y se utilizó Gemini para analizar la estructura compleja de estos archivos, extrayendo patrones y relaciones clave que no son inmediatamente evidentes. Posteriormente, en la fase de revisión sistemática profunda del corpus de 39 artículos, la herramienta principal fue NotebookLM. Se cargó el texto completo de cada artículo para crear una base de conocimiento específica. Sobre esta base, se realizaron consultas estructuradas en lenguaje natural (prompts) para interrogar al corpus sobre temas concretos. Por ejemplo, se formularon preguntas del tipo: "Sintetiza la información referente a los desafíos éticos, técnicos y humanos en la adopción de la IA en la gestión de RRHH, detallando los riesgos de sesgos algorítmicos, la necesidad de transparencia y los factores de aceptación organizacional". Este método de diálogo con la literatura permitió extraer y sintetizar la información de manera sistemática y orientada a los objetivos de la investigación.

¹ JSON (JavaScript Object Notation) es un formato de texto ligero para el intercambio de datos, basado en un subconjunto del estándar de JavaScript. Su sintaxis simple facilita que sea tanto legible por humanos como fácilmente analizable por las máquinas, convirtiéndolo en un estándar de facto para la transmisión de datos en aplicaciones web. (Bray, 2017)

El punto de partida de este proceso metodológico fue la fase de búsqueda y selección de literatura. Este proceso se inició estableciendo la problemática central: "Análisis de agentes inteligentes aplicados a la gestión de personas en organizaciones". A partir de aquí, se definió la pregunta de investigación que guía este estudio: ¿Cómo afecta la adopción de agentes de IA en los procesos clave de RRHH (selección, evaluación, desarrollo de talento, etc.) dentro de las organizaciones? Para responder a esta pregunta, se seleccionó la base de datos Scopus como fuente de información, buscando simplificar el proceso y reconociendo que, según Gavel & Iselid, 2008, Scopus dispone de un solapamiento considerable en la mayoría de las publicaciones relevantes con otra de las fuentes principales como es Web of Science. Las palabras clave utilizadas para la búsqueda en Scopus, enfocadas en el título, resumen y palabras clave de los artículos, fueron:

```
artificial intelligence, ai, machine learning, intelligent systems.  
human resource management, hrm, talent management, personnel management,  
people operations.
```

De forma deliberada, no se incluyeron términos como "agente inteligente" o "agente de IA" en esta fase inicial para permitir un análisis más general del panorama antes de profundizar en nichos específicos. La cadena de búsqueda introducida en Scopus fue la siguiente:

```
TITLE-ABS-KEY ( "artificial intelligence" OR ai OR "machine learning"  
OR "intelligent systems" ) AND TITLE-ABS-KEY ( "human resource  
management" OR hrm OR "talent management" OR "personnel management" OR  
"people operations" )
```

Se aplicó un filtro para seleccionar únicamente "artículos". El periodo temporal para la recopilación de literatura se fijó desde enero de 2020 hasta mayo de 2025 (fecha de la última búsqueda). La elección del año 2020 como comienzo del periodo de búsqueda reside principalmente en que dicho año se destaca como un punto de partida clave con el lanzamiento de GPT-3 por OpenAI que marcó un hito en la IA generativa, superando a modelos anteriores («GPT-3», 2024). Al mismo tiempo AlphaFold 2 de Google DeepMind, aportó un gran avance en el problema científico de plegamiento de proteínas, lo que abrió nuevas fronteras a la investigación e inversión científica en la IA (Jumper et al., 2021). Adicionalmente, a partir de este año se observó que se produjo una aceleración notable en el desarrollo de IA con lanzamientos sucesivos de más modelos.

Para asegurar la pertinencia de los estudios seleccionados, se definieron criterios estrictos de inclusión y exclusión. Los *criterios clave de inclusión* fueron: temática central enfocada en la gestión de personas y el impacto de la IA o agentes de IA; artículos escritos en inglés; publicados entre enero de 2020 y mayo de 2025; ser artículos científicos de revistas académicas revisadas por pares; tener acceso al texto completo; y pertenecer al campo de conocimiento de Business, Management and Accounting. Por otro lado, los *criterios clave de exclusión* comprendieron: tópicos no relevantes (artículos solo sobre RRHH sin IA, o

solo sobre aspectos técnicos de IA sin aplicación a RRHH); idiomas distintos al inglés; fechas de publicación fuera del rango establecido; tipos de publicación diferentes a artículos científicos (como conferencias, libros, etc.); artículos sin acceso al texto completo; y artículos no pertenecientes al campo de conocimiento de Business, Management and Accounting.

El proceso de selección y cribado de la literatura comenzó con una búsqueda inicial en Scopus que arrojó 3817 resultados (Véase figura 1). La aplicación del filtro temporal redujo esta cifra a 2798 referencias. Un filtro posterior por área disciplinar (“Business, Management and Accounting”) acotó los resultados a 712 trabajos, y la selección exclusiva de “Articles” resultó en 348 artículos. Un análisis retrospectivo de referencias mediante VOSviewer permitió añadir 1 artículo relevante, elevando el total a 349. De estos, se lograron descargar 233 textos completos, combinando la descarga directa y el acceso universitario. Finalmente, tras una revisión del formato e idioma de los archivos descargados, se eliminaron aquellos que no cumplían los requisitos, quedando un corpus de 226 artículos.

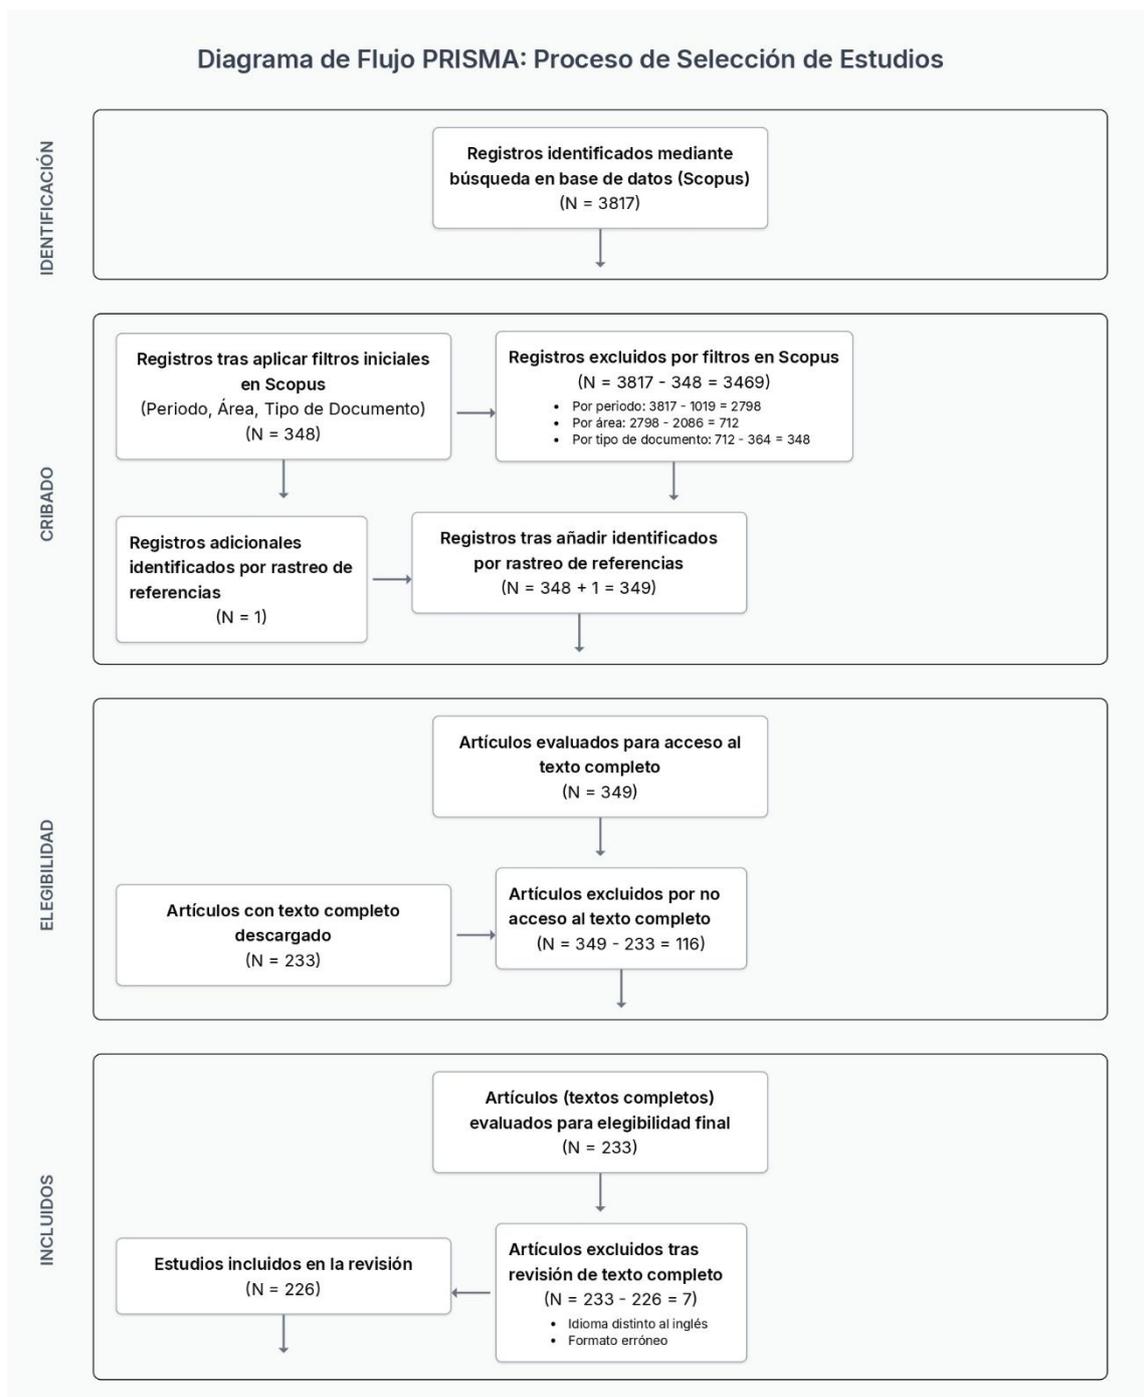


Figura 1: Diagrama de flujo PRISMA del proceso de Selección de Artículos

Fuente: Elaboración propia mediante Gemini.

Una vez culminada la fase de búsqueda con un corpus final de 226 artículos, se dio paso al análisis de datos. Este se estructuró en dos etapas diferenciadas. La primera consistió en un análisis bibliométrico exploratorio con VOSviewer para obtener un mapa general de la literatura. Tras este mapeo inicial, y con el fin de profundizar en las contribuciones más significativas, se procedió a una segunda etapa de revisión sistemática. Para ello, se acotó el corpus a través del “Análisis de Citación de Documentos” (detallado en el capítulo 3), el

cual identificó los 39 artículos con mayor número de citas. La selección de este conjunto de documentos se fundamenta en que aglutinan las discusiones y hallazgos más influyentes validados por la comunidad científica. Sobre este corpus se realizó la revisión sistemática, empleando NotebookLM y Gemini para ejecutar un análisis textual profundo, extraer y sintetizar la información clave, y elaborar las tablas informativas que consolidan los resultados de esta investigación.

Capítulo 3. Resultados

1. Resultados del Análisis Bibliométrico

El propósito del análisis bibliométrico llevado a cabo fue obtener una comprensión panorámica de la producción científica contenida en los 226 artículos seleccionados. Se buscó identificar los principales clústeres temáticos, las palabras clave más relevantes y sus interconexiones, así como posibles tendencias emergentes en el campo de la IA aplicada a la gestión de personas, utilizando la herramienta VOSviewer.

El proceso implicó varias fases tal y como se describe con detalle a continuación.

Análisis de Coocurrencia de Palabras Clave:

En este análisis se consideran aquellas palabras clave que presentan un mínimo de tres apariciones en el corpus de 226 artículos desvelando una estructura temática interconectada. Los términos "artificial intelligence" (localizado en el Clúster 2 con 120 ocurrencias), "human resource management" (predominante en el Clúster 1 con 88 ocurrencias) y "machine learning" (también en el Clúster 1 con 33 ocurrencias) se posicionan como nodos de gran tamaño y peso en la red, evidenciando su relevancia (Véase figura 2 y Tabla 2)

Tabla 2: Clústeres, Palabras Clave y Artículos

Fuente: Elaboración propia con los datos procesados de VosViewer

| Color | Clúster ID | Palabra Clave | Ocurrencias |
|----------|------------|------------------------------|-------------|
| Rojo | 1 | Human resource management | 88 |
| Rojo | 1 | Machine learning | 33 |
| Verde | 2 | Artificial intelligence | 120 |
| Verde | 2 | Industry 4.0 | 9 |
| Azul | 3 | Human resources management | 14 |
| Azul | 3 | Decision making | 8 |
| Azul | 3 | Information management | 7 |
| Amarillo | 4 | Recruitment | 10 |
| Amarillo | 4 | Human resources | 6 |
| Amarillo | 4 | E-hrm | 5 |
| Amarillo | 4 | Digital transformation | 4 |
| Amarillo | 4 | Ethics | 4 |
| Amarillo | 4 | Information systems | 4 |
| Lila | 5 | AI | 15 |
| Lila | 5 | Hrm | 11 |
| Turquesa | 6 | Artificial intelligence (ai) | 12 |
| Turquesa | 6 | AI adoption | 4 |
| Naranja | 7 | HR analytics | 7 |

Tal y como se muestra en la figura 2, el mapa generado por VOSviewer exhibe 3 clústeres principales y otros secundarios, lo que sugiere agrupaciones temáticas bien definidas. Así, el clúster prominente, identificado como Clúster 1 (Rojo) incluye "machine learning" y "human resource management" (88 ocurrencias). El Clúster 2 (Verde), centrado en "artificial intelligence" (120 ocurrencias), vincula este concepto con términos como "industry 4.0", como se puede observar en la Tabla 2, lo que sugiere una línea de investigación enfocada en el impacto estratégico de la IA en la transformación industrial y la gestión del talento, así como en los desafíos asociados. Por su parte, el Clúster 3 (Azul), liderado por "human resources management" (14 ocurrencias), conecta este término con "decision making" e "information management", apuntando a estudios sobre cómo técnicas avanzadas de IA respaldan la toma de decisiones en el ámbito de los RRHH. El resto de clústeres identificados apuntan a áreas más específicas. El Clúster 4 (Amarillo) destaca la modernización y digitalización del reclutamiento y sus implicaciones éticas. El Clúster 5 (Lila) refleja un enfoque más general sobre el impacto de la automatización en el desarrollo organizacional. Finalmente, los clústeres 6 (Turquesa) y 7 (Naranja) señalan, respectivamente, el interés emergente en la IA generativa, como ChatGPT, y la consolidación de la analítica de datos para la adquisición de talento.

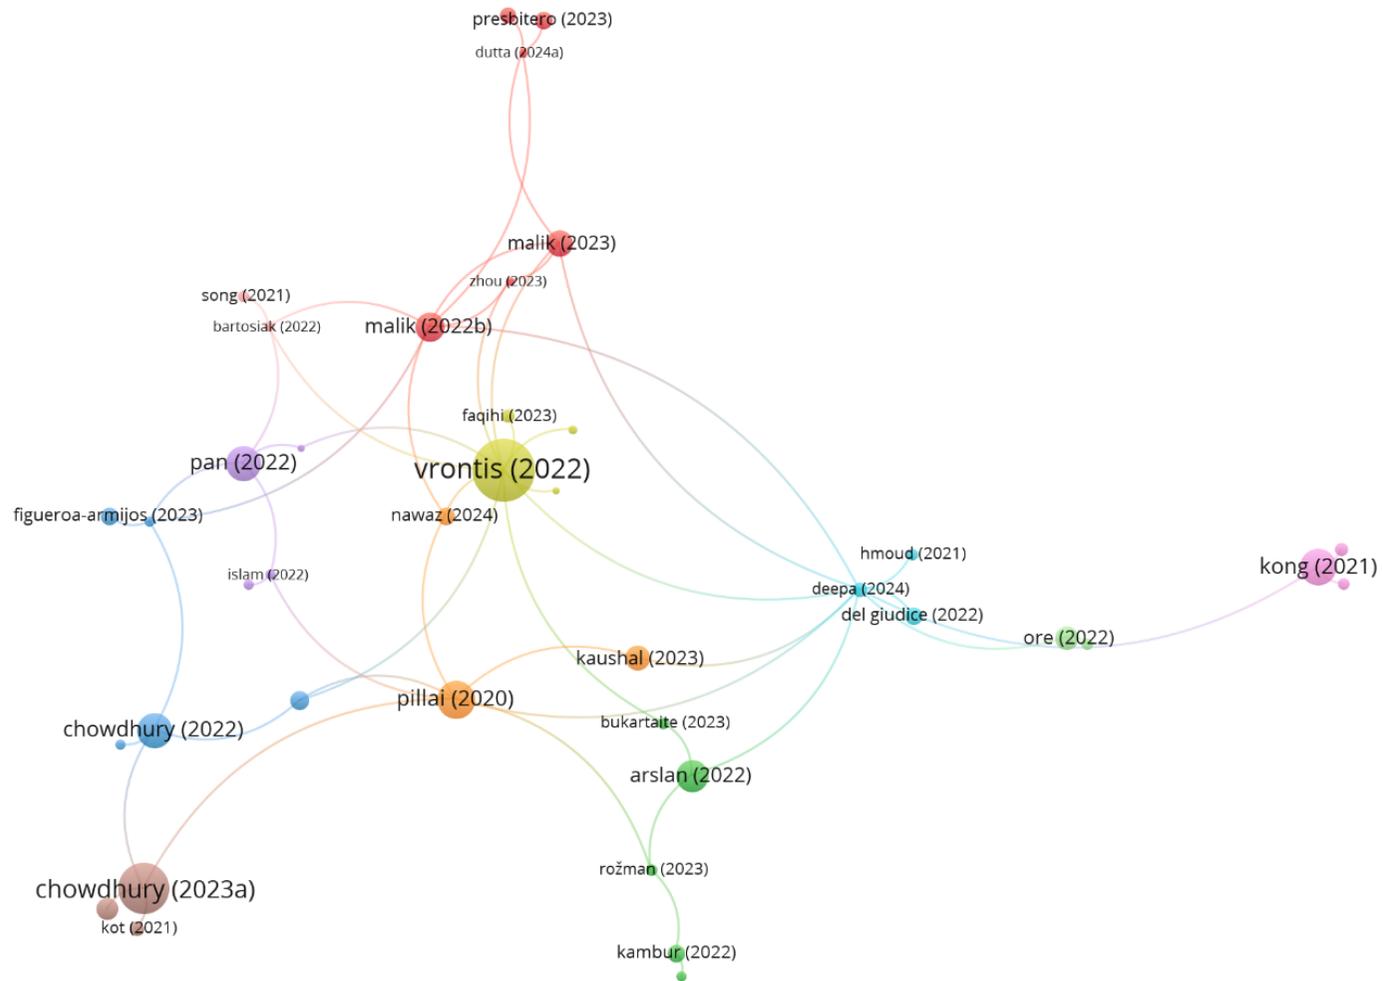
En conjunto, la Figura 2 y la Tabla 2 no solo confirman la interconexión de la investigación en IA y RRHH, sino que también revelan la existencia de subcampos de investigación bien definidos, desde la aplicación técnica de algoritmos de machine learning (Clúster 1) hasta las implicaciones estratégicas y éticas de la IA (Clústeres 2 y 4), el auge de la IA generativa (Clúster 6) y la importancia creciente del análisis de datos en RRHH (Clúster 7).

Análisis de Citación de Documentos:

A continuación, se presenta un análisis de las relaciones de citación entre los documentos que integran el corpus de 226 artículos, centrado de manera particular en aquellos trabajos que han alcanzado un umbral mínimo de 10 citaciones totales conforme a los registros de Scopus. Este enfoque metodológico permite no solo destacar los trabajos de mayor relevancia, sino también desentrañar las interconexiones y agrupaciones que evidencian las corrientes de pensamiento y los fundamentos teóricos predominantes en el ámbito de la IA aplicada a la gestión de personas. Los resultados de este análisis se encuentran detallados en la Tabla 15 (véase Anexo 1) y representados gráficamente en la Figura 3, que ofrece una representación visual de la red de citaciones, utilizando nodos cuyos tamaños reflejan el número de citaciones recibidas por cada documento (indicativo de su influencia) y colores que agrupan los trabajos en clústeres según sus patrones de

intercitación. Este esquema visual no solo pone de manifiesto los artículos más citados, sino que también delinea las relaciones entre ellos, proporcionando una perspectiva integral de las líneas de investigación que dominan el corpus.

Dentro de este análisis, ciertos documentos se erigen como pilares fundamentales debido a su elevado impacto. Vrontis et al. (2022), es el trabajo más relevante con 610 citaciones. Su carácter de revisión sistemática sobre IA, robótica y gestión de RRHH justifica su importancia, ya que integra el conocimiento existente hasta la fecha y establece directrices para investigaciones futuras. Asimismo, Chowdhury et al. (2023a), con 412 citaciones, propone un marco conceptual de capacidades de IA para la gestión de RRHH, cuya estructura ha sido ampliamente adoptada y referenciada. Estos trabajos, por su naturaleza y resonancia, constituyen referencias clave en la literatura reciente sobre este campo (Véase figura 3).



*Figura 3: Red de citación de Documentos.
Fuente: Elaboración propia mediante VosViewer*

El análisis conjunto de la Tabla 15 y la Figura 3 permite una interpretación profunda de los clústeres identificados, cada uno caracterizado por temáticas específicas y sustentado por autores clave que han moldeado el desarrollo del área:

Clúster 1 (rojo): Dedicado a la experiencia del empleado y la eficiencia de los bots en la gestión de RRHH. Destacan Malik et al. (2022), y Malik et al. (2023), que exploran el impacto de los ecosistemas de RRHH basados en IA, especialmente los chatbots, en la experiencia individualizada y la rentabilidad. Otros trabajos relevantes incluyen Dutta et al. (2023), sobre el uso de chatbots para fomentar la voz y el compromiso del empleado, y Presbitero et al. (2023), que analiza las actitudes laborales ante la IA.

Clúster 2 (verde): Centrado en la interacción humano-IA y el desarrollo de RRHH. Arslan et al. (2022), examina los desafíos y estrategias de gestión de RRHH en la interacción entre IA y trabajadores a nivel de equipo. Kambur et al. (2022) aborda el desarrollo de RRHH mediante IA, mientras que Bukartaite et al. (2023) se enfoca en las necesidades futuras de habilidades derivadas de la automatización y la IA.

Clúster 3 (azul): Enfocado en la colaboración IA-empleado y su influencia en el rendimiento empresarial. Chowdhury et al. (2022), integra la visión basada en el conocimiento y los sistemas sociotécnicos como nodo central. Este clúster también incluye Chowdhury et al. (2023b), que aborda la transparencia en modelos de IA para predecir la rotación de empleados, y Figueroa-Armijos et al. (2023), que explora las percepciones éticas de la IA en la contratación. La presencia recurrente de Chowdhury en este y otros clústeres resalta su contribución sostenida al campo.

Clúster 4 (amarillo): Liderado por la revisión sistemática de Vrontis et al. (2022), este clúster actúa como un nexo central en la red de citas, conectando múltiples trabajos, como lo evidencia su prominencia en la Figura 3. Incluye también a Faqih et al. (2023), que trata sobre sistemas de gestión de talento impulsados por IA.

Clúster 5 (morado): Concentrado en la adopción de IA en el reclutamiento, Pan et al. (2022) analiza los factores contextuales que influyen en esta adopción, mientras que Islam et al. (2022) explora el tema en un contexto específico.

Clúster 6 (celeste): Este clúster agrupa estudios sobre las competencias emergentes y la adopción de nuevas tecnologías. Destaca Deepa et al. (2024), que aborda el impacto de la IA en las competencias sociales y técnicas de los gerentes de RRHH, y Del Giudice et al. (2022), que analiza la adopción de robots humanoides y su efecto en la productividad. Este

agrupamiento sugiere un interés en cómo la tecnología redefine tanto las habilidades requeridas como la dinámica laboral.

Clúster 7 (naranja): Relacionado con la adopción de IA para la adquisición de talento y revisiones bibliométricas. Pillai et al. (2020), se posiciona como un artículo seminal, y Kaushal et al. (2023) ofrece un análisis bibliométrico que orienta futuras investigaciones.

Clúster 8 (marrón/rojo oscuro): Además de Chowdhury et al. (2023a), incluye a Kshetri (2020), que examina los usos evolutivos de la IA en la Gestión de RRHH en economías emergentes.

Clúster 9 (rosa): Liderado por Kong et al. (2021), este clúster investiga la influencia de la conciencia sobre IA en la competencia profesional y el agotamiento profesional, extendiéndose en Kong et al. (2024) al análisis de la resiliencia de carrera.

La Figura 3 revela detalles adicionales. Por ejemplo, Deepa et al. (2024), ocupa una posición estratégica en la red que sugiere una relevancia creciente en el debate sobre las competencias sociales y técnicas de los gerentes de recursos humanos en la era de la IA. Esto podría señalar un tema emergente que está ganando tracción con rapidez.

En síntesis, este análisis de citas, fundamentado en la Tabla 6 y enriquecido por la Figura 3, no solo identifica los artículos más influyentes en el campo de la IA aplicada a la gestión de personas, sino que también expone la estructura intelectual del área. Revela las principales líneas de investigación, la naturaleza de los trabajos seminales y la emergencia de autores y temáticas clave que están configurando de manera definitiva la conversación actual en este dominio.

Análisis de Acoplamiento Bibliográfico entre Documentos:

A continuación, se presenta un análisis del acoplamiento bibliográfico entre los documentos que conforman el corpus de artículos, basado en las relaciones de referencias compartidas. Este enfoque metodológico permite identificar las bases teóricas y empíricas comunes sobre las cuales se construyen las investigaciones actuales en el campo de la IA aplicada a la Gestión de Personas en las Organizaciones. Los resultados de este análisis se encuentran detallados en la Tabla 16 (véase Anexo) y representados gráficamente en la Figura 4.

El análisis de acoplamiento bibliográfico examina las referencias compartidas entre dos o más documentos del corpus. Cuando dos artículos citan una o más publicaciones idénticas, se consideran acoplados bibliográficamente, lo que evidencia que comparten una base de conocimiento o fundamentos teóricos comunes. Un elevado número de "links" (enlaces de acoplamiento) asociados a un documento indica que este se sustenta en una literatura ampliamente compartida por otros trabajos del corpus, incluso si no existe una relación de citación directa entre ellos. Aplicado a los 226 documentos analizados, este método revela la estructura de las corrientes de investigación y sus influencias compartidas, mostrando sobre qué "hombros de gigantes" se erigen las investigaciones actuales.

El trabajo de Chowdhury et al. (2023a) desde un "marco de capacidades de IA para la Gestión de RRHH", no solo goza de un alto número de citas directas, sino que también se fundamenta en un conjunto de referencias comunes a una amplia porción del corpus. Este hecho sugiere que su marco conceptual está profundamente arraigado en una literatura fundamental y ampliamente reconocida en el ámbito de estudio.

En una posición cercana se encuentran Prikshat et al. (2023a) y Chowdhury et al. (2022), ambos con 63 links. Estos trabajos, enfocados en la Gestión de RRHH aumentada por IA y la colaboración entre IA y empleados, respectivamente, comparten una extensa base bibliográfica con otros estudios del corpus. La concentración de documentos altamente interconectados en el Clúster 6 señala que este agrupa una corriente de investigación particularmente cohesiva, en la cual diversos autores recurren a fuentes teóricas y empíricas similares para explorar la integración de la IA en la gestión de RRHH.

Otros documentos relevantes por su alto número de enlaces incluyen Chowdhury et al. (2023b), Kambur & Akar (2022) y Prikshat et al. (2023b). Mientras que Chowdhury et al. (2023b) se enfoca en la transparencia de los modelos de IA para predecir y explicar la rotación de empleados, Prikshat et al. (2023b) aborda los antecedentes y consecuencias de la gestión de RRHH aumentada por IA, Kambur & Akar (2022) se centra en el desarrollo de RRHH mediante el uso de IA.

La visualización generada por VOSviewer en la Figura 4, complementada por los datos de la Tabla 16, permite interpretar los clústeres no solo a partir de los temas tratados en los artículos, sino también según el tipo de conocimiento fundamental que comparten:

Clúster 6 (verde claro): Este clúster se distingue como el más denso en términos de referencias compartidas, lo que refleja una notable cohesión en su base teórica. Los trabajos de autores como Chowdhury (Chowdhury et al., 2023a; Chowdhury et al., 2022;

Chowdhury et al., 2023b), Prikshat (Prikshat et al., 2023a), Malik (Malik et al., 2022), Basu (Basu et al., 2023), Arslan (Arslan et al., 2022) y Kambur (Arslan et al., 2022) abordan temáticas que incluyen marcos conceptuales para la IA en gestión de RRHH, revisiones sistemáticas, la interacción entre IA y empleados, y cuestiones éticas. La alta interconexión por acoplamiento indica que estos estudios, a pesar de sus enfoques específicos, se sustentan en un conjunto común de artículos fundamentales relacionadas con la IA, la gestión de recursos humanos, la adopción tecnológica y el cambio organizacional. La prominencia de autores como Chowdhury y Prikshat, con múltiples trabajos altamente enlazados, evidencia el desarrollo de líneas de investigación coherentes y sólidamente ancladas en la literatura existente.

Clúster 1 (rojo): En este clúster, Vrontis et al. (2022) muestra que su revisión sistemática se basa en una amplia gama de literatura también referenciada por otros trabajos. Asimismo, Huang et al. (2023), centrado en la gestión de RRHH personalizada, y Del Giudice et al. (2022), sobre robots humanoides y productividad, sugieren que las discusiones sobre la aplicación de IA y robótica a la personalización y la productividad en RRHH comparten una base teórica común. La presencia de Kong et al. (2021), que explora la conciencia de la IA y el agotamiento profesional y Votto et al. (2021), otra revisión sistemática sobre IA en la Gestión de RRHH táctica, refuerza la noción de una fundamentación teórica compartida orientada a comprender el impacto de la IA en los empleados y las operaciones de RRHH.

Clúster 3 (azul): Este clúster está liderado por Giraud et al. (2023), que analiza el impacto de la IA en las habilidades gerenciales, y Li et al. (2023), que evalúa el impacto de la IA en el rendimiento de recursos humanos. Aquí se agrupan investigaciones que se apoyan en teorías comunes sobre la transformación del trabajo, el desarrollo de competencias y la evaluación del rendimiento en el contexto de la IA. La inclusión de Korzynski et al. (2023), que examina ChatGPT desde las teorías de gestión, apunta a la integración de tecnologías generativas emergentes sobre esta base compartida, aunque con una menor densidad de enlaces.

Clúster 4 (amarillo): Con Deepa et al. (2024), que trata sobre las competencias de los gerentes de RRHH, Zhou et al. (2023), que explora el "lado oscuro" de la Gestión de RRHH habilitada por IA, y Menzies et al. (2024), sobre IA en negocios internacionales, este clúster sugiere una base teórica compartida enfocada en las nuevas demandas competenciales y los desafíos éticos y estratégicos de la IA en contextos globales y organizacionales. La recurrencia de trabajos de Dutta con un número significativo de links señala una línea de investigación bien fundamentada.

Clúster 5 (morado): Además de Prikshat et al. (2023b), este clúster incluye Odugbesan et al. (2023), que aborda la gestión del talento verde y el comportamiento innovador, e Islam et al. (2022), sobre la adopción de IA en el reclutamiento. Estos trabajos indican que las investigaciones sobre aplicaciones específicas de la IA, como el reclutamiento y temas emergentes, como la sostenibilidad y la Gestión de RRHH verde, se están construyendo sobre un conjunto de referencias fundamentales compartidas, posiblemente relacionadas con la adopción tecnológica, la innovación y la gestión del talento.

