



Sistema de Recomendación con Inteligencia Artificial para el Desarrollo de Carrera y la Gestión del Talento Interno

Profesora de trabajo final: Dra. Marcela Samela

Alumno: Damián Agustín López

Trabajo final de carrera presentado para obtener el título de
Lic. en Gestión de Tecnología Informática

Diciembre 2025

Resumen

El presente trabajo constituye una propuesta de intervención en el campo profesional, cuyo objetivo principal es mejorar los procesos de desarrollo de carrera y movilidad interna en grandes organizaciones mediante el diseño de un sistema inteligente basado en inteligencia artificial. En muchas empresas, los empleados encuentran obstáculos para visualizar oportunidades de crecimiento o transitar trayectorias profesionales alineadas a sus intereses y competencias. Esta situación afecta negativamente la motivación, la retención del talento y la planificación estratégica de recursos humanos.

Frente a esta problemática, se plantea el diseño de un sistema basado en inteligencia artificial, concebido para analizar información clave como descripciones de puestos, currículums, evaluaciones de desempeño, habilidades declaradas y preferencias profesionales. Para ello, se emplearán técnicas de Procesamiento de Lenguaje Natural (PLN) que permitirán transformar datos textuales en representaciones comparables y útiles para la toma de decisiones.

El núcleo de la solución es un módulo de recomendación semántica y prospectiva, alimentado por las representaciones obtenidas a partir del PLN, orientado a identificar oportunidades internas alineadas con el perfil de cada colaborador, señalar brechas de habilidades y proyectar trayectorias de desarrollo junto con capacitaciones relevantes. De esta manera, se ofrecerán recomendaciones personalizadas que contemplan tanto la situación actual del empleado como la evolución de su carrera en el tiempo, considerando además sus intereses y metas profesionales declaradas.

Durante el trabajo se presentarán los módulos del sistema, las técnicas utilizadas, los flujos de información y los beneficios esperados, entre los que destacan una mayor retención del talento, el fortalecimiento del compromiso organizacional y la optimización del uso estratégico de los recursos humanos.

Palabras clave: aprendizaje automático, desarrollo de carrera, inteligencia artificial, procesamiento de lenguaje natural, sistemas de gestión del talento humano, sistemas de recomendación

Abstract

This work constitutes a professional intervention proposal whose main objective is to improve career development processes and internal mobility in large organizations through the design of an intelligent system based on artificial intelligence. In many companies, employees face obstacles when trying to identify growth opportunities or pursue career paths aligned with their interests and competencies. This situation negatively impacts motivation, talent retention, and strategic human resource planning.

To address this problem, the proposal consists of a system designed to analyze key information such as job descriptions, résumés, performance evaluations, declared skills, and professional preferences. Natural Language Processing (NLP) techniques will be applied to transform textual data into comparable representations that support decision-making.

The core of the solution is a semantic and prospective recommendation module, powered by the representations obtained through NLP. This module is oriented toward identifying internal opportunities aligned with each employee's profile, highlighting skill gaps, and projecting career development paths together with relevant training. In this way, the system provides personalized recommendations that consider both the employee's current situation and the evolution of their career over time, while also integrating their declared interests and professional goals.

The work presents the system's modules, the techniques employed, the information flows, and the expected benefits, including greater talent retention, strengthened organizational commitment, and the strategic optimization of human resource management.

Keywords: artificial intelligence, career development, human resource management systems, machine learning, natural language processing, recommender systems

Índice General

Resumen.....	2
Abstract.....	3
Estructura General del Trabajo Final	12
Capítulos	12
Anexos	12
Acrónimos	12
Referencias.....	12
En la sección de referencias encontraremos toda la bibliografía consultada y citada que forma parte de este trabajo	13
Capítulo 1 – Introducción	14
1.1 Descripción Del Problema.....	14
1.2 Justificación De La Propuesta	15
1.3 Marco Institucional.....	16
1.4 Objetivos Del Trabajo General.....	16
<i>1.4.1 Objetivo General</i>	16
<i>1.4.2 Objetivos Específicos</i>	16
1.5 Contribuciones Principales	17
Capítulo 2 – Estado del arte.....	18
2.1 Introducción.....	18

2.2 Analítica de talento: el caso Optigrow.....	19
2.3 Asistentes cognitivos para desarrollo de carrera	20
2.4 Talent marketplaces corporativos	21
2.5 Modelos de recomendación aplicados al desarrollo de carrera	24
2.6 Discusión	28
Capítulo 3 – Marco Teórico.....	30
3.1 Autogestión y desarrollo de carrera con IA.....	30
3.1.1 Introducción.....	30
3.1.2 Modelos tradicionales	30
3.1.3 Nuevos enfoques de carrera: del modelo organizacional a la autogestión	31
3.1.4 Inteligencia artificial en la personalización del desarrollo profesional.....	33
3.2 Procesamiento de Lenguaje Natural (PLN).....	34
3.2.1 Introducción.....	34
3.2.2 Técnica de preprocesamiento de textos.....	35
3.2.3 Técnicas de representación vectorial	37
3.2.4 Desafíos del PLN y la IA en RR.HH.....	41
3.3 Modelos de recomendación	42
3.3.1 Introducción.....	42
3.3.2 Filtrado colaborativo	43
3.3.3 Sistemas basados en contenido	44

3.3.4 Sistemas basados en conocimientos	46
3.3.5 Sistemas híbridos	48
3.3.6 Evaluación de un sistema de recomendación	49
Capítulo 4 – Propuesta De Intervención	51
4.1 Metodología.....	51
4.2 Descripción.....	51
4.2.1 Capacidades funcionales del sistema	53
4.2.1.1 Recomendación de oportunidades internas.....	53
4.2.1.2 Trayectorias prospectivas de carrera	54
4.2.1.3 Detección de brechas de competencias y capacitaciones	54
4.2.1.4 Explicabilidad de las recomendaciones.....	54
4.2.1.5 Evaluación de resultados	56
4.2.1.6 Preferencias y objetivos del usuario	57
4.2.2 Arquitectura y tecnología	58
4.2.2.1 Arquitectura del sistema basado en microservicios	58
4.2.2.2 Tecnologías empleadas.....	61
4.2.2.3 Interfaz de usuario	62
4.3 Acciones a realizar	64
4.3.1 Análisis y planificación	64
4.3.2 Diseño.....	65

4.3.3 Implementación	65
4.3.4 Pruebas.....	66
4.3.5 Despliegue	67
4.4 Determinación de recursos necesarios.....	68
4.4.1 Recursos	68
4.4.1.1 Recursos humanos	68
4.4.1.2 Recursos tecnológicos	69
4.5 Costos	72
4.5.1 Hardware	72
4.5.2 Licencias de software y servicios.....	73
4.5.3 Capital humano	75
4.5.4 Costo total	77
4.6 Determinación del cronograma.....	77
4.6.1 Justificación	77
4.6.2 Diagrama de Gantt	79
4.7 Factores externos condicionantes	83
4.7.1 Factores tecnológicos	83
4.7.2 Factores legales y éticos	83
4.7.3 Factores organizacionales y culturales	84
4.7.4 Factores sociales y competitivos.....	84

4.8 Factores internos condicionantes	85
Conclusiones	87
Futuras líneas de trabajo.....	89
Acrónimos	90
Anexos	92
Anexo I. Implementación técnica del modelo de recomendación	92
Anexo II. Esquema de base de datos y flujo de información	95
Anexo III. Vistas ampliadas de la interfaz del sistema de recomendación	97
Referencias.....	101

Índice de figuras

Figura 1	<i>Ejemplo simplificado de trayectorias de carrera representadas como event logs</i>	25
Figura 2	<i>Aplicaciones de PLN en recursos humanos: tareas upstream, downstream y sub-representadas</i>	27
Figura 3	<i>Ejemplo de representación Bag of Words (BoW)</i>	38
Figura 4	<i>Ejemplo de representación TF-IDF</i>	39
Figura 5	<i>Arquitectura general de un sistema de recomendación basado en contenido</i>	45
Figura 6	<i>Fuentes de conocimiento en sistemas de recomendación</i>	47
Figura 7	<i>Recomendación explicada</i>	56
Figura 8	<i>Interfaz de evaluación de recomendaciones</i>	57
Figura 9	<i>Arquitectura del sistema de recomendación inteligente</i>	58
Figura 10	<i>Interfaz de usuario</i>	63
Figura 11	<i>Asistente de carrera conversacional</i>	63
Figura 12	<i>Diagrama de Gannt completo de la propuesta</i>	79
Figura 13	<i>Diagrama de Gannt en la etapa de análisis y planificación</i>	80
Figura 14	<i>Diagrama de Gannt en la etapa de diseño</i>	80
Figura 15	<i>Diagrama de Gannt en la etapa de implementación</i>	81
Figura 16	<i>Diagrama de Gannt en la etapa de pruebas</i>	82
Figura 17	<i>Diagrama de Gannt en la etapa de despliegue</i>	82
Figura 18	<i>Ejemplo de extracción y normalización de habilidades</i>	92

Figura 19	<i>Ejemplo de código para el cálculo de similitud semántica entre perfil y puesto</i>	93
Figura 20	<i>Ejemplo de código para la generación del puntaje híbrido y la explicación de recomendaciones</i>	94
Figura 21	<i>Ejemplo de código para las sugerencias de capacitaciones a partir de brechas de habilidades.....</i>	94
Figura 22	<i>Salida de ejecución del modelo de recomendación</i>	95
Figura 23	<i>Esquema lógico de la base de datos del sistema de recomendación</i>	96
Figura 24	<i>Flujo de información entre los módulos del sistema</i>	97
Figura 25	<i>Vista principal del panel de recomendaciones</i>	98
Figura 26	<i>Vista ampliada de trayectoria y desarrollo profesional.....</i>	99
Figura 27	<i>Asistente conversacional integrado al sistema</i>	100

Índice de tablas

Tabla 1	<i>Comparación del rendimiento de embeddings contextuales.....</i>	40
Tabla 2	<i>Estimación de costos de hardware</i>	73
Tabla 3	<i>Estimación de costos de licencias y servicio</i>	74
Tabla 4	<i>Estimación de costos de capital humano</i>	76
Tabla 5	<i>Costos total de la propuesta.....</i>	77

Estructura General del Trabajo Final

Capítulos

El capítulo 1 abordará la introducción del trabajo final, donde se describirá la problemática actual relacionada con la falta de visibilidad de trayectorias de carrera y oportunidades internas en grandes organizaciones. Se presentará brevemente la propuesta de intervención, su justificación, el marco institucional al cual se dirige y los objetivos generales y específicos. Además, se incluirán las principales contribuciones que se esperan lograr con esta propuesta.