El análisis de acoplamiento bibliográfico resulta esencial al revelar las "raíces intelectuales" compartidas de los trabajos actuales. Un elevado número de links no implica necesariamente que un artículo sea el más citado (lo que reflejaría su influencia directa), sino que está firmemente anclado en la literatura central y ampliamente aceptada del campo, sirviendo como base para otros investigadores. La Figura 4 visualiza estas conexiones: los nodos más grandes, como Chowdhury et al. (2023a), Giraud et al. (2023) y Prikshat et al. (2023a), son los que comparten más referencias con el resto del corpus. La densidad del Clúster 6 sugiere la existencia de "escuelas de pensamiento" o frentes de investigación que operan sobre una base teórica común sólida, mientras que la dispersión en otros clústeres podría indicar áreas más recientes o con fundamentos teóricos más diversificados.

Este análisis se complementa con el de citación directa, ya que mientras que este último muestra el impacto hacia adelante de un trabajo, el acoplamiento bibliográfico desvela su conexión hacia atrás con el conocimiento establecido y su relación con investigaciones contemporáneas. Ambos enfoques, en conjunto, proporcionan una visión integral de la estructura y dinámica del campo de investigación.

2. Resultados de la Revisión Sistemática de la Literatura.

El "Análisis de Citación de Documentos", presentado en el capítulo 3, ha permitido identificar un conjunto selecto de 39 artículos que ostentan los recuentos de citas más elevados dentro del corpus, revelando así los pilares fundamentales que aglutinan las principales discusiones, los avances teóricos y los descubrimientos empíricos más influyentes en el ámbito de la IA aplicada a la Gestión de Personas. En consecuencia, la revisión sistemática se enfocará de manera exclusiva en este grupo de documentos, posibilitando un examen detallado de las contribuciones que han sido ampliamente validadas y reconocidas por la comunidad investigadora. El objetivo primordial es destilar una comprensión verificada del estado del arte basada en los trabajos más destacados. Para ello, se han empleado herramientas de inteligencia artificial como NotebookLM y

Gemini para llevar a cabo una revisión exhaustiva, facilitando un procesamiento y un análisis textual detallado que ha permitido la extracción, la síntesis de información clave y la creación de tablas informativas.

La integración de la IA en la Gestión de RRHH ha redefinido de manera sustancial las funciones tradicionales del área, afectando a los procesos de reclutamiento y selección, gestión y evaluación del desempeño, formación y desarrollo y compensación y beneficios (véase tabla 3).

Tabla 3: Resumen de Aplicaciones de IA en las funciones de RRHH

Fuente: Elaboración propia con los datos obtenidos por NotebookLM

| Función de Gestión de RRHH | Ejemplos de Aplicación con IA | Beneficio Principal Asociado |
|-----------------------------------|--|---|
| Reclutamiento y Selección | Sistemas ATS, cribado inteligente de CVs, chatbots, análisis de videoentrevistas, predicción de ajuste. | Eficiencia, objetividad, mejora en la calidad de la contratación. |
| Gestión del Desempeño | Seguimiento continuo, evaluación 360°, feedback automatizado, análisis de la "voz del empleado". | Objetividad, ahorro de tiempo, desarrollo continuo. |
| Formación y Desarrollo (L&D) | Plataformas de aprendizaje adaptativo, recomendación de itinerarios, detección de brechas de competencias. | Personalización, alineación estratégica, aprendizaje continuo. |
| Compensación y Beneficios | Previsión salarial, análisis de equidad, diseño de pago variable, personalización de beneficios. | Equidad, transparencia, optimización presupuestaria. |

Comenzando por los procesos de reclutamiento y selección, la literatura analizada demuestra que la IA se ha consolidado como una herramienta para optimizar la precisión en la evaluación de candidatos y para identificar perfiles que se ajusten a las vacantes disponibles (Faqih et al., 2023). Esta optimización se materializa en soluciones como los sistemas de seguimiento de candidatos (ATS – Applicant Tracking System) potenciados con IA, que automatizan y agilizan las fases iniciales del proceso. Un ejemplo destacado es la plataforma Phenom Talent Experience Management, construida sobre un sistema de IA que busca enriquecer la experiencia de candidatos, reclutadores y empleados mediante una mayor personalización y automatización (Kshetri, 2020). Adicionalmente, el cribado inteligente de currículums emerge como una aplicación fundamental, donde algoritmos de aprendizaje automático filtran y clasifican un gran volumen de candidaturas de manera eficiente (Ore & Sposato, 2022). En fases más avanzadas, las entrevistas asistidas por IA se presentan como una herramienta complementaria, empleando chatbots conversacionales para un primer filtro, cuya efectividad ha sido validada por estudios como el de Cowgill (2017) y adoptada por empresas como L'Oréal (Brin, 2018; Kambur et al.,

2022). Las videoentrevistas analizadas por IA representan un paso más allá, al evaluar aspectos como el lenguaje corporal, las expresiones faciales y el tono de voz; ejemplos notables de esta tecnología incluyen las plataformas desarrolladas por HireVue (HireVue, 2017; Kaushal et al., 2023), así como las herramientas "Utah" de Unilever y "net-Interviewer" de PwC (PricewaterhouseCoopers). Finalmente, el proceso se enriquece con la capacidad predictiva de la IA, que permite anticipar el riesgo de abandono del puesto (Weber, 2023). Además, para determinar el grado de ajuste entre el candidato y el puesto, se destaca el uso de sistemas expertos. Estos sistemas incorporan el conocimiento y las habilidades de toma de decisiones de un experto humano en RRHH, lo que, en combinación con las plataformas de reclutamiento online, permite una evaluación más profunda y efectiva del encaje del candidato en la organización (Kambur et al., 2022).

Una vez incorporado el talento, la gestión de su desempeño se convierte en una prioridad, un área donde la IA también introduce optimizaciones significativas, evidenciadas por un ahorro de hasta un 50% del tiempo en la preparación y un 60% en el tiempo total del proceso de evaluación. Esta eficiencia se logra al permitir que el gerente programe evaluaciones basadas en una amplia variedad de datos, como puntuaciones de rendimiento previas, participación en proyectos y cursos de formación asistidos (Kambur et al., 2022). Se proponen métodos de evaluación más integrales, como el enfoque de 360 grados ² asistido por sistemas inteligentes que aglutinan retroalimentación de múltiples fuentes para una visión holística (Kaushal et al., 2023). La IA facilita, además, un seguimiento continuo y fundamentado en datos, lo que permite una retroalimentación más oportuna y objetiva (Zhou et al., 2023). El análisis de estos datos a gran escala posibilita la identificación de patrones de desempeño, que pueden correlacionarse con la probabilidad de promoción de los empleados (Kambur et al., 2022). Este feedback en tiempo real, a menudo vehiculado por chatbots, no solo mejora la comunicación, sino que puede fundamentar decisiones sobre aumentos salariales, mientras que el análisis de la "voz del

² Es un método de evaluación del desempeño que recopila de forma sistemática la percepción sobre las competencias y el comportamiento de un empleado desde múltiples perspectivas. Estas fuentes suelen incluir a sus superiores directos, compañeros de equipo (pares), subordinados y, en ocasiones, clientes internos o externos.

empleado" (VoE) ³ que utiliza datos de la intranet o los correos electrónicos para predecir el rendimiento y medir el clima laboral, siendo IBM Watson y Microsoft Workplace Analytics ejemplos de herramientas que se aplican en este ámbito (Kaushal et al., 2023; Malik et al., 2023).

La identificación de estos patrones de desempeño y áreas de mejora se conecta directamente con la necesidad de una formación y desarrollo (L&D) personalizados, otra capacidad potenciada por la IA. En este ámbito, la habilidad de la IA para analizar datos masivos permite identificar las necesidades de desarrollo individuales y adaptar los itinerarios formativos (Kaushal et al., 2023). Esta personalización responde a la demanda de los empleados por una formación relevante que apoye tanto sus objetivos profesionales como los de la empresa (Rožman et al., 2023), Surgen así plataformas de aprendizaje adaptativo que utilizan IA para ajustar dinámicamente el contenido y el ritmo de la formación según el progreso individual, lo que conduce a un aprendizaje más rápido, eficiente y con menor margen de error (Rožman et al., 2023). Estos sistemas no solo imparten formación, sino que actúan como herramientas para la detección de carencias de habilidades, facilitando un aprendizaje continuo y estratégico alineado con las futuras competencias que requerirá la organización (Kambur et al., 2022).

El desarrollo de competencias y la mejora del rendimiento suelen ir de la mano de las expectativas de compensación y beneficios, un campo en el que la IA también comienza a jugar un papel crucial. Se observa que su aplicación contribuye a la previsión salarial, ayudando a establecer estándares de mercado (Song et al., 2021), y al diseño de sistemas que definen métricas de pago variable para recompensar el esfuerzo de los empleados. Asimismo, se menciona el uso de bots para la gestión del reconocimiento y las recompensas, vinculando esta función con los sistemas de evaluación del desempeño (Malik et al., 2023). Sin embargo, la aplicación de la IA en un área tan sensible exige que las decisiones algorítmicas se rijan por principios de transparencia, justicia y explicabilidad.

³ Existen diversos tipos de voz del empleado, pero en términos generales, se entiende como la comunicación entre los empleados y la dirección, a través de la cual los trabajadores comparten sugerencias y expresan problemas que pueden influir en las decisiones de la organización. (Dutta et al., 2023)

Aunque se empleen datos objetivos, se subraya que estos sistemas deben funcionar como herramientas de consulta, recayendo la decisión final en la responsabilidad del gerente, quien debe supervisar y validar las recomendaciones del sistema (Kambur et al., 2022).

Tal y como se acaba de analizar así pues, se observa una transición desde la simple automatización hacia la optimización y personalización de las funciones clave de la gestión de RRHH. En cada una de las áreas, la IA no solo aporta eficiencia operativa, sino que introduce un enfoque basado en datos que permite una toma de decisiones más estratégica y un mayor grado de individualización, desde la selección del talento hasta su retención y desarrollo.

El impacto transversal de estas aplicaciones se manifiesta de manera prominente en la optimización de la eficiencia y la productividad del departamento de RRHH. La automatización de tareas administrativas, como la preselección de currículums, reduce la carga de trabajo y permite a los profesionales de RRHH concentrarse en tareas de mayor valor añadido y más estratégicas, como la mentoría y el feedback continuo (Pillai et al., 2020). Un ejemplo concreto es el de la cadena de hoteles Hilton, que logró reducir su tiempo de contratación de 42 a 5 días mediante el uso de videoentrevistas asistidas por IA (Kaushal et al., 2023). Esta optimización de los procesos se sustenta en la capacidad de la IA para analizar grandes volúmenes de datos, lo que a su vez transforma la toma de decisiones, permitiendo que sean más informadas y estratégicas (Faqihi et al., 2023). Para facilitar este cambio, la literatura destaca el auge de los Sistemas Inteligentes de Soporte a la Decisión (IDSS) y de técnicas consolidadas como el análisis de RRHH (HR Analytics), técnica que un 63% de las empresas estaría dispuesto a aplicar (Xiao et al., 2025). Estas herramientas son las que permiten, en la práctica, transformar los datos en conocimiento aplicable, como la predicción de la probabilidad de abandono o la identificación del potencial de promoción de los empleados (Chowdhury et al., 2023b; Kambur et al., 2022). La implementación de estos procesos eficientes y personalizados, guiados por los datos, se alinea con el objetivo final de mejorar la experiencia global del empleado.

Sin embargo, para que este potencial se materialice, es crucial abordar los desafíos y consideraciones éticas inherentes a la IA (véase tabla 4).

Tabla 4: Principales Desafíos en la Implementación de IA en la Gestión de RRHH

Fuente: Elaboración propia con los datos obtenidos por NotebookLM

| Categoría del Desafío | Desafío Específico | Descripción/Implicación Clave |
|------------------------------|--------------------------------|--|
| Ético-Algorítmico | Sesgos y Discriminación | Riesgo de perpetuar o amplificar desigualdades si la IA se entrena con datos históricos sesgados. |
| Ético-Algorítmico | Transparencia y Explicabilidad | Dificultad para entender las decisiones de algoritmos de "caja negra", lo que erosiona la confianza. |

| Categoría del Desafío | Desafío Específico | Descripción/Implicación Clave |
|------------------------------|----------------------------|---|
| Gestión de Datos | Privacidad y Seguridad | Necesidad de proteger los datos sensibles de los empleados y cumplir con normativas como el RGPD. |
| Humano-Organizacional | Desconfianza y Aceptación | Resistencia por parte de empleados y gerentes debido a la falta de explicabilidad y al temor a la discriminación. |
| Humano-Organizacional | Temor al Reemplazo Laboral | Preocupación por la sustitución de puestos de trabajo que genera resistencia al cambio. |
| Humano-Organizacional | Falta de Capacitación | Carencia de habilidades técnicas y analíticas en los equipos de RRHH para gestionar sistemas de IA. |

Los obstáculos para la adopción de la IA no son meramente técnicos, sino que se extienden a complejas dimensiones éticas, de datos y humanas. En el plano ético-algorítmico, existe un riesgo significativo de que los sistemas perpetúen sesgos históricos si se entrenan con datos incorrectos (Chowdhury et al., 2024; Faqih et al., 2023). Este problema se agrava por la naturaleza de "caja negra" de muchos algoritmos, lo que demanda una mayor transparencia y explicabilidad para generar confianza y asegurar que las decisiones sean justas y comprensibles (Deepa et al., 2024; Olan et al., 2024). Por ello, se subraya que la responsabilidad final de supervisar y validar las decisiones de la IA debe recaer en los gerentes de RRHH. En la gestión de datos, la confidencialidad, privacidad y seguridad son primordiales, y el cumplimiento de normativas como el RGPD, que garantiza el derecho a la explicación de decisiones automatizadas, se vuelve crucial (Berman et al., 2024; Dutta et al., 2024). Finalmente, en el ámbito humano-organizacional, la desconfianza de los empleados, el temor al reemplazo laboral y la falta de capacitación de los profesionales de RRHH emergen como barreras clave (Arslan et al., 2022; Chowdhury et al., 2023a). Para superar esta resistencia, se propone la "socialización de la IA", un proceso educativo y de apoyo para fomentar una colaboración humano-IA que aumente y haga destacar las capacidades humanas en lugar de reemplazarlas (Malik et al., 2022). Para que los gerentes puedan liderar eficazmente este proceso de socialización y promover una interacción positiva, resulta imprescindible que desarrollen un conjunto específico de competencias. En esta línea, se identifican tres capacidades gerenciales críticas que los responsables de RRHH deben desarrollar para una adopción efectiva de la IA: la capacidad cognitiva, el capital humano y el capital social.

Para la cognición gerencial, se señalan como competencias necesarias la toma de decisiones éticas, la resolución de problemas y la validación de los resultados propuestos por la IA. En cuanto al capital humano, se destaca la importancia de desarrollar la pericia técnica, las habilidades de liderazgo, la agilidad, la capacidad para la configuración institucional y las destrezas de formación. Finalmente, para el capital social, se identifican competencias como la habilidad para obtener y utilizar tecnologías de IA, mantener la

justicia social, mejorar la experiencia del empleado, las habilidades de mentoría y la capacidad de colaboración humano-IA (Deepa et al., 2024).

Para comprender y estructurar el análisis de esta compleja transformación, la literatura académica ha recurrido a diversas perspectivas teóricas (véase tabla 5).

Tabla 5: Principales Marcos Teóricos en la Investigación de IA en la Gestión de RRHH

Fuente: Elaboración propia con los datos obtenidos por NotebookLM

| Perspectiva | Teorías / Marcos | Aplicación Principal en Gestión de RRHH con IA |
|----------------------------|-------------------------|--|
| Adopción Tecnológica | UTAUT, TOE, TTF, DOI | Explicar la aceptación y el uso de herramientas de IA por parte de los empleados y la organización. |
| Estratégica y Organizativa | RBV, DCV, OSF, STS, KBV | Analizar cómo la IA puede generar ventaja competitiva y cómo se integra en la estructura y cultura organizativa. |

Como se observa en la Tabla 5, se clasifican los marcos teóricos predominantes utilizados en la literatura analizada para estudiar el fenómeno de la IA en la gestión de RRHH. Se pueden agrupar en dos grandes enfoques. Por un lado, las teorías de Adopción Tecnológica se emplean para explicar los factores que impulsan o frenan la aceptación de la IA; entre ellas, el marco Tecnología-Organización-Entorno (TOE) analiza la adopción a nivel organizacional (Faqihi et al., 2023; Pillai et al., 2020), mientras que la Teoría Unificada de Aceptación y Uso de la Tecnología (UTAUT) se centra en la perspectiva individual (Deepa et al., 2024; Islam et al., 2022). Por otro lado, las perspectivas Estratégica y Organizativa se utilizan para analizar cómo la IA puede ser una fuente de valor; aquí, la Visión Basada en Recursos (RBV) y la Visión Basada en las Capacidades Dinámicas (DCV) son fundamentales para argumentar cómo la IA mejora la competitividad (Chowdhury et al., 2023b; Deepa et al., 2024), mientras que la Teoría de Sistemas Sociotécnicos (STS) y la Teoría de Socialización Organizacional (OSF) ayudan a entender la integración de la IA en los aspectos sociales y colaborativos de la empresa (Chowdhury et al., 2022). Esta dualidad teórica evidencia que un entendimiento completo de la IA en la gestión de RRHH requiere considerar tanto los aspectos tecnológicos y de usuario como los de gestión estratégica y organizacional.

El análisis de la literatura también revela significativas brechas de conocimiento y delinea una clara agenda de investigación futura. Se demanda una mayor cantidad de investigación empírica, longitudinal e interdisciplinaria para validar los modelos conceptuales y entender los factores contextuales (Chowdhury et al., 2022; Kaushal et al., 2023). En cuanto a los temas específicos, la IA generativa emerge como un campo prioritario que requiere marcos estratégicos propios (Chowdhury et al., 2024). Junto a ello, la ética y la gobernanza siguen siendo un tema central, con la necesidad de profundizar en cómo evitar sesgos y garantizar la justicia (Chowdhury et al., 2023b). Asimismo, se considera fundamental investigar la

colaboración humano-IA y el impacto social y psicológico de la IA en los empleados, incluyendo su influencia en el bienestar mental (Chowdhury et al., 2022; Dutta et al., 2024).

Además, existe una demanda recurrente de más investigación empírica para validar los numerosos modelos conceptuales existentes (Bartosiak et al., 2022; Chowdhury et al., 2022), así como de estudios cualitativos para comprender en profundidad las interpretaciones y experiencias individuales frente a la IA (Chowdhury et al., 2024; Dutta et al., 2024; Faqih et al., 2023). Del mismo modo, se señala la escasez de estudios longitudinales, que observen los efectos de la IA a lo largo del tiempo, y de investigaciones comparativas e interdisciplinarias que analicen cómo los factores contextuales (país, sector) afectan a la adopción (Arslan et al., 2022; Kaushal et al., 2023; Vrontis et al., 2022). En cuanto a los temas de investigación futura, la IA generativa se posiciona como un área prioritaria que requiere marcos estratégicos específicos (Chowdhury et al., 2024). La ética y la gobernanza de la IA continúan siendo centrales, con un llamado a investigar cómo asegurar la justicia y la transparencia (Chowdhury et al., 2023b; Figueroa-Armijos et al., 2023). Finalmente, se considera fundamental profundizar en la colaboración humano-IA y en el impacto social y psicológico de la tecnología en los empleados, incluyendo su influencia en el bienestar mental (Chowdhury et al., 2022; Dutta et al., 2024).

Capítulo 4. Conclusiones

El propósito de esta investigación fue examinar el estado actual del conocimiento relativo a la aplicación de la IA en el ámbito de la gestión de personas en las organizaciones. Inicialmente, se estableció que el enfoque se centraría específicamente en el concepto de agentes inteligentes, sin embargo el análisis de la literatura académica desveló un panorama más amplio y complejo. Los términos agente inteligente y agente de IA no se consolidaron como constructos centrales en los trabajos más influyentes seleccionados para la revisión sistemática. Esta ausencia se explica, en gran medida, por la metodología de selección empleada, la cual priorizó los artículos con mayor número de citas. Al analizar el corpus completo, compuesto por 226 artículos, se constató la existencia de investigaciones que abordan los temas de agentes inteligentes e inteligencia artificial generativa, considerada la base de funcionamiento de los agentes. No obstante, estos temas de vanguardia aún no han alcanzado el volumen de citas acumulado por los trabajos más citados del campo. En consecuencia, las conclusiones derivadas de este estudio reflejan el estado del conocimiento más consolidado y citado, centrándose en los patrones y temas predominantes identificados en la literatura.

El análisis bibliométrico llevado a cabo como etapa inicial de la investigación, ha permitido mapear la estructura intelectual del campo de estudio relacionado con la aplicación de la IA en la gestión de RRHH. A partir de este examen cuantitativo se desprende una conclusión primordial: la investigación en este ámbito, aunque mantiene una cohesión en torno a los conceptos fundamentales de IA y gestión de RRHH, evidencia una progresiva segmentación en subcampos de carácter especializado. Se distinguen claramente varias corrientes dentro de esta estructura intelectual. En primer lugar, una corriente de investigación técnica se centra en la implementación de algoritmos de aprendizaje automático orientados a la predicción y optimización del rendimiento, lo que subraya el interés por soluciones prácticas y cuantificables. Paralelamente, una corriente estratégica examina el impacto transformador de la IA en la industria y en la gestión del talento, abordando aspectos de mayor alcance organizacional. Asimismo, una corriente de modernización se ocupa de la digitalización de procesos como el reclutamiento, considerando no solo sus avances tecnológicos, sino también las implicaciones éticas derivadas de su uso. Finalmente, se identifica una corriente emergente que concentra su atención en la inteligencia artificial generativa, un campo que ha ganado relevancia reciente y que sugiere nuevas posibilidades de innovación.

El conocimiento de este dominio se basa en un conjunto limitado de estudios influyentes, principalmente revisiones sistemáticas y marcos conceptuales, que son esenciales para futuras investigaciones y destacan la necesidad de diversificar las perspectivas.

En la segunda etapa de revisión sistemática de la literatura sobre los artículos más influyentes, no solo se corrobora estas estructuras, sino que se les dota de un significado. Los clústeres temáticos identificados en el análisis bibliométrico encuentran su correspondencia directa en las aplicaciones y desafíos discutidos en la revisión sistemática. Por ejemplo, la prominencia del clúster de "machine learning" y "performance" se verifica con la detallada exploración de cómo la IA está transformando la gestión del desempeño, evidenciando un paso desde la evaluación anual hacia un seguimiento continuo y un feedback automatizado. De igual manera, los clústeres sobre "ética" y "desafíos", que en el mapa bibliométrico aparecen como conceptos interconectados, se ven expandidos en la revisión, que categoriza de forma precisa estas barreras en dimensiones ético-algorítmicas (sesgos, explicabilidad), de gestión de datos (privacidad, seguridad) y humano-organizacionales (confianza, temor al reemplazo). Esta profundización demuestra que la adopción de la IA es un desafío fundamentalmente sociotécnico, donde la tecnología es inseparable de sus implicaciones humanas y organizativas. La revisión también confirma que el interés en el "análisis de RRHH" se traduce en la implementación de Sistemas Inteligentes de Soporte a la Decisión (IDSS), que son el vehículo práctico a través del cual el análisis de datos redefine el rol estratégico del departamento de RRHH, permitiendo una toma de decisiones más predictiva y alineada con los objetivos de negocio.

De esta manera, se pueden derivar varias conclusiones generales que definen el estado del arte actual. La primera es la dualidad inherente de la IA en la Gestión de Personas en las Organizaciones: por un lado, se presenta como una herramienta de optimización con un potencial innegable para mejorar la eficiencia, la productividad y la toma de decisiones basada en datos; por otro, su implementación está intrínsecamente ligada a profundos desafíos éticos y humanos que dominan gran parte de la conversación académica y que deben ser gestionados para que los beneficios se materialicen.

La segunda gran conclusión es la transformación del rol del profesional de RRHH. Lejos de una narrativa de reemplazo, la literatura apunta de manera consistente hacia una redefinición de las competencias necesarias. La automatización de tareas administrativas libera a los profesionales para que asuman un papel más estratégico, centrado en la interpretación de los análisis de la IA, la supervisión ética de los algoritmos, la gestión del cambio y el fomento de una colaboración efectiva entre humanos y máquinas. El desarrollo

de capacidades gerenciales en los ámbitos cognitivo, de capital humano y de capital social se vuelve, por tanto, imprescindible.

Finalmente, se concluye que la investigación en IA aplicada a la Gestión de RRHH se encuentra en una fase de consolidación teórica que ahora enfrenta el desafío de validar y expandir sus hallazgos. Aunque se ha establecido un robusto cuerpo de marcos conceptuales, el análisis evidencia una clara necesidad de trascender la teoría hacia la práctica, con una demanda recurrente de estudios empíricos y longitudinales que puedan medir el impacto real y a largo plazo de estas tecnologías en contextos organizacionales diversos. Las fronteras más prometedoras para la investigación futura se perfilan en torno a la gestión de la IA generativa, la profundización en los modelos de colaboración humano-máquina y una mayor atención al impacto de la IA en el bienestar psicológico de los empleados. Estos son los ejes que, previsiblemente, guiarán la evolución y la relevancia de este dinámico campo de estudio en los próximos años.

Parte 2. DISEÑO Y DESARROLLO DE UN AGENTE DE IA PARA EL ESTUDIO DE REFERENCIAS BIBLIOGRÁFICAS EN EL ÁMBITO DE LA GESTIÓN DE PERSONAS EN LAS ORGANIZACIONES

Capítulo 5. Introducción

Esta segunda parte del Trabajo de Fin de Grado (TFG) se adentra en el dominio de la Ingeniería de Tecnologías de Telecomunicación para abordar el diseño y desarrollo de una solución práctica de Inteligencia Artificial (IA) aplicado al estudio/análisis de referencias bibliográficas en el ámbito de la gestión de personas en las organizaciones. Mientras que el análisis teórico revela el potencial y los desafíos de la IA en los Recursos Humanos (RRHH), esta sección se enfoca en la materialización de dicho potencial a través de la propuesta de un Producto Mínimo Viable (MVP) de un agente de IA.

Los objetivos de esta segunda parte, que parten de la propuesta inicial del anteproyecto, han sido redefinidos para ajustarse al enfoque práctico finalmente adoptado. Se centran en la materialización de una herramienta de IA para la investigación. De forma más específica, se persiguen los siguientes fines:

- Realizar una investigación exhaustiva del estado del arte de las tecnologías que habilitan la creación de agentes de IA conversacionales modernos, con un énfasis particular en las arquitecturas de Generación Aumentada por Recuperación (RAG).
- Identificar y definir los requisitos técnicos y funcionales necesarios para el desarrollo de un agente inteligente especializado en el análisis y la gestión de referencias bibliográficas en el ámbito de la IA aplicada a la gestión de personas.
- Diseñar, desarrollar y validar un prototipo funcional de dicho agente de IA, concebido como una herramienta de asistencia a la investigación.
- Evaluar la efectividad del prototipo para analizar y calificar la relevancia de artículos científicos con respecto a uno o varios criterios, validando su potencial para optimizar el proceso de revisión bibliográfica.

Para alcanzar estos objetivos, el presente documento se estructura en los siguientes capítulos:

- Capítulo 5: Introducción. El presente capítulo introduce el contexto y los objetivos de esta segunda parte del trabajo, centrada en el desarrollo práctico de la solución de IA. Se presentan los fines específicos del proyecto y se describe la hoja de ruta a seguir en los capítulos subsecuentes.
- Capítulo 6: Estado del Arte: Fundamentos del Dominio de Aplicación y Arquitecturas Tecnológicas. Este capítulo sienta la doble base fundamental sobre la que se edificará el prototipo. Primero, se realiza un análisis del estado del arte de la IA en la Gestión de Personas. Este estudio es un requisito indispensable para definir el dominio de aplicación, permitiéndonos comprender la terminología, los retos y los criterios de relevancia que nuestro agente deberá manejar. Segundo, se investigan las arquitecturas tecnológicas, herramientas y plataformas (con foco en RAG, bases de datos vectoriales y n8n) que habilitan la construcción de agentes modernos. Este análisis tecnológico justifica las decisiones de diseño e implementación que se detallarán en el capítulo siguiente.
- Capítulo 7: Diseño y Desarrollo de un Agente de IA aplicado al estudio/análisis de referencias bibliográficas. Aquí se detallará el diseño conceptual y técnico del MVP propuesto. Se describirá la arquitectura específica del agente, el proceso de ingesta y gestión del conocimiento (los artículos científicos), el flujo de trabajo de calificación de relevancia implementado en n8n y la interfaz para la interacción con el investigador. Además, se planteará una hoja de ruta para la evolución y escalado de la solución.
- Capítulo 8: Conclusiones y Resultados del Agente. Finalmente, este capítulo presentará una discusión sobre los resultados esperados del agente, sus limitaciones y las conclusiones técnicas derivadas del proceso de diseño. Se reflexionará sobre la viabilidad de la propuesta y se identificarán las futuras líneas de trabajo para su mejora y expansión.

Capítulo 6. Estado del arte: Fundamentos del Dominio de Aplicación y Arquitecturas Tecnológicas del MVP.

El propósito de este capítulo es establecer la base de conocimiento fundamental, tanto teórica como técnica, que permitirá abordar el diseño y desarrollo del agente de IA propuesto. Para ello, el análisis se ha estructurado en dos partes claramente diferenciadas pero complementarias. En primer lugar, se explorará el estado del arte del campo de aplicación (la IA en la gestión de personas) con el fin de definir con precisión el contexto en el que operará la herramienta y los criterios que determinarán la relevancia de la información a analizar. En segundo lugar, se abordará el estado del arte de las tecnologías clave para el desarrollo de agentes de IA, analizando las arquitecturas, modelos y herramientas que posibilitan el desarrollo del MVP propuesto. De este modo, el presente capítulo proporciona el "qué" (el dominio) y el "cómo" (la tecnología) que sustentan y justifican el trabajo práctico descrito en el Capítulo 7.

1. Marco conceptual de la Gestión de Personas en las Organizaciones

La gestión de RRHH ha sido definida desde diversas perspectivas. Autores como Schermerhorn [1] la conciben como el proceso de desarrollar una fuerza de trabajo inteligente para alcanzar las metas organizacionales, mientras que Storey [2] la ve como un método para mantener una plantilla habilidosa y dedicada que otorgue una ventaja competitiva. Por su parte, Boselie [3] la definen como un conjunto de prácticas interconectadas. Sintetizando estas visiones, se entiende la gestión de RRHH como el conjunto de prácticas y políticas necesarias para dirigir los aspectos relativos a las personas en la organización, incluyendo el reclutamiento, la selección, la formación, las remuneraciones y la evaluación del desempeño. Cada una de estas prácticas, que en conjunto constituyen el ciclo de vida del empleado en la organización, se define de la siguiente manera: el reclutamiento se enfoca en atraer a un grupo de candidatos potencialmente cualificados para un puesto, mientras que la selección es el proceso de elegir al individuo más idóneo de ese grupo. La formación abarca todas las actividades destinadas a mejorar las competencias y conocimientos de los empleados para su puesto actual o futuro. Por su parte, las remuneraciones comprenden el conjunto de compensaciones, tanto económicas como en beneficios, que el empleado recibe a cambio

de su trabajo. Finalmente, la evaluación del desempeño es el proceso sistemático mediante el cual se mide y analiza el rendimiento laboral de un empleado en relación con los objetivos de su puesto. [4]

Por otro lado, la irrupción de la IA está transformando profundamente estas prácticas clave:

- **Reclutamiento y Selección:** La IA se ha consolidado como una herramienta para optimizar la precisión en la evaluación de perfiles [5]. Esto se materializa en soluciones como los Sistemas de Seguimiento de Candidatos (ATS) que automatizan el cribado de currículums [6], chatbots que realizan entrevistas preliminares y sistemas de videoentrevistas que analizan el lenguaje no verbal, como los desarrollados por HireVue, Unilever o PwC (PricewaterhouseCoopers) [7], [8]. Además, se emplean sistemas expertos que evalúan el ajuste del candidato con el puesto y la cultura de la empresa [7].
- **Gestión del Desempeño:** Tradicionalmente, este es un proceso que consume mucho tiempo. La IA promete reducirlo hasta en un 60% [7]. Esto se logra mediante un seguimiento continuo basado en datos objetivos. Se emplean enfoques como la evaluación de 360 grados⁴ asistida por IA y el análisis de la "voz del empleado"⁵ (VoE) para obtener una visión holística y predictiva del rendimiento [8], [10].
- **Formación y Desarrollo (L&D):** En respuesta a la demanda de los empleados por una formación personalizada, la IA permite analizar grandes cantidades de datos para identificar necesidades de desarrollo individuales y adaptar los itinerarios formativos [11]. Surgen así plataformas de aprendizaje adaptativo que ajustan dinámicamente el contenido y el ritmo de la formación, actuando también como herramientas de diagnóstico para detectar brechas de competencias y predecir necesidades futuras [7], [8].

⁴ Es un método de evaluación del desempeño que recopila de forma sistemática la percepción sobre las competencias y el comportamiento de un empleado desde múltiples perspectivas. Estas fuentes suelen incluir a sus superiores directos, compañeros de equipo (pares), subordinados y, en ocasiones, clientes internos o externos.

⁵ Existen diversos tipos de voz del empleado, pero en términos generales, se entiende como la comunicación entre los empleados y la dirección, a través de la cual los trabajadores comparten sugerencias y expresan problemas que pueden influir en las decisiones de la organización. [9]

- **Compensación y Beneficios:** La IA contribuye a la previsión salarial para establecer estándares de mercado y al diseño de métricas de pago variable [7], [12]. Sin embargo, se subraya que estos sistemas deben funcionar como herramientas consultivas, recayendo la decisión final en la responsabilidad de un gerente para garantizar la equidad y la transparencia [7], [13].

Más allá de la optimización de procesos individuales, la literatura destaca que un hilo conductor en la modernización de la Gestión de Personas es el creciente énfasis en el Bienestar del Empleado. Este es un concepto multidimensional que abarca la salud física, mental, social y financiera de los trabajadores [14]. Incluye aspectos como la Calidad de Vida Laboral (QWL), que mide la capacidad de los empleados para satisfacer sus necesidades personales a través del trabajo, y la satisfacción laboral, que se refiere a las actitudes y emociones positivas hacia el entorno laboral [15], [16].

La importancia de fomentar el bienestar es tanto ética como estratégica. Un alto nivel de bienestar se correlaciona directamente con un mayor compromiso, una menor tasa de rotación y, consecuentemente, un aumento de la productividad y la innovación. La implementación de tecnologías de IA, al personalizar la experiencia del empleado y optimizar los procesos, tiene el potencial de contribuir positivamente a este bienestar, siempre y cuando se gestionen adecuadamente sus implicaciones.

Abordar estas consecuencias resulta fundamental, ya que la adopción de la IA genera un impacto transversal en la organización que se manifiesta en la productividad, la ética y la gestión de datos.

- **Impacto en la Productividad y Eficiencia:** El beneficio más directo y documentado de la IA en RRHH es el aumento de la eficiencia. La automatización de tareas administrativas, como la preselección de CVs, reduce la carga de trabajo y libera a los profesionales de RRHH para que se enfoquen en actividades de mayor valor estratégico, como la mentoría o la planificación del talento [8], [17]. Este aumento de la productividad se fundamenta en la capacidad de la IA para procesar grandes volúmenes de datos, lo que a su vez habilita una toma de decisiones más informada y predictiva a través de técnicas como el Análisis de RRHH (HR Analytics) [5], [18].
- **Implicaciones Éticas, Técnicas y de Protección de Datos:** A pesar de su potencial, la implementación de la IA está intrínsecamente ligada a desafíos significativos. El principal riesgo ético reside en los sesgos algorítmicos, donde los sistemas, entrenados con datos históricos, pueden perpetuar o incluso amplificar discriminaciones existentes [5], [19]. Este problema se ve agravado por la naturaleza de "caja negra" de muchos

algoritmos, lo que genera una demanda de mayor transparencia y explicabilidad para fomentar la confianza [13], [20]. A estos desafíos se suma la crítica gestión de datos de los empleados. La recopilación y el análisis masivo de información personal plantean serios retos de privacidad y seguridad, haciendo fundamental el cumplimiento de normativas como el Reglamento General de Protección de Datos (RGPD) y el "derecho a la explicación" de las decisiones automatizadas, un requisito técnico y ético clave en el diseño de cualquier sistema de IA en este ámbito [21], [22].

A pesar de los avances conceptuales, el análisis de la literatura revela que la investigación en IA aplicada a la gestión de RRHH es un campo en plena maduración, pero con claras brechas de conocimiento que definen la agenda futura. Existe una demanda recurrente de más estudios empíricos y longitudinales para validar los numerosos marcos teóricos y medir el impacto real y a largo plazo de estas tecnologías [8], [23].

Los temas que se perfilan como las fronteras más relevantes para la investigación futura son:

1. La gestión de la IA generativa, que requiere el desarrollo de marcos estratégicos específicos para su aplicación en RRHH [19].
2. La profundización en los modelos de colaboración humano-IA, para entender cómo optimizar la simbiosis entre las capacidades humanas y las de la máquina.
3. Un mayor enfoque en el impacto social y psicológico de la IA en los empleados, incluyendo su influencia en el bienestar mental [22], [23].

En conjunto, los autores analizados señalan que estos ejes de investigación constituyen la hoja de ruta para el futuro de la innovación tecnológica en la gestión de personas. Se destaca en la literatura la importancia de avanzar en estas áreas para asegurar que las futuras herramientas de IA no solo sean técnicamente robustas, sino que también estén diseñadas de manera responsable y alineadas con las complejidades del entorno organizacional y humano.

2. Fundamentos técnicos para el desarrollo de agentes de IA.

En este apartado se explorarán en profundidad los pilares conceptuales y tecnológicos esenciales para la creación y funcionamiento de agentes de IA. El análisis comenzará estableciendo las bases teóricas y el recorrido histórico del campo. Posteriormente, se profundizará en las arquitecturas generativas modernas, como los Transformers y los LLM, que actúan como el motor de la IA actual. A continuación, se examinarán los requerimientos técnicos de hardware, las limitaciones y las estrategias de optimización necesarias para

ejecutar estos modelos de manera eficiente. Finalmente, se abordará el concepto de agente inteligente, detallando sus componentes y diferentes tipologías, así como las herramientas que nos permiten crearlos y técnicas cruciales para aumentar el contexto y conocimiento de los mismos.

2.1. Definiciones Clave y Evolución Histórica.

El desarrollo de agentes de IA puede entenderse como la orquestación de varios componentes especializados que funcionan en conjunto, en lugar de una única tecnología monolítica. Para facilitar una visión clara de cómo se ensamblan estos sistemas, este apartado presentará las bases fundamentales en una secuencia lógica, desde la visión general hasta las técnicas específicas que la hacen posible.

El objetivo general de la IA, en su visión más aceptada, es la creación de sistemas que operen de forma racional y autónoma. La materialización de esta idea es el Agente Inteligente, que se define como cualquier entidad capaz de percibir su entorno y actuar sobre él para alcanzar objetivos específicos [24]. Para que un agente pueda razonar y tomar decisiones, necesita un "cerebro"; este es el rol de los Modelos de Lenguaje Extenso (LLM), redes neuronales avanzadas entrenadas para procesar y generar texto de forma coherente [25]. A su vez, para que un LLM pueda trabajar con el lenguaje, primero debe convertir las palabras y sus significados en un formato matemático que pueda comprender, una tarea que realiza mediante Embeddings, que son representaciones vectoriales de conceptos semánticos [24]. Finalmente, como el conocimiento de un LLM es inherentemente estático, derivado de un entrenamiento previo, se necesita un mecanismo para darle acceso a información externa y actualizada. Esta función la cumple la Generación Aumentada por Recuperación (RAG), una técnica que conecta al agente con bases de datos externas para enriquecer y fundamentar sus respuestas en tiempo real [26].

Una vez establecidos estos componentes técnicos fundamentales, es posible profundizar en la propia naturaleza de la IA. El campo no ha surgido de una única visión; por el contrario, su desarrollo ha estado marcado por un debate continuo sobre qué significa que una máquina sea inteligente. A continuación, se examinan los cuatro enfoques principales que han guiado la investigación y han definido los objetivos de la IA a lo largo de su historia.

Según Russell y Norvig [24], la IA ha sido abordada desde cuatro perspectivas distintas. Por un lado, están los enfoques centrados en la fidelidad humana. La IA como actuación humana se popularizó con el Test de Turing, que evalúa si una máquina puede conversar de forma indistinguible de una persona. De manera complementaria, la IA como

pensamiento humano busca replicar los procesos cognitivos, construyendo modelos computacionales que intentan simular cómo pensamos. Por otro lado, los enfoques centrados en un ideal de racionalidad definen la inteligencia de otra manera. La IA como pensamiento racional se basa en la lógica formal, buscando crear sistemas que razonen de manera estructurada para inferir conclusiones correctas. Sin embargo, el enfoque más influyente en la actualidad es la IA como actuación racional, que vincula la inteligencia al concepto de agente inteligente: un sistema que opera de forma autónoma, percibe su entorno y actúa para alcanzar sus objetivos de la manera más eficiente posible.

Estas cuatro perspectivas (la imitación del comportamiento humano, la réplica del pensamiento, el razonamiento lógico o la actuación racional) no han existido de forma aislada. Por el contrario, han competido y coexistido a lo largo del tiempo, con diferentes enfoques ganando prominencia según las capacidades tecnológicas y el paradigma científico de cada momento. La historia de la IA, por tanto, no es un relato de progreso lineal, sino un viaje cíclico marcado por épocas de gran optimismo ("veranos de la IA") seguidas de períodos de desilusión y desinversión ("inviernos de la IA"), reflejando la tensión constante entre la ambición conceptual y la realidad técnica. (Véase tabla 6)

Tabla 6: Hitos Históricos de la IA

Fuente: Elaboración propia mediante Gemini a partir de [24]

| Año(s) | Hito/Evento | Contribuyentes Clave | Significado/Impacto |
|-----------------------|---|--|--|
| 1950 | Publicación de "Computing Machinery and Intelligence" y la Prueba de Turing | Alan Turing | Estableció el marco filosófico y el objetivo de la IA: crear máquinas con un comportamiento inteligente indistinguible del humano. |
| 1956 | Conferencia de Dartmouth | John McCarthy, Marvin Minsky, Claude Shannon | Acuñó el término "Inteligencia Artificial" y fundó formalmente el campo de investigación. |
| 1958 | Invencción del Perceptrón | Frank Rosenblatt | Creó la primera red neuronal artificial, un modelo que podía aprender a reconocer patrones y sentó las bases para el aprendizaje automático. |
| 1966 | Creación de ELIZA | Joseph Weizenbaum (MIT) | Desarrolló el primer chatbot, demostrando el potencial de la interacción humano-computadora a través del lenguaje natural. |
| 1966-1972 | Desarrollo de Shakey the Robot | Stanford Research Institute (SRI) | Fue el primer robot móvil de propósito general que integraba percepción, razonamiento y acción, un hito en la robótica y la IA. |
| 1974-1980 | Primer "Invierno de la IA" | Críticas como el Informe Lighthill | Período de reducción de la financiación y el interés debido a expectativas no cumplidas y limitaciones tecnológicas. |
| Década de 1980 | Auge de los Sistemas Expertos | Edward Feigenbaum, DEC (con XCON) | Resurgimiento de la IA a través de aplicaciones comerciales que demostraron su valor práctico y económico. |
| 1997 | Deep Blue derrota a Garry Kasparov | IBM | La IA venció al campeón mundial de ajedrez, mostrando su superioridad en tareas de alta complejidad estratégica y cálculo. |
| 2011 | Watson gana en <i>Jeopardy!</i> | IBM | Demostó una capacidad avanzada para comprender y procesar el lenguaje natural, incluyendo ambigüedades y matices. [27] |
| 2012 | AlexNet gana el ImageNet Challenge | Alex Krizhevsky, Geoffrey Hinton, Ilya Sutskever | Marcó un punto de inflexión para el aprendizaje profundo, demostrando la eficacia de las redes neuronales convolucionales profundas en el reconocimiento de imágenes a gran escala. [28] |
| 2016 | AlphaGo derrota a Lee Sedol | DeepMind (Google) | La IA dominó el juego de Go, considerado mucho más intuitivo que el ajedrez, utilizando aprendizaje profundo y por refuerzo. [29] |
| 2020 | Lanzamiento de GPT-3 | OpenAI | Demostó el poder de los grandes modelos de lenguaje (LLM) para generar texto coherente y de alta calidad, catalizando la actual era de la IA generativa. [30] |

El viaje histórico comienza con los Orígenes de la Inteligencia Artificial (1943-1956), un período inicial definido por el modelo matemático de neuronas de McCulloch y Pitts y, de manera crucial, la Conferencia de Dartmouth en 1956, donde se acuñó el término "Inteligencia Artificial" y se establecieron las bases del campo. A esta le siguió la Primera Ola de Entusiasmo y Grandes Expectativas (1952-1969), una era dominada por la IA simbólica en la que se desarrollaron sistemas como el General Problem Solver y el lenguaje LISP, demostrando capacidades de razonamiento en entornos controlados pero con dificultades para escalar al mundo real. [24]

El optimismo inicial se topó con la Crisis de la IA y sus Limitaciones Técnicas (1966-1973). La "explosión combinatoria" hizo que la mayoría de los problemas fueran intratables, y el influyente Informe Lighthill en el Reino Unido provocó drásticos recortes de financiación, marcando el primer "invierno de la IA". El campo experimentó un Resurgimiento con los Sistemas Expertos (1969-1986), donde programas como MYCIN, que codificaban el conocimiento experto en reglas, alcanzaron el éxito comercial. Sin embargo, su rigidez y los problemas de mantenimiento condujeron a un segundo "invierno". Finalmente, el Renacimiento con Redes Neuronales y Aprendizaje Profundo (1986-presente) define la era moderna. La combinación de la técnica de backpropagation, la explosión de Big Data y la potencia de las Unidades de Procesamiento Gráfico (GPUs) permitió el auge del aprendizaje profundo, consolidado por hitos icónicos como la victoria de AlphaGo sobre el campeón mundial de Go. [24]

Este recorrido histórico culmina en la dicotomía fundamental que ha definido el campo: la tensión entre la IA simbólica y la IA basada en aprendizaje. La IA simbólica, a menudo llamada "Good Old-Fashioned AI" (GOFAI), dominó las primeras décadas. Su enfoque se basaba en manipular símbolos mediante reglas lógicas explícitas. Sistemas como MYCIN o DENDRAL demostraron ser eficaces en tareas acotadas, pero su rigidez y la dificultad para manejar la ambigüedad del mundo real los hacían "quebradizos" y difíciles de escalar, lo que contribuyó directamente a los "inviernos de la IA". [24]

En contraste, el paradigma actual del aprendizaje profundo adopta un enfoque conexionista. En lugar de reglas preprogramadas, las redes neuronales aprenden patrones y representaciones directamente de grandes volúmenes de datos. Impulsado por la disponibilidad de Big Data y la potencia de las GPUs, este método ofrece una flexibilidad y capacidad de generalización sin precedentes. Su verdadero poder reside en la habilidad de inferir sus propias reglas, como demostró AlphaGo al desarrollar estrategias que

superaron la comprensión humana, consolidando el aprendizaje profundo como la fuerza motriz de la IA moderna [29].

2.2. Fundamentos de la IA Generativa y los Sistemas de Agentes

El triunfo del aprendizaje profundo ha culminado en la era de la IA generativa, una fase revolucionaria en la que los modelos no solo analizan datos, sino que crean contenido completamente nuevo. A diferencia de los modelos predictivos, que clasifican o pronostican, los sistemas generativos producen texto, imágenes, música o código basándose en los patrones y estructuras que han aprendido de vastos conjuntos de datos. Este avance nos adentra en el corazón de la IA moderna, donde los LLM se erigen como la tecnología fundamental.

Los LLM representan una categoría de vanguardia dentro de la IA, específicamente diseñados para comprender, procesar y generar texto con una fluidez y coherencia notables. Utilizando volúmenes masivos de datos textuales y arquitecturas de red neuronal basadas en transformadores, estos modelos son capaces de abordar una amplia gama de tareas lingüísticas complejas sin necesidad de un entrenamiento específico para cada una de ellas [25]. Su principio fundamental es la predicción contextual de palabras: funcionan estimando la siguiente palabra más probable en una secuencia, basándose en el análisis del texto previo mediante sofisticados mecanismos de autoatención. Esta capacidad les permite adaptarse a nuevas tareas sobre la marcha, simplemente a partir de los ejemplos proporcionados en el prompt, lo que constituye uno de sus avances más significativos.

Existe una amplia variedad de LLMs, cada uno con diferentes propósitos, es decir, con un mayor grado de entrenamiento en ciertas áreas de conocimiento o aspectos técnicos. Se pueden clasificar según su funcionalidad (propósito único vs. multimodal) y accesibilidad (pago, código abierto o gratuito).

- Enfocados en texto: GPT-4, Claude, Mistral y LLaMA, entre otros, son ampliamente utilizados para redacción, generación de código y chatbots avanzados. [30], [31], [32], [33]
- Multimodales: Gemini, GPT-4 Turbo y PaLM-E pueden procesar no solo texto, sino también imágenes, audio y otros formatos, siendo útiles para visión artificial y análisis de contenido multimedia. [34], [35]
- De código abierto: BLOOM, LLaMA, Mistral y GPT-NeoX permiten a los desarrolladores utilizarlos y modificarlos en sus propios servidores. [35], [36]

- Especializados: Code Llama y WizardCoder se especializan en generación de código, mientras que Snowflake Arctic se enfoca en análisis financiero. [35], [37], [38]
- Arquitecturas Híbridas: Modelos como Mixtral 8x22B utilizan un enfoque de Mixture-of-Experts (MoE) para mejorar la eficiencia, activando solo partes especializadas del modelo según la tarea, lo que reduce el consumo computacional. [32], [35]

Independientemente de su especialización, la gran mayoría de estos modelos comparten un mismo motor: la arquitectura Transformer, presentada en 2017, que supuso una revolución al abandonar los métodos que leían el texto palabra por palabra. En su lugar, introdujo el mecanismo de auto-atención, que permite al modelo procesar todas las palabras de una frase a la vez y entender cómo se relacionan entre sí, sin importar lo lejos que estén unas de otras. [39]

El mecanismo opera de la siguiente manera: para cada palabra (token) de la secuencia de entrada, se generan tres vectores distintos: una Consulta (Query), una Clave (Key) y un Valor (Value). La Consulta representa la palabra actual que busca información contextual. Esta Consulta se compara matemáticamente con las Claves de todas las demás palabras de la secuencia para calcular una "puntuación de atención", que cuantifica la relevancia de cada palabra para la palabra actual. Estas puntuaciones se normalizan y se utilizan como pesos para realizar una suma ponderada de los vectores de Valor. El resultado es una nueva representación para la palabra original, ahora enriquecida con información contextual de toda la secuencia. Este proceso, repetido a través de múltiples capas y "cabezas de atención" en paralelo, es lo que permite a los Transformers captar los matices y las complejas relaciones del lenguaje humano. [40], [41]

Habiendo desglosado la arquitectura conceptual que permite a los LLM comprender el lenguaje, el siguiente análisis se centrará en el plano material. La viabilidad de estos modelos no reside únicamente en su diseño, sino en la capacidad de la infraestructura física para soportar sus demandas computacionales. Por ello, es esencial abordar los requerimientos técnicos, desde la elección del hardware hasta las técnicas de optimización que permiten su funcionamiento eficiente.

Entre estos requerimientos técnicos están las Unidades de Procesamiento de Cálculo (CPUs) tradicionales que, aunque son capaces de ejecutar modelos pequeños, el estándar de la industria para el entrenamiento, inferencia y ejecución de LLMs son las GPUs. Su arquitectura, diseñada para la paralelización masiva de operaciones, es ideal para los cálculos matriciales que realizan estos modelos. Tecnologías especializadas como los Tensor Cores de NVIDIA aceleran aún más estos procesos [42]. Junto a la potencia de

cálculo, la memoria es el segundo factor crítico. Los LLMs requieren ingentes cantidades de memoria para almacenar el modelo en ejecución, y la cantidad de VRAM en una GPU se convierte en un cuello de botella que determina directamente el tamaño máximo del modelo que se puede cargar [43], [44]. En cuanto al despliegue, las organizaciones se enfrentan a una decisión estratégica entre las infraestructuras en la nube (Cloud) y las locales (On-Premise). Las plataformas cloud como AWS, Google Cloud y Azure ofrecen acceso inmediato a hardware de última generación sin una gran inversión inicial, pero sus costos operativos pueden ser elevados en despliegues a gran escala. Por el contrario, una solución on-premise otorga un control total sobre la seguridad y control de los datos y puede ser más rentable a largo plazo, aunque exige una inversión inicial considerable y conocimientos técnicos para su mantenimiento [43], [45].

Para mitigar los exigentes requisitos de hardware, se emplean diversas estrategias de optimización. El tamaño del modelo, medido en miles de millones de parámetros (ej. 8B, 70B, 401B), presenta un compromiso directo: los modelos más grandes ofrecen un rendimiento y una capacidad de razonamiento superiores, pero a un coste computacional de cálculo y de memoria mucho mayor, mientras que los modelos más pequeños son más rápidos y eficientes, pero menos potentes [46]. Una de las técnicas de optimización más efectivas es la cuantización, que consiste en reducir la precisión numérica de los parámetros del modelo. En lugar de almacenar cada parámetro con el formato estándar de alta precisión (32 bits), se utilizan representaciones numéricas mucho más compactas, reduciendo la precisión a 16, 8 o incluso 4 bits por número. Esta reducción disminuye drásticamente los requisitos de memoria, con una pérdida de calidad a menudo aceptable [47]. Otras estrategias avanzadas incluyen la destilación de conocimiento, donde se entrena un modelo pequeño y eficiente ("estudiante") para que imite el comportamiento de un modelo más grande y potente ("profesor") [48], y la poda de parámetros o pruning en inglés, consiste en identificar y eliminar conexiones neuronales redundantes dentro del modelo para reducir su tamaño, campo de conocimiento y complejidad computacional sin un impacto significativo en su rendimiento [49].

Habiendo analizado los componentes fundamentales de la inteligencia artificial moderna, como los LLMs y los transformers, así como las técnicas para su optimización, el siguiente paso lógico es ensamblar estas piezas para construir sistemas con mayor autonomía y capacidad de acción. Este enfoque nos conduce directamente al concepto de agentes inteligentes.

Un agente de IA se define como una entidad autónoma que utiliza sus componentes para interactuar de forma significativa con su entorno y alcanzar objetivos. La definición formal

establece que un agente percibe su entorno a través de sensores y actúa sobre él mediante actuadores [50]. En el contexto del software moderno, esto se traduce en una arquitectura donde, según [51]:

- **Percepción (Sensores):** Son los canales de entrada de información, que pueden ir desde una consulta de un usuario en lenguaje natural hasta datos en tiempo real provenientes de una API, el contenido de una base de datos o eventos de un sistema de monitoreo .
- **Razonamiento (Motor):** Es el núcleo cognitivo del agente. Hoy en día, este papel lo desempeña casi universalmente un LLM. El modelo es responsable de la planificación de tareas, la descomposición de problemas complejos, la toma de decisiones y, fundamentalmente, la selección de herramientas adecuadas para cada paso.
- **Acción (Actuadores):** Son las capacidades que el agente tiene para influir en su entorno. Esto se logra mediante la ejecución de un conjunto de "herramientas" predefinidas, que pueden ser cualquier función o sistema externo: llamar a una API meteorológica, ejecutar una consulta SQL, realizar una búsqueda web o incluso escribir y ejecutar código.
- **Memoria:** Para realizar tareas complejas que requieren múltiples pasos o para mantener una conversación coherente, los agentes necesitan un sistema de memoria. Esta puede ser a corto plazo, para mantener el contexto de la interacción actual, o a largo plazo, donde los conocimientos y experiencias se almacenan de forma persistente en una base de datos (a menudo una base de datos vectorial) para su posterior recuperación. [52]

Según [24], los agentes inteligentes pueden clasificarse en una jerarquía de complejidad y capacidades, donde cada nivel se construye sobre el anterior:

- **Agentes Reactivos Simples:** Son los más básicos. Como se observa en el esquema de la Figura 5, su funcionamiento es directo: los sensores captan información del entorno ("What the world is like now") y, basándose en un conjunto de reglas de condición-acción predefinidas, el agente selecciona una acción ("What action I should do now") que ejecuta a través de sus actuadores. No tienen memoria del pasado; solo reaccionan al presente. Un ejemplo actual podría ser un termostato que enciende la calefacción solo cuando la temperatura baja de un umbral, o las luces automáticas que se activan con el movimiento. Su gran limitación es que son ineficaces si el entorno no es completamente observable.

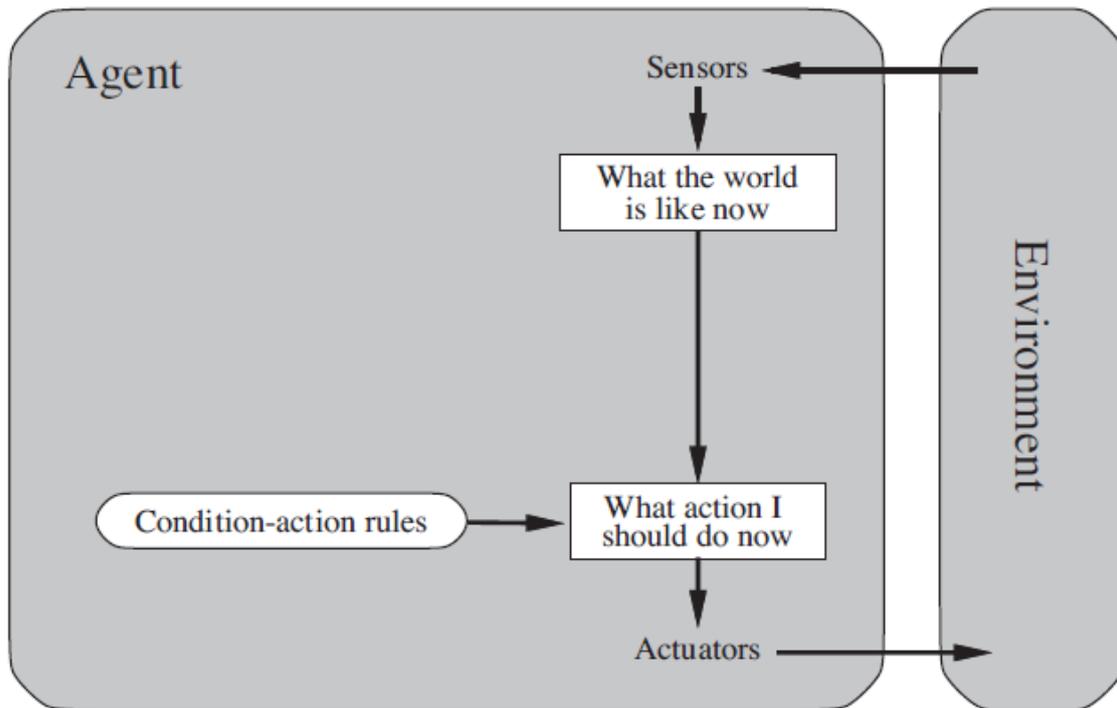


Figura 5: Esquema de un agente reactivo simple

Fuente: Tomado de [28]

- Agentes Reactivos Basados en Modelos: Para superar la limitación de la observabilidad parcial, estos agentes, como se muestra en la Figura 6, mantienen un estado interno o "modelo del mundo". Este modelo se actualiza constantemente considerando cómo evoluciona el entorno por sí mismo ("How the world evolves") y cómo las propias acciones del agente lo afectan ("What my actions do"). Gracias a este estado interno, el agente puede inferir aspectos del entorno que no percibe directamente, lo que le permite tomar decisiones más informadas. Un ejemplo claro es un robot aspirador que crea un mapa de una casa para recordar la ubicación de los muebles y optimizar su ruta de limpieza, incluso si no los ve en todo momento.

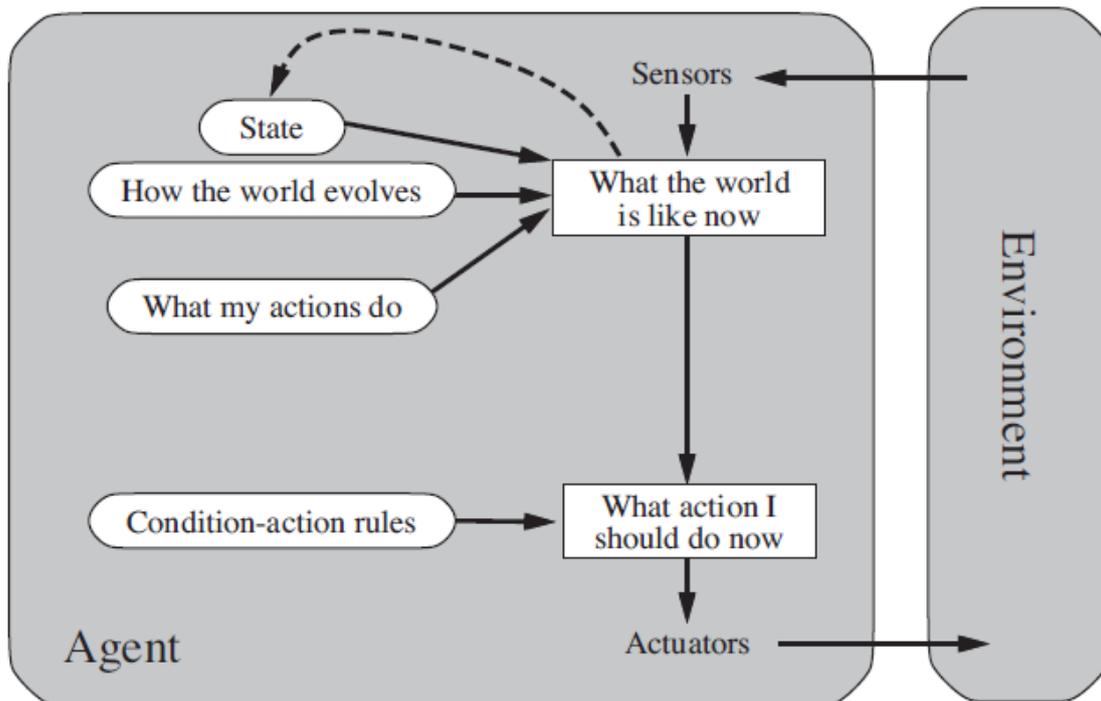


Figura 6: Esquema de un agente reactivo basado en modelos

Fuente: Tomado de [28]

- Agentes Basados en Objetivos: Conocer el estado del mundo no es suficiente; un agente necesita un propósito. Como ilustra la Figura 7, estos agentes incorporan metas ("Goals"). Además de modelar el mundo, pueden evaluar los resultados de sus posibles acciones ("What it will be like if I do action A") para elegir aquella que los acerque a su objetivo. Esto introduce capacidades de búsqueda y planificación. Un sistema de navegación GPS es un ejemplo perfecto: su objetivo es llevarte a un destino, y para ello planifica una secuencia de acciones (giros, seguir recto) que le permitan alcanzar esa meta.