El capítulo 2 estará destinado al desarrollo del estado del arte. Se realizará una revisión de antecedentes, incluyendo investigaciones académicas y experiencias organizacionales relevantes, con el fin de contextualizar la propuesta en relación con soluciones existentes y tendencias recientes en el área.

El capítulo 3 se enfocará en el marco teórico, donde se presentarán los conceptos clave que sustentan la propuesta: desarrollo de carrera, autogestión, inteligencia artificial, procesamiento de lenguaje natural y sistemas de recomendación. La integración de estas nociones permitirá establecer la base conceptual del trabajo.

El capítulo 4 estará dedicado a la propuesta de intervención. Se detallará el diseño del sistema, describiendo sus módulos principales, las técnicas empleadas y los flujos de información que los articulan. También se propondrá un plan de implementación, incluyendo un análisis de factibilidad, impacto organizacional y cultural, y una estimación de los costos asociados a la solución.

Anexos

En este apartado se incorporará material complementario que contribuye a una mejor comprensión de la propuesta de intervención, ofreciendo detalles técnicos, ilustraciones o desarrollos que amplían la información presentada en el cuerpo principal del trabajo.

Acrónimos

Esta sección reúne todas las siglas empleadas a lo largo del documento. Cada una se presenta acompañada por su denominación completa

Referencias

En la sección de referencias encontraremos toda la bibliografía consultada y citada que forma parte de este trabajo

Capítulo 1 – Introducción

1.1 Descripción Del Problema

En las grandes organizaciones, los colaboradores suelen enfrentar una baja visibilidad de las oportunidades internas de desarrollo profesional alineadas con sus intereses, competencias y aspiraciones. La evidencia muestra que el 73 % de los empleados desea conocer sus opciones de crecimiento dentro de la empresa y que quienes no tienen visibilidad son un 61 % más propensos a planear su renuncia (Cornerstone & Lighthouse Research, 2023, p. 18).

A su vez, los equipos de Recursos Humanos implementan prácticas como evaluaciones de desempeño, planes de carrera o entrevistas periódicas. Sin embargo, estas herramientas no siempre logran abordar de forma integral y personalizada las trayectorias profesionales en contextos complejos. Tecnologías habituales como los sistemas de gestión del aprendizaje (*Learning Management Systems* [LMS]), los tableros de empleo internos o las evaluaciones aisladas de habilidades no fueron diseñadas para vincular intereses, competencias y vacantes. En cambio, los *opportunity marketplaces*, plataformas que conectan empleados con proyectos, vacantes internas y oportunidades de aprendizaje, y los sistemas de *career pathing*, herramientas que permiten visualizar rutas de evolución profesional han demostrado ser más efectivos para promover la movilidad interna y la satisfacción del empleado (Cornerstone & Lighthouse Research, 2023, p. 10).

Asimismo, ciertas políticas organizacionales actúan como barreras a la movilidad interna. El informe de Cornerstone y Lighthouse Research (2023) indica que más de la mitad de los empleadores exige la aprobación del jefe para postularse a otras vacantes, lo que fomenta *el talent hoarding*, la retención excesiva de empleados por parte de los supervisores y reduce significativamente las oportunidades de desarrollo (p. 9). El mismo informe documenta el caso de un sistema de salud donde los empleados se postularon en la página externa de la empresa utilizando variaciones de su nombre para evitar la aprobación del gerente, lo que evidencia cómo estas restricciones generan desconfianza y prácticas informales (p. 9).

Como consecuencia, se desaprovecha el potencial interno, se obstaculiza la movilidad y aumenta la rotación no deseada, con la consiguiente pérdida de capacidades críticas y conocimiento institucional. La evidencia del Workplace Learning Report 2025 muestra que solo el 36 % de las organizaciones se ubican en la categoría de “*career development champions*”, es

decir, con programas maduros de desarrollo de carrera. Estas organizaciones superan al resto en varios indicadores: reportan mayor confianza para atraer y retener talento, una perspectiva más favorable sobre la rentabilidad y son un 42 % más proclives a liderar la adopción de IA generativa (LinkedIn, 2025).

Este escenario exige repensar el acompañamiento del desarrollo profesional mediante soluciones que permitan visualizar trayectorias posibles, cerrar brechas de habilidades y fortalecer la gestión estratégica del talento. Los marcos contemporáneos proponen avanzar con transparencia en roles y competencias, estructuras de carrera dinámicas, tecnología que centralice datos de habilidades y oportunidades, y la formación de los managers como *career coaches*, capaces de acompañar la autogestión del crecimiento profesional (Quantum Workplace, 2025).

1.2 Justificación De La Propuesta

La propuesta de intervención parte de la necesidad de mejorar los procesos de desarrollo de carrera y movilidad interna dentro de grandes organizaciones, desde la perspectiva del empleado. En muchas empresas, los colaboradores enfrentan dificultades para visualizar oportunidades de crecimiento acordes a sus intereses, competencias y trayectorias, y quienes no tienen visibilidad sobre estas oportunidades son 61% más propensos a planear su renuncia (Cornerstone & Lighthouse Research, 2023, p. 18). Esta situación limita su desarrollo profesional, afecta la motivación y dificulta la retención del talento.

Actualmente, las herramientas disponibles en Recursos Humanos no siempre resultan suficientes para brindar un acompañamiento personalizado y continuo en los procesos de movilidad interna. En este contexto, se propone el diseño de un sistema de recomendación inteligente que permita a los empleados conocer en todo momento qué oportunidades laborales internas podrían ser adecuadas para ellos, qué capacitaciones podrían acercarlos a sus metas y qué trayectorias de carrera están alineadas a su perfil. Este sistema, basado en inteligencia artificial, combinará técnicas de Procesamiento de Lenguaje Natural para interpretar datos textuales (como currículums y descripciones de puestos) con un módulo de recomendación que sugerirá oportunidades y trayectorias personalizadas a partir de evaluaciones de desempeño y preferencias profesionales.

La solución busca empoderar al empleado en la gestión activa de su desarrollo dentro de la organización, fomentando una movilidad interna más equitativa, transparente y proactiva. Al

mismo tiempo, aporta a la organización una estrategia sólida para optimizar la asignación de talento, mejorar la planificación de carrera y fortalecer el vínculo entre los objetivos organizacionales y las aspiraciones individuales.

1.3 Marco Institucional

La presente propuesta se orienta a empresas de gran escala pertenecientes a sectores como tecnología, servicios financieros, telecomunicaciones o energía, donde el conocimiento y las competencias del personal constituyen el principal activo de la organización. Estas compañías suelen contar con estructuras complejas, alta diversidad de perfiles profesionales y múltiples unidades de negocio, lo que dificulta la visibilidad de oportunidades internas y la gestión integrada del talento.

El sistema propuesto busca integrarse al ecosistema digital de recursos humanos de este tipo de organizaciones incluyendo plataformas de gestión del desempeño, aprendizaje y movilidad interna con el fin de brindar recomendaciones personalizadas que fortalezcan la autogestión del desarrollo profesional y la retención del talento.

Este trabajo no aborda el desarrollo de un software operativo, sino el diseño técnico de un sistema de recomendación aplicable a entornos corporativos reales. La propuesta está dirigida a organizaciones que ya cuentan con una infraestructura tecnológica consolidada y buscan evolucionar hacia modelos de gestión del talento más predictivos, personalizados y transparentes, en consonancia con las tendencias actuales de digitalización y analítica de personas.

1.4 Objetivos Del Trabajo General

1.4.1 Objetivo General

Diseñar un sistema de recomendación, basado en inteligencia artificial y técnicas procesamiento de lenguaje natural, que facilite a los empleados la gestión autónoma de su desarrollo profesional mediante sugerencias personalizadas de trayectorias de carrera, oportunidades internas y acciones de capacitación.

1.4.2 Objetivos Específicos

- Identificar los obstáculos que dificultan la movilidad interna y el desarrollo profesional en grandes organizaciones.

-
- Analizar técnicas de procesamiento de lenguaje natural aplicables al análisis de perfiles y descripciones de puestos.
 - Diseñar un sistema de recomendación semántica y prospectiva que vincule perfiles, puestos y trayectorias profesionales.

1.5 Contribuciones Principales

Esta propuesta brindará a las organizaciones un sistema de recomendación inteligente capaz de analizar información clave sobre puestos, currículums, evaluaciones y preferencias profesionales, transformándola mediante técnicas de procesamiento de lenguaje natural en insumos útiles para la toma de decisiones. El módulo de recomendación semántica y prospectiva permitirá identificar oportunidades internas, señalar brechas de habilidades y sugerir trayectorias de desarrollo junto con capacitaciones alineadas a cada perfil. Se espera que la implementación de este sistema tenga un impacto positivo en la visibilidad de los caminos de carrera, la autonomía del empleado en la gestión de su desarrollo profesional y la eficiencia de los procesos de movilidad interna, contribuyendo a una gestión del talento más equitativa y sostenible.

Capítulo 2 – Estado del arte

2.1 Introducción

En un contexto de transformación digital, las organizaciones enfrentan el desafío de gestionar carreras más dinámicas, diversas y personalizadas. Este fenómeno se observa tanto en mercados globales como en América Latina, donde la adopción de tecnologías basadas en inteligencia artificial está redefiniendo la manera en que las empresas desarrollan, retienen y movilizan su talento interno.

En la última década, la gestión del talento dentro de las organizaciones pasó de enfoques descriptivos de *workforce analytics* a soluciones impulsadas por inteligencia artificial que recomiendan oportunidades internas, formación y trayectorias de desarrollo. Este cambio en la gestión del talento ha sido ampliamente documentado por Cornerstone y Lighthouse Research (2023, p. 4), quienes destacan la transición hacia modelos más predictivos y personalizados de gestión de carrera. Se explica, en gran medida, por tres elementos: la disponibilidad de datos cada vez más ricos sobre las carreras (por ejemplo, historiales de puestos y desempeño); el avance de técnicas de aprendizaje automático capaces de modelar preferencias y transiciones laborales; y el progreso del procesamiento de lenguaje natural (PLN) para aprovechar grandes volúmenes de texto no estructurado, como evaluaciones, *feedback* o descripciones de puesto (Tambe et al., 2019, p. 18). Estos elementos abren la posibilidad de sistemas que no solo “hacen *matching*”, sino que también proyectan pasos de carrera factibles y personalizados.

Dentro de esta evolución pueden distinguirse tres hitos que sirven de hilo conductor al presente capítulo. Primero, soluciones pioneras basadas en perfilado estadístico demostraron el valor económico de la movilidad interna, aunque con adopción limitada y sin modelar trayectorias longitudinales (Wei et al., 2015, pp. 539–541). Segundo, los asistentes cognitivos corporativos y los *talent marketplaces* escalaron el descubrimiento de oportunidades como roles, gigs y mentorías y mejoraron la experiencia del empleado, como documentan Bersin y Enderes (2022, pp. 2–6). Sin embargo, su funcionamiento dependió en gran medida de datos autodeclarados y taxonomías relativamente rígidas, una limitación también señalada por el Aspen Institute (2023, pp. 5–6). Tercero, los modelos de recomendación aplicados al internal placement empezaron a incorporar la lógica de eventos a lo largo del tiempo, representando la carrera como un event log y mejorando la precisión frente a enfoques basados solo en historial inmediato (De Vos et al., 2022, pp. 1–2, 6–7).

A la par, el PLN amplió el alcance de estas soluciones al estructurar información textual (extracción de habilidades, normalización de cargos) y habilitar aplicaciones *downstream* como recomendación de empleos o asistentes conversacionales; sin embargo, la literatura sigue concentrándose en *pre-hiring*, con menos evidencia en *post-hiring* y movilidad interna (Otani et al., 2024, p. 2). Todo ello convive con desafíos organizacionales y éticos: la calidad y disponibilidad de los datos, la presencia de sesgos y la aceptación por parte de los empleados, que obligan a combinar los avances técnicos con marcos de transparencia y explicabilidad (Tambe et al., 2019, pp. 20–24).

Sobre este trasfondo, el capítulo revisa en profundidad cuatro líneas de evolución: (2.2) un antecedente pionero en analítica de talento (Optigrow); (2.3) la irrupción de asistentes cognitivos orientados al desarrollo de carrera; (2.4) la consolidación de *talent marketplaces* en grandes organizaciones; y (2.5) los enfoques más recientes de recomendación basados en datos longitudinales y en aportes del PLN.

2.2 Analítica de talento: el caso Optigrow

Wei et al. (2015) desarrollaron Optigrow: *People Analytics for Job Transfers*, un sistema implementado por la división de servicios de IBM con el objetivo de facilitar la reasignación interna hacia áreas de crecimiento estratégico como *cloud*, *analytics* o seguridad. El modelo se basaba en un algoritmo de perfilado estadístico que integraba datos estructurados, como taxonomías de roles, evaluaciones de *expertise* y registros de proyectos, y también datos no estructurados, como currículums, con el fin de generar un puntaje de adecuación y priorizar candidatos internos. Su principal aporte consistió en identificar no solo a empleados que ya poseían las competencias requeridas, sino también a aquellos con habilidades de base que, con un breve entrenamiento, podían adaptarse a nuevos roles.

En los resultados de su investigación, Wei et al. (2015) explican que el sistema mostró beneficios económicos relevantes: IBM estimó que cada transferencia interna generaba un ahorro superior a 50 000 dólares al evitar costos de despido, contratación externa y pérdida de productividad asociada a la adaptación de nuevos empleados (p. 539). Sin embargo, pese a la solidez técnica del modelo, su adopción organizacional fue limitada. Los autores señalan que las resistencias de los gerentes a liberar talento clave, la falta de procedimientos de reemplazo y la preferencia por contrataciones externas redujeron el impacto del sistema en la práctica (p. 541).

Desde una perspectiva crítica, el mismo estudio reconoce que el algoritmo no incorporaba la similitud entre trayectorias de habilidades ni la facilidad relativa para adquirir nuevas competencias, lo que limitaba su capacidad predictiva (p. 541). Así, Optigrow se consolidó como un antecedente pionero en analítica de talento, aunque su enfoque fue fundamentalmente estadístico, más cercano al *workforce analytics* que a la inteligencia artificial en sentido estricto. Estas limitaciones explican por qué el modelo no integraba información longitudinal ni generaba proyecciones dinámicas de desarrollo. En contraste, la presente propuesta se plantea como una evolución natural de estos sistemas, al incorporar técnicas de procesamiento de lenguaje natural y modelos de recomendación basados en inteligencia artificial, capaces de procesar datos no estructurados, como evaluaciones y feedback en texto libre, integrar trayectorias completas y ofrecer recomendaciones personalizadas con un enfoque prospectivo.

2.3 Asistentes cognitivos para desarrollo de carrera

IBM desarrolló, en el marco de su estrategia de transformación digital, el *Watson Career Coach*, conocido internamente como *Myca*, que constituye un antecedente relevante en la aplicación de asistentes cognitivos al desarrollo de carrera. Este asistente conversacional permite a los empleados realizar consultas sobre sus trayectorias profesionales, recibir recomendaciones de vacantes internas y explorar posibles caminos de crecimiento dentro de la organización. El sistema se apoya en capacidades de procesamiento de lenguaje natural a través de *Watson Conversation* y utiliza la base de datos de *IBM Talent Frameworks* como insumo principal para mapear perfiles y generar sugerencias de carrera (IBM, 2021). Una de sus funcionalidades más destacadas era el módulo *Career Navigator*, diseñado para proponer posibles progresiones de carrera basadas en patrones observados en otros empleados de la compañía. Sin embargo, estas proyecciones se apoyaban en la taxonomía estática de *IBM Talent Frameworks* y en datos agregados, sin incorporar los historiales longitudinales de cada trabajador, lo que restringía la personalización de las recomendaciones. En la práctica, *Myca* funcionaba más como un motor de matching con interfaz conversacional que como un verdadero sistema predictivo de trayectorias (IBM, 2021). Una limitación similar ya se había señalado en Optigrow (Wei et al., 2015).

En línea con esta evolución, Mercy (2025, pp. 2–4) muestra que los chatbots de RR. HH. impulsados por inteligencia artificial se han consolidado como asistentes virtuales capaces de gestionar múltiples funciones, entre ellas la automatización de procesos de onboarding, el soporte

administrativo a través de helpdesk, la recolección y análisis de feedback de desempeño, la gestión de licencias y ausentismo, y la recomendación de programas de aprendizaje y desarrollo. Estas aplicaciones, sintetizadas en la tabla que presenta la autora, evidencian la creciente versatilidad de los chatbots para atender necesidades recurrentes de los empleados y liberar a los equipos de RR. HH. de tareas operativas. Asimismo, la autora reporta que las organizaciones que incorporan chatbots han observado reducciones cercanas al 40 % en la carga operativa de RR. HH. y mejoras del orden del 30 % en el compromiso de los empleados, asociadas con una mayor accesibilidad a los servicios, disponibilidad de soporte en tiempo real y 24/7, reducción de costos y una experiencia más satisfactoria gracias a respuestas rápidas y personalizadas.

Mercy (2025) señala que estos sistemas enfrentan limitaciones críticas, entre ellas los riesgos vinculados a la privacidad y seguridad de los datos sensibles, la dificultad de los chatbots para gestionar consultas complejas que requieren juicio humano o empatía, y la resistencia de ciertos empleados a interactuar con herramientas automatizadas en lugar de con personal de RR. HH. (p. 4). Además, la autora indica que, si bien el futuro de los asistentes cognitivos estará marcado por avances en procesamiento de lenguaje natural (PLN) y *machine learning*, con el potencial de habilitar interacciones más personalizadas y capacidades predictivas (p. 5), en la actualidad su uso sigue orientado principalmente a tareas administrativas y de soporte.