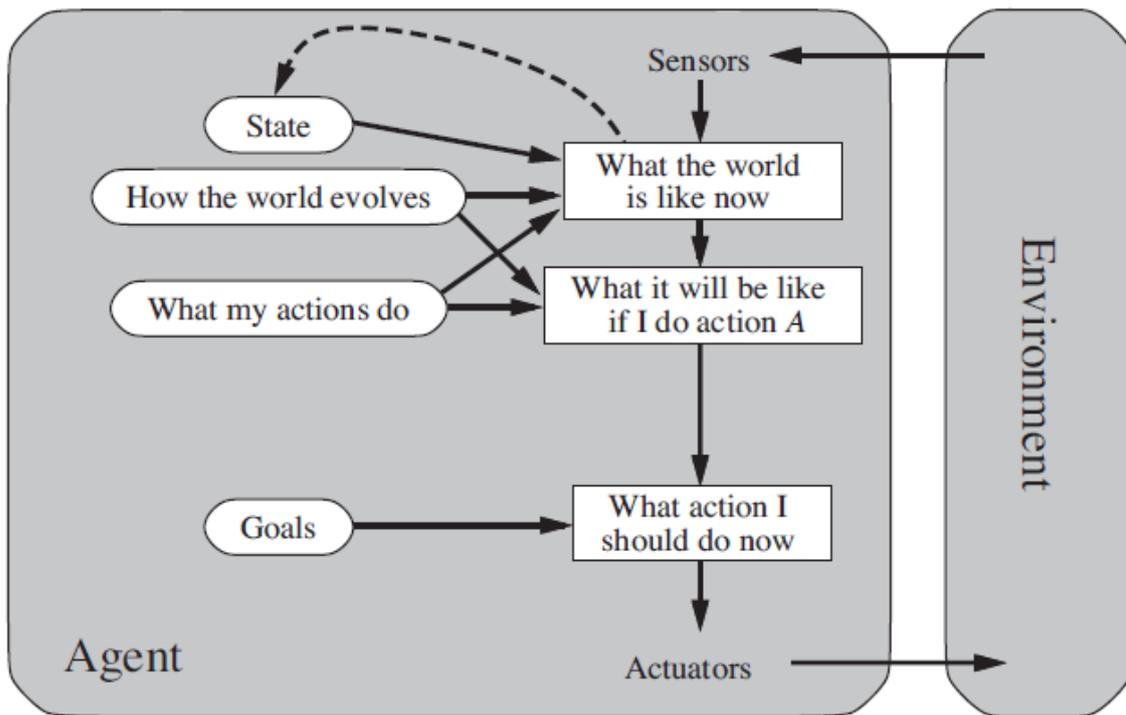


Figura 7: Esquema de un agente basado en objetivos

Fuente: Tomado de [28]

- **Agentes Basados en Utilidad:** A menudo, un objetivo puede alcanzarse de múltiples maneras, pero algunas son preferibles a otras. Los agentes basados en utilidad (Figura 8) no solo buscan una meta, sino que intentan maximizar su "felicidad" o rendimiento. Para ello, emplean una función de utilidad ("Utility") que asigna un valor numérico a cada estado del mundo. El agente evalúa qué tan "feliz" estará en los posibles estados futuros ("How happy I will be in such a state") y elige la acción que conduce al estado con la máxima utilidad esperada. Por ejemplo, una aplicación de trading automático no solo busca generar ganancias (objetivo), sino maximizar el retorno de inversión ajustado al riesgo (utilidad).

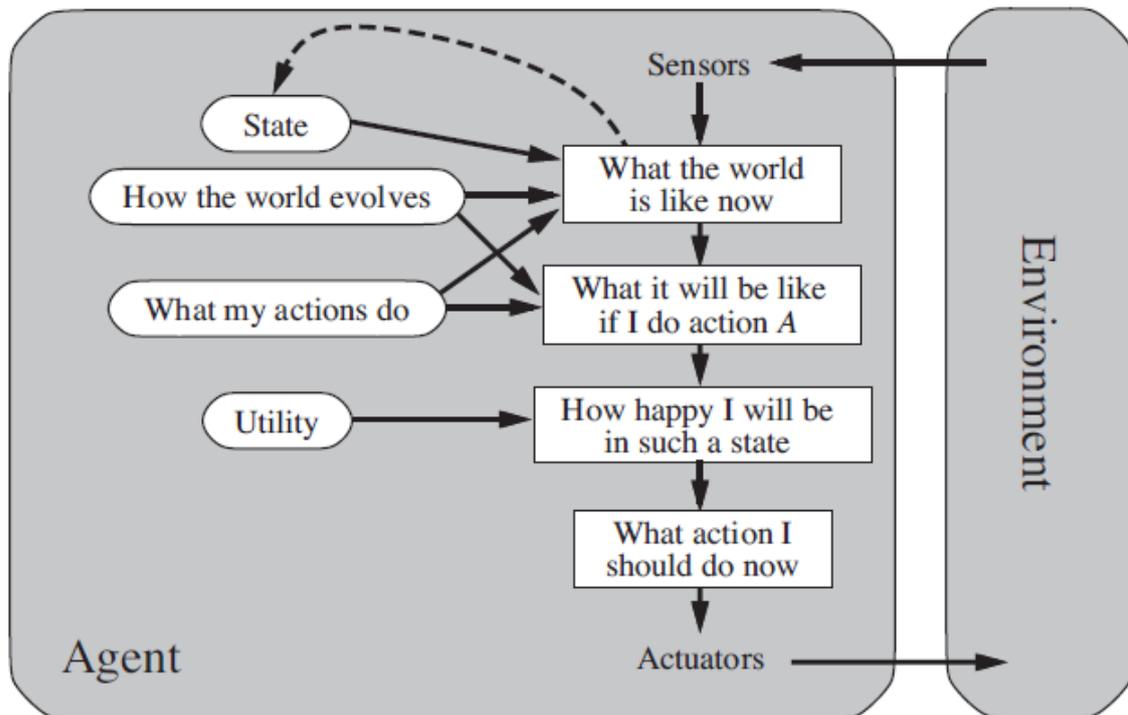


Figura 8: Esquema de un agente basado en utilidad

Fuente: Tomado de [28]

- Agentes de Aprendizaje: A diferencia de los anteriores, diseñados con una lógica fija, los agentes de aprendizaje pueden mejorar su rendimiento con la experiencia. La Figura 9 muestra su estructura, que consta de cuatro componentes clave: el elemento de actuación (que ejecuta las acciones), el crítico (que evalúa el rendimiento con un estándar de referencia y proporciona retroalimentación), el elemento de aprendizaje (que usa esa retroalimentación para modificar el conocimiento del agente) y el generador de problemas (que sugiere acciones nuevas para explorar y aprender). Un ejemplo representativo son los sistemas de recomendación de plataformas como Netflix o Spotify, que aprenden de tus gustos para sugerirte contenido cada vez más afín.

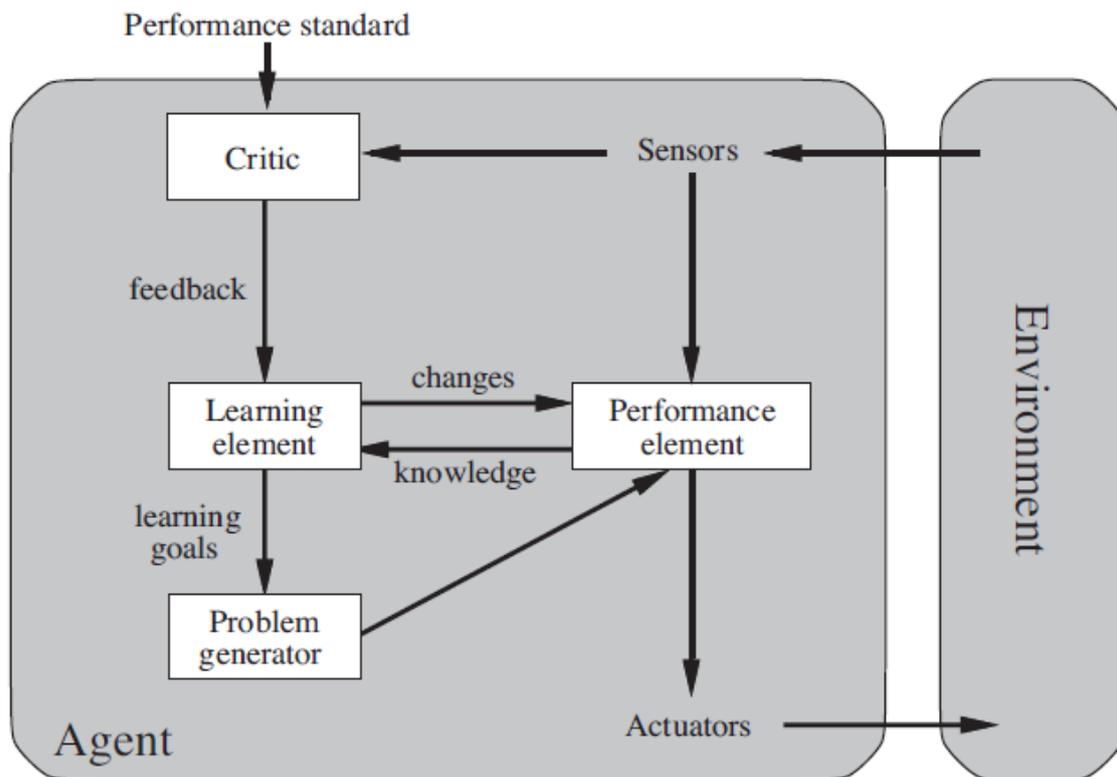


Figura 9: Esquema de un agente basado en aprendizaje

Fuente: Tomado de [28]

En el contexto de este trabajo, el agente desarrollado es un asistente de ayuda a la investigación científica, diseñado para optimizar el proceso de revisión bibliográfica. Este agente se puede clasificar como un sistema híbrido. Es fundamentalmente un agente basado en objetivos, ya que su meta principal es clara: filtrar un gran volumen de referencias para entregar al investigador una lista con las más relevantes. A su vez, es un agente basado en utilidad, puesto que no solo cumple el objetivo, sino que lo hace buscando la máxima afinidad. La "utilidad" viene definida por los criterios específicos o la rúbrica que el investigador proporciona, permitiendo al agente ponderar y clasificar las referencias para encontrar las óptimas. Aunque no es un agente de aprendizaje que modifique sus algoritmos internos, sí exhibe la capacidad de adaptar su conocimiento dinámicamente, asimilando nueva información (los artículos y los criterios) en tiempo real para refinar sus resultados en cada consulta.

Para materializar la construcción de estos agentes, existen diferentes enfoques. Mientras que los frameworks de código ofrecen una gran flexibilidad, la construcción y, sobre todo, la integración de agentes en procesos de negocio existentes se simplifica enormemente con plataformas de bajo código. Una de las más destacadas en este ámbito es n8n, que se posiciona como una "plataforma de automatización de flujos de trabajo para equipos técnicos". [53], [54]

N8n opera bajo una filosofía de flujo de información, sea JSON u objetos binarios, de forma visual basándose en nodos, donde los usuarios conectan diferentes bloques para crear automatizaciones complejas. Cada nodo representa un paso en el proceso: un disparador (Trigger) inicia el flujo (p. ej., un nuevo email o una llamada a una API), y los nodos de acción ejecutan tareas específicas, como leer una base de datos o interactuar con un LLM [55], [56]. Su principal ventaja es que combina la simplicidad de una interfaz de arrastrar y soltar con la capacidad de poder escribir código propio (JavaScript/Python) en cualquier punto del flujo, ofreciendo un puente entre los desarrolladores avanzados y los usuario principiantes [57], [58].

Para la creación de agentes, n8n dispone de un nodo llamado AI Agent (véase figura 10) que actúa como un orquestador. Este nodo utiliza un modelo de lenguaje (como GPT-4 o Claude) como motor de razonamiento y le proporciona la capacidad de conectar un conjunto de "herramientas", que no son más que otros nodos funcionales conectados a él. El agente, guiado por un prompt de sistema que define su objetivo, personalidad, restricciones, ejemplos y demás datos que el diseñador crea necesario, decide de forma autónoma qué herramienta utilizar en cada paso para cumplir con la solicitud del usuario. Esto permite construir agentes complejos que pueden interactuar con cientos de aplicaciones (como Slack, Google Sheets o bases de datos SQL) de forma visual e intuitiva. Además, la capacidad de auto-alojamiento de n8n proporciona un control total sobre los datos, un factor crucial para la seguridad y la privacidad en entornos empresariales críticos. [59], [60], [61], [62]

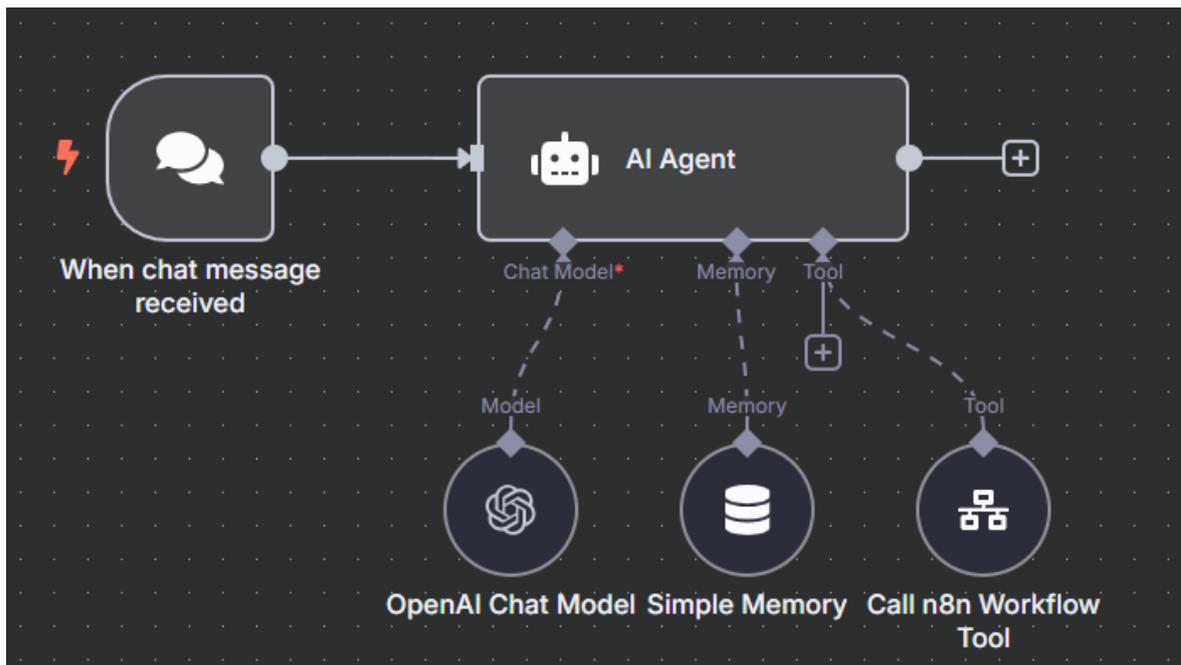


Figura 10: Ejemplo de agente en n8n

Fuente: Captura de workflow en n8n

Tras examinar la arquitectura y la clasificación teórica de los agentes, la implementación práctica de estos sistemas se enfrenta a un desafío fundamental: la base de su conocimiento. El Motor de Razonamiento (el LLM) y el sistema de Memoria deben operar con información que sea actual, fiable y específica del dominio de la tarea. Sin embargo, los LLM por sí solos poseen un conocimiento estático, congelado en el tiempo de su entrenamiento, lo que les lleva a "alucinar" o a proporcionar información desactualizada, un problema crítico para cualquier agente que deba actuar en el mundo real.

Aquí es donde la arquitectura de Recuperación Aumentada por Generación (RAG) se convierte en una técnica indispensable. Combina la recuperación de información con la capacidad generativa de los LLM para mejorar drásticamente la precisión y fiabilidad de las respuestas del agente [26]. El proceso se alinea perfectamente con la estructura del agente:

- El Recuperador (Retriever) actúa como el sistema de memoria externa del agente. Dada una consulta, su función es buscar en una base de conocimiento (que puede consistir en documentos, páginas web, o una base de datos vectorial especializada) y extraer los fragmentos de información más relevantes. Este proceso dota al agente de un conocimiento dinámico y específico que va más allá de su entrenamiento inicial.
- El Generador (Generator) es el motor de razonamiento (el LLM). En lugar de responder basándose únicamente en su conocimiento estático, recibe la consulta original junto con la información contextual recuperada por el Retriever. Con este contexto adicional,

el LLM puede razonar sobre información veraz y actual, generando una respuesta mucho más precisa, fundamentada y fiable.

Este método ofrece beneficios cruciales para la construcción de agentes robustos: reduce la generación de información falsa respecto del tema de interés, permite una actualización del conocimiento simplemente actualizando la base de datos externa, sin necesidad de reentrenar o cambiar de modelo, y aumenta la trazabilidad de las respuestas al poder citar las fuentes utilizadas. Al poder adaptar la base de conocimiento a dominios específicos, RAG se convierte en una técnica esencial para crear agentes especializados en aplicaciones empresariales y críticas [63].

Capítulo 7. Diseño y Desarrollo de un Agente de IA para la Asistencia a la investigación.

Tras haber establecido el marco conceptual y tecnológico en el capítulo anterior, el presente capítulo se adentra en el núcleo de este TFG: el diseño y desarrollo de un agente de IA para la asistencia a la investigación. El objetivo es documentar el proceso práctico seguido para la construcción del prototipo, desde la conceptualización inicial hasta la arquitectura final propuesta, detallando las fases experimentales, las decisiones de diseño y los aprendizajes obtenidos.

El problema fundamental que se aborda con este agente surge de un cuello de botella crítico en el proceso de investigación: la revisión bibliográfica. En la actualidad, los investigadores se enfrentan a un crecimiento exponencial en el volumen de publicaciones científicas. La tarea de identificar, filtrar y seleccionar los artículos más relevantes para un campo de estudio específico se ha convertido en un proceso manual arduo y extremadamente lento. Este cribado manual no solo consume una cantidad desproporcionada de tiempo y esfuerzo, sino que también es susceptible a la subjetividad y al error humano, con el riesgo inherente de omitir trabajos cruciales para el estado del arte.

Frente a este desafío, se propone el desarrollo de un agente inteligente como una solución para automatizar y optimizar esta fase de la investigación. La visión es ofrecer una herramienta que, a partir de criterios definidos por el investigador, pueda analizar sistemáticamente un gran corpus de documentos y entregar una selección priorizada y justificada de las referencias más pertinentes. Al delegar la tarea mecánica del filtrado inicial a un sistema de IA, se busca no solo acelerar drásticamente el proceso, sino también aumentar su objetividad y exhaustividad. Esto permitiría a los investigadores liberar tiempo valioso para dedicarlo a tareas de mayor nivel intelectual, como el análisis crítico, la síntesis de información y la generación de nuevo conocimiento.

El desarrollo no se abordó como un proceso lineal, sino como una exploración iterativa de diferentes metodologías. Se partió de enfoques sencillos y de bajo coste computacional para validar la viabilidad del concepto, para luego explorar progresivamente arquitecturas más complejas y potentes. Antes de desglosar las aproximaciones específicas, es fundamental presentar el diseño conceptual que ha guiado todo el proceso. La arquitectura general del agente se articula en torno a un flujo de trabajo que define la interacción entre

el investigador y el sistema de IA, tal como se representa en la Figura 11. Este proceso se estructura en tres etapas secuenciales:

- **Entrada (Input):** En la primera fase, el investigador proporciona los dos elementos clave que alimentan al sistema. Por un lado, el Corpus de Artículos, que consiste en los metadatos (título, resumen, etc.) de los documentos a evaluar, estructurados en un formato accesible como una hoja de cálculo. Por otro lado, la Pregunta de Investigación o Rúbrica, que define los criterios temáticos y las directrices que el agente debe seguir para su análisis.
- **Procesamiento (Núcleo del Agente):** La segunda etapa constituye el núcleo del sistema. El Motor de Razonamiento, impulsado por un Modelo de Lenguaje Extenso (LLM), recibe la información de entrada. Utilizando un prompt específico que integra la rúbrica y los metadatos de un artículo, el modelo evalúa la relación entre ambos, un proceso que se repite de forma iterativa para cada entrada del corpus.
- **Salida (Output):** Finalmente, el agente genera los resultados de su análisis. Para cada artículo, produce dos tipos de salida: una Calificación de Relevancia, que puede ser una puntuación numérica o una categoría (ej. "Muy Relevante"), y una Justificación Argumentada, que consiste en un texto breve que explica por qué se asignó dicha calificación, basándose en los criterios de la rúbrica.

Estructura del Agente de IA para Asistencia a la Investigación

Flujo de trabajo conceptual desde la entrada de datos hasta el resultado final

1. Entrada (Input)

El investigador proporciona los datos iniciales



Corpus de Artículos

Metadatos (título, abstract, etc.) estructurados en una hoja de cálculo (ej. Google Drive).



Pregunta de Investigación / Rúbrica

Criterios temáticos definidos por el investigador para guiar la evaluación del agente.

2. Procesamiento (Núcleo del Agente)

El LLM analiza cada artículo según las instrucciones

Motor de Razonamiento (LLM)

Utilizando un **System Message** y un **Prompt** específico que incluye la rúbrica, el modelo evalúa la relación entre los metadatos de cada artículo y los criterios del investigador. Este proceso se repite para cada entrada del corpus.

3. Salida (Output)

Resultados generados por el agente



Calificación de Relevancia

Una puntuación numérica o una categoría (ej. "Muy Relevante") para cada artículo.



Justificación Argumentada

Un texto breve que explica por qué se asignó esa calificación, basándose en la rúbrica.

Figura 11: Estructura del Agente de IA para asistencia a la Investigación

Fuente: Elaboración propia mediante Gemini.

El desarrollo del agente se realizó a través de varias fases experimentales. Se comenzó con un análisis de los metadatos de los artículos para validar la idea, para después explorar enfoques más avanzados que implicaban el análisis del contenido completo de los documentos. En las siguientes secciones, se documenta este proceso iterativo, detallando cada aproximación y las decisiones de diseño que llevaron a la arquitectura final del MVP.

1. Fase 1: Análisis de metadatos y primeras categorizaciones.

La primera fase del desarrollo se centró en probar la viabilidad del concepto utilizando los datos más accesibles: los metadatos de los artículos (título, resumen, palabras clave) extraídos de Scopus y cargados en una hoja de cálculo de Google Drive.

1º Aproximación. Proceso de filtrado de varias etapas.

La primera aproximación se basó en un proceso de filtrado en varias etapas, con el objetivo de reducir un gran número de artículos a un conjunto final más relevante. La fase inicial consistió en una búsqueda exhaustiva en Scopus para construir el corpus de trabajo. Se realizaron dos consultas: la primera, más específica, combinaba los términos "human resources", "artificial intelligence" y "wellbeing" en los títulos con un filtro de área ("Ciencia de computadores", "Ciencias Sociales", "Ingeniería", "Empresa, gestión y contabilidad"), obteniendo 25 resultados. La segunda, más amplia, utilizó "human resources" y "artificial intelligence" con un filtro temporal (2019-2025) y de área ("Empresa, gestión y contabilidad"), arrojando 776 resultados. Siendo estas las cadenas de búsqueda correspondientes:

```
(TITLE-ABS-KEY(human resources) AND TITLE-ABS-KEY(artificial intelligence) AND TITLE-ABS-KEY(wellbeing)) AND ( LIMIT-TO ( DOCTYPE,"ar" ) OR LIMIT-TO ( DOCTYPE,"ch" ) ) AND ( LIMIT-TO ( SUBJAREA,"SOCI" ) OR LIMIT-TO ( SUBJAREA,"BUSI" ) OR LIMIT-TO ( SUBJAREA,"COMP" ) OR LIMIT-TO ( SUBJAREA,"ENGI" ) )
```

```
(TITLE-ABS-KEY(human AND resources) AND TITLE-ABS-KEY(artificial AND intelligence)) AND PUBYEAR > 2018 AND PUBYEAR < 2026 AND ( LIMIT-TO ( DOCTYPE,"ar" ) OR LIMIT-TO ( DOCTYPE,"ch" ) ) AND ( LIMIT-TO ( SUBJAREA,"BUSI" ) )
```

De este modo, se conformó un corpus inicial combinado de 801 artículos, que posteriormente fue sometido a un proceso de criba en tres pasos, a través de n8n, asistido por diferentes modelos de IA.

- Criba 1 (Filtro por Palabras Clave): Se aplicó un filtro programático para descartar cualquier artículo cuyo título y resumen no contuvieran un conjunto predefinido de

palabras clave⁶. Tras este paso y la eliminación de entradas sin abstract, el corpus se redujo a 764 artículos.

- Criba 2 (Calificación Binaria de Relevancia): Para el primer filtro de contenido, se empleó un panel de modelos de IA (GPT-4o mini, Gemini 2.0 Flash, Mistral Nemo, Gemma 3 y Llama 3.2) para comparar posteriormente los resultados. Cada modelo clasificó los 764 artículos como relevante ("Sí") o no relevante ("No") utilizando el siguiente prompt.

```
"Analyze the following abstract and determine whether it is related to the use of artificial intelligence and intelligent agents in human resource management within organizations. Respond only with 'Yes' if it is related, or 'No' if it is not."
Abstract: {{ $json.Abstract }}
```

- Criba 3 (Clasificación Temática): Los artículos que superaron la criba anterior fueron sometidos a una clasificación temática. Para ello, se aplicó un marco conceptual basado en el trabajo de Santanna [64], que propone cuatro grandes grupos para clasificar el impacto de la IA en la Gestión de RRHH. Utilizando el mismo panel de modelos de IA, cada artículo fue asignado a uno de estos cuatro grupos conceptuales. Se instruyó a los modelos mediante un prompt específico que solicitaba una respuesta exclusivamente numérica para asegurar la consistencia de los datos:

```
"Analyze the following title and abstract and determine which of the following categories it belongs to. Respond only with the number corresponding to the most relevant category. Do not provide any explanation."
Categories:
1 HRM policies and practices: Use of AI in HR functions such as recruitment and selection, job design, performance management, training and development, compensation and benefits.
2 Role of HRM specialists with AI: Impact of AI on the work of HRM professionals, automation of their tasks, or changing roles.
3 Perceptions and experiences of management by AI-HRM: How employees experience being managed by AI, including redistribution of HR tasks and employee-AI relationships.
4 Work-floor employees collaborate with AI: Collaboration between employees and AI/robots, including support or training needed to enable this collaboration.
Title: {{ $json.Title }}
Abstract: {{ $json.Abstract }}
```

⁶ Palabras clave: "Artificial Intelligence", "Machine Learning", "Deep Learning", "Neural Networks", "Natural Language Processing", "AI-powered", "Data Science", "Predictive Analytics", "Generative AI", "Automation", "Human Resources", "HR Management", "Workforce Planning", "Employee Engagement", "Recruitment", "HR Technology", "Organizational Behavior", "AI in HR", "AI Recruitment", "Automated Hiring", "HR Chatbots", "AI-driven Performance Reviews", "AI-powered Employee Retention", "Predictive Hiring", "Well-being", "Workplace Wellness" y "Corporate Well-being"

El proceso de criba multi-etapa no solo sirvió como un método para refinar el corpus, sino que también proporcionó una valiosa oportunidad para realizar una evaluación comparativa del comportamiento de los diferentes LLMs. El análisis de los resultados de las Cribas 2 y 3 reveló patrones significativos en cómo cada modelo interpreta y clasifica la información.

El primer patrón observable, derivado de la calificación binaria de la Criba 2 es la existencia de un claro "espectro de exigencia" entre los modelos (véase tabla 7).

Tabla 7: Resultados de Calificación Binaria por Modelo

Fuente: Elaboración propia.

| Modelo | Artículos "Sí" (Relevantes) | Artículos "No" (No Relevantes) | % de Relevancia |
|------------------|------------------------------------|---------------------------------------|------------------------|
| Mistral Nemo | 593 | 171 | 77.6% |
| Llama 3.2 | 533 | 231 | 69.8% |
| Gemini 2.0 Flash | 522 | 242 | 68.3% |
| GPT-4o mini | 491 | 273 | 64.3% |
| Gemma | 456 | 308 | 59.7% |

Se observa que Mistral Nemo es el modelo más inclusivo, considerando relevante a más del 77% del corpus. En el otro extremo, Gemma se posiciona como el más estricto, aplicando los criterios de relevancia (internos del modelo) más severos. Los demás modelos se sitúan en puntos intermedios. No obstante, es preciso señalar que estos resultados no deben extrapolarse a otros dominios temáticos sin una validación previa, ya que, como se demostrará, las métricas de rendimiento pueden variar drásticamente en función del contexto, la estructura del prompt y el formato de los datos de entrada.

El análisis de la clasificación temática revela el hallazgo más significativo, una divergencia fundamental en la interpretación del marco conceptual definido anteriormente (Véase tabla 8).

Tabla 8: Distribución Temática por Modelo

Fuente: Elaboración propia.

| Modelo | Grupo 1 | Grupo 2 | Grupo 3 | Grupo 4 | Sin Grupo | Total "Sí" |
|------------------|---------|---------|---------|---------|-----------|------------|
| GPT-4o mini | 372 | 39 | 58 | 22 | 0 | 491 |
| Gemini 2.0 Flash | 375 | 22 | 45 | 68 | 12 | 522 |
| Mistral Nemo | 245 | 155 | 121 | 1 | 71 | 593 |
| Llama 3.2 | 140 | 151 | 242 | 0 | 0 | 533 |
| Gemma | 117 | 124 | 215 | 0 | 0 | 456 |

Los modelos en la nube (GPT-4o mini, Gemini) muestran una fuerte convergencia, asignando la gran mayoría de sus artículos seleccionados al Grupo 1, que representa el núcleo temático del estudio. En contraste, los modelos locales (Llama 3.2, Gemma) priorizan los Grupos 2 y 3, e ignoran por completo el Grupo 4. Esto sugiere que no se trata de un simple error, sino de una interpretación fundamentalmente distinta del marco teórico proporcionado, donde los modelos locales tienden a favorecer temas secundarios o tangenciales.

A raíz de estos hallazgos, se extrajeron dos conclusiones clave para el diseño del agente. Primero, la notable divergencia en la interpretación temática y los considerablemente mayores tiempos de ejecución de los modelos locales para procesar el corpus completo, llevaron a la decisión de centrar las siguientes fases de la investigación exclusivamente en los modelos en la nube. Segundo, la necesidad de una guía precisa para evitar respuestas inconsistentes o "alucinaciones" del modelo, hizo evidente que el diseño final del MVP debería incorporar un prompt ya construido y específicamente adaptado al área temática de la investigación, en lugar de permitir que el investigador definiera los criterios libremente y sin una estructura definida.

2º Aproximación. Rúbrica editable.

Las observaciones de la primera aproximación, en particular la divergencia en la clasificación temática entre modelos, indicaron la conveniencia de un método de evaluación con mayor estructura y control por parte del investigador. En consecuencia, se desarrolló una segunda aproximación que introdujo una rúbrica de evaluación editable dentro del prompt. Este enfoque no solo buscaba mejorar la calidad de la clasificación, sino también dotar al proceso de una mayor transparencia y consistencia, permitiendo al investigador guiar el razonamiento del modelo de forma explícita. El componente central de esta

aproximación es un prompt complejo, diseñado no como una simple pregunta, sino como un completo instrumento de análisis para guiar el comportamiento del LLM. Su estructura se compone de varios elementos clave, tal y como se visualiza en la Figura 12, para asegurar un rendimiento preciso y predecible:



Figura 12: Estructura visual de prompt con rúbrica

Fuente: Elaboración propia mediante Gemini

Los elementos fundamentales del prompt son:

- **Asignación de Rol:** El prompt comienza definiendo una identidad para el modelo: "You are an expert AI agent in analyzing academic and research literature, specializing in the intersection of Artificial Intelligence (AI) and Human Resource Management (HRM)". Esta técnica de juego de roles establece un contexto claro y activa en el modelo los conocimientos y el vocabulario específicos del dominio, preparando el terreno para una evaluación más informada.
- **Instrucciones por Pasos:** En lugar de solicitar una única respuesta, el prompt desglosa la tarea en un proceso lógico y secuencial: "Paso 1: Lectura Inicial", "Paso 2: Aplicar Criterios de la Rúbrica", etc. Este enfoque, conocido como razonamiento de cadena de pensamiento, obliga al modelo a seguir un proceso de evaluación sistemático, lo que mejora la fiabilidad de los resultados y facilita la depuración de errores.
- **Contextualización y Ejemplo de Salida:** El prompt incluye una sección de "Contexto" que subraya la importancia de la tarea, y un "Ejemplo" que muestra un caso práctico con la respuesta esperada en formato JSON. Esta técnica de aprendizaje "one-shot" resultó ser el método más efectivo para estandarizar la salida del modelo, asegurando que la respuesta se ajuste de manera consistente al formato de datos requerido.

El componente central que permite esta evaluación estructurada es la rúbrica, que transforma un juicio subjetivo en un proceso cuantificable y basado en criterios explícitos.

- **Rúbrica Modular:** La rúbrica se divide en dos secciones principales: una "Evaluación de Temática General" para una valoración holística de la pertinencia del documento, y una sección de "Evaluaciones de Subgrupos" que desglosa el análisis en seis áreas clave de la Gestión de Recursos Humanos (Reclutamiento, Diseño del Trabajo, etc.). Este diseño granular permite una evaluación multifacética y otorga al investigador la flexibilidad de enfocarse en los subgrupos más relevantes para su investigación.
- **Sistema de Puntuación por Criterio:** Cada criterio dentro de la rúbrica se califica en una escala de 1 a 5. Esta escala está diseñada para medir la especificidad y claridad de la información presente en el texto. Una puntuación de 1 indica la ausencia total o una mención muy vaga del concepto evaluado, mientras que una puntuación de 5 representa un enfoque explícito, detallado y específico sobre el criterio en cuestión. Los niveles intermedios (2, 3 y 4) permiten una matización que refleja la profundidad con la que el documento trata cada aspecto.
- **Interpretación de las Puntuaciones Agregadas:** Las puntuaciones individuales de cada criterio se suman para obtener una puntuación total tanto para la temática general como para cada subgrupo. Estos totales se interpretan según los umbrales definidos,

permitiendo una clasificación rápida y estandarizada de la relevancia de cada documento, como se detalla en la Tabla 9.

Tabla 9: Interpretación de la puntuación para la sección "Temática General".

Fuente: Elaboración propia.

| Puntuación Total (Máx. 25) | Nivel de Relevancia (Temática General) | Descripción |
|-----------------------------------|---|---|
| 21-25 | Muy Alta Relevancia | El documento tiene un enfoque explícito y detallado en la aplicación de IA en RRHH. |
| 16-20 | Alta Relevancia | El documento es claramente relevante, aunque puede carecer de detalles específicos en algunos aspectos. |
| 11-15 | Relevancia Moderada | El documento trata el tema, pero de manera general o con conexiones indirectas. |
| 6-10 | Baja Relevancia | La conexión con el tema es superficial o tangencial. |
| 1-5 | Mínima o Irrelevante | El documento apenas menciona los conceptos clave o no los relaciona. |

De forma similar, se evalúa la especificidad con la que se trata cada subárea de RRHH (véase tabla 10):

Tabla 10: Interpretación de la puntuación para las secciones de "Subgrupos".

Fuente: Elaboración propia.

| Puntuación Total (Máx. 15) | Nivel de Especificidad (Subgrupos) | Descripción |
|-----------------------------------|---|---|
| 13-15 | Muy Alta Especificidad | Análisis detallado y profundo de la aplicación de IA en esta subárea. |
| 9-12 | Especificidad Moderada | Se proporcionan detalles aceptables sobre la aplicación de la IA. |
| 5-8 | Superficial | Se menciona la aplicación de la IA, pero con escaso detalle. |
| 1-4 | Muy Limitada | La mención es mínima o inexistente. |

En conjunto, estos elementos transforman una simple instrucción en un prometedor instrumento de evaluación. La combinación de un rol definido, un proceso por pasos, una rúbrica detallada y un ejemplo claro permite guiar al LLM hacia la generación de resultados consistentes, auditables y de calidad aceptable. Este enfoque mitiga el problema de la "caja

negra", ofreciendo una explicabilidad total sobre la calificación asignada a cada artículo. Debido a estas características de control, transparencia y granularidad en la evaluación, este enfoque fue seleccionado como la base para la arquitectura final del prototipo (MVP) de la herramienta.

Resultados de la calificación por rúbrica.

Una vez aplicado el prompt con la rúbrica a los artículos seleccionados mediante los modelos GPT-4o mini y Gemini 2.0 Flash, se procedió a un análisis estadístico y visual de los resultados para evaluar su consistencia y comportamiento.

Es importante destacar que la rúbrica empleada evalúa dos grandes apartados: la temática general y una serie de subgrupos. Los resultados que se exponen en esta sección se centran exclusivamente en las puntuaciones obtenidas en el criterio de temática general, con el fin de ofrecer una visión clara de la pertinencia global asignada por cada modelo.

El análisis descriptivo revela diferencias sutiles pero informativas. La puntuación media de Gemini (13.07) fue ligeramente superior a la de ChatGPT (10.27). Ambas medias se sitúan en el rango de "Relevancia Moderada" (11-15 puntos), aunque la calificación de Gemini sugiere una tendencia general a considerar los artículos como ligeramente más pertinentes. A pesar de esta diferencia, las desviaciones estándar son muy similares (6.83 para Gemini frente a 7.14 para ChatGPT), indicando un grado de dispersión comparable en sus evaluaciones.

El análisis de los histogramas (véanse Figuras 13 y 14) expone perfiles de calificación distintos. La distribución de ChatGPT presenta una notable concentración de puntuaciones en el rango más bajo (1-5), correspondiente a la categoría "Mínima o Irrelevante". Esto sugiere una tendencia a ser más estricto, asignando calificaciones mínimas cuando un artículo no cumple con un umbral básico de relevancia. Por otro lado, la distribución de Gemini, aunque más centrada en el rango medio con un pico en torno a los 16 puntos (calificado como "Alta Relevancia"), muestra un comportamiento anómalo. Se observan calificaciones que superan con creces el máximo posible de 25 puntos establecido en la rúbrica, llegando incluso a valores cercanos a 45. Este fenómeno es un claro ejemplo de una "alucinación" del modelo, donde la IA no se adhiere estrictamente a las restricciones numéricas del prompt, a pesar de las instrucciones explícitas.

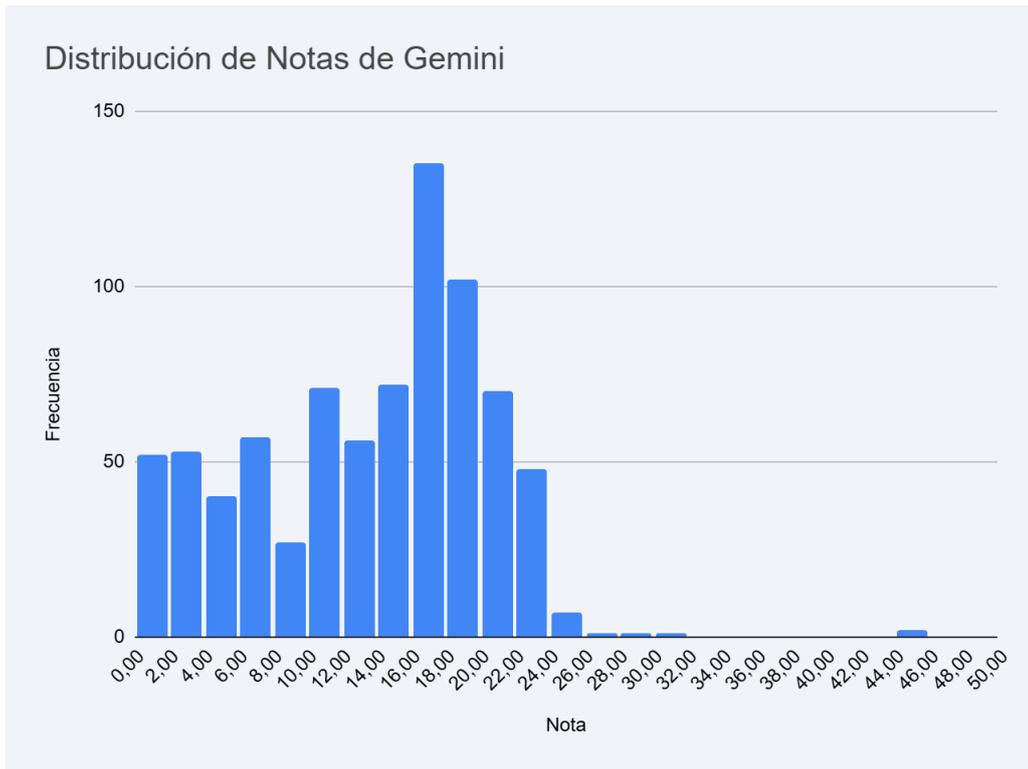


Figura 13: Distribución de Notas de Gemini

Fuente: Elaboración propia.

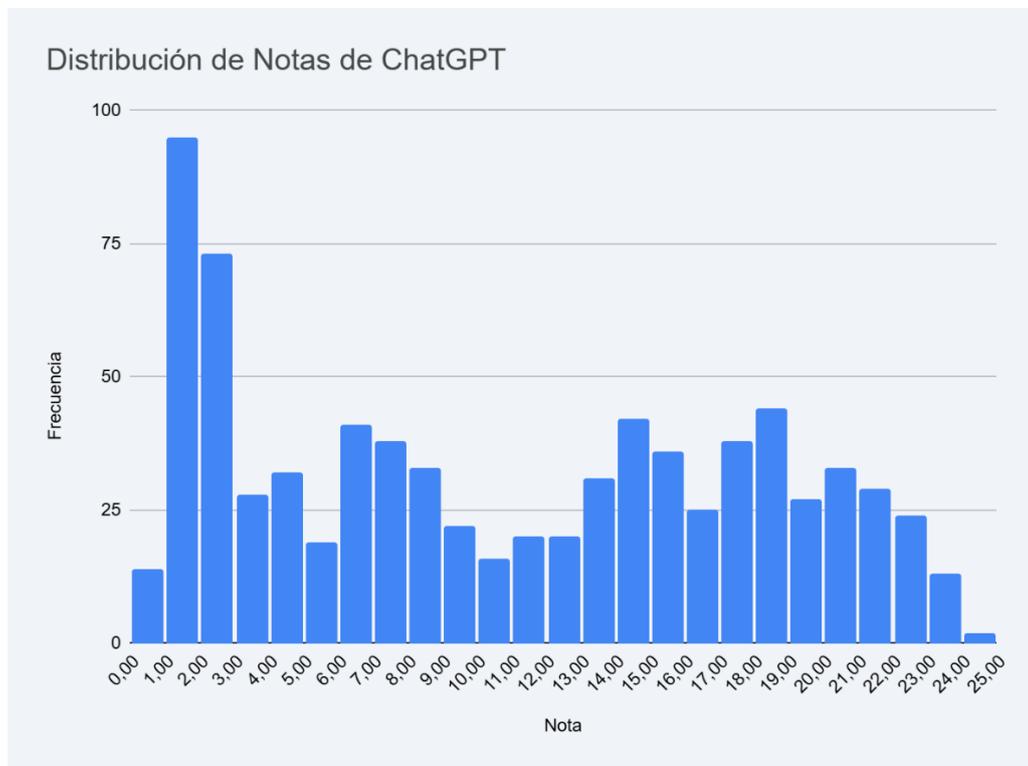


Figura 14: Distribución de Notas de ChatGPT

Fuente: Elaboración propia.

A pesar de las anomalías, el hallazgo más relevante se obtiene del análisis de correlación. Con un coeficiente de 0.53, se demuestra una correlación positiva moderada entre las puntuaciones. Como se ilustra en el gráfico de dispersión (véase figura 15), existe una tendencia clara a que las calificaciones se muevan en la misma dirección. Este hecho valida la robustez de la rúbrica como un instrumento capaz de guiar a diferentes LLMs hacia evaluaciones consistentes.

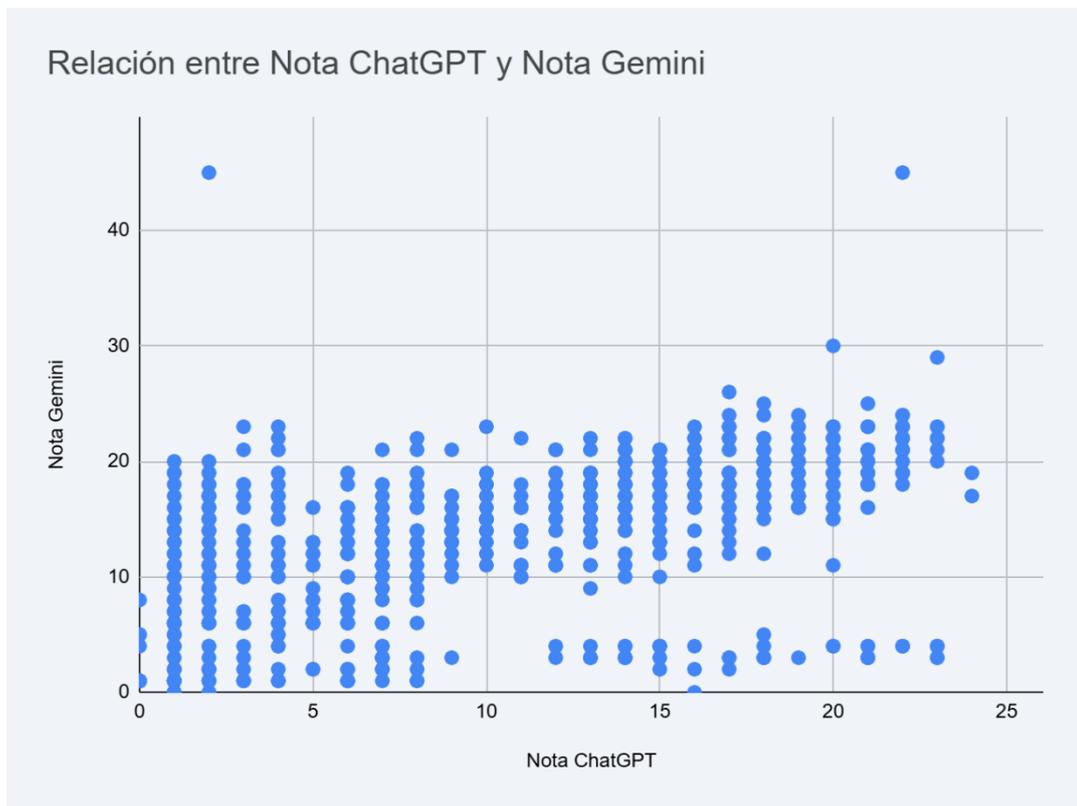


Figura 15: Gráfico de dispersión entre ChatGPT y Gemini
Fuente: Elaboración propia.

No obstante, la correlación moderada también evidencia que los modelos no son perfectamente intercambiables. El uso de una rúbrica estructurada es crucial para obtener resultados fiables y comparables, aunque no elimina por completo las "alucinaciones" o las interpretaciones inherentes al razonamiento de cada modelo. En conclusión, este método de calificación estructurada se muestra muy superior a la simple clasificación binaria, proporcionando una evaluación granular y justificable. Sin embargo, se debe reconocer que la rúbrica empleada en esta fase es un prototipo y requeriría un proceso de análisis y validación formal para su uso en un entorno de producción.

2. Fase 2: Exploración de Enfoques Avanzados Basados en Contenido Completo

Una vez analizado el enfoque basado en metadatos, se procedió a explorar aproximaciones que implicaban el análisis del contenido completo de los artículos. Durante el desarrollo de esta investigación, el campo de la IA ha experimentado avances acelerados, destacando la aparición de nuevos modelos en la nube con ventanas de contexto que llegan al millón de tokens [65]. Estos avances, que no estaban disponibles al inicio del TFG, abren la puerta a arquitecturas que antes eran teóricamente interesantes pero computacionalmente limitadas. La siguiente sección describe una aproximación que, gracias a estos desarrollos recientes, se perfila como una línea de trabajo futuro viable y de gran potencial.

3º Aproximación. Sistema de análisis de artículos y agente doble.

Este enfoque en concreto consistió en un sistema de doble agente diseñado para procesar el contenido completo de los documentos PDF. Este método se inspira en las capacidades de plataformas de investigación como Scispace [66], que extraen información estructurada de artículos científicos para facilitar su análisis.

El flujo teórico se dividió en dos procesos automatizados, cada uno representando un agente con una tarea específica:

- **Agente de Extracción de Datos:** Este flujo de trabajo automatizado se diseñó para la ingesta y el pre-procesamiento de documentos académicos en formato PDF, transformándolos en datos estructurados listos para el análisis (véase figura 16). El sistema se inicia monitorizando una carpeta de Google Drive, verificando cada archivo contra un registro para procesar únicamente los documentos nuevos y evitar así la duplicación de tareas. Una vez identificado un nuevo PDF, el flujo de trabajo utiliza un servicio de Reconocimiento Óptico de Caracteres (Mistral OCR) para extraer todo el texto. Posteriormente, un LLM analiza el contenido con un prompt detallado para identificar y extraer elementos clave como conclusiones, métodos o resultados. Esta información se organiza en una ficha-resumen que se almacena automáticamente en una hoja de cálculo de Google Sheets, consolidando los datos para su fácil consulta.

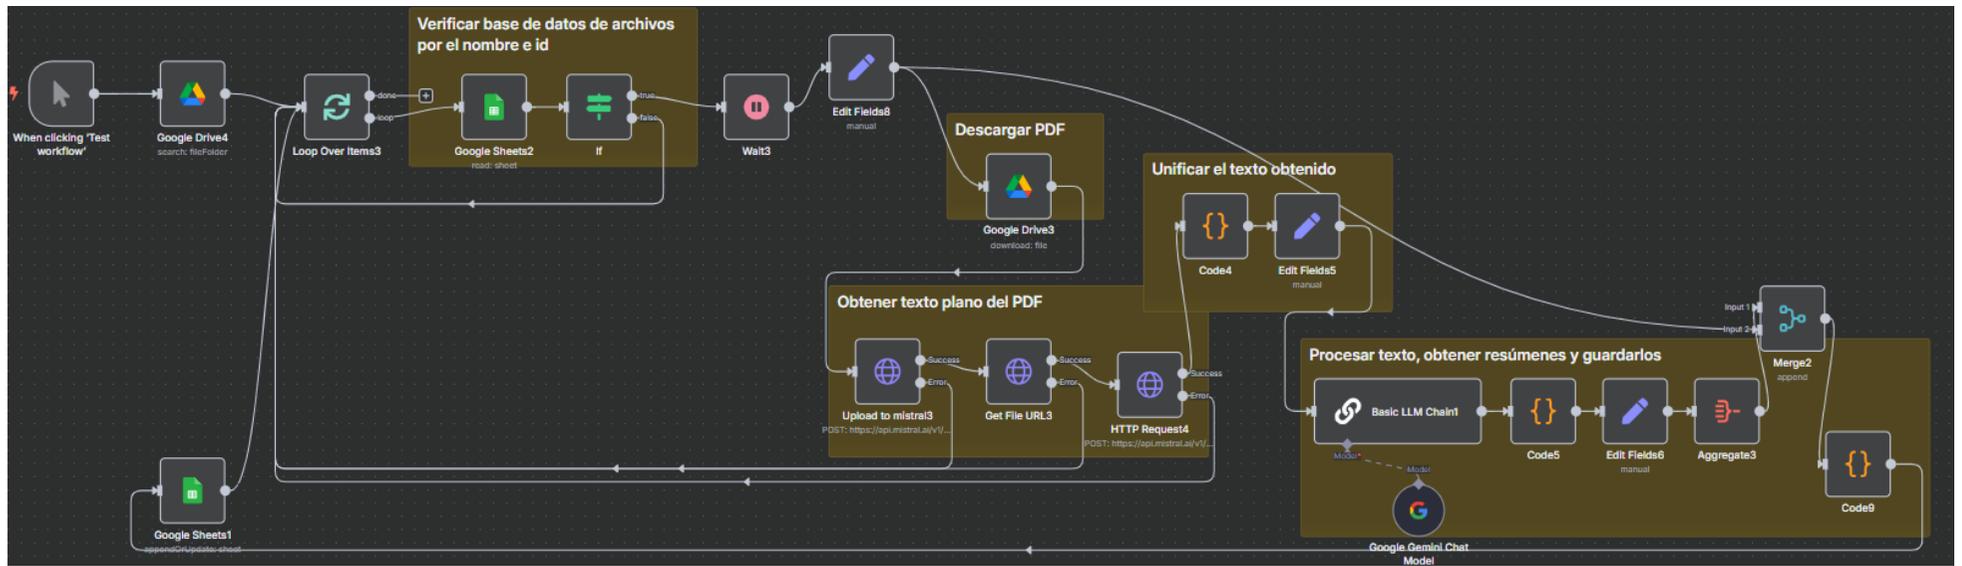


Figura 16: Agente de extracción de datos

Fuente: Captura de flujo de trabajo de n8n.

- **Agente de Calificación Final:** El segundo flujo de trabajo se activa una vez que el agente de extracción ha procesado los artículos. Este agente lee los resúmenes y datos estructurados de cada documento desde una hoja de cálculo de Google Sheets para realizar una evaluación cuantitativa detallada. Su objetivo es calificar la relevancia y calidad de cada artículo basándose en una rúbrica de investigación específica, en lugar de una simple evaluación binaria. Para ello, el agente itera sobre cada artículo y envía sus datos a un LLM provisto de un prompt con una rúbrica de evaluación compleja. El modelo puntúa el artículo de 0 a 10 en siete criterios ponderados distintos, como la profundidad metodológica, el análisis ético o la identificación de oportunidades. Finalmente, el sistema calcula una calificación final ponderada, estructura estos resultados en un formato JSON y los almacena en una nueva hoja de Google Sheets, creando así un registro detallado de la puntuación de cada documento (véase figura 17).

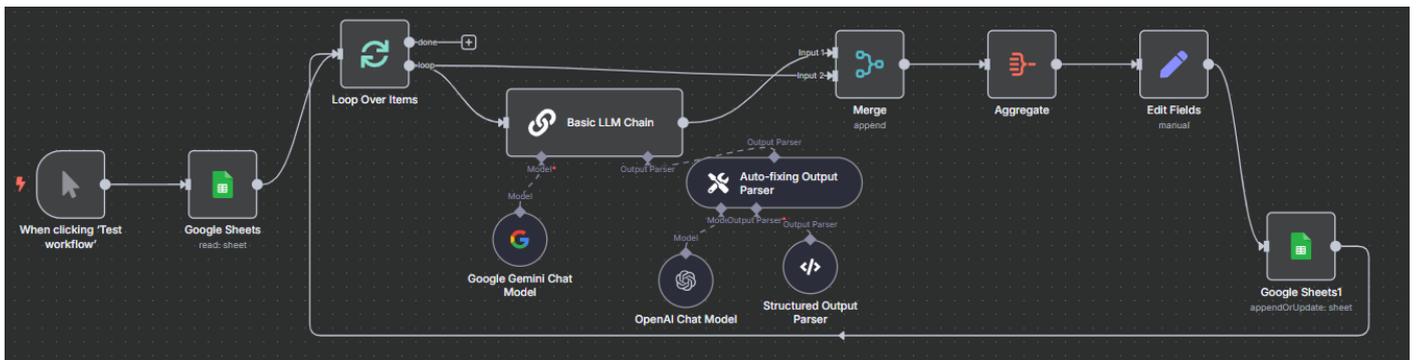


Figura 17: Agente de Calificación Final

Fuente: Captura de flujo de trabajo de n8n.

Este diseño de doble agente presenta ventajas teóricas significativas. En primer lugar, ofrece una mayor profundidad de análisis en comparación con el simple examen del título y el resumen (abstract), ya que se basa en el contenido completo del artículo. En segundo lugar, supone una optimización de recursos: permite utilizar un modelo de IA más ligero y rápido (y, por ende, más económico) para la tarea de extracción masiva de datos y resúmenes, mientras que se reserva un modelo más potente y con mayores capacidades de razonamiento (más costoso) únicamente para la tarea final de calificación. Además, este enfoque genera una base de conocimiento estructurada y reutilizable para futuras consultas. Sin embargo, a pesar de esta eficiencia conceptual, su implementación a escala presenta desafíos técnicos y logísticos. El proceso requiere la disponibilidad y carga previa de todos los documentos en formato PDF. A esto se suma el principal obstáculo técnico: la dificultad de extraer texto limpio y sin errores de forma consistente, un problema común en el OCR de documentos con formatos complejos. Finalmente, los altos costes

computacionales y económicos asociados al procesamiento de cientos de documentos extensos a través de las API, junto con las limitaciones en el número de tokens que los modelos pueden procesar en una sola llamada en el momento del desarrollo, llevaron a la decisión de proponer este método como línea de investigación futura.

3. Arquitectura propuesta para el MVP y flujo de trabajo de N8N.

Basándose en los resultados de las fases experimentales, la arquitectura final propuesta para el MVP se consolida en torno a la Aproximación 2: Evaluación basada en Metadatos y Rúbrica Editable. La implementación de esta solución se articula a través de una arquitectura de agente conversacional que orquesta un flujo de trabajo asíncrono, utilizando la plataforma n8n.

El proceso, como se ilustra en la Figura 18, se desarrolla de la siguiente manera:



Figura 18: Arquitectura completa del MVP

Fuente: Elaboración propia mediante Gemini.

- Interfaz de Chat y Carga de Archivo: El investigador inicia la interacción a través de una interfaz de chat, donde envía un mensaje y adjunta un archivo (Excel o CSV) con los metadatos de los artículos a evaluar. El flujo de n8n se activa al recibir este mensaje.

- **Procesamiento y Almacenamiento Inicial:** Un nodo condicional verifica la existencia del archivo adjunto. Si se confirma, el archivo se procesa y se carga en una carpeta predefinida de Google Drive, obteniendo un identificador único (`file_id`).
- **Orquestación del Agente Principal:** El `file_id` se pasa al nodo AI Agent. Este agente principal, configurado con un modelo de lenguaje y un sistema de memoria, no realiza el análisis directamente. Su función es actuar como un orquestador que inicia el proceso de calificación.
- **Delegación a un Flujo Asíncrono:** Siguiendo las instrucciones de su system message, el agente invoca su única herramienta disponible: `start_analysis_with_rubric`. Esta herramienta es en realidad un webhook que llama a un segundo flujo de trabajo en n8n. Este diseño es crucial, ya que desacopla la interacción inmediata con el usuario del proceso de análisis, que puede ser largo, evitando así que el agente se cuelgue.
- **Ejecución del Análisis en Segundo Plano:** El segundo flujo de trabajo, activado por el webhook, es el que ejecuta la tarea principal. Lee la hoja de cálculo de Google Drive usando el `file_id`, itera sobre cada artículo, construye el prompt con la rúbrica, llama al LLM para obtener la calificación y escribe los resultados en un nuevo archivo.
- **Notificación Final:** Una vez que el flujo de análisis ha terminado de procesar todos los artículos, el último paso es enviar una notificación por correo electrónico al investigador, informándole de que la tarea ha finalizado y proporcionando un enlace a los resultados.

Para ilustrar cómo se implementan estos pasos en la práctica dentro de n8n, a continuación se detallan los dos flujos de trabajo que componen el sistema.

El primer flujo (Figura 19) corresponde al Agente Principal, que gestiona la interacción con el usuario. Este flujo se activa al recibir un mensaje en el chat, comprueba si se ha adjuntado un archivo, lo sube a Google Drive para obtener su `file_id` y finalmente pasa el control al nodo "AI Agent". Este agente, actuando como orquestador, invoca su única herramienta (`start_analysis_with_rubric`), que es un webhook que desencadena el segundo flujo de trabajo para el análisis pesado.

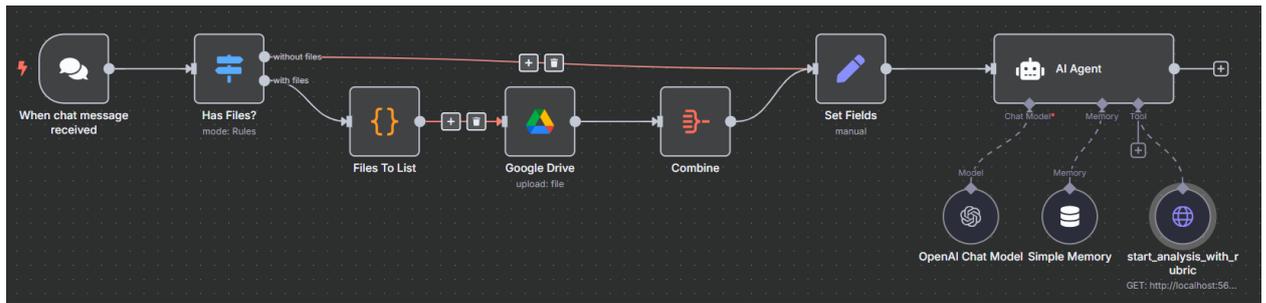


Figura 19: Flujo de Trabajo del Agente Principal (Orquestador)

Fuente: Captura de Flujo de trabajo de n8n

El segundo flujo (Figura 20) es el motor de calificación asíncrono. Se activa mediante el webhook llamado por el agente principal. Su primera acción es descargar el archivo de metadatos desde Google Drive. A continuación, entra en un bucle que procesa cada artículo (cada fila de la hoja de cálculo) de forma individual. Dentro del bucle, se construye el prompt con la rúbrica, se llama al LLM para obtener la calificación y la justificación, y los resultados se van almacenando. Una vez procesados todos los artículos, los resultados finales se guardan en una nueva hoja de cálculo en Google Drive y se envía una notificación por correo electrónico al investigador.