Por lo tanto, los asistentes cognitivos representan un paso intermedio en la evolución de la movilidad interna: introdujeron la integración de interfaces conversacionales basadas en PLN y validaron su utilidad para orientar a los empleados en procesos de soporte y experiencia laboral, pero mantienen limitaciones al centrarse en funciones operativas y estructuras de *matching* rígido. Este escenario abre la necesidad de avanzar hacia soluciones más robustas, como la presente propuesta, que combina PLN avanzado con modelos de recomendación prospectiva para ofrecer trayectorias de carrera personalizadas, dinámicas y sustentadas en datos longitudinales, superando las restricciones que caracterizan a los chatbots actuales.

2.4 Talent marketplaces corporativos

A diferencia de los asistentes cognitivos individuales, que se orientaban principalmente a la interacción conversacional con los empleados; en los últimos años, se consolidó un nuevo enfoque basado en los *talent marketplaces* corporativos. Estas plataformas digitales escalan la movilidad interna a nivel organizacional al conectar de manera simultánea vacantes, proyectos y

oportunidades de mentoría con los perfiles de los empleados. Se trata de soluciones que, al mismo tiempo que generan beneficios en términos de eficiencia y retención, también plantean desafíos relacionados con la calidad de los datos y la cultura organizacional.

En términos de adopción, estudios recientes muestran que más del 70 % de las empresas han incrementado su inversión en movilidad interna y un 47 % elevó la proporción de contrataciones internas, aunque solo una de cada cuatro declara tener una estrategia madura y 77 % reconoce haber perdido talento por falta de oportunidades de desarrollo. Las iniciativas más efectivas se asocian a enfoques basados en habilidades (*skills-based*) y a la personalización de la experiencia. Asimismo, las organizaciones de mejor desempeño reportan mejoras del 77 % en retención, 65 % en experiencia del empleado y 60 % en diversidad, equidad e inclusión (DEI) cuando aplican programas de movilidad interna apoyados en inteligencia artificial y métricas de desempeño integradas (Laurano, 2023, pp. 2–3, 14–15).

Un caso relevante es el de Schneider Electric, que en 2020 lanzó su plataforma interna *Open Talent Market (OTM)* en alianza con la empresa Gloat. El objetivo era enfrentar uno de los principales problemas de la compañía: casi la mitad de los empleados que abandonaban la organización lo hacían por percibir falta de oportunidades de crecimiento interno (Bersin & Enderes, 2022, p. 2). El *OTM* se diseñó como un ecosistema digital que integraba tres dimensiones: posiciones permanentes, proyectos temporales (*gigs*) y oportunidades de mentoría. Para los empleados, la plataforma permitía completar un perfil y recibir recomendaciones de roles, proyectos y mentores alineados con sus intereses y competencias, mientras que para los managers ofrecía la posibilidad de publicar vacantes y recibir sugerencias de candidatos internos basadas en algoritmos de IA (Bersin & Enderes, 2022, p. 3).

La implementación de OTM fue rápida y global: en apenas dos semanas, la compañía desplegó la plataforma a sus 135.000 empleados. En menos de dos meses, un 60 % ya se había registrado, y se habían desbloqueado más de 127.000 horas de talento previamente desaprovechado dentro de la organización (Bersin & Enderes, 2022, p. 4). Estos resultados inmediatos mostraron el potencial del marketplace para mejorar la asignación de recursos y el compromiso de los empleados, quienes pasaron a tener mayor visibilidad y control sobre su desarrollo profesional. Sin embargo, la experiencia también evidenció limitaciones: el sistema dependía de perfiles autodeclarados y de estructuras formales de vacantes y proyectos, lo que podía favorecer únicamente a los empleados más visibles o proactivos en la actualización de sus datos.

Además, como señalaron los propios responsables de la iniciativa, la implementación no era solo tecnológica, sino que requería un cambio cultural profundo hacia la transparencia y la movilidad interna (Bersin & Enderes, 2022, pp. 5–6).

En la misma línea, Williamson y Carroll (2023) documentaron que lanzar un talent marketplace como el piloto de *Booz Allen* en Estados Unidos implica superar barreras conductuales y de adopción vinculadas a la gestión del cambio y a la resistencia cultural. Los autores concluyen que la tecnología solo genera impacto cuando se acompaña de procesos de liderazgo y comunicación sostenidos.

Otro ejemplo relevante es el de PepsiCo, que con más de 300.000 empleados en todo el mundo ha desarrollado una estrategia integral de *upskilling* para preparar a su fuerza laboral frente a los desafíos de la digitalización. Entre sus programas se destacan *Digital Academy*, que ofrece más de 11.000 recursos de aprendizaje digital y cientos de certificaciones en áreas de alta demanda, y *myeducation*, un beneficio que cubre el 100 % del costo de títulos, certificados y credenciales en campos estratégicos como análisis de datos, ciberseguridad y *supply chain* (Aspen Institute, 2023, pp. 1–3).

El enfoque de PepsiCo se orienta a transformar la experiencia del empleado en el marco de su desarrollo profesional. Con este objetivo, la compañía implementó *myDevelopment*, un *talent marketplace* interno que combina formación académica con proyectos de corta duración (*stretch assignments*), lo que permite a los empleados adquirir nuevas competencias al tiempo que aplican sus habilidades en diferentes áreas de la organización. Los resultados han sido significativos: los participantes de *myeducation* presentan un 18 % menos de rotación y son 1,7 veces más propensos a experimentar un cambio de rol en comparación con quienes no participan (Aspen Institute, 2023, pp. 5–6).

Un componente clave de la estrategia es la integración con *Draup*, una plataforma de analítica de talento basada en IA que organiza competencias en clústeres dinámicos y permite identificar *root skills* fundamentales, como alfabetización digital o pensamiento crítico. Además, aplica un modelo de madurez de habilidades que orienta la secuencia óptima para desarrollar nuevas capacidades (Team Draup, 2025, p. 2). De esta forma, PepsiCo ofrece a cada empleado información sobre cómo sus competencias actuales se alinean con roles de mayor proyección, qué habilidades debe fortalecer y qué itinerarios de *upskilling* o *reskilling* son más factibles. Ejemplos concretos muestran el impacto: un operario de planta logró reconvertirse en analista de datos tras

completar un certificado en *myeducation*, mientras que otro trabajador de línea accedió a un puesto como mecánico certificado, pasando de una tarea operativa a una función crítica de mantenimiento (Aspen Institute, 2023, p. 6).

La estrategia de PepsiCo representa un avance adicional respecto de Schneider Electric, al integrar el marketplace con programas de formación y herramientas de analítica avanzada de talento. No obstante, mantiene limitaciones importantes: su funcionamiento descansa principalmente en datos declarativos de los empleados y en estructuras formales de vacantes, lo que restringe la capacidad de capturar trayectorias más completas (Aspen Institute, 2023). Además, como señalan Bersin y Enderes (2022) este tipo de plataformas tienden a reproducir la lógica de matching estático y requieren de un cambio cultural profundo para consolidar la movilidad interna. A ello se suma que, según el equipo de Draup (2025), aún no se explota plenamente el potencial de la inteligencia artificial para organizar y analizar información no estructurada en clústeres dinámicos de habilidades, ni para proyectar trayectorias longitudinales con un enfoque predictivo.


Los casos de Schneider Electric y PepsiCo evidencian que los *talent marketplaces* corporativos constituyen una innovación organizacional clave para la movilidad interna. Han demostrado beneficios tangibles en retención, compromiso y asignación de talento, validando la viabilidad de soluciones basadas en IA a gran escala. No obstante, comparten un conjunto de limitaciones estructurales: dependen de perfiles autodeclarados, operan sobre taxonomías rígidas y carecen de componentes predictivos. Estas restricciones refuerzan la necesidad de avanzar hacia sistemas más sofisticados, como el que se plantea en esta propuesta, que combine PLN avanzado, datos longitudinales y modelos de recomendación prospectiva para orientar el desarrollo de carrera de manera integral y personalizada.

2.5 Modelos de recomendación aplicados al desarrollo de carrera

Un aporte relevante en esta línea es el trabajo de De Vos et al. (2022), quienes desarrollaron un sistema de recomendación para *internal placement* en organizaciones, orientado a guiar los movimientos de los empleados dentro de sus trayectorias laborales. Los autores parten de la premisa de que los datos de RR. HH. poseen una estructura longitudinal, por lo cual la carrera de cada trabajador puede representarse como un *event log*, es decir, una secuencia de actividades registradas a lo largo del tiempo (p. 1). Esta lógica se ilustra en la figura 1, que muestra un ejemplo simplificado de tres carreras modeladas desde una perspectiva de procesos (p. 2).

Figura 1

Ejemplo simplificado de trayectorias de carrera representadas como event logs



Nota. Obtenido de *Internal placement: Job recommender systems with social regularization* (p. 2), por S. De Vos et al., 2022.

De Vos et al. (2022) proponen un enfoque de *collaborative filtering* (CF) que predice la adecuación entre un empleado y un puesto en función de las similitudes de desempeño con otros trabajadores. Para superar la limitación del CF clásico, que aprende únicamente de los puestos previamente ocupados, los autores introducen la técnica de *social regularization* (SR), que agrega atributos estructurados como el campo de estudio, nivel educativo, tipo de contrato o localización, con el fin de que empleados con características similares tengan representaciones más próximas en el espacio latente del modelo (p. 4). El modelo fue validado con tres conjuntos de datos reales correspondientes a los sectores de I+D, TI y servicios de RR. HH., cada uno representado como *event log* con miles de trayectorias laborales registradas entre 2009 y 2022 (p. 5). La evaluación se realizó mediante métricas como MAE, RMSE y correlaciones de *ranking*, y los resultados evidenciaron que el modelo CF+SR mejora de manera sistemática la precisión de las recomendaciones frente al CF estándar y a predicciones aleatorias (pp. 6–7). Este trabajo representa un avance significativo al introducir la longitudinalidad en los sistemas de recomendación para movilidad interna. Sin embargo, mantiene limitaciones relevantes: se apoya exclusivamente en puntajes de desempeño y atributos estructurados, sin integrar información no estructurada como *feedback* textual o evaluaciones narrativas. Asimismo, sus predicciones se enfocan en el “siguiente paso” inmediato en la carrera, sin generar trayectorias prospectivas completas (p. 7).