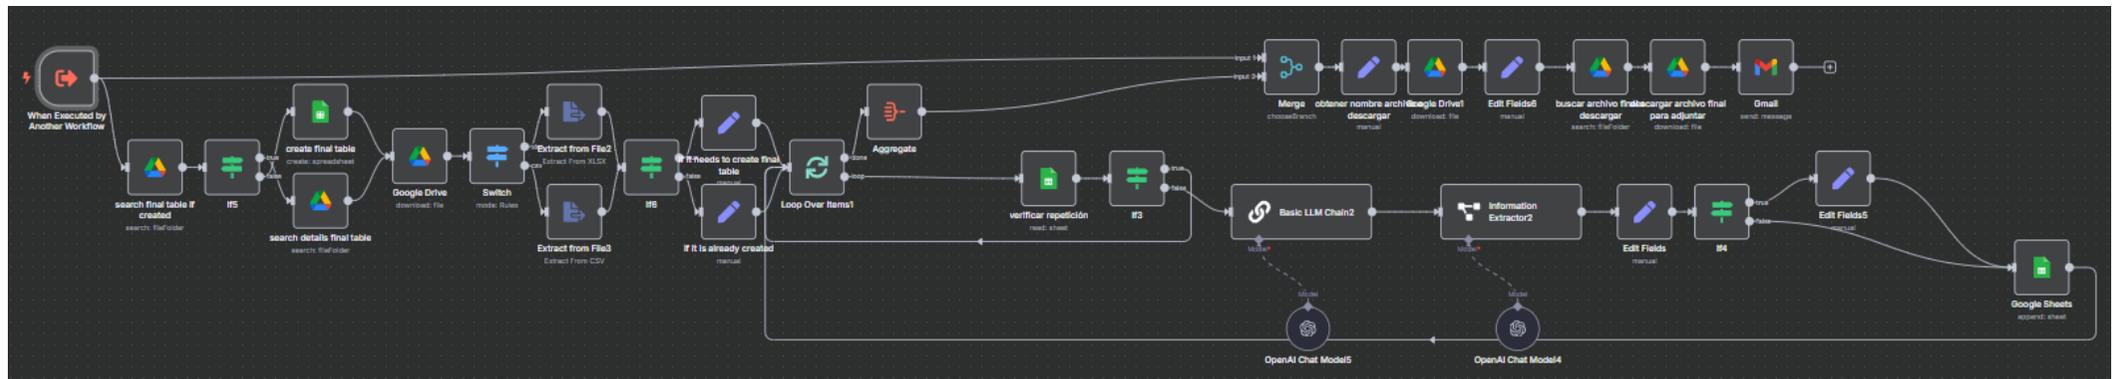


Figura 20: Flujo de Trabajo de Calificación Asíncrono

Fuente: Captura de flujo de trabajo de n8n

Cabe destacar que la arquitectura del agente es deliberadamente sencilla. Esta simplicidad es una consecuencia directa del enfoque del proyecto, que priorizó uno de los objetivos clave: diseñar y validar un sistema de calificación efectivo para evaluar la relevancia de artículos científicos. Por tanto, el esfuerzo principal no se destinó a construir un agente con múltiples y complejas funcionalidades, sino a perfeccionar el núcleo de la solución (el método de evaluación por rúbrica) para asegurar que fuera robusto, granular y justificable.

Asimismo, el agente ha sido diseñado para operar principalmente en segundo plano. Esta decisión responde directamente a la naturaleza de la tarea: el análisis de grandes volúmenes de datos bibliográficos es un proceso que consume una cantidad de tiempo considerable. Para evitar largos periodos de espera en la interfaz, el sistema ejecuta el análisis de forma asíncrona y notifica al investigador por correo electrónico una vez que el proceso ha concluido.

4. Hoja de ruta y evolución futura del agente

A partir del estudio y desarrollo presentados en este capítulo, la evolución futura del agente contempla una serie de líneas de investigación y desarrollo que mejorarían sus capacidades considerablemente. La siguiente hoja de ruta describe los pasos posteriores enfocados en la automatización de procesos, la expansión de las capacidades analíticas y la mejora de la accesibilidad del sistema. Estos pasos siguen un orden establecido, el cuál se considera el adecuado para conseguir un sistema totalmente funcional, desde el principio del proceso de investigación hasta la selección de los artículos más significantes para el tema elegido por el investigador. De esta manera, esta hoja de ruta permite la idealización de un sistema completo de ayuda a la investigación que ofrece un gran valor añadido en cuanto a trazabilidad y explicabilidad de las decisiones del agente, además de un considerable ahorro de tiempo al investigador.

Paso 1: Integración con Bases de Datos Académicas. La primera mejora consistiría en conectar el agente directamente a las APIs de bases de datos académicas como Scopus o Google Scholar. Esto eliminaría la necesidad de que el investigador cargue manualmente los metadatos, permitiendo al agente realizar búsquedas bibliográficas de forma autónoma a partir de las especificaciones del usuario, lo que agilizaría considerablemente la fase inicial del proceso.

Paso 2: Ideación y Generación Automática de Rúbricas. El siguiente avance se enfocaría en potenciar la capacidad del agente para definir los criterios de evaluación. Se investigaría el desarrollo de un sistema donde el agente, a partir de unas características clave o una

pregunta de investigación proporcionada por el usuario, generase automáticamente una rúbrica de evaluación detallada. El objetivo sería diseñar una plantilla de rúbrica universal y metodológicamente robusta, que el agente pudiera rellenar de forma dinámica para adaptarse a cualquier temática de investigación, garantizando consistencia y objetividad.

Paso 3: Implementación de un Sistema Híbrido de Análisis con RAG. Una vez consolidada la calificación basada en metadatos, se exploraría la integración del análisis de contenido completo. Aprovechando el acceso a los artículos a través de las APIs, se diseñaría un sistema híbrido. Primero, el agente aplicaría la rúbrica generada para realizar un filtrado inicial sobre los metadatos. A continuación, con los artículos mejor calificados, construiría dinámicamente una base de conocimiento para un sistema de Generación Aumentada por Recuperación (RAG). Este sistema permitiría al investigador realizar consultas en lenguaje natural sobre el contenido completo de los documentos más relevantes, obteniendo respuestas precisas y contextualizadas para una criba final mucho más profunda.

Paso 4: Desarrollo de una Interfaz Gráfica de Usuario (GUI). Finalmente, como último paso hacia una posible puesta en producción, se abordaría el diseño de una interfaz de usuario web. El objetivo sería ofrecer la funcionalidad del agente como un servicio visual e intuitivo, que facilitase la interacción del investigador con el sistema y presentase los resultados de una manera clara y amigable, democratizando el acceso a esta herramienta de asistencia a la investigación.

Capítulo 8. Conclusiones y resultados del Agente.

A lo largo del diseño y desarrollo experimental del agente de IA, se han extraído una serie de conclusiones fundamentales tanto sobre la viabilidad de la herramienta como sobre el comportamiento de los Modelos de Lenguaje Extensos (LLM) en tareas de análisis académico. Los resultados obtenidos en las distintas fases del proyecto no solo validan la arquitectura final del prototipo, sino que también iluminan el camino para futuras mejoras y aplicaciones.

Una de las conclusiones más determinantes del estudio es la superioridad del enfoque basado en rúbricas. La experimentación inicial, que se basaba en clasificaciones binarias y temáticas simples, reveló una divergencia significativa en la interpretación de los distintos LLMs. Se observó un "espectro de exigencia" y, más importante aún, una comprensión fundamentalmente distinta de los marcos conceptuales. Este hallazgo fue crucial, ya que demostró que un enfoque sin una guía explícita es poco fiable. La introducción de una rúbrica de evaluación estructurada solucionó parcialmente este problema, forzando a los modelos a seguir un razonamiento específico y mejorando drásticamente la consistencia y la transparencia de los resultados.

La robustez de la rúbrica como instrumento de evaluación se validó cuantitativamente. A pesar de las diferencias inherentes a cada modelo, el análisis de correlación entre las puntuaciones de GPT-4o mini y Gemini 2.0 Flash arrojó una correlación positiva moderada (0.53). Este resultado demuestra que es posible alinear las evaluaciones de diferentes LLMs y obtener resultados consistentes si se les proporciona un marco de trabajo bien definido, lo que es esencial para la fiabilidad del agente.

Ahora bien, para calibrar la eficacia del agente, se comparó su selección de artículos (aquellos calificados con una relevancia de moderada a muy alta, es decir, con una puntuación en la rúbrica ≥ 13) con un corpus de referencia obtenido mediante una búsqueda manual general, es decir, un primer filtrado amplio antes de la selección experta final. Los resultados muestran que el agente logra una coincidencia de entre el 45% y el 50% con este corpus general. Este dato no debe interpretarse como una incapacidad de replicar un criterio, sino como una evidencia de que el enfoque cualitativo de la rúbrica analiza la literatura de una forma fundamentalmente distinta a la de una búsqueda por palabras clave. El agente no solo automatiza, sino que transforma la búsqueda. Además, tiende a ser más inclusivo, lo que lo posiciona como una potente herramienta de descubrimiento capaz de revelar artículos pertinentes que una búsqueda convencional podría obviar.

De manera significativa, el estudio reveló que la combinación de la evaluación cualitativa del agente con métricas académicas tradicionales mejora notablemente los resultados. Al filtrar ambos conjuntos (el del agente y el de la búsqueda manual general) para incluir solo artículos con un mínimo de diez citaciones, la coincidencia entre ambos ascendió hasta el 53,33% en el caso de Gemini. Este hallazgo sugiere que los flujos de trabajo más eficaces serán probablemente híbridos, donde el agente realiza una primera criba cualitativa a gran escala sobre un corpus amplio y el investigador aplica filtros cuantitativos de calidad para refinar el resultado final, combinando lo mejor de ambos enfoques.

En relación con los objetivos generales planteados al inicio de este trabajo, los resultados obtenidos permiten confirmar su consecución. El primer objetivo, centrado en analizar el estado del arte de la IA en la gestión de personas, se ha cumplido a través de la exhaustiva revisión bibliográfica de la primera parte, cuyos hallazgos informaron el diseño del agente. El segundo objetivo, consistente en diseñar y proponer un agente de IA para la asistencia a la investigación, se ha materializado en el prototipo funcional evaluado. Este agente materializa dicha aplicación práctica, y su validación experimental ha demostrado la eficacia de la metodología de calificación basada en rúbricas, superando los enfoques más simples y estableciendo un rendimiento cuantificable y comparable.

Por supuesto, el proceso de evaluación también sirvió para identificar limitaciones importantes en los LLMs, como las "alucinaciones", donde un modelo no se adhirió a las restricciones numéricas del prompt, lo que subraya que la supervisión humana sigue siendo necesaria. Finalmente, la arquitectura asíncrona del prototipo se demostró como una solución práctica y altamente escalable. Las pruebas experimentales indican que el agente requiere aproximadamente 47,5 segundos para evaluar 10 abstracts mediante la rúbrica. Para poner esta cifra en perspectiva, consideremos el tiempo que requiere un humano: la lectura de un abstract puede tomar alrededor de un minuto, pero a ello debe sumarse el proceso de evaluación crítica. Este segundo paso puede ser inmediato si la pertinencia del artículo es clara, pero puede extenderse varios minutos si el contenido es ambiguo o requiere un análisis más detenido. A esta variabilidad se suma el factor idiomático, ya que la gran mayoría de los abstracts se encuentran en inglés, lo que puede ralentizar o acelerar el proceso dependiendo del nivel de competencia del investigador. Por tanto, el tiempo total por cada abstract puede oscilar fácilmente entre 3 y 5 minutos, o incluso más. Esto implica que, mientras un humano invertiría entre 30 o 50 minutos en evaluar esos mismos 10 resúmenes, el agente completa la tarea en menos de un minuto, demostrando un ahorro de tiempo drástico.

En resumen, este proyecto ha logrado desarrollar un agente de IA funcional que asiste eficazmente en la criba de literatura académica. Las conclusiones extraídas validan el enfoque metodológico basado en rúbricas y cuantifican su rendimiento frente a un estándar humano, además de que revelan su potencial como herramienta de descubrimiento. Estos hallazgos sientan unas bases sólidas para la hoja de ruta futura, cuya implementación es el siguiente paso lógico.

Como líneas futuras de investigación y desarrollo, se propone una evolución del agente en varias etapas clave para transformarlo en una herramienta de investigación integral. El primer paso sería la integración directa con bases de datos académicas como Scopus o Google Scholar, permitiendo al agente realizar búsquedas autónomas y eliminando la carga manual de datos. A continuación, se podría desarrollar una capacidad de generación automática de rúbricas, donde el agente, a partir de una simple pregunta de investigación, construya los criterios de evaluación, estandarizando y objetivando el proceso. El avance más significativo sería la implementación de un sistema híbrido de análisis con RAG. Esta arquitectura permitiría al agente realizar un primer filtrado con la rúbrica sobre los metadatos para luego, con los artículos más relevantes, analizar su contenido completo y responder a preguntas complejas del investigador. Finalmente, el desarrollo de una GUI haría accesible la herramienta, presentando sus capacidades de forma intuitiva y visual. Esta evolución convertiría al prototipo actual en un asistente de investigación completo, capaz no solo de calificar, sino de interactuar y razonar sobre el conocimiento científico de forma profunda, trazable y fiable.

Bibliografía Parte 1 (ADE).

- Adams, S. S., Arel, I., Bach, J., Coop, R., Furlan, R., Goertzel, B., Hall, J. S., Samsonovich, A., Scheutz, M., Schlesinger, M., Shapiro, S. C., & Sowa, J. F. (2012). Mapping the Landscape of Human-Level Artificial General Intelligence. *AI Magazine*, 33(1), 25-41. <https://doi.org/10.1609/aimag.v33i1.2322>
- Al Qahtani, E., & Alsmairat, M. (2023). Assisting artificial intelligence adoption drivers in human resources management: A mediation model. *Acta Logistica*, 10(1), 141-150. <https://doi.org/10.22306/al.v10i1.371>
- Arslan, A., Cooper, C., Khan, Z., Golgeci, I., & Ali, I. (2022). Artificial intelligence and human workers interaction at team level: A conceptual assessment of the challenges and potential HRM strategies. *International Journal of Manpower*. Scopus. <https://doi.org/10.1108/IJM-01-2021-0052>
- Bartosiak, M. L., & Modlinski, A. (2022). Fired by an algorithm? Exploration of conformism with biased intelligent decision support systems in the context of workplace discipline. *Career Development International*. Scopus. <https://doi.org/10.1108/CDI-06-2022-0170>
- Basu, S., Majumdar, B., Mukherjee, K., Munjal, S., & Palaksha, C. (2023). Artificial Intelligence–HRM Interactions and Outcomes: A Systematic Review and Causal Configurational Explanation. *Human Resource Management Review*. Scopus. <https://doi.org/10.1016/j.hrmmr.2022.100893>
- Berman, A., de Fine Licht, K., & Carlsson, V. (2024). Trustworthy AI in the public sector: An empirical analysis of a Swedish labor market decision-support system. *Technology in Society*. Scopus. <https://doi.org/10.1016/j.techsoc.2024.102471>

- Boselie, P., Dietz, G., & Boon, C. (2005). Commonalities and Contradictions in HRM and Performance Research. *Human Resource Management Journal*, 15, 67-94. <https://doi.org/10.1111/j.1748-8583.2005.tb00154.x>
- Bray, T. (2017). *The JavaScript Object Notation (JSON) Data Interchange Format* (No. RFC8259; p. RFC8259). RFC Editor. <https://doi.org/10.17487/RFC8259>
- Brin, D. W. (2018). Recruit Globally. *HRMagazine*, 63(5), 40-45.
- Bukartaite, R., & Hooper, D. (2023). Automation, artificial intelligence and future skills needs: An Irish perspective. *European Journal of Training and Development*. Scopus. <https://doi.org/10.1108/EJTD-03-2023-0045>
- Chowdhury, S., Budhwar, P., Dey, P. K., Joel-Edgar, S., & Abadie, A. (2022). AI-employee collaboration and business performance: Integrating knowledge-based view, socio-technical systems and organisational socialisation framework. *Journal of Business Research*, 144, 31-49. <https://doi.org/10.1016/j.jbusres.2022.01.069>
- Chowdhury, S., Budhwar, P., & Wood, G. (2024). Generative Artificial Intelligence in Business: Towards a Strategic Human Resource Management Framework. *British Journal of Management*. Scopus. <https://doi.org/10.1111/1467-8551.12824>
- Chowdhury, S., Dey, P., Joel-Edgar, S., Bhattacharya, S., Rodriguez-Espindola, O., Abadie, A., & Truong, L. (2023). Unlocking the value of artificial intelligence in human resource management through AI capability framework. *Human Resource Management Review*. Scopus. <https://doi.org/10.1016/j.hmr.2022.100899>
- Chowdhury, S., Joel-Edgar, S., Dey, P. K., Bhattacharya, S., & Kharlamov, A. (2023). Embedding transparency in artificial intelligence machine learning models: Managerial implications on predicting and explaining employee turnover.

International Journal of Human Resource Management. Scopus.
<https://doi.org/10.1080/09585192.2022.2066981>

Cowgill, B. (2017). *The Labor Market Effects of Hiring through Machine Learning*. Working Paper.

Da Silva, L. B. P., Soltovski, R., Pontes, J., Treinta, F. T., Leitão, P., Mosconi, E., De Resende, L. M. M., & Yoshino, R. T. (2022). Human resources management 4.0: Literature review and trends. *Computers & Industrial Engineering*, 168, 108111.
<https://doi.org/10.1016/j.cie.2022.108111>

Deepa, R., Sekar, S., Malik, A., Kumar, J., & Attri, R. (2024). Impact of AI-focussed technologies on social and technical competencies for HR managers – A systematic review and research agenda. *Technological Forecasting and Social Change*. Scopus. <https://doi.org/10.1016/j.techfore.2024.123301>

Del Giudice, M., Scuotto, V., Ballestra, L. V., & Pironti, M. (2022). Humanoid robot adoption and labour productivity: A perspective on ambidextrous product innovation routines. *International Journal of Human Resource Management*. Scopus.
<https://doi.org/10.1080/09585192.2021.1897643>

Department of Applied Economics and Management, National I-Lan University, Taiwan, Hsiao, J.-M., & Lin, D.-S. (2018). The Impacts of Working Conditions and Employee Competences of Fresh Graduates on Job Expertise, Salary and Job Satisfaction. *Journal of Reviews on Global Economics*, 7, 246-259. <https://doi.org/10.6000/1929-7092.2018.07.22>

Dutta, D., & Mishra, S. K. (2024). Bots for mental health: The boundaries of human and technology agencies for enabling mental well-being within organizations. *Personnel Review*. Scopus. <https://doi.org/10.1108/PR-11-2022-0832>

- Dutta, D., Mishra, S. K., & Tyagi, D. (2023). Augmented employee voice and employee engagement using artificial intelligence-enabled chatbots: A field study. *International Journal of Human Resource Management*. Scopus. <https://doi.org/10.1080/09585192.2022.2085525>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Faqihi, A., & Miah, S. J. (2023). Artificial Intelligence-Driven Talent Management System: Exploring the Risks and Options for Constructing a Theoretical Foundation. *Journal of Risk and Financial Management*. Scopus. <https://doi.org/10.3390/jrfm16010031>
- Figueroa-Armijos, M., Clark, B. B., & da Motta Veiga, S. P. (2023). Ethical Perceptions of AI in Hiring and Organizational Trust: The Role of Performance Expectancy and Social Influence. *Journal of Business Ethics*. Scopus. <https://doi.org/10.1007/s10551-022-05166-2>
- Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., Luetge, C., Madelin, R., Pagallo, U., Rossi, F., Schafer, B., Valcke, P., & Vayena, E. (2018). AI4People—An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations. *Minds and Machines*, 28(4), 689-707. <https://doi.org/10.1007/s11023-018-9482-5>

- Gavel, Y., & Iselid, L. (2008). Web of Science and Scopus: A journal title overlap study. *Online Information Review*, 32(1), 8-21. Scopus. <https://doi.org/10.1108/14684520810865958>
- Giraud, L., Zaher, A., Hernandez, S., & Akram, A. A. (2023). The impacts of artificial intelligence on managerial skills. *Journal of Decision Systems*. Scopus. <https://doi.org/10.1080/12460125.2022.2069537>
- GPT-3. (2024). En *Wikipedia, la enciclopedia libre*. <https://es.wikipedia.org/w/index.php?title=GPT-3&oldid=163883376>
- HireVue. (2017). *HireVue: Case Study*. https://cdn2.hubspot.net/hubfs/464889/Hilton%20Aug%202017/2017_12_Success_Story_Hilton_CustomerMarketing3.pdf
- Huang, M.-H., & Rust, R. T. (2018). Artificial Intelligence in Service. *Journal of Service Research*, 21(2), 155-172. <https://doi.org/10.1177/1094670517752459>
- Huang, X., Yang, F., Zheng, J., Feng, C., & Zhang, L. (2023). Personalized human resource management via HR analytics and artificial intelligence: Theory and implications. *Asia Pacific Management Review*. Scopus. <https://doi.org/10.1016/j.apmr.2023.04.004>
- Islam, M., Mamun, A. A., Afrin, S., Ali Quaosar, G. M. A., & Uddin, M. A. (2022). Technology Adoption and Human Resource Management Practices: The Use of Artificial Intelligence for Recruitment in Bangladesh. *South Asian Journal of Human Resources Management*. Scopus. <https://doi.org/10.1177/23220937221122329>
- Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., Tunyasuvunakool, K., Bates, R., Žídek, A., Potapenko, A., Bridgland, A., Meyer, C., Kohl, S. A. A., Ballard, A. J., Cowie, A., Romera-Paredes, B., Nikolov, S., Jain, R.,

Adler, J., ... Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596(7873), 583-589. <https://doi.org/10.1038/s41586-021-03819-2>

Kambur, E., & Akar, C. (2022). Human resource developments with the touch of artificial intelligence: A scale development study. *International Journal of Manpower*. Scopus. <https://doi.org/10.1108/IJM-04-2021-0216>

Kaushal, N., Kaurav, R. P. S., Sivathanu, B., & Kaushik, N. (2023). Artificial intelligence and HRM: identifying future research Agenda using systematic literature review and bibliometric analysis. *Management Review Quarterly*. Scopus. <https://doi.org/10.1007/s11301-021-00249-2>

Kong, H., Jiang, X., Zhou, X., Baum, T., Li, J., & Yu, J. (2024). Influence of artificial intelligence (AI) perception on career resilience and informal learning. *Tourism Review*. Scopus. <https://doi.org/10.1108/TR-10-2022-0521>

Kong, H., Yuan, Y., Baruch, Y., Bu, N., Jiang, X., & Wang, K. (2021). Influences of artificial intelligence (AI) awareness on career competency and job burnout. *International Journal of Contemporary Hospitality Management*. Scopus. <https://doi.org/10.1108/IJCHM-07-2020-0789>

Korzynski, P., Mazurek, G., Altmann, A., Ejdys, J., Kazlauskaite, R., Paliszkievicz, J., Wach, K., & Ziemia, E. (2023). Generative artificial intelligence as a new context for management theories: Analysis of ChatGPT. *Central European Management Journal*. Scopus. <https://doi.org/10.1108/CEMJ-02-2023-0091>

Kshetri, N. (2020). Evolving uses of artificial intelligence in human resource management in emerging economies in the global South: Some preliminary evidence. *Management Research Review*. Scopus. <https://doi.org/10.1108/MRR-03-2020-0168>

- Li, P., Bastone, A., Mohamad, T. A., & Schiavone, F. (2023). How does artificial intelligence impact human resources performance. Evidence from a healthcare institution in the United Arab Emirates. *Journal of Innovation and Knowledge*. Scopus. <https://doi.org/10.1016/j.jik.2023.100340>
- Malik, A., Budhwar, P., Mohan, H., & Srikanth, N. R. (2023). Employee experience –the missing link for engaging employees: Insights from an MNE’s AI-based HR ecosystem. *Human Resource Management*. Scopus. <https://doi.org/10.1002/hrm.22133>
- Malik, A., Budhwar, P., Patel, C., & Srikanth, N. R. (2022). May the bots be with you! Delivering HR cost-effectiveness and individualised employee experiences in an MNE. *International Journal of Human Resource Management*. Scopus. <https://doi.org/10.1080/09585192.2020.1859582>
- Marin-García, J. A., Bonavia, T., & Losilla, J. M. (2011). Exploring working conditions as determinants of job satisfaction: An empirical test among Catalonia service workers. *The Service Industries Journal*, 31(12), 2051-2066. <https://doi.org/10.1080/02642069.2011.559226>
- Mccarthy, J., Minsky, M., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI Magazine*, 27.
- Menzies, J., Sabert, B., Hassan, R., & Mensah, P. K. (2024). Artificial intelligence for international business: Its use, challenges, and suggestions for future research and practice. *Thunderbird International Business Review*. Scopus. <https://doi.org/10.1002/tie.22370>
- Mosisa, G., Abadiga, M., Oluma, A., & Wakuma, B. (2022). Quality of work-life and associated factors among nurses working in Wollega zones public hospitals, West

- Ethiopia: A cross-sectional study. *International Journal of Africa Nursing Sciences*, 17, 100466. <https://doi.org/10.1016/j.ijans.2022.100466>
- Odugbesan, J. A., Aghazadeh, S., Al Qaralleh, R. E., & Sogeke, O. S. (2023). Green talent management and employees' innovative work behavior: The roles of artificial intelligence and transformational leadership. *Journal of Knowledge Management*. Scopus. <https://doi.org/10.1108/JKM-08-2021-0601>
- OECD. (2024). *OECD AI Principles Overview*. <https://oecd.ai/en/ai-principles>
- Olan, F., Nyuur, R. B., & Arakpogun, E. O. (2024). AI: A knowledge sharing tool for improving employees' performance. *Journal of Decision Systems*. Scopus. <https://doi.org/10.1080/12460125.2023.2263687>
- Ore, O., & Sposato, M. (2022). Opportunities and risks of artificial intelligence in recruitment and selection. *International Journal of Organizational Analysis*. Scopus. <https://doi.org/10.1108/IJOA-07-2020-2291>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, n71. <https://doi.org/10.1136/bmj.n71>
- Pan, Y., Froese, F., Liu, N., Hu, Y., & Ye, M. (2022). The adoption of artificial intelligence in employee recruitment: The influence of contextual factors. *International Journal of Human Resource Management*. Scopus. <https://doi.org/10.1080/09585192.2021.1879206>

- Pillai, R., & Sivathanu, B. (2020). Adoption of artificial intelligence (AI) for talent acquisition in IT/ITeS organizations. *Benchmarking*. Scopus. <https://doi.org/10.1108/BIJ-04-2020-0186>
- Presbitero, A., & Teng-Calleja, M. (2023). Job attitudes and career behaviors relating to employees' perceived incorporation of artificial intelligence in the workplace: A career self-management perspective. *Personnel Review*. Scopus. <https://doi.org/10.1108/PR-02-2021-0103>
- Prikshat, V., Islam, M., Patel, P., Malik, A., Budhwar, P., & Gupta, S. (2023). AI-Augmented HRM: Literature review and a proposed multilevel framework for future research. *Technological Forecasting and Social Change*. Scopus. <https://doi.org/10.1016/j.techfore.2023.122645>
- Prikshat, V., Malik, A., & Budhwar, P. (2023). AI-augmented HRM: Antecedents, assimilation and multilevel consequences. *Human Resource Management Review*. Scopus. <https://doi.org/10.1016/j.hrmmr.2021.100860>
- Ren, S., Tang, G., & Jackson, S. E. (2018). Green Human Resource Management Research in Emergence: A Review and Future Directions. *Asia Pacific Journal of Management*, 35(3), 769-803. <https://doi.org/10.1007/s10490-017-9532-1>
- Rich, E. (1983). Users are individuals: Individualizing user models. *International Journal of Man-Machine Studies*, 18(3), 199-214. [https://doi.org/10.1016/S0020-7373\(83\)80007-8](https://doi.org/10.1016/S0020-7373(83)80007-8)
- Robbins, S. (2020). AI and the path to envelopment: Knowledge as a first step towards the responsible regulation and use of AI-powered machines. *AI & SOCIETY*, 35(2), 391-400. <https://doi.org/10.1007/s00146-019-00891-1>
- Rodgers, W. (2019). *Trust Throughput Modeling Pathways*. Nova Publication.

- Rodgers, W., & Al Fayi, S. (2019). Ethical Pathways of Internal Audit Reporting Lines. *Accounting Forum*, 43(2), 220-245. <https://doi.org/10.1016/j.accfor.2019.01.002>
- Rožman, M., Tominc, P., & Milfelner, B. (2023). Maximizing employee engagement through artificial intelligent organizational culture in the context of leadership and training of employees: Testing linear and non-linear relationships. *Cogent Business and Management*. Scopus. <https://doi.org/10.1080/23311975.2023.2248732>
- Schermerhorn, J. R. (2001). *Management Update 2001* (6.^a ed.). John Wiley and Sons.
- Song, Y., & Wu, R. (2021). Analysing human-computer interaction behaviour in human resource management system based on artificial intelligence technology. *Knowledge Management Research and Practice*. Scopus. <https://doi.org/10.1080/14778238.2021.1955630>
- Stefana, E., Marciano, F., & Rossi, D. (2021). Composite Indicators to Measure Quality of Working Life in Europe: A Systematic Review. *Social Indicators Research*, 157(3), 1047-1078. <https://doi.org/10.1007/s11205-021-02679-y>
- Storey, J. (2004). *Leadership in Organizations: Current Issues and Key Trends*. Routledge.
- Thierer, A., O'Sullivan Castillo, A., & Russell, R. (2017). *Artificial Intelligence and Public Policy*. Mercatus Center at George Mason University. <https://www.mercatus.org/system/files/thierer-artificial-intelligence-policymmmercatusv1.pdf>
- Votto, A. M., Valecha, R., Najafirad, P., & Rao, H. R. (2021). Artificial Intelligence in Tactical Human Resource Management: A Systematic Literature Review. *International Journal of Information Management Data Insights*. Scopus. <https://doi.org/10.1016/j.jjime.2021.100047>

- Vrontis, D., Christofi, M., Pereira, V., Tarba, S., Makrides, A., & Trichina, E. (2022). Artificial intelligence, robotics, advanced technologies and human resource management: A systematic review. *International Journal of Human Resource Management*. Scopus. <https://doi.org/10.1080/09585192.2020.1871398>
- Wall, T. D., & Wood, S. J. (2005). *The Romance of Human Resource Management and Business Performance and the Case for Big Science*. Penguin.
- Weber, P. (2023). Unrealistic Optimism Regarding Artificial Intelligence Opportunities in Human Resource Management. *International Journal of Knowledge Management*. Scopus. <https://doi.org/10.4018/IJKM.317217>
- Wooldridge, M. (2013). Intelligent Agents. En G. Weiss (Ed.), *Multiagent Systems* (pp. 3-50). The MIT Press.
- Xiao, Q., Yan, J., & Bamber, G. J. (2025). How does AI-enabled HR analytics influence employee resilience: Job crafting as a mediator and HRM system strength as a moderator. *Personnel Review*. Scopus. <https://doi.org/10.1108/PR-03-2023-0198>
- Zhou, Y., Wang, L., & Chen, W. (2023). The dark side of AI-enabled HRM on employees based on AI algorithmic features. *Journal of Organizational Change Management*. Scopus. <https://doi.org/10.1108/JOCM-10-2022-0308>

Bibliografía Parte 2 (GITT)

- [1] J. R. Schermerhorn, *Management Update 2001*, 6.^a ed. New York, NY: John Wiley and Sons, 2001.
- [2] J. Storey, *Leadership in Organizations: Current Issues and Key Trends*. London: Routledge, 2004.
- [3] P. Boselie, G. Dietz, y C. Boon, «Commonalities and Contradictions in HRM and Performance Research», *Hum. Resour. Manag. J.*, vol. 15, pp. 67-94, 2005, doi: 10.1111/j.1748-8583.2005.tb00154.x.
- [4] T. D. Wall y S. J. Wood, *The Romance of Human Resource Management and Business Performance and the Case for Big Science*. Harmondsworth: Penguin, 2005.
- [5] A. Faqih y S. J. Miah, «Artificial Intelligence-Driven Talent Management System: Exploring the Risks and Options for Constructing a Theoretical Foundation», *J. Risk Financ. Manag.*, 2023, doi: 10.3390/jrfm16010031.
- [6] O. Ore y M. Sposato, «Opportunities and risks of artificial intelligence in recruitment and selection», *Int. J. Organ. Anal.*, 2022, doi: 10.1108/IJOA-07-2020-2291.
- [7] E. Kambur y C. Akar, «Human resource developments with the touch of artificial intelligence: a scale development study», *Int. J. Manpow.*, 2022, doi: 10.1108/IJM-04-2021-0216.
- [8] N. Kaushal, R. P. S. Kaurav, B. Sivathanu, y N. Kaushik, «Artificial intelligence and HRM: identifying future research Agenda using systematic literature review and bibliometric analysis», *Manag. Rev. Q.*, 2023, doi: 10.1007/s11301-021-00249-2.