En respuesta a estas limitaciones, Madhumithaa et al. (2025) destacan el papel de la inteligencia artificial en la personalización del desarrollo profesional mediante el uso de aprendizaje automático y analítica predictiva. Los autores explican que los sistemas inteligentes pueden analizar competencias, detectar brechas de habilidades y recomendar trayectorias formativas dinámicas y alineadas con los objetivos organizacionales (p. 135). Además, subrayan que la incorporación de chatbots y mentores virtuales mejora el feedback en tiempo real y promueve la autonomía del empleado en su proceso de crecimiento (p. 136). No obstante, advierten sobre desafíos éticos vinculados a la privacidad de los datos y al sesgo algorítmico, que requieren políticas de gobernanza y transparencia para asegurar un uso responsable (p. 137). De este modo, su estudio amplía la mirada técnica de De Vos et al. (2022) al situar la IA como un puente entre la recomendación algorítmica y un desarrollo de carrera más humano y continuo. En este mismo sentido, la propuesta del presente trabajo se alinea con esta visión al incorporar IA para acompañar el crecimiento del empleado de forma adaptativa, aunque con un énfasis mayor en la movilidad interna y la personalización basada en similitud semántica. En esta línea, Guan et al. (2024) presentan JobFormer, un modelo de recomendación skill-aware que aborda dos problemas frecuentes: la pobreza semántica de ciertas job descriptions (JDs) y la brecha heterogénea entre JDs en texto breve y perfiles de usuario resumidos como distribuciones de habilidades. El enfoque combina un transformer con atención local–global para enriquecer la representación de cada JD incorporando vecinos semánticos, y una estrategia de dos etapas: primero una etapa de recuperación (recall) guiada por la distribución de habilidades del usuario para formar el conjunto candidato y, luego, una etapa de ordenamiento (ranking) que predice la Click-Through Rate (CTR) mediante atención cruzada entre JD y perfil. El modelo añade, además, regularizaciones para correlación de habilidades y consistencia relacional entre JDs vecinos, lo que estabiliza el aprendizaje y mejora la recuperación. En evaluaciones con datasets reales de gran escala, reporta mejoras consistentes frente a baselines en Recall@K y NDCG@K, demostrando que representaciones semánticas más ricas y un enfoque en dos etapas incrementan la calidad de las recomendaciones. Este aporte resulta especialmente relevante para la propuesta de este trabajo, ya que valida la eficacia de arquitecturas basadas en atención y representaciones vectoriales, principios que también sustentan el módulo de recomendación semántica aquí desarrollado.

En paralelo a estos avances, Otani et al. (2024) ofrecen una revisión sistemática sobre las aplicaciones del procesamiento de lenguaje natural (PLN) en recursos humanos. Su análisis

organiza las contribuciones existentes en tareas *upstream*, orientadas a enriquecer los datos textuales mediante extracción de habilidades, normalización de títulos de puesto y clasificación de documentos, y en tareas *downstream*, que abarcan aplicaciones como la recomendación de empleos, la generación automática de descripciones de puestos y el diseño de sistemas conversacionales para entrevistas o asistencia virtual (pp. 3–4). Asimismo, identifican un conjunto de tareas sub-representadas, entre ellas la evaluación del desempeño y el análisis de satisfacción de empleados, que podrían beneficiarse de los avances recientes en PLN (p. 2).

Los autores destacan que gran parte de la literatura se concentra en escenarios de pre-hiring, como el *matching* entre currículums y ofertas laborales, mientras que las aplicaciones de PLN al post-hiring incluyendo la movilidad interna y el desarrollo de carrera, se encuentran considerablemente menos exploradas (p. 2). Entre los desafíos que explican esta brecha se encuentran la heterogeneidad de los datos de RR. HH., la dificultad de procesar estilos textuales diversos (desde currículums esquemáticos hasta evaluaciones narrativas) y la escasez de corpus públicos que permitan la validación de modelos en contextos organizacionales reales (pp. 1–2).

Esta clasificación se sintetiza en la figura 2, que organiza de manera esquemática los principales enfoques y vacíos actuales en la intersección entre PLN y gestión de personas.

Figura 2

Aplicaciones de PLN en recursos humanos: tareas upstream, downstream y sub-representadas



Nota. Obtenido de *Natural language processing for human resources: A survey* (p. 2), por Otani et al., 2024.

El trabajo de Otani et al. (2024) aporta un marco conceptual que refuerza la importancia del PLN para transformar grandes volúmenes de texto no estructurado en representaciones comparables y útiles para la toma de decisiones. Al mismo tiempo, los autores subrayan la necesidad de avanzar hacia enfoques holísticos que integren distintos niveles de análisis y permitan mejorar la capacidad predictiva de estos sistemas en contextos de RR. HH. (p. 6).

Por otra parte, Tambe et al. (2019) ofrecen un análisis crítico sobre la aplicación de inteligencia artificial en la gestión de recursos humanos. Los autores identifican, en primer lugar, la complejidad de los fenómenos de RR. HH., dado que resulta difícil definir y medir con precisión qué constituye un “buen empleado” (p. 18). En segundo lugar, señalan la limitación de los conjuntos de datos, que suelen ser pequeños en comparación con otros ámbitos de negocio, lo que restringe la capacidad predictiva de los modelos (pp. 19–20). También destacan los riesgos éticos y legales, dado que los algoritmos pueden reproducir sesgos históricos y generar impactos adversos en grupos protegidos (pp. 20–21). Por último, advierten sobre las reacciones de los empleados frente a decisiones algorítmicas, que pueden percibirse como menos justas o difíciles de aceptar en comparación con decisiones humanas (pp. 23–24). A partir de estos desafíos, los autores sostienen que la adopción exitosa de estas tecnologías requiere no solo avances técnicos, sino también marcos organizacionales y éticos que aseguren transparencia, explicabilidad y confianza (pp. 23–24).

2.6 Discusión

La revisión realizada muestra una evolución constante en el uso de la tecnología para el desarrollo de carrera: desde modelos estadísticos pioneros como *Optigrow*, pasando por asistentes cognitivos y *talent marketplaces*, hasta llegar a propuestas más recientes basadas en sistemas de recomendación y procesamiento de lenguaje natural. En conjunto, estos trabajos revelan una tendencia hacia soluciones más inteligentes, capaces de interpretar patrones complejos en los datos laborales y de ofrecer recomendaciones adaptadas al contexto y las necesidades de cada empleado.

Aun así, persisten algunas limitaciones. Por un lado, muchos enfoques dependen principalmente de datos estructurados o autodeclarados y generan recomendaciones estáticas, sin considerar de manera sólida la evolución longitudinal de las trayectorias profesionales (De Vos et al., 2022, p. 7). Por otro, aunque la inteligencia artificial ha impulsado la personalización de

experiencias formativas (Madhumithaa et al., 2025, p. 135) y los modelos basados en atención han mejorado la calidad de las recomendaciones (Guan et al., 2024), su aplicación en el ámbito del *post-hiring*, especialmente para promover la movilidad interna continúa siendo limitada (Otani et al., 2024, p. 2). A esto se suman los desafíos éticos y de transparencia señalados por Tambe et al. (2019, pp. 20–21), que enfatizan la necesidad de equilibrar la eficiencia algorítmica con la equidad y la explicabilidad.

En este escenario, la propuesta desarrollada en los capítulos siguientes se presenta como una respuesta integral a dichas limitaciones. El sistema combina técnicas de procesamiento de lenguaje natural con un modelado longitudinal de trayectorias y un módulo de recomendación semántica y prospectiva. Esta integración permitirá representar la evolución profesional de forma dinámica y contextualizada. De este modo, se espera superar las limitaciones de los modelos basados únicamente en datos estructurados, potenciar la personalización del desarrollo de carrera y contribuir al fortalecimiento de la movilidad interna y la gestión estratégica del talento en organizaciones complejas.

Capítulo 3 – Marco Teórico

3.1 Autogestión y desarrollo de carrera con IA

3.1.1 Introducción

El concepto de carrera profesional ha cambiado notablemente a lo largo del tiempo. En sus orígenes, la carrera profesional se concebía como una secuencia estable y predecible de ascensos dentro de una misma organización, guiada por una estructura jerárquica bien definida (Chiavenato, 2009, p. 418). Bajo esta lógica, el desarrollo profesional dependía de la planificación institucional y del reconocimiento interno, más que de la iniciativa del propio trabajador.

Sin embargo, los cambios económicos, tecnológicos y sociales de las últimas décadas — como la globalización, la digitalización y la transformación del empleo— modificaron profundamente esta dinámica. En la actualidad, se reconoce que la trayectoria laboral ya no constituye un camino lineal, sino un proceso en constante adaptación, donde el individuo asume un rol activo en la gestión de su desarrollo (Greenhaus et al., 2018, pp. 24–26).

En este nuevo escenario, las organizaciones ya no pueden ofrecer un recorrido profesional único ni garantizado. La responsabilidad de construir una carrera sostenible recae, en gran medida, sobre cada persona. De allí surge la necesidad de herramientas que acompañen esta autogestión, facilitando el análisis de habilidades, intereses y oportunidades internas. Este es precisamente el enfoque que retoma el presente trabajo al proponer un sistema inteligente de recomendación de trayectorias de carrera, orientado a fortalecer la autonomía del trabajador sin perder de vista los objetivos organizacionales.

3.1.2 Modelos tradicionales

En los modelos tradicionales, la carrera se concebía como una secuencia ascendente de puestos dentro de una misma organización, en la que el progreso profesional dependía de la antigüedad, la jerarquía y la estabilidad laboral (Chiavenato, 2009, p. 418). Este enfoque suponía que las organizaciones eran responsables de planificar y administrar las trayectorias de sus empleados, ofreciendo seguridad y reconocimiento a cambio de lealtad y rendimiento. El desarrollo profesional era un proceso estructurado y previsible, en el que el éxito se medía por el ascenso vertical y la permanencia prolongada en la empresa (Hall, 2002, pp. 20, 26).

Hall (2002) explica que este modelo estaba sostenido por un contrato psicológico de largo plazo, que implicaba un intercambio simbólico: la organización ofrecía estabilidad y oportunidades de promoción, mientras que el trabajador aportaba compromiso, conformidad y permanencia. No obstante, ese contrato comenzó a erosionarse con la globalización, la desregulación y el avance tecnológico, que generaron entornos más competitivos y cambiantes. En este nuevo escenario, las empresas comenzaron a reorganizarse mediante fusiones, adquisiciones y reducciones de personal, modificando las reglas del desarrollo de carrera (Hall, 2002, pp. 20–21). El recorrido profesional que antes se extendía por décadas dentro de una misma organización pasó a fragmentarse en múltiples experiencias laborales más breves, y la relación empleado – empresa adoptó un carácter transaccional y renovable según las necesidades del momento.

Como señala Chiavenato (2009, p. 419), incluso cuando las organizaciones intentaron adaptar estos esquemas e incorporar las aspiraciones individuales, los mecanismos tradicionales seguían limitando la participación activa del empleado en la toma de decisiones sobre su trayectoria. Si bien este modelo resultaba eficaz en contextos estables, comenzó a perder vigencia ante la creciente volatilidad y complejidad del mercado laboral contemporáneo. Hall (2002) advierte que, en este nuevo contexto, la carrera se ha convertido en un fenómeno más interno y subjetivo, en el que los individuos buscan sentido, aprendizaje continuo y equilibrio entre la vida personal y profesional (pp. 21–22).

Estas transformaciones abren paso a enfoques centrados en la autogestión de la carrera, donde cada persona asume la responsabilidad de construir su propio recorrido profesional. Desde esta perspectiva, la tecnología, y en particular la inteligencia artificial, ofrecen oportunidades inéditas para acompañar esa transición, ayudando a los trabajadores a identificar habilidades, comparar trayectorias posibles y tomar decisiones informadas sobre su desarrollo, lo que inspira directamente la propuesta del presente trabajo: un sistema inteligente que promueva una gestión más autónoma, informada y personalizada del crecimiento profesional dentro de las organizaciones.

3.1.3 Nuevos enfoques de carrera: del modelo organizacional a la autogestión

El modelo tradicional ofrecía una visión de carrera estable, con promociones predecibles y un vínculo relacional entre empleado y empleador, basado en la lealtad mutua y la permanencia en

el tiempo (Greenhaus et al., 2018, p. 24). No obstante, este paradigma comenzó a erosionarse a partir de la década de 1980, producto de las reestructuraciones organizacionales, los despidos masivos y la creciente necesidad de flexibilidad por parte de las empresas (p. 25). En este contexto, se debilitó la noción de carrera lineal administrada por la organización, dando paso a modelos que sitúan al individuo como protagonista de su propio desarrollo profesional (p. 26).

Frente a estos cambios, diversos autores reformularon la noción de carrera, enfatizando la importancia de la autogestión y la adaptabilidad. Hall (1976, como se citó en Greenhaus et al., 2018) introduce el concepto de carrera *proteana*, entendida como un proceso autodirigido por la persona y guiado por sus propios valores, en contraposición al control organizacional tradicional. En este modelo, el individuo define su éxito profesional en términos subjetivos, a partir de metas significativas y coherentes con su identidad personal (Greenhaus et al., 2018, pp. 26–27). Este cambio de perspectiva da lugar al concepto de éxito psicológico, entendido como la sensación de logro, aprendizaje y propósito derivada del alineamiento entre valores personales y decisiones laborales.

Además, los autores proponen una mirada integral de la carrera, denominada *whole-life perspective*, que considera el impacto del trabajo en la vida total del individuo, incluyendo sus roles familiares, sociales y personales (Greenhaus et al., 2018, p. 27). De esta manera, el desarrollo de carrera deja de limitarse a la promoción jerárquica para convertirse en un proceso de crecimiento continuo y multidimensional.

Por su parte, el concepto de carrera sin fronteras, desarrollado por Arthur y Rousseau en la década de 1990, describe trayectorias profesionales que trascienden los límites de una única organización. Como señalan Greenhaus et al. (2018, p. 27), este enfoque se centra en la movilidad entre sectores, empleadores y entornos, así como en la construcción de redes profesionales y la acumulación de capital social. Incluso dentro de una misma empresa, los individuos que adoptan esta lógica redefinen sus roles y vínculos más allá de las estructuras formales, articulando sus experiencias laborales con proyectos personales y oportunidades externas.

Si bien los modelos proteano y sin fronteras difieren en su énfasis, ambos comparten una premisa esencial: en un entorno laboral dinámico, incierto y menos estructurado, los trabajadores deben actuar como agentes activos de su desarrollo. Greenhaus et al. (2018, p. 28) destacan que competencias como la autoevaluación, la fijación de metas realistas, la adaptabilidad y la

planificación autodirigida resultan fundamentales para sostener la empleabilidad y el bienestar profesional a largo plazo.

Este recorrido teórico permite comprender por qué se vuelve necesario explorar nuevas herramientas que acompañen este proceso de autogestión. En un escenario caracterizado por la movilidad, la incertidumbre y la diversidad de trayectorias, las tecnologías emergentes en particular, la inteligencia artificial ofrecen la posibilidad de ampliar las capacidades individuales de análisis, aprendizaje y toma de decisiones, sentando las bases para soluciones como la que se propone en este trabajo.

3.1.4 Inteligencia artificial en la personalización del desarrollo profesional

La evolución hacia modelos de carrera más autodirigidos y flexibles exige también nuevas formas de acompañar el desarrollo profesional. Tal como se analizó en las secciones anteriores, las trayectorias laborales actuales ya no responden a estructuras jerárquicas ni a planes de promoción lineales, sino que dependen en gran medida de la capacidad del individuo para gestionar su propio crecimiento y aprendizaje. En este contexto, los enfoques tradicionales de desarrollo, basados en programas estandarizados y uniformes, comienzan a mostrar claras limitaciones.

Diversas investigaciones señalan que los modelos de capacitación homogéneos no logran atender las diferencias individuales en estilos de aprendizaje, motivaciones y trayectorias (Madhumithaa et al., 2025, p. 134). De manera coincidente, Huang et al. (2023) advierten que este tipo de enfoques repercute negativamente en la eficacia de los programas de desarrollo (p. 598) y subrayan la necesidad de diseñar estrategias de crecimiento profesional que reconozcan la singularidad de cada persona (pp. 599–600). En este sentido, distintos autores destacan el potencial de las tecnologías emergentes particularmente la inteligencia artificial (IA) para impulsar una gestión más personalizada del talento. Según Madhumithaa et al. (2025), los enfoques de capacitación basados en módulos uniformes resultan insuficientes frente a la diversidad de aspiraciones y competencias de la fuerza laboral actual. La IA permite superar estas limitaciones mediante la creación de experiencias formativas adaptadas, trayectorias profesionales personalizadas y recomendaciones derivadas de datos de desempeño y preferencias individuales (pp. 134–135).

Por su parte, Huang et al. (2023) sostienen que el concepto de *personalized HRM* representa una evolución dentro de la gestión estratégica de personas. Gracias a los sistemas inteligentes que

analizan grandes volúmenes de información, las organizaciones pueden implementar políticas de formación, compensación y desarrollo que varíen según las características de cada empleado, optimizando tanto la motivación individual como el desempeño colectivo (pp. 599–602).

Además, Tambe et al. (2019) sostienen que el uso de inteligencia artificial en la gestión de personas solo puede ser verdaderamente valioso si se combina la eficiencia de los algoritmos con la transparencia y la participación humana en la toma de decisiones. En otras palabras, la tecnología debe servir para ampliar las capacidades de las personas, no para reemplazarlas. Este enfoque ético resulta esencial para generar confianza y asegurar que las herramientas automatizadas contribuyan al crecimiento profesional y no a la despersonalización del trabajo.

En este marco, la personalización del desarrollo profesional no solo mejora los resultados de la organización, sino que también potencia la autogestión y el sentido de propósito de los trabajadores (Madhumithaa et al., 2025, p. 136). De igual modo, Huang et al. (2023, p. 603) destacan la importancia de mantener un equilibrio entre automatización y supervisión humana para garantizar procesos más justos, transparentes y equitativos. La integración de la inteligencia artificial en la gestión del desarrollo profesional abre un camino concreto para materializar los principios de la carrera proteana y sin fronteras: autonomía, aprendizaje continuo y construcción activa del propio recorrido.

Desde esta perspectiva, el presente trabajo propone el diseño de un sistema inteligente que actúe como asistente estratégico del desarrollo de carrera, ofreciendo recomendaciones basadas en datos, pero siempre orientadas a potenciar la autogestión, la equidad y el desarrollo integral de las personas dentro de las organizaciones.