- [9] D. Dutta, S. K. Mishra, y D. Tyagi, «Augmented employee voice and employee engagement using artificial intelligence-enabled chatbots: a field study», *Int. J. Hum. Resour. Manag.*, 2023, doi: 10.1080/09585192.2022.2085525.
- [10] A. Malik, P. Budhwar, H. Mohan, y N. R. Srikanth, «Employee experience –the missing link for engaging employees: Insights from an MNE’s AI-based HR ecosystem», *Hum. Resour. Manage.*, 2023, doi: 10.1002/hrm.22133.
- [11] M. Rožman, P. Tominc, y B. Milfelner, «Maximizing employee engagement through artificial intelligent organizational culture in the context of leadership and training of employees: Testing linear and non-linear relationships», *Cogent Bus. Manag.*, 2023, doi: 10.1080/23311975.2023.2248732.
- [12] Y. Song y R. Wu, «Analysing human-computer interaction behaviour in human resource management system based on artificial intelligence technology», *Knowl. Manag. Res. Pract.*, 2021, doi: 10.1080/14778238.2021.1955630.
- [13] R. Deepa, S. Sekar, A. Malik, J. Kumar, y R. Attri, «Impact of AI-focussed technologies on social and technical competencies for HR managers – A systematic review and research agenda», *Technol. Forecast. Soc. Change*, 2024, doi: 10.1016/j.techfore.2024.123301.
- [14] E. Stefana, F. Marciano, y D. Rossi, «Composite Indicators to Measure Quality of Working Life in Europe: A Systematic Review», *Soc. Indic. Res.*, vol. 157, n.º 3, pp. 1047-1078, 2021, doi: 10.1007/s11205-021-02679-y.
- [15] G. Mosisa, M. Abadiga, A. Oluma, y B. Wakuma, «Quality of work-life and associated factors among nurses working in Wollega zones public hospitals, West Ethiopia: A cross-sectional study», *Int. J. Afr. Nurs. Sci.*, vol. 17, p. 100466, 2022, doi: 10.1016/j.ijans.2022.100466.

- [16] J. A. Marin-García, T. Bonavia, y J. M. Losilla, «Exploring working conditions as determinants of job satisfaction: an empirical test among Catalonia service workers», *Serv. Ind. J.*, vol. 31, n.º 12, pp. 2051-2066, sep. 2011, doi: 10.1080/02642069.2011.559226.
- [17] R. Pillai y B. Sivathanu, «Adoption of artificial intelligence (AI) for talent acquisition in IT/ITeS organizations», *Benchmarking*, 2020, doi: 10.1108/BIJ-04-2020-0186.
- [18] S. Chowdhury *et al.*, «Unlocking the value of artificial intelligence in human resource management through AI capability framework», *Hum. Resour. Manag. Rev.*, 2023, doi: 10.1016/j.hrmmr.2022.100899.
- [19] S. Chowdhury, P. Budhwar, y G. Wood, «Generative Artificial Intelligence in Business: Towards a Strategic Human Resource Management Framework», *Br. J. Manag.*, 2024, doi: 10.1111/1467-8551.12824.
- [20] F. Olan, R. B. Nyuur, y E. O. Arakpogun, «AI: A knowledge sharing tool for improving employees' performance», *J. Decis. Syst.*, 2024, doi: 10.1080/12460125.2023.2263687.
- [21] A. Berman, K. de Fine Licht, y V. Carlsson, «Trustworthy AI in the public sector: An empirical analysis of a Swedish labor market decision-support system», *Technol. Soc.*, 2024, doi: 10.1016/j.techsoc.2024.102471.
- [22] D. Dutta y S. K. Mishra, «Bots for mental health: the boundaries of human and technology agencies for enabling mental well-being within organizations», *Pers. Rev.*, 2024, doi: 10.1108/PR-11-2022-0832.
- [23] S. Chowdhury, P. Budhwar, P. K. Dey, S. Joel-Edgar, y A. Abadie, «AI-employee collaboration and business performance: Integrating knowledge-based view, socio-

- technical systems and organisational socialisation framework», *J. Bus. Res.*, vol. 144, pp. 31-49, may 2022, doi: 10.1016/j.jbusres.2022.01.069.
- [24] S. J. Russell y P. Norvig, *Artificial intelligence: a modern approach*, Fourth edition, Global edition. en Prentice Hall series in artificial intelligence. Boston: Pearson, 2022.
- [25] H. Naveed *et al.*, «A Comprehensive Overview of Large Language Models», 17 de octubre de 2024, *arXiv*: arXiv:2307.06435. doi: 10.48550/arXiv.2307.06435.
- [26] Y. Gao *et al.*, «Retrieval-Augmented Generation for Large Language Models: A Survey», 27 de marzo de 2024, *arXiv*: arXiv:2312.10997. doi: 10.48550/arXiv.2312.10997.
- [27] D. Ferrucci *et al.*, «Building Watson: An Overview of the DeepQA Project», *AI Mag.*, vol. 31, n.º 3, pp. 59-79, sep. 2010, doi: 10.1609/aimag.v31i3.2303.
- [28] A. Krizhevsky, I. Sutskever, y G. E. Hinton, «ImageNet Classification with Deep Convolutional Neural Networks», en *Advances in Neural Information Processing Systems*, F. Pereira, C. J. Burges, L. Bottou, y K. Q. Weinberger, Eds., Curran Associates, Inc., 2012. [En línea]. Disponible en: https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf
- [29] D. Silver *et al.*, «Mastering the game of Go with deep neural networks and tree search», *Nature*, vol. 529, n.º 7587, pp. 484-489, ene. 2016, doi: 10.1038/nature16961.
- [30] «OpenAI». Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://openai.com/>

- [31] «Claude». Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://claude.ai/login?returnTo=%2F%3F>
- [32] «Mistral AI | Frontier AI in your hands». Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://mistral.ai/>
- [33] «Llama», Meta Llama. Accedido: 14 de marzo de 2025. [En línea]. Disponible en: <https://www.llama.com/>
- [34] «Our latest AI models – Google AI - Google AI». Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://ai.google/get-started/our-models/>
- [35] «Hugging Face – The AI community building the future.» Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://huggingface.co/>
- [36] «Home», Bloom AI. Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://bloomai.co/>
- [37] «Arctic - Snowflake-Built Enterprise LLMs». Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://www.snowflake.com/content/snowflake-site/global/en/product/features/arctic>
- [38] X. Zhang, Q. Yang, y D. Xu, «XuanYuan 2.0: A Large Chinese Financial Chat Model with Hundreds of Billions Parameters», 19 de mayo de 2023, *arXiv*: arXiv:2305.12002. doi: 10.48550/arXiv.2305.12002.
- [39] A. Vaswani *et al.*, «Attention Is All You Need», 2017, *arXiv*. doi: 10.48550/ARXIV.1706.03762.
- [40] J. Alammari, «The Illustrated Transformer». Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://jalammari.github.io/illustrated-transformer/>

- [41] L. Weng, «Attention? Attention!» Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://lilianweng.github.io/posts/2018-06-24-attention/>
- [42] Z. Zhang, «Understanding GPU Architecture Implications on LLM Serving Workloads», p. 63 p., 2024, doi: 10.3929/ETHZ-B-000701757.
- [43] P. Ersoy y M. Erşahin, «Optimal LLM Execution Strategies for Llama 3.1 Language Models Across Diverse Hardware Configurations: A Comprehensive Guide», vol. 5, n.º 1, 2024.
- [44] S. Na, G. Jeong, B. H. Ahn, J. Young, T. Krishna, y H. Kim, «Understanding Performance Implications of LLM Inference on CPUs», en *2024 IEEE International Symposium on Workload Characterization (IISWC)*, sep. 2024, pp. 169-180. doi: 10.1109/IISWC63097.2024.00024.
- [45] G. Bai *et al.*, «Beyond Efficiency: A Systematic Survey of Resource-Efficient Large Language Models», 29 de diciembre de 2024, *arXiv*: arXiv:2401.00625. doi: 10.48550/arXiv.2401.00625.
- [46] «¿Qué es un LLM? - Explicación de los modelos de lenguaje grandes - AWS», Amazon Web Services, Inc. Accedido: 14 de marzo de 2025. [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/large-language-model/>
- [47] «¿Qué es la cuantificación? | IBM». Accedido: 14 de marzo de 2025. [En línea]. Disponible en: <https://www.ibm.com/es-es/think/topics/quantization>
- [48] «¿Qué es la destilación del conocimiento? | IBM». Accedido: 14 de marzo de 2025. [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/knowledge-distillation>
- [49] M. Sun, Z. Liu, A. Bair, y J. Z. Kolter, «A Simple and Effective Pruning Approach for Large Language Models», 6 de mayo de 2024, *arXiv*: arXiv:2306.11695. doi: 10.48550/arXiv.2306.11695.

- [50] G. F. Luger, *Artificial intelligence: structures and strategies for complex problem solving*, 6th ed. Boston: Pearson Addison-Wesley, 2009.
- [51] «AI Agents Explained: From Theory to Practical Deployment», n8n Blog. Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://blog.n8n.io/ai-agents/>
- [52] «Conceptual guide |   LangChain». Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://python.langchain.com/docs/concepts/>
- [53] TextCortex, «N8N Review: Features, Pricing & Use Cases». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://textcortex.com/post/n8n-review>
- [54] WorkOS, «n8n: The workflow automation tool for the AI age». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://workos.com/blog/n8n-the-workflow-automation-tool-for-the-ai-age>
- [55] n8n, «Workflows App Automation Features from n8n.io». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://n8n.io/features/>
- [56] L. M, «What is n8n? Intro to a workflow automation tool». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://www.hostinger.com/tutorials/what-is-n8n>
- [57] A. Conway, «I just started using n8n to automate my workflow, and I wish I had sooner». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://www.xda-developers.com/using-n8n-automate-workflow/>
- [58] n8n, «Powerful Workflow Automation Software & Tools - n8n». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://n8n.io/>
- [59] Pondhouse Data, «Building AI Agents with n8n: Low-Code approach to AI workflows». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://www.pondhouse-data.com/blog/ai-agents-with-n8n>

- [60] F. Probst, «How To Build Your First AI Agent (+Free Workflow Template)». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://blog.n8n.io/how-to-build-ai-agent/>
- [61] Northflank, «How to self-host n8n AI workflow automation on Northflank». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://northflank.com/guides/how-to-self-host-n8n-ai-workflow-automation-on-northflank>
- [62] n8n, «Enterprise Workflow Automation Software & Tools | n8n». Accedido: 16 de junio de 2025. [En línea]. Disponible en: <https://n8n.io/enterprise/>
- [63] G. B y A. Purwar, «Evaluating the Efficacy of Open-Source LLMs in Enterprise-Specific RAG Systems: A Comparative Study of Performance and Scalability», 17 de junio de 2024, *arXiv*: arXiv:2406.11424. doi: 10.48550/arXiv.2406.11424.
- [64] M. Santanna, R. Valle-Cabrera, y D. Ulrich, Eds., *New directions in the future of work*, First edition. Bingley, UK: Emerald Publishing Limited, 2022.
- [65] «Our next-generation model: Gemini 1.5», Google. Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://blog.google/technology/ai/google-gemini-next-generation-model-february-2024/>
- [66] «The AI for Academic Research | SciSpace». Accedido: 6 de julio de 2025. [En línea]. Disponible en: <https://scispace.com>

Presupuesto

A continuación, se presenta el desglose económico detallado para la realización de este Trabajo Fin de Grado. Al ser un proyecto de naturaleza académica, la valoración se ha realizado utilizando como guía las tarifas de referencia del Colegio Oficial de Graduados e Ingenieros Técnicos de Telecomunicación (COITT) [67], entendiéndose que las condiciones del mercado profesional pueden variar. Es importante destacar que, en el ámbito profesional, la evaluación económica de un proyecto debe ajustarse a las indicaciones del Ministerio de Economía y Hacienda, que ha instado a los colegios profesionales a eliminar los baremos orientativos tradicionales en cumplimiento de las directivas europeas. Sin embargo de manera orientativa se ha utilizado su baremo orientativo que se calcula en función de las horas invertidas y factores de reducción.

La estimación económica se ha estructurado en base a los siguientes puntos clave:

- Valoración de los recursos técnicos y software empleados.
- Estimación del coste por dedicación profesional.
- Coste asociado a la elaboración de la memoria técnica.
- Cálculo del presupuesto final y su correspondiente carga fiscal.

1. Amortización y coste de recursos materiales

En este apartado se cuantifica el coste de los medios materiales necesarios para el desarrollo del trabajo, distinguiendo entre los equipos físicos (hardware) y las herramientas lógicas (software).

1.1. Amortización del material hardware

Para la ejecución de este trabajo, se ha requerido el uso de equipos informáticos durante un periodo de dos meses. El coste derivado de su utilización se calcula mediante una amortización lineal, considerando una vida útil estándar de 36 meses (3 años) y aplicando la parte proporcional al tiempo de uso.

Tabla 11: Tabla de amortización de recursos hardware

| Elemento | Valor de adquisición | Amortización |
|------------------------------------|----------------------|-----------------|
| Ordenador personal portátil | 850,00 € | 47,22 € |
| Servidor Linux con tarjeta gráfica | 1.501,78 € | 83,43 € |
| Total | | 130,65 € |

Se está calculando el porcentaje de amortización proporcional al tiempo de uso del equipo durante el proyecto, concretamente durante 2 meses de los 36 meses (3 años) que normalmente se consideran como vida útil del hardware.

Cálculo del porcentaje:

$$2 \text{ Meses} / 36 \text{ Meses} = 1/18 \approx 0.0556 = 5.56\%$$

Aplicación sobre el valor del equipo:

Valor del equipo * 5,56% = Valor amortizado

El coste total de amortización para los elementos de hardware durante el periodo de desarrollo asciende a doscientos sesenta y un euros con treinta céntimos (130,65 €).

1.2. Coste del material software

Para el desarrollo de este proyecto se ha utilizado exclusivamente software de carácter libre y de código abierto, o bien herramientas facilitadas mediante licencias académicas. Por este motivo, no se han generado costes directos asociados a la adquisición de licencias de software.

Sin embargo, para la interacción con modelos de inteligencia artificial se ha recurrido a la API de OpenAI. El coste derivado del consumo de tokens para la realización de consultas y prompts a los diferentes modelos de la compañía ascendió a un total de 20,00 €. A diferencia de los activos que se deprecian, este importe se considera un gasto operativo directo, ya que el saldo se consume con el uso.

Por tanto, la totalidad del importe se computa como un gasto necesario para la realización del proyecto, siendo el coste total asociado al software de veinte euros (20,00 €).

2. Trabajo tarifado por tiempo empleado

Para realizar este proyecto se han invertido alrededor de **150 horas** en diseño, desarrollo y elaboración de documentación. Para calcular el valor del trabajo empleado se ha elegido la siguiente ecuación:

$$H = Ct * 74,88 * Hn + Ct * 96,72 * He$$

Siendo:

- H: Honorarios totales recibidos por el proyecto
- Ct: Factor de corrección dependiendo del número de horas trabajadas

- Hn: Horas trabajadas en horario laboral
- He: Horas trabajadas fuera del horario laboral (en este proyecto no han existido así que su valor es 0)

Teniendo en cuenta una posible distribución del factor de corrección descrito en la siguiente tabla, el valor es de 0.65.

Tabla 12: Valores del factor de corrección en función a las horas trabajadas

| Horas empleadas | Factor de corrección Ct |
|-----------------|-------------------------|
| $X < 36$ | 1 |
| $36 < X < 72$ | 0,90 |
| $72 < X < 108$ | 0,80 |
| $108 < X < 144$ | 0,70 |
| $144 < X < 180$ | 0,65 |
| $180 < X < 360$ | 0,60 |
| $360 < X < 540$ | 0,55 |

Según esta tabla, al estar este proyecto finalizado en 150 horas, se deberá escoger el factor de corrección con un valor de 0.65. Dado esto, la formula anterior queda de la siguiente manera:

$$H=0,65*74,88*150+0,65*96.72*0=7.300,80€$$

Los honorarios derivados al tiempo dedicado al proyecto libre de impuestos ascienden a unos siete mil trescientos euros con ochenta céntimos (7.300,80 €).

3. Redacción de documentación

Con respecto al coste de la redacción del documento se utiliza la ecuación:

$$H=0,07*P*Cn$$

Teniendo en cuenta que:

- H: Honorarios por la redacción del documento.
- P: es el presupuesto del trabajo.
- Cn: es el coeficiente de ponderación en función del presupuesto.

El presupuesto del trabajo (P) es la suma de los costes de hardware, software y el trabajo tarifado, como se observa en la Tabla 13.

Tabla 13: Presupuesto de Ejecución (Base para cálculo de documentación)

| Descripción | Costes |
|--------------------------------------|-------------------|
| Amortización de recursos hardware | 130,65 € |
| Coste de recursos software | 20,00 € |
| Trabajo tarifado por tiempo empleado | 7.300,80 € |
| Total (P) | 7.451,45 € |

Debido a que el coeficiente de ponderación para presupuestos menores de 30.050,00€ es de 1.00, el coste de la redacción de documento del TFG es de:

$$H=0,07*7.451,45*1=521,60€$$

Finalmente, el coste de la redacción del proyecto se queda con un valor de quinientos veintiún euros con sesenta céntimos (521,60 €).

4. Aplicación de impuestos y coste total

Al desarrollo de este Trabajo de Fin de Grado se le aplica el Impuesto General Indirecto Canario (IGIC), que se corresponde con el 7% del valor del presupuesto. El presupuesto total del proyecto se recoge en la Tabla 14.

Tabla 14: Presupuesto Total del Proyecto

| Concepto | Coste |
|--------------------------------------|-------------------|
| Amortización de recursos hardware | 130,65 € |
| Coste de recursos software | 20,00 € |
| Trabajo tarifado por tiempo empleado | 7.300,80 € |
| Redacción de documentación | 521,60 € |
| Subtotal (Sin IGIC) | 7.973,05 € |
| IGIC (7%) | 558,11 € |
| Total | 8.531,16 € |

El trabajo de Fin de Grado con título “Análisis de agentes inteligentes aplicado a la gestión de personas en las organizaciones” desarrollado en la Escuela de Ingeniería de Telecomunicaciones y Electrónica de la Universidad de las Palmas de Gran Canaria, tiene un coste de desarrollo total, para la parte correspondiente al Grado en Ingeniería en Tecnologías de la Telecomunicación, de ocho mil quinientos treinta y un euros con dieciséis céntimos (8.531,16 €), correspondiente a la suma de las cantidades consignadas a los apartados considerados previamente.

Las Palmas de Gran Canaria, a 9 de julio de 2025

Firma: Antonio Cristian Regina Puccini

ANEXOS

1. Parte 1: ADE

1.1. Análisis de citación de documentos

Tabla 15: Análisis de citación de documentos

Fuente: Elaboración propia con los datos procesados de VosViewer

| Citaciones | Referencia | Título | Fuente | URL/DOI | Clúster |
|------------|---------------------------|---|--|---|---------|
| 610 | Vrontis, et al. (2022) | Artificial intelligence, robotics, advanced technologies and human resource management: a systematic review | International Journal of Human Resource Management, 33(6), 1237-1266 | https://doi.org/10.1080/09585192.2020.1871398 | 4 |
| 412 | Chowdhury, et al. (2023a) | Unlocking the value of artificial intelligence in human resource management through ai capability framework | Human Resource Management Review, 33(1) | https://doi.org/10.1016/j.hrmmr.2022.100899 | 8 |
| 230 | Pillai, et al. (2020) | Adoption of artificial intelligence (ai) for talent acquisition in it/ites organizations | Benchmarking, 27(9), 2599-2629 | https://doi.org/10.1108/bij-04-2020-0186 | 7 |
| 212 | Kong, et al. (2021) | Influences of artificial intelligence (ai) awareness on career competency and job burnout | International Journal of Contemporary Hospitality Management, 33(2), 717-734 | https://doi.org/10.1108/ijchm-07-2020-0789 | 9 |
| 197 | Pan, et al. (2022) | The adoption of artificial intelligence in employee recruitment: the influence of contextual factors | International Journal of Human Resource Management, 33(6), 1125-1147 | https://doi.org/10.1080/09585192.2021.1879206 | 5 |

| Citaciones | Referencia | Título | Fuente | URL/DOI | Clúster |
|-------------------|--------------------------------|--|---|---|----------------|
| 187 | Chowdhury, et al. (2022) | Ai-employee collaboration and business performance... | Journal of Business Research, 144, 31-49 | https://doi.org/10.1016/j.jbusres.2022.01.069 | 3 |
| 157 | Arslan, et al. (2022) | Artificial intelligence and human workers interaction at team level... | International Journal of Manpower, 43(1), 75-88 | https://doi.org/10.1108/ijm-01-2021-0052 | 2 |
| 130 | Malik, et al. (2022) | May the bots be with you! delivering hr cost-effectiveness and individualised employee experiences in an mne | International Journal of Human Resource Management, 33(6), 1148-1178 | https://doi.org/10.1080/09585192.2020.1859582 | 1 |
| 106 | Malik, et al. (2023) | Employee experience –the missing link for engaging employees: insights from an mne's ai-based hr ecosystem | Human Resource Management, 62(1), 97-115 | https://doi.org/10.1002/hrm.22133 | 1 |
| 96 | Kaushal, et al. (2023) | Artificial intelligence and hrm: identifying future research agenda using systematic literature review... | Management Review Quarterly, 73(2), 455-493 | https://doi.org/10.1007/s11301-021-00249-2 | 7 |
| 89 | Ore, et al. (2022) | Opportunities and risks of artificial intelligence in recruitment and selection | International Journal of Organizational Analysis, 30(6), 1771-1782 | https://doi.org/10.1108/ijoa-07-2020-2291 | 11 |
| 82 | Kshetri (2020) | Evolving uses of artificial intelligence in human resource management in emerging economies... | Management Research Review, 44(7), 970-990 | https://doi.org/10.1108/mrr-03-2020-0168 | 8 |
| 58 | Chowdhury, et al. (2023b) | Embedding transparency in artificial intelligence machine learning models... | International Journal of Human Resource Management, 34(14), 2732-2764 | https://doi.org/10.1080/09585192.2022.2066981 | 3 |
| 54 | Nawaz, et al. (2024) | The adoption of artificial intelligence in human resources management practices | International Journal of Information Management Data Insights, 4(1) | https://doi.org/10.1016/j.jjime.2023.100208 | 7 |
| 52 | Kambur, et al. (2022) | Human resource developments with the touch of artificial intelligence: a scale development study | International Journal of Manpower, 43(1), 168-205 | https://doi.org/10.1108/ijm-04-2021-0216 | 2 |
| 51 | Figuroa-Armijos, et al. (2023) | Ethical perceptions of ai in hiring and organizational trust... | Journal of Business Ethics, 186(1), 179-197 | https://doi.org/10.1007/s10551-022-05166-2 | 3 |

| Citaciones | Referencia | Título | Fuente | URL/DOI | Clúster |
|-------------------|----------------------------|--|---|---|----------------|
| 50 | Presbitero, et al. (2023) | Job attitudes and career behaviors relating to employees' perceived incorporation of artificial intelligence in the workplace... | Personnel Review, 52(4), 1169-1187 | https://doi.org/10.1108/pr-02-2021-0103 | 1 |
| 47 | Del Giudice, et al. (2022) | Humanoid robot adoption and labour productivity: a perspective on ambidextrous product innovation routines | International Journal of Human Resource Management, 33(6), 1098-1124 | https://doi.org/10.1080/09585192.2021.1897643 | 6 |
| 42 | Dutta, et al. (2023) | Augmented employee voice and employee engagement using artificial intelligence-enabled chatbots: a field study | International Journal of Human Resource Management, 34(12), 2451-2480 | https://doi.org/10.1080/09585192.2022.2085525 | 1 |
| 38 | Kot, et al. (2021) | The role of artificial intelligence recruitment and quality to explain the phenomenon of employer reputation | Journal of Business Economics and Management, 22(4), 867-883 | https://doi.org/10.3846/jbem.2021.14606 | 8 |
| 34 | Deepa, et al. (2024) | Impact of ai-focussed technologies on social and technical competencies for hr managers... | Technological Forecasting and Social Change, 202 | https://doi.org/10.1016/j.techfore.2024.123301 | 6 |
| 31 | Faqihi, et al. (2023) | Artificial intelligence-driven talent management system: exploring the risks and options... | Journal of Risk and Financial Management, 16(1) | https://doi.org/10.3390/jrfm16010031 | 4 |
| 28 | Giraud, et al. (2023) | The impacts of artificial intelligence on managerial skills | Journal of Decision Systems, 32(3), 566-599 | https://doi.org/10.1080/12460125.2022.2069537 | 9 |
| 25 | Sposato (2024) | Leadership training and development in the age of artificial intelligence | Development and Learning in Organizations, 38(4), 4-7 | https://doi.org/10.1108/dlo-12-2023-0256 | 11 |
| 25 | Bukartaite, et al. (2023) | Automation, artificial intelligence and future skills needs: an irish perspective | European Journal of Training and Development, 47(10), 163-185 | https://doi.org/10.1108/ejtd-03-2023-0045 | 2 |
| 24 | Song, et al. (2021) | Analysing human-computer interaction behaviour in human resource management system... | Knowledge Management Research and Practice | https://doi.org/10.1080/14778238.2021.1955630 | 10 |
| 23 | Kong, et al. (2024) | Influence of artificial intelligence (ai) perception on career resilience and informal learning | Tourism Review, 79(1), 219-233 | https://doi.org/10.1108/tr-10-2022-0521 | 9 |

| Citaciones | Referencia | Título | Fuente | URL/DOI | Clúster |
|-------------------|--------------------------|---|--|---|----------------|
| 23 | Rožman, et al. (2023) | Maximizing employee engagement through artificial intelligent organizational culture... | Cogent Business and Management, 10(2) | https://doi.org/10.1080/23311975.2023.2248732 | 2 |
| 23 | Hmoud (2021) | The adoption of artificial intelligence in human resource management | Forum Scientiae Oeconomia, 9(1), 105-118 | https://doi.org/10.23762/fso_vol9_no1_7 | 6 |
| 20 | Islam, et al. (2022) | Technology adoption and human resource management practices: the use of artificial intelligence for recruitment in bangladesh | South Asian Journal of Human Resources Management, 9(2), 324-349 | https://doi.org/10.1177/23220937221122329 | 5 |
| 19 | Berman, et al. (2024) | Trustworthy ai in the public sector: an empirical analysis of a swedish labor market decision-support system | Technology in Society, 76 | https://doi.org/10.1016/j.techsoc.2024.102471 | 3 |
| 19 | Chowdhury, et al. (2024) | Generative artificial intelligence in business: towards a strategic human resource management framework | British Journal of Management, 35(4), 1680-1691 | https://doi.org/10.1111/1467-8551.12824 | 3 |
| 18 | Qahtani, et al. (2023) | Assisting artificial intelligence adoption drivers in human resources management: a mediation model | Acta Logistica, 10(1), 141-150 | https://doi.org/10.22306/al.v10i1.371 | 5 |
| 17 | Xiao, et al. (2025) | How does ai-enabled hr analytics influence employee resilience... | Personnel Review, 54(3), 824-843 | https://doi.org/10.1108/pr-03-2023-0198 | 2 |
| 16 | Bartosiak, et al. (2022) | Fired by an algorithm? exploration of conformism with biased intelligent decision support systems... | Career Development International, 27(45844), 601-615 | https://doi.org/10.1108/cdi-06-2022-0170 | 10 |
| 15 | Zhou, et al. (2023) | The dark side of ai-enabled hrm on employees based on ai algorithmic features | Journal of Organizational Change Management, 36(7), 1222-1241 | https://doi.org/10.1108/jocm-10-2022-0308 | 1 |
| 13 | Dutta, et al. (2024) | Bots for mental health: the boundaries of human and technology agencies for enabling mental well-being within organizations | Personnel Review, 53(5), 1129-1156 | https://doi.org/10.1108/pr-11-2022-0832 | 1 |
| 13 | Weber (2023) | Unrealistic optimism regarding artificial intelligence opportunities in human resource management | International Journal of Knowledge Management, 19(1), 1-19 | https://doi.org/10.4018/ijkm.317217 | 4 |

| Citaciones | Referencia | Título | Fuente | URL/DOI | Clúster |
|-------------------|------------------------|--|--|---|----------------|
| 10 | Olan, et al. (2024) | Ai: a knowledge sharing tool for improving employees' performance | Journal of Decision Systems, 33(4), 700-720 | https://doi.org/10.1080/12460125.2023.2263687 | 4 |