3.2 Procesamiento de Lenguaje Natural (PLN)

3.2.1 Introducción

El procesamiento de lenguaje natural (PLN) se ha consolidado como una disciplina esencial para aprovechar el creciente volumen de información digital. Tal como señalan Hernández y Gómez (2013, pp. 87–88), buena parte del conocimiento humano se encuentra en colecciones de datos no estructurados como documentos en texto libre o semiestructurados como páginas web con etiquetas, lo que dificulta su aprovechamiento directo sin técnicas especializadas. En este sentido, el PLN permite transformar el lenguaje humano en representaciones formales

manipulables por computadoras, con aplicaciones en la recuperación y extracción de información, la minería de datos, la traducción automática, los sistemas de búsqueda de respuestas, la generación de resúmenes y el análisis de sentimientos.

Hernández y Gómez (2013, p. 88) destacan que estos datos resultan difíciles de aprovechar sin técnicas de procesamiento que los transformen en representaciones claras y sistemáticas. Documentos como currículums, evaluaciones de desempeño o descripciones de puestos constituyen justamente este tipo de información: valiosa, pero poco explotable en su forma original. Mediante PLN, estos textos pueden convertirse en representaciones comparables, habilitando tareas como el emparejamiento semántico de perfiles, la detección de brechas de habilidades y la recomendación de trayectorias de desarrollo profesional, lo que posiciona al PLN como un pilar técnico fundamental de la presente propuesta de intervención.

En esta sección se examinan las principales técnicas de preprocesamiento y representación de textos, ya que constituyen los pasos iniciales que permiten transformar documentos no estructurados como currículums, evaluaciones de desempeño o descripciones de puestos— en insumos numéricos comparables (Patil et al., 2023, p. 36120). Estas operaciones son fundamentales para que los sistemas de inteligencia artificial puedan reconocer competencias, identificar brechas y generar recomendaciones profesionales. En el ámbito de la gestión del talento, donde los datos suelen ser limitados y las decisiones deben garantizar criterios de equidad y explicabilidad, su correcta aplicación resulta crítica para el diseño de sistemas justos y efectivos (Tambe et al., 2019, pp. 2–3).

3.2.2 Técnica de preprocesamiento de textos

El preprocesamiento de texto constituye una etapa fundamental en cualquier sistema de Procesamiento de Lenguaje Natural (PLN). Como explican Gurusamy y Kannan (2014, pp. 2–6), los caracteres, palabras y oraciones identificados en esta fase se convierten en las unidades básicas que serán procesadas por las etapas posteriores, tales como analizadores morfológicos, etiquetadores de categorías gramaticales o aplicaciones como la recuperación de información y la traducción automática. Estas operaciones buscan transformar los documentos textuales en datos más limpios y estructurados, eliminando elementos irrelevantes para el análisis semántico como signos de puntuación o formatos numéricos no informativos y palabras de poco valor semántico,

tales como preposiciones o pronombres, con el objetivo de mejorar la eficiencia de los sistemas de minería de texto, tal como señalan los autores.

Una de las primeras tareas es la tokenización, que consiste en dividir un flujo de texto en palabras, frases o símbolos, llamados *tokens* (Patil et al., 2023, p. 36120). Estos tokens constituyen la entrada para procesos posteriores como el análisis sintáctico o la minería de texto. Aunque puede parecer trivial, la tokenización enfrenta desafíos asociados a la eliminación de puntuación, el tratamiento de abreviaturas y la homogeneización de formatos numéricos o temporales. La complejidad varía según el idioma: mientras lenguas como el inglés son de tipo *space-delimited* (delimitadas por espacios), otras como el chino o el tailandés son *unsegmented*, es decir, no presentan límites claros entre palabras y requieren información léxica y morfológica adicional. En el ámbito de esta propuesta, la tokenización permite identificar elementos clave en los documentos —como habilidades técnicas o nombres de instituciones— y convertirlos en unidades comparables.

Posteriormente, se aplica la eliminación de palabras vacías (*stop word removal*), que busca descartar términos de alta frecuencia pero escasa relevancia semántica, tales como “and”, “are” o “this” (Patil et al., 2023, p. 36121). Estas palabras, al no aportar información significativa, pueden dificultar los procesos de clasificación o minería de texto, incrementando el tamaño de los datos sin mejorar el desempeño del sistema. En documentos organizacionales, este paso contribuye a filtrar conectores o expresiones recurrentes como “responsable de” o “experiencia en” y permite concentrarse en los términos verdaderamente distintivos de cada perfil.

Otra técnica esencial es el *stemming*, mediante el cual las palabras se reducen a su raíz común o *stem* (Gurusamy & Kannan, 2014, p. 5). De este modo, términos como *presentation*, *presented* y *presenting* se transforman en la raíz *present*. Esta normalización mejora la recuperación de información al permitir que una consulta cubra múltiples variantes morfológicas de un término. No obstante, este proceso no está exento de errores: el *over-stemming* ocurre cuando se reducen palabras distintas a la misma raíz (falsos positivos), mientras que el *under-stemming* se da cuando palabras de la misma familia no se reducen a una raíz común (falsos negativos). En la gestión del talento, esta técnica es útil para unificar variaciones terminológicas frecuentes —por ejemplo, *analyst*, *analyzing* y *analysis*— y mejorar la comparación entre perfiles y puestos.

Existen distintos algoritmos para implementar el *stemming*. Entre ellos, los *n-gram stemmers* utilizan la similitud de secuencias de caracteres consecutivos. Este método, descrito por

Gurusamy y Kannan (2014, p. 6), calcula una medida de similitud entre pares de términos en función de los *dígramas* pares de letras consecutivas que comparten. La similitud se determina mediante el coeficiente que los autores definen de la siguiente manera.

$$S = \frac{2C}{A + B}$$

donde C es el número de dígramas compartidos entre dos términos, A el número de dígramas únicos en la primera palabra y B el número de dígramas únicos en la segunda. Con este cálculo se construye una matriz de similitud que permite agrupar términos mediante métodos de *clustering*.

En el marco de esta propuesta, su valor añadido radica en que posibilitan normalizar y limpiar documentos no estructurados propios de la gestión del talento, creando una base sólida para representaciones vectoriales más avanzadas, que se abordarán en la siguiente sección.

3.2.3 Técnicas de representación vectorial

El preprocesamiento de texto, descrito en la sección anterior, permite limpiar, normalizar y segmentar los datos en sus unidades mínimas (tokens). Sin embargo, estas unidades continúan siendo símbolos lingüísticos que las máquinas no pueden procesar directamente (Gurusamy & Kannan, 2014, p. 2). Para superar esta limitación, el Procesamiento de Lenguaje Natural requiere transformar el texto en una forma numérica que pueda ser interpretada computacionalmente. Según Patil et al. (2023, p. 36120), este proceso comprende dos pasos principales: representar el texto mediante vectores o matrices y diseñar modelos que operen sobre esos datos para cumplir un objetivo específico. La presente sección se concentra en el primero de ellos, analizando la evolución de las representaciones vectoriales desde los métodos estadísticos iniciales hasta los *embeddings* neuronales contemporáneos.

Los métodos estadísticos iniciales proyectaban documentos en vectores de conteo como *One-Hot*, *Bag of Words* (BoW), *TF* y *TF-IDF*. Estos enfoques reducen documentos de cualquier longitud a listas fijas de números, habilitando la aplicación de operaciones algebraicas para calcular similitudes y distancias (Patil et al., 2023, p. 36122). En el caso de BoW, los textos se transforman en matrices donde cada fila corresponde a una oración y cada columna a un término del vocabulario. La figura 3 muestra un ejemplo de esta representación, en el que tres oraciones se proyectan sobre un vocabulario de veinticinco términos, dando como resultado una matriz de dimensión (3, 25) que refleja la presencia o ausencia de cada palabra (Patil et al., 2023, p. 36123).

Figura 3

Ejemplo de representación Bag of Words (BoW)

	Sam	started	driving	...	preferred	outdoor	activities
Sent1	1	1	1	...	0	0	0
Sent2	0	0	0	...	0	0	0
Sent3	0	0	0	...	1	1	1

Nota. Obtenido de *A survey of text representation and embedding techniques in NLP* (p. 36123), por Patil et al. (2023).

En el contexto de esta propuesta, estas técnicas iniciales permiten calcular similitudes básicas entre documentos como currículums, evaluaciones o descripciones de puestos, aunque presentan limitaciones importantes: no logran identificar que términos distintos puedan referirse a la misma competencia profesional.

Para superar parte de esas limitaciones se incorporó la ponderación *Term Frequency-Inverse Document Frequency* (TF-IDF), que combina la frecuencia de un término en un documento con la medida de su rareza en el resto del corpus (Vijayarani et al., 2015, p. 14). Matemáticamente, el TF-IDF se define como el producto de dos factores:

$$Tf(t, d) = 0.5 + 0.5 \cdot \frac{f_{t,d}}{\max(f_{w,d})}$$

donde $f(t, d)$ es la frecuencia del término t en el documento d , y $\max(f_{w,d})$ representa la frecuencia máxima de cualquier palabra en ese documento.

$$Idf(t, D) = \log \frac{|D|}{1 + |\{d \in D : t \in d\}|}$$

donde $|D|$ es el número total de documentos y el denominador indica en cuántos documentos aparece el término t .

$$Tf - Idf(t, d, D) = Tf(t, d) \cdot Idf(t, D)$$

De esta manera, TF-IDF asigna mayor peso a los términos que son frecuentes en un documento pero poco comunes en el corpus global, lo que permite resaltar palabras verdaderamente distintivas.