1.2. Análisis de acoplamiento bibliográfico

Tabla 16: Análisis de acoplamiento bibliográfico

Fuente: Elaboración propia con los datos procesados de VosViewer

| Links | Referencia | Título | Fuente | URL/DOI | Citaciones | Clúster |
|-------|----------------------------|--|---|---|------------|---------|
| 55 | Vrontis, et al. (2022) | Artificial intelligence, robotics, advanced technologies and human resource management: a systematic review | International Journal Of Human Resource Management, 33(6) | https://doi.org/10.1080/09585192.2020.1871398 | 610 | 1 |
| 54 | Huang, et al. (2023) | Personalized human resource management via hr analytics and artificial intelligence: theory and implications | Asia Pacific Management Review, 28(4) | https://doi.org/10.1016/j.apmr.2023.04.004 | 60 | 1 |
| 49 | Olan, et al. (2024) | Ai: a knowledge sharing tool for improving employees' performance | Journal Of Decision Systems, 33(4) | https://doi.org/10.1080/12460125.2023.2263687 | 10 | 1 |
| 49 | Del Giudice, et al. (2022) | Humanoid robot adoption and labour productivity: a perspective on ambidextrous product innovation routines | International Journal Of Human Resource Management, 33(6) | https://doi.org/10.1080/09585192.2021.1897643 | 47 | 1 |
| 47 | Bartosiak, et al. (2022) | Fired by an algorithm? exploration of conformism with biased intelligent decision support systems in the context of workplace discipline | Career Development International, 27(45844) | https://doi.org/10.1108/cdi-06-2022-0170 | 16 | 1 |
| 44 | Kong, et al. (2021) | Influences of artificial intelligence (ai) awareness on career competency and job burnout | International Journal Of Contemporary Hospitality Management, 33(2) | https://doi.org/10.1108/ijchm-07-2020-0789 | 212 | 1 |
| 42 | Votto, et al. (2021) | Artificial intelligence in tactical human resource management: a systematic literature review | International Journal Of Information Management Data Insights, 1(2) | https://doi.org/10.1016/j.jjime.2021.100047 | 169 | 1 |

| | | | | | | |
|----|-----------------------------|---|--|---|-----|---|
| 39 | Hogreve, et al. (2022) | The service-profit chain: reflections, revisions, and reimaginings | Journal Of Service Research, 25(3) | https://doi.org/10.1177/10946705211052410 | 37 | 1 |
| 39 | Bukartaite, et al. (2023) | Automation, artificial intelligence and future skills needs: an irish perspective | European Journal Of Training And Development, 47(10) | https://doi.org/10.1108/ejtd-03-2023-0045 | 25 | 1 |
| 32 | Roberts, et al. (2024) | Artificial intelligence and innovation management: charting the evolving landscape | Technovation, 136 | https://doi.org/10.1016/j.technovation.2024.103081 | 19 | 1 |
| 32 | Kong, et al. (2024) | Influence of artificial intelligence (ai) perception on career resilience and informal learning | Tourism Review, 79(1) | https://doi.org/10.1108/tr-10-2022-0521 | 23 | 1 |
| 31 | Johnson, et al. (2022) | Artificial intelligence and public human resource management: questions for research and practice | Public Personnel Management, 51(4) | https://doi.org/10.1177/00910260221126498 | 40 | 1 |
| 29 | Malik, et al. (2022) | Impact of artificial intelligence on employees working in industry 4.0 led organizations | International Journal Of Manpower, 43(2) | https://doi.org/10.1108/ijm-03-2021-0173 | 202 | 1 |
| 28 | Prentice, et al. (2023) | Artificial intelligence as a boundary-crossing object for employee engagement and performance | Journal Of Retailing And Consumer Services, 73 | https://doi.org/10.1016/j.jretconser.2023.103376 | 43 | 1 |
| 27 | Qin, et al. (2023) | Perceived fairness of human managers compared with artificial intelligence in employee performance evaluation | Journal Of Management Information Systems, 40(4) | https://doi.org/10.1080/07421222.2023.2267316 | 20 | 1 |
| 24 | Tursunbayeva, et al. (2023) | Artificial intelligence in health-care: implications for the job design of healthcare professionals | Asia Pacific Journal Of Human Resources, 61(4) | https://doi.org/10.1111/1744-7941.12325 | 55 | 1 |
| 22 | Presbitero, et al. (2023) | Job attitudes and career behaviors relating to employees' perceived incorporation of artificial intelligence in the workplace: a career self-management perspective | Personnel Review, 52(4) | https://doi.org/10.1108/pr-02-2021-0103 | 50 | 1 |

| | | | | | | |
|----|-----------------------------|---|---|---|-----|---|
| 20 | Chang (2020) | Artificial intelligence in personnel management: the development of apm model | Bottom Line, 33(4) | https://doi.org/10.1108/bl-08-2020-0055 | 33 | 1 |
| 16 | Egana-delsol, et al. (2022) | Automation in latin america: are women at higher risk of losing their jobs? | Technological Forecasting And Social Change, 175 | https://doi.org/10.1016/j.techfore.2021.121333 | 36 | 1 |
| 13 | Kot, et al. (2021) | The role of artificial intelligence recruitment and quality to explain the phenomenon of employer reputation | Journal Of Business Economics And Management, 22(4) | https://doi.org/10.3846/jbem.2021.14606 | 38 | 1 |
| 10 | Fan, et al. (2023) | The impact of improving employee psychological empowerment and job performance based on deep learning and artificial intelligence | Journal Of Organizational And End User Computing, 35(3) | https://doi.org/10.4018/joec.321639 | 13 | 1 |
| 52 | Prikshat, et al. (2022) | A multi-stakeholder ethical framework for ai-augmented hrm | International Journal Of Manpower, 43(1) | https://doi.org/10.1108/ijm-03-2021-0118 | 26 | 2 |
| 46 | Kaushal, et al. (2023) | Artificial intelligence and hrm: identifying future research agenda using systematic literature review and bibliometric analysis | Management Review Quarterly, 73(2) | https://doi.org/10.1007/s11301-021-00249-2 | 96 | 2 |
| 30 | Gurusinghe, et al. (2021) | Predictive hr analytics and talent management: a conceptual framework | Journal Of Management Analytics, 8(2) | https://doi.org/10.1080/23270012.2021.1899857 | 54 | 2 |
| 24 | Strohmeier, et al. (2022) | (how) do advanced data and analyses enable hr analytics success? a neo-configurational analysis | Baltic Journal Of Management, 17(3) | https://doi.org/10.1108/bjm-05-2021-0188 | 11 | 2 |
| 24 | Johnson, et al. (2020) | The benefits of ehrm and ai for talent acquisition | Journal Of Tourism Futures, 7(1) | https://doi.org/10.1108/jtf-02-2020-0013 | 105 | 2 |
| 23 | Hmoud (2021) | The adoption of artificial intelligence in human resource management | Forum Scientiae Oeconomia, 9(1) | https://doi.org/10.23762/fso_vol9_no1_7 | 23 | 2 |
| 15 | Ore, et al. (2022) | Opportunities and risks of artificial intelligence in recruitment and selection | International Journal Of Organizational Analysis, 30(6) | https://doi.org/10.1108/ijoa-07-2020-2291 | 89 | 2 |

| | | | | | | |
|----|--------------------------------|--|---|---|----|---|
| 12 | Mozaffari, et al. (2023) | Employee attrition prediction in a pharmaceutical company using both machine learning approach and qualitative data | Benchmarking, 30(10) | https://doi.org/10.1108/bij-11-2021-0664 | 16 | 2 |
| 12 | Shet, et al. (2023) | Quality of hire: expanding the multi-level fit employee selection using machine learning | International Journal Of Organizational Analysis, 31(6) | https://doi.org/10.1108/ijoa-06-2021-2843 | 15 | 2 |
| 9 | Al-nammari, et al. (2023) | Exploring drivers of staff engagement in healthcare organizations using tree-based machine learning algorithms | Ieee Transactions On Engineering Management, 70(8) | https://doi.org/10.1109/tem.2022.3209879 | 10 | 2 |
| 9 | Jenkins, et al. (2022) | Predicting success in united states air force pilot training using machine learning techniques | Socio-economic Planning Sciences, 79 | https://doi.org/10.1016/j.seps.2021.101121 | 13 | 2 |
| 9 | Sharif, et al. (2022) | The ethics of blockchain in organizations | Journal Of Business Ethics, 178(4) | https://doi.org/10.1007/s10551-022-05058-5 | 39 | 2 |
| 6 | Wang, et al. (2021) | A machine learning-based analytical framework for employee turnover prediction | Journal Of Management Analytics, 8(3) | https://doi.org/10.1080/23270012.2021.1961318 | 30 | 2 |
| 3 | Schlembach, et al. (2022) | Forecasting the olympic medal distribution – a socioeconomic machine learning model | Technological Forecasting And Social Change, 175 | https://doi.org/10.1016/j.techfore.2021.121314 | 18 | 2 |
| 2 | Abbasianjahromi, et al. (2023) | Safety performance prediction and modification strategies for construction projects via machine learning techniques | Engineering, Construction And Architectural Management, 30(3) | https://doi.org/10.1108/ecam-04-2021-0303 | 24 | 2 |
| 1 | Anwer, et al. (2023) | Identification and classification of physical fatigue in construction workers using linear and nonlinear heart rate variability measurements | Journal Of Construction Engineering And Management, 149(7) | https://doi.org/10.1061/jcemd4.coeng-13100 | 22 | 2 |
| 1 | Xin, et al. (2022) | Review on a big data-based innovative knowledge teaching evaluation system in universities | Journal Of Innovation And Knowledge, 7(3) | https://doi.org/10.1016/j.jik.2022.100197 | 37 | 2 |

| | | | | | | |
|----|---------------------------|--|---|---|-----|---|
| 66 | Giraud, et al. (2023) | The impacts of artificial intelligence on managerial skills | Journal Of Decision Systems, 32(3) | https://doi.org/10.1080/12460125.2022.2069537 | 28 | 3 |
| 59 | Li, et al. (2023) | How does artificial intelligence impact human resources performance. evidence from a healthcare institution in the united arab emirates | Journal Of Innovation And Knowledge, 8(2) | https://doi.org/10.1016/j.jik.2023.100340 | 52 | 3 |
| 51 | Nawaz, et al. (2024) | The adoption of artificial intelligence in human resources management practices | International Journal Of Information Management Data Insights, 4(1) | https://doi.org/10.1016/j.jjime.2023.100208 | 54 | 3 |
| 50 | Faqihi, et al. (2023) | Artificial intelligence-driven talent management system: exploring the risks and options for constructing a theoretical foundation | Journal Of Risk And Financial Management, 16(1) | https://doi.org/10.3390/jrfm16010031 | 31 | 3 |
| 38 | Kshetri (2020) | Evolving uses of artificial intelligence in human resource management in emerging economies in the global south: some preliminary evidence | Management Research Review, 44(7) | https://doi.org/10.1108/mrr-03-2020-0168 | 82 | 3 |
| 32 | Trocin, et al. (2021) | How artificial intelligence affords digital innovation: a cross-case analysis of scandinavian companies | Technological Forecasting And Social Change, 173 | https://doi.org/10.1016/j.techfore.2021.121081 | 115 | 3 |
| 27 | Chilunjika, et al. (2022) | Artificial intelligence and public sector human resource management in south africa: opportunities, challenges and prospects | Sa Journal Of Human Resource Management, 20 | https://doi.org/10.4102/sajhrm.v20i0.1972 | 32 | 3 |
| 27 | Einola, et al. (2023) | Best friend or broken tool? exploring the co-existence of humans and artificial intelligence in the workplace ecosystem | Human Resource Management, 62(1) | https://doi.org/10.1002/hrm.22147 | 74 | 3 |
| 24 | Korzynski, et al. (2023) | Generative artificial intelligence as a new context for management theories: analysis of chatgpt | Central European Management Journal, 31(1) | https://doi.org/10.1108/cemj-02-2023-0091 | 200 | 3 |

| | | | | | | |
|----|-------------------------|---|--|---|----|---|
| 18 | Kraus, et al. (2023) | The future of work: how innovation and digitalization re-shape the workplace | Journal Of Innovation And Knowledge, 8(4) | https://doi.org/10.1016/j.jik.2023.100438 | 60 | 3 |
| 18 | Tian, et al. (2023) | A machine learning-based human resources recruitment system for business process management: using lsa, bert and svm | Business Process Management Journal, 29(1) | https://doi.org/10.1108/bpmj-08-2022-0389 | 35 | 3 |
| 14 | Monod, et al. (2023) | Does ai control or support? power shifts after ai system implementation in customer relationship management | Journal Of Decision Systems, 32(3) | https://doi.org/10.1080/12460125.2022.2066051 | 43 | 3 |
| 7 | Kulkov (2021) | The role of artificial intelligence in business transformation: a case of pharmaceutical companies | Technology In Society, 66 | https://doi.org/10.1016/j.techsoc.2021.101629 | 76 | 3 |
| 5 | Aleem, et al. (2023) | Remote work and the covid-19 pandemic: an artificial intelligence-based topic modeling and a future agenda | Journal Of Business Research, 154 | https://doi.org/10.1016/j.jbusres.2022.113303 | 52 | 3 |
| 4 | Siswanto, et al. (2022) | Interview bot development with natural language processing and machine learning | International Journal Of Technology, 13(2) | https://doi.org/10.14716/ijtech.v13i2.5018 | 21 | 3 |
| 4 | Harl, et al. (2020) | Explainable predictive business process monitoring using gated graph neural networks | Journal Of Decision Systems, 29(sup1) | https://doi.org/10.1080/12460125.2020.1780780 | 66 | 3 |
| 59 | Deepa, et al. (2024) | Impact of ai-focussed technologies on social and technical competencies for hr managers – a systematic review and research agenda | Technological Forecasting And Social Change, 202 | https://doi.org/10.1016/j.techfore.2024.123301 | 34 | 4 |
| 54 | Zhou, et al. (2023) | The dark side of ai-enabled hrm on employees based on ai algorithmic features | Journal Of Organizational Change Management, 36(7) | https://doi.org/10.1108/jocm-10-2022-0308 | 15 | 4 |

| | | | | | | |
|----|------------------------|---|--|---|-----|---|
| 54 | Menzies, et al. (2024) | Artificial intelligence for international business: its use, challenges, and suggestions for future research and practice | Thunderbird International Business Review, 66(2) | https://doi.org/10.1002/tic.22370 | 16 | 4 |
| 47 | Dutta, et al. (2023) | Augmented employee voice and employee engagement using artificial intelligence-enabled chatbots: a field study | International Journal Of Human Resource Management, 34(12) | https://doi.org/10.1080/09585192.2022.2085525 | 42 | 4 |
| 46 | Böhmer, et al. (2023) | Critical exploration of ai-driven hrm to build up organizational capabilities | Employee Relations, 45(5) | https://doi.org/10.1108/er-04-2022-0202 | 53 | 4 |
| 43 | Weber (2023) | Unrealistic optimism regarding artificial intelligence opportunities in human resource management | International Journal Of Knowledge Management, 19(1) | https://doi.org/10.4018/ijkm.317217 | 13 | 4 |
| 41 | Dutta, et al. (2024) | The machine/human agentic impact on practices in learning and development: a study across msme, ngo and mnc organizations | Personnel Review, 53(3) | https://doi.org/10.1108/pr-09-2022-0658 | 12 | 4 |
| 38 | Malik, et al. (2023) | Employee experience –the missing link for engaging employees: insights from an mne's ai-based hr ecosystem | Human Resource Management, 62(1) | https://doi.org/10.1002/hrm.22133 | 106 | 4 |
| 34 | Qahtani, et al. (2023) | Assisting artificial intelligence adoption drivers in human resources management: a mediation model | Acta Logistica, 10(1) | https://doi.org/10.22306/al.v10i1.371 | 18 | 4 |
| 32 | Xiao, et al. (2025) | How does ai-enabled hr analytics influence employee resilience: job crafting as a mediator and hrm system strength as a moderator | Personnel Review, 54(3) | https://doi.org/10.1108/pr-03-2023-0198 | 17 | 4 |
| 28 | Dutta, et al. (2024) | Bots for mental health: the boundaries of human and technology agencies for enabling mental well-being within organizations | Personnel Review, 53(5) | https://doi.org/10.1108/pr-11-2022-0832 | 13 | 4 |

| | | | | | | |
|----|--------------------------|---|---|---|----|---|
| 27 | Suen, et al. (2024) | Revealing the influence of ai and its interfaces on job candidates' honest and deceptive impression management in asynchronous video interviews | Technological Forecasting And Social Change, 198 | https://doi.org/10.1016/j.techfore.2023.123011 | 11 | 4 |
| 21 | Chowdhury, et al. (2024) | Generative artificial intelligence in business: towards a strategic human resource management framework | British Journal Of Management, 35(4) | https://doi.org/10.1111/1467-8551.12824 | 19 | 4 |
| 10 | Berman, et al. (2024) | Trustworthy ai in the public sector: an empirical analysis of a swedish labor market decision-support system | Technology In Society, 76 | https://doi.org/10.1016/j.techsoc.2024.102471 | 19 | 4 |
| 4 | De Kock, et al. (2020) | The profile of the 'good judge' in hrm: a systematic review and agenda for future research | Human Resource Management Review, 30(2) | https://doi.org/10.1016/j.hrmr.2018.09.003 | 28 | 4 |
| 1 | Sposato (2024) | Leadership training and development in the age of artificial intelligence | Development And Learning In Organizations, 38(4) | https://doi.org/10.1108/dlo-12-2023-0256 | 25 | 4 |
| 60 | Prikshat, et al. (2023b) | Ai-augmented hrm: antecedents, assimilation and multilevel consequences | Human Resource Management Review, 33(1) | https://doi.org/10.1016/j.hrmr.2021.100860 | 99 | 5 |
| 51 | Odugbesan, et al. (2023) | Green talent management and employees' innovative work behavior: the roles of artificial intelligence and transformational leadership | Journal Of Knowledge Management, 27(3) | https://doi.org/10.1108/jkm-08-2021-0601 | 88 | 5 |
| 50 | Islam, et al. (2022) | Technology adoption and human resource management practices: the use of artificial intelligence for recruitment in bangladesh | South Asian Journal Of Human Resources Management, 9(2) | https://doi.org/10.1177/23220937221122329 | 20 | 5 |
| 43 | Yadav, et al. (2024) | Adopting artificial intelligence (ai) for employee recruitment: the influence of contextual factors | International Journal Of System Assurance Engineering And Management, 15(5) | https://doi.org/10.1007/s13198-023-02163-0 | 11 | 5 |

| | | | | | | |
|----|-------------------------|---|--|---|-----|---|
| 43 | Pan, et al. (2022) | The adoption of artificial intelligence in employee recruitment: the influence of contextual factors | International Journal Of Human Resource Management, 33(6) | https://doi.org/10.1080/09585192.2021.1879206 | 197 | 5 |
| 38 | Pillai, et al. (2020) | Adoption of artificial intelligence (ai) for talent acquisition in it/ites organizations | Benchmarking, 27(9) | https://doi.org/10.1108/bij-04-2020-0186 | 230 | 5 |
| 36 | Rožman, et al. (2023) | Maximizing employee engagement through artificial intelligent organizational culture in the context of leadership and training of employees: testing linear and non-linear relationships | Cogent Business And Management, 10(2) | https://doi.org/10.1080/23311975.2023.2248732 | 23 | 5 |
| 32 | Ogbeibu, et al. (2024) | Demystifying the roles of organisational smart technology, artificial intelligence, robotics and algorithms capability: a strategy for green human resource management and environmental sustainability | Business Strategy And The Environment, 33(2) | https://doi.org/10.1002/bse.3495 | 47 | 5 |
| 14 | Ogbeibu, et al. (2022) | Green talent management and turnover intention: the roles of leader stara competence and digital task interdependence | Journal Of Intellectual Capital, 23(1) | https://doi.org/10.1108/jic-01-2021-0016 | 66 | 5 |
| 11 | Ruel, et al. (2020) | Ai redefining the hospitality industry | Journal Of Tourism Futures, 7(1) | https://doi.org/10.1108/jtf-03-2020-0032 | 78 | 5 |
| 9 | Shayegan, et al. (2023) | Realization of sustainable organizational performance using new technologies and green human resource management practices | Foresight And Sti Governance, 17(2) | https://doi.org/10.17323/2500-2597.2023.2.95.105 | 10 | 5 |
| 7 | Sharma, et al. (2024) | Artificial intelligence in indian higher education institutions: a quantitative study on adoption and perceptions | International Journal Of System Assurance Engineering And Management | https://doi.org/10.1007/s13198-023-02193-8 | 27 | 5 |

| | | | | | | |
|----|--------------------------------|---|--|---|-----|---|
| 6 | Chiarini, et al. (2022) | What is quality 4.0? an exploratory sequential mixed methods study of italian manufacturing companies | International Journal Of Production Research, 60(16) | https://doi.org/10.1080/00207543.2021.1942285 | 60 | 5 |
| 5 | Agarwal, et al. (2024) | Prioritizing the barriers of green smart manufacturing using ahp in implementing industry 4.0: a case from indian automotive industry | Tqm Journal, 36(1) | https://doi.org/10.1108/tqm-07-2022-0229 | 17 | 5 |
| 1 | Kemendi, et al. (2022) | Industry 4.0 and 5.0 – organizational and competency challenges of enterprises... | Polish Journal Of Management Studies, 26(2) | https://doi.org/10.17512/pjms.2022.26.2.13 | 27 | 5 |
| 71 | Chowdhury, et al. (2023) | Unlocking the value of artificial intelligence in human resource management... | Human Resource Management Review, 33(1) | https://doi.org/10.1016/j.hrnr.2022.100899 | 412 | 6 |
| 63 | Prikshat, et al. (2023a) | Ai-augmented hrm: literature review and a proposed multilevel framework... | Technological Forecasting And Social Change, 193 | https://doi.org/10.1016/j.techfore.2023.122645 | 52 | 6 |
| 63 | Chowdhury, et al. (2022) | Ai-employee collaboration and business performance... | Journal Of Business Research, 144 | https://doi.org/10.1016/j.jbusres.2022.01.069 | 187 | 6 |
| 62 | Chowdhury, et al. (2023) | Embedding transparency in artificial intelligence machine learning models... | International Journal Of Human Resource Management, 34(14) | https://doi.org/10.1080/09585192.2022.2066981 | 58 | 6 |
| 60 | Kambur, et al. (2022) | Human resource developments with the touch of artificial intelligence... | International Journal Of Manpower, 43(1) | https://doi.org/10.1108/ijm-04-2021-0216 | 52 | 6 |
| 56 | Basu, et al. (2023) | Artificial intelligence–hrm interactions and outcomes: a systematic review... | Human Resource Management Review, 33(1) | https://doi.org/10.1016/j.hrnr.2022.100893 | 72 | 6 |
| 53 | Malik, et al. (2022) | May the bots be with you! delivering hr cost-effectiveness... | International Journal Of Human Resource Management, 33(6) | https://doi.org/10.1080/09585192.2020.1859582 | 130 | 6 |
| 48 | Arslan, et al. (2022) | Artificial intelligence and human workers interaction at team level... | International Journal Of Manpower, 43(1) | https://doi.org/10.1108/ijm-01-2021-0052 | 157 | 6 |
| 47 | Figuroa-Armijos, et al. (2023) | Ethical perceptions of ai in hiring and organizational trust... | Journal Of Business Ethics, 186(1) | https://doi.org/10.1007/s10551-022-05166-2 | 51 | 6 |

| | | | | | | |
|----|--------------------------|---|--|---|-----|---|
| 42 | Rodgers, et al. (2023) | An artificial intelligence algorithmic approach to ethical decision-making... | Human Resource Management Review, 33(1) | https://doi.org/10.1016/j.hrmr.2022.100925 | 154 | 6 |
| 40 | Song, et al. (2021) | Analysing human-computer interaction behaviour... | Knowledge Management Research And Practice | https://doi.org/10.1080/14778238.2021.1955630 | 24 | 6 |
| 14 | Marabelli, et al. (2025) | Ai and the metaverse in the workplace: dei opportunities and challenges | Personnel Review, 54(3) | https://doi.org/10.1108/pr-04-2023-0300 | 10 | 6 |

2. Parte 2: GITT

2.1. Prompt del agente calificador con rúbrica.

Role:

You are an expert AI agent in analyzing academic and research literature, specializing in the intersection of Artificial Intelligence (`AI`) and Human Resource Management (`HRM`). Your function is to evaluate the relevance and specificity of document abstracts regarding this topic classifying these documents according to the provided rubric and following the step-by-step roadmap to ensure accurate and consistent evaluation.

Instructions:

Rubric:

General Topic Assessment

Criteria and Scoring (1-5)

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|---|--------------------------|--|--|---|---|
| Relevance of AI in HRM | No mention of AI or HRM. | Indirect/vague mention of AI in organizational contexts. | Clear mention of AI in organizational contexts but no direct HRM connection. | Clear HRM connection but superficial/general. | Explicit focus on specific, detailed AI applications in HRM. |
| Clarity of AI Impact | No impact mentioned. | General tech impact mentioned (not AI-specific). | General AI impact mentioned (no specifics). | Identifies specific but limited impacts. | Clearly describes relevant, specific AI impacts in HRM. |
| Specificity of HRM Practices | No specific mention. | Generic references to management practices. | Identifies at least one general HRM practice. | Clearly identifies multiple specific practices. | Details specific practices and how AI modifies/improves them. |
| Empirical Research Mention | No empirical reference. | Generic/implicit research need mentioned. | Explicitly identifies need for empirical studies. | Briefly summarizes empirical results or suggests studies. | Clearly based on specific empirical results or proposes detailed future research. |
| Connection to Future of Work (FoW) | No FoW reference. | Generic FoW reference (no AI/HRM link). | Generic link between AI, HRM, and FoW. | Clearly mentions specific FoW changes anticipated from AI in HRM. | Detailed analysis of AI's future impact on specific HRM practices related to FoW. |

Subgroup Assessments

1. Recruitment and Selection

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|--------------------------------|------------------------------------|---------------------------------------|---|--|--|
| **Process Automation** | No automation mentioned. | Vague/indirect automation reference. | General mention without specifics. | Clear automation in at least one process area. | Detailed automation across multiple process stages with quantifiable improvements. |
| **Cost/Time Reduction** | No mention of cost/time reduction. | Vague reduction claim (no specifics). | General mention of cost/time reduction. | Specific reduction in time/costs mentioned. | Precise details on how AI achieves measurable reductions. |

2. Work Design

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|---|---------------------------|-------------------------------|---|--|---|
| **Task Automation** | No automation mentioned. | General automation reference. | Identifies generic automated tasks. | Clear partial task automation. | Details specific automated tasks and their impacts. |
| **Human-AI Interaction** | No interaction mentioned. | Vague interaction reference. | General human-AI interaction described. | Clear description of human-AI interaction. | In-depth analysis of human-AI interaction dynamics. |
| **Algorithmic Decision Risks (Black-box)** | No risks mentioned. | Generic risk reference. | General risks identified. | Specific risks clearly mentioned. | Detailed risks with concrete examples. |

3. Performance Management

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|--|--------------------------|---------------------------------|--------------------------------------|---|---|
| **Performance Evaluation with AI** | No evaluation mentioned. | Vague tech reference. | General mention of AI in evaluation. | Clear evaluation methods identified. | Specific details on AI-driven evaluation methods. |
| **Instant Feedback** | No feedback mentioned. | General mention of AI feedback. | Specific AI feedback described. | Details benefits of AI-driven instant feedback. | N/A (covered in previous row). |
| **Perceived Fairness/Transparency** | No mention. | Generic fairness reference. | General fairness issues identified. | Specific fairness/transparency issues. | Detailed analysis with proposed solutions. |

4. Training and Development

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|---|----------------------|-----------------------------|-----------------------------------|---|---|
| **Personalized Recommendations** | No mention. | Vague platform reference. | General mention without detail. | Clear personalized recommendations. | Specific methods/benefits of AI-driven recommendations. |
| **Digital Platform Use** | No platform mention. | Generic platform reference. | General platform mention. | Specific platform data usage described. | N/A (covered in previous row). |
| **Need for Empirical Research** | No mention. | Generic research need. | Explicit empirical research need. | Briefly suggests empirical studies. | Proposes detailed, specific future research. |

5. Workforce Planning and Scheduling

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|---|----------------------------|-------------------------------|---|---|---|
| **AI Optimization** | No optimization mentioned. | Vague optimization reference. | General AI optimization mention. | Specific optimization methods. | Detailed methods and measurable benefits. |
| **Application in Specific Contexts** | No context mentioned. | Generic labor context. | Generic AI application contexts. | Specific contexts (e.g., gig economy). | Precise examples of AI in specific labor contexts. |
| **Algorithm Trust Perception** | No mention. | Vague trust reference. | General algorithm vs. human comparison. | Clear algorithm perception in planning. | In-depth analysis of perceived trust in algorithms. |

6. Compensation and Benefits

| Criterion | Score 1 | Score 2 | Score 3 | Score 4 | Score 5 |
|--|--------------|----------------------------|--------------------------------|-------------------------------------|--|
| **Algorithm Use in Compensation** | No mention. | Vague algorithm reference. | General algorithm mention. | Specific algorithmic methods. | Detailed algorithms and concrete benefits. |
| **Specific Application Examples** | No examples. | Generic case references. | General existing applications. | Specific examples (e.g., Google). | Detailed examples with results analysis. |
| **Gaps and Opportunities** | No mention. | Generic gap reference. | General unexplored areas. | Specific research/application gaps. | Detailed gaps and future research proposals. |

Step 1: Initial Reading

Carefully read the abstract or full text and take brief notes identifying explicit or implicit mentions related to ****AI****, ****HRM****, and specific subgroups.

Step 2: Apply Rubric Criteria

Answer the following questions for each section, assigning scores according to the given rubric (1-5):

****General Topic****

1. ****AI-HRM Connection****: How clearly does the document link AI to HRM?
2. ****Impact Specificity****: Does it describe **specific** AI impacts on HRM?
3. ****HRM Practices****: Does it detail **which** HRM practices AI affects?
4. ****Empirical Basis****: Are empirical studies cited or proposed?
5. ****Future of Work (FoW)****: Does it analyze AI's long-term HRM implications?

****Subgroups****

1. ****Recruitment & Selection****:
 - Does it explain AI automation in hiring?
 - Does it quantify cost/time reductions?
2. ****Work Design****:
 - Are specific automated tasks listed?
 - Is human-AI interaction analyzed?
 - Are algorithmic risks (e.g., black-box) addressed?
3. ****Performance Management****:
 - Does it describe AI-driven evaluation methods?
 - Is instant feedback via AI explained?
 - Are fairness/transparency concerns discussed?
4. ****Training & Development****:
 - Are personalized AI recommendations detailed?
 - Are digital platforms mentioned?
 - Is empirical research needed highlighted?
5. ****Workforce Planning****:
 - Are AI optimization methods specified?
 - Are concrete labor contexts (e.g., gig economy) analyzed?
 - Is algorithm trust perception evaluated?
6. ****Compensation & Benefits****:
 - Are compensation algorithms explained?
 - Are real-world examples (e.g., Google) provided?
 - Are research gaps/opportunities identified?

Step 3: Record Scores

- Score each criterion (1-5).
- Calculate totals:
 - ****General Topic****: Sum of 5 criteria (max 25).
 - ****Subgroups****: Sum of subgroup criteria (max 15 per subgroup).

Step 4: Interpret Results

General Topic

- **21-25** : Very high relevance.
- **16-20** : High relevance, limited details.
- **11-15** : Moderate relevance.
- **6-10** : Low relevance.
- **1-5** : Minimal/irrelevant.

Subgroups

- **13-15** : Very high specificity.
- **9-12** : Moderate, acceptable details.
- **5-8** : Superficial.
- **1-4** : Very limited.

Context:

Your task is critical to organizing a research database on the use of Artificial Intelligence in Human Resource Management (HRM). The central topic is how AI is being implemented or researched in relation to specific HRM practices and policies (recruitment, job design, performance management, training, workforce planning, compensation, etc.). By accurately analyzing and scoring each abstract according to the rubric, you will help researchers and practitioners quickly identify documents relevant to their specific needs, saving countless hours of manual searching and sorting. Your rigorous analysis will help accelerate research in this emerging field and facilitate informed decision-making.

Example:

Abstract:

This paper investigates the potential of Natural Language Processing (NLP) techniques to analyze internal communication patterns for identifying employee skill gaps and suggesting personalized training modules. By analyzing anonymized project discussion logs and comparing them against defined competency frameworks, the system aims to provide objective insights into developmental needs without relying solely on manager assessments. The study discusses the technical implementation using transformer models and preliminary validation results showing correlation with existing performance metrics. Ethical considerations regarding data privacy and potential biases in NLP models are also addressed.

Expected Agent Response:

"score": 19 _ (special delimiter to later adapt the response)

"explanation": "***General Topic Evaluation:**\n\n* **Relevance of AI use in HRM:** The abstract clearly focuses on a specific AI application (NLP) within HRM functions (Training/Development, potentially impacting Performance Management) by analyzing communications to identify skill gaps. **Score: 5**\n\n* **Clarity in identifying the impact of AI:** It describes the intended impact (identifying skill gaps, suggesting training modules, providing objective insights) but lacks specific quantifiable results in the abstract, only mentioning 'preliminary validation results showing correlation'.

Score: 3\n* **Specificity regarding HRM practices or policies:** It details specific HRM practices (skill gap identification, personalized training suggestion) and how AI modifies them (analyzing communication logs instead of relying solely on manager assessments). **Score: 5**\n* **Degree of analysis or empirical research mentioned:** The abstract mentions 'technical implementation' and 'preliminary validation results', indicating empirical work has been conducted or is in progress. **Score: 4**\n* **Relevance to the future of work (FoW):** It implicitly touches upon shifts in assessment methods (less reliance on managers), which relates to FoW, but does not explicitly analyze broader FoW trends. **Score: 2**\n\n**Evaluation of Relevant Subgroups:**\n\n* **Subgroup: Training and Development**\n* **Personalized recommendations:** Explicitly states the aim is 'suggesting personalized training modules' based on the AI analysis of identified skill gaps. **Score: 5**\n* **Use of digital platforms:** Mentions analyzing 'anonymized project discussion logs,' implying the use of data from digital platforms, but doesn't detail platform specifics or the AI's interaction beyond analysis. **Score: 3**\n* **Need for empirical research:** Discusses 'preliminary validation' and 'ethical considerations', suggesting further work is needed, but doesn't explicitly call for future empirical studies within the abstract. **Score: 3**\n* **Subgroup: Performance Management**\n* **Performance evaluation with AI:** Describes using AI for 'objective insights into developmental needs' correlated with 'performance metrics,' which informs performance understanding but isn't presented as a direct, standalone evaluation method. **Score: 3**\n* **Instant feedback:** The abstract does not mention the provision of instant feedback via the system. **Score: 1**\n* **Perception of fairness and transparency:** It explicitly addresses 'ethical considerations regarding data privacy and potential biases', which directly relates to fairness and transparency concerns. **Score: 4**\n* **Other Subgroups:** (Recruitment and Selection, Job Design, Staff Planning and Scheduling, Compensation and Benefits) Are not mentioned in the abstract."

Observations:

Remember to evaluate solely based on the provided abstract text.

Remember that the evaluation scores should be always integers, they MUST NOT be decimals.

the minimum score is 0 and the maximum score is 25.

Ensure you justify EVERY assigned score.