En la figura 4, obtenida de Patil et al. (2023, p. 36126), se muestra un ejemplo con cuatro documentos. Los términos *repair*, *maintenance* y *labor cost* permiten identificar los textos A y C como relativos a “costos de reparación”, mientras que *safety*, *commute* y *schools* destacan en B y D, asociados a la temática de “comunidad y vecindario”.

Figura 4

Ejemplo de representación TF-IDF

	house	apartment	repair	maintenance	labor-cost	safety	commute	school	grocery	env
doc-A	125	210	100	200	32	0	0	0	0	0
doc-B	150	235	0	0	0	71	55	81	32	64
doc-C	175	261	150	350	21	0	0	0	0	0
doc-D	140	284	0	0	0	98	44	76	28	53
IDF	1	1	2	2	2	2	2	2	2	2

Nota. Obtenido de *A survey of text representation and embedding techniques in NLP* (p. 36126), por Patil et al. (2023).

Este ejemplo ilustra cómo TF-IDF mejora la capacidad de discriminación temática respecto de BoW, aunque continúa siendo de alta dimensionalidad y no logra capturar relaciones semánticas más profundas como la sinonimia o antonimia (Patil et al., 2023, p. 36126).

A pesar de estas mejoras, el problema de la “maldición de la dimensionalidad” llevó al desarrollo de técnicas de reducción, entre ellas el *Latent Semantic Indexing* (LSI). Esta técnica utiliza descomposición en valores singulares (SVD) para proyectar los vectores en un espacio latente de tópicos. De este modo, documentos con coocurrencias frecuentes quedan representados en dimensiones semánticas compartidas, lo que produce una representación más compacta y estructurada conceptualmente (Patil et al., 2023, pp. 36127–36128).

Posteriormente, se incorporaron enfoques más sofisticados. Por un lado, el *Explicit Semantic Analysis* (ESA) utiliza conceptos de Wikipedia para anclar los textos en vectores de

interpretación basados en conocimiento de dominio, ofreciendo mejores resultados frente a polisemia y sinonimia. Por otro, los *embeddings* de densidad modelan cada palabra como una distribución gaussiana o una mezcla de gaussianas, lo que permite capturar incertidumbre y reflejar múltiples sentidos (Patil et al., 2023, pp. 36131–36133).

El cambio de paradigma se produjo con los *embeddings* aprendidos automáticamente mediante redes neuronales. Modelos como *Word2Vec* o *GloVe* representaron palabras en vectores densos de baja dimensión que capturan regularidades semánticas y sintácticas a partir de grandes corpus, aunque de forma estática (Patil et al., 2023, pp. 36133–36134). Para superar esa limitación surgieron los *embeddings* contextuales, que generan representaciones dinámicas según el entorno en el que aparece la palabra. En su estudio, Patil et al. (2023) destacan cómo modelos como *CoVe*, *ELMo*, *GPT* y, especialmente, *BERT*, lograron avances sustanciales en tareas de reconocimiento de entidades, desambiguación y resolución de correferencias (pp. 36133–36135).

En la tabla 1 se presentan los resultados de distintos modelos en el *benchmark* GLUE, donde se observa que BERT supera consistentemente a GPT y ELMo en la mayoría de las tareas evaluadas, con la versión *BERT-large* alcanzando un rendimiento aún más alto que *BERT-base* (Patil et al., 2023, p. 36136). Esta superioridad se explica por su estrategia de preentrenamiento bidireccional, basada en *Masked Language Modeling* (MLM) y *Next Sentence Prediction* (NSP), que permite capturar dependencias contextuales más profundas y comprender relaciones entre oraciones, aspecto clave en tareas como la inferencia natural o la respuesta a preguntas (Devlin et al., 2019).

En el ámbito de esta propuesta, esta evolución es particularmente relevante: los *embeddings* contextuales permiten reconocer que expresiones diferentes como “ingeniero de software” y “desarrollador backend” aluden a competencias similares. Esta capacidad resulta esencial para emparejar perfiles de empleados con vacantes internas, identificar brechas de habilidades y recomendar trayectorias de desarrollo personalizadas.

Tabla 1

Comparación del rendimiento de embeddings contextuales

	Co- LA	SS- T2	MR- PC	ST- SB	QQP	QN- LI	RTE	MN- LI m	MN- LI mm
ELMo	36	90.4	84.9	73.3	64.8	79.8	56.8	76.4	76.1
GPT	45.4	91.3	82.3	80	70.3	87.4	56.0	82.1	81.4
BERT- base	52.1	93.5	88.9	85.8	71.2	90.5	66.4	84.6	83.4
BERT- large	60.5	94.9	89.3	86.5	72.1	92.7	70.1	86.7	85.9
UNILM	61.1	94.5	90	87.7	71.7	92.7	70.9	87	85.9

Nota. Obtenido de *A survey of text representation and embedding techniques in NLP* (p. 36136), por Patil et al. (2023).

La evolución de las representaciones vectoriales evidencia el paso de modelos discretos e interpretables hacia otros densos y contextuales, capaces de captar matices semánticos complejos. Estas herramientas constituyen la base de los sistemas modernos de procesamiento del lenguaje natural y, aunque aún presentan desafíos vinculados con los sesgos, la interpretabilidad o la privacidad, conforman el soporte técnico fundamental de las aplicaciones avanzadas (Patil et al., 2023, p. 36143). En esta propuesta se adopta BERT como modelo de referencia, dado que ofrece representaciones semánticas profundas y sensibles al contexto, adecuadas para la recomendación de trayectorias de carrera (Patil et al., 2023, p. 36135).

3.2.4 Desafíos del PLN y la IA en RR.HH

El Procesamiento de Lenguaje Natural (PLN) aplicado a los recursos humanos todavía enfrenta limitaciones importantes. Según Otani et al. (2024), este dominio está poco explorado en la investigación académica de NLP, ya que en conferencias internacionales apenas aparecen trabajos centrados en HR (p. 1). A ello se suma la heterogeneidad de los datos: los currículums, las descripciones de puestos y las evaluaciones de desempeño presentan formatos y estilos lingüísticos muy distintos, lo que dificulta la estandarización y el entrenamiento de modelos (p. 2). Además, existe una escasez de datos públicos y balanceados, porque la mayoría de los documentos de RR.HH. son privados y los pocos conjuntos disponibles suelen concentrarse en ciertos sectores, aumentando el riesgo de sesgos y reduciendo la capacidad de generalización de los sistemas (pp. 1, 7).

Tambe et al. (2019) advierten que uno de los principales desafíos de aplicar IA en RR.HH. es la escasez y baja frecuencia de los datos disponibles, ya que los eventos de interés como despidos por bajo rendimiento o promociones ocurren en pocos casos (p. 2). Esta limitación reduce

la capacidad de los algoritmos para identificar patrones confiables, lo que evidencia que la dificultad no radica tanto en la técnica, sino en la naturaleza restringida y sensible de los datos de RR.HH.

De acuerdo con Otani et al. (2024), la falta de datasets públicos y balanceados restringe la capacidad de generalización de los modelos (pp. 1–2, 7), mientras que Tambe et al. (2019) agregan que la escasez y baja frecuencia de los datos en RR.HH. no solo limita la precisión predictiva, sino que también plantea riesgos para la equidad y legitimidad de las decisiones sobre personas (pp. 2–3). Superar estos desafíos resulta clave para avanzar hacia sistemas más justos y efectivos, capaces de adaptarse a la complejidad de los entornos organizacionales actuales.

3.3 Modelos de recomendación

3.3.1 Introducción

Según Ricci et al. (2011), los sistemas de recomendación son herramientas de software que generan sugerencias personalizadas sobre *ítems* es decir, las entidades recomendadas, como productos, noticias o puestos con el fin de asistir el proceso de toma de decisiones cuando el número de alternativas resulta abrumador para el usuario (p. 1). En su forma más común, entregan listas ordenadas de opciones que intentan predecir cuáles son más adecuadas para cada persona a partir de preferencias explícitas (por ejemplo, calificaciones) o señales implícitas derivadas de su interacción como navegación o clics (p. 2). La disciplina emerge, en parte, de imitar la recomendación social “*personas parecidas eligieron X*” y se consolida como respuesta al exceso de información de la web, donde la abundancia de opciones no siempre se traduce en mejores decisiones (pp. 2–3).

Los sistemas colaborativos parten de la idea de que si dos usuarios compartieron intereses en el pasado, es probable que coincidan en el futuro; por ello, explotan historiales de elección o valoración de una comunidad para inferir afinidades, aun sin conocer el contenido de los ítems (Jannach et al., 2010, p. 3).

Los sistemas basados en contenido, en cambio, comparan perfiles de usuario con descripciones manuales o extraídas automáticamente de los ítems y resultan especialmente útiles cuando no hay grandes poblaciones o historiales, ya que pueden operar con la sola información de contenido (Jannach et al., 2010, p. 4).

Asimismo, Jannach et al. (2010) señalan que existen aproximaciones basadas en conocimiento, las cuales incorporan reglas y restricciones de dominio y, mediante una interacción más rica con el usuario, capturan requisitos cuando no es viable apoyarse en historiales de compra o uso (pp. 4–5). Finalmente, los sistemas híbridos combinan estas lógicas para aprovechar sus fortalezas y mitigar sus debilidades, por ejemplo, utilizando contenido para afrontar el arranque en frío y la señal colaborativa cuando está disponible (p. 7).

La efectividad de un recomendador no depende únicamente de la precisión algorítmica. Según Ricci et al. (2011), la interacción humano–computadora condiciona la aceptación: la confianza del usuario, la transparencia sobre “por qué” se sugiere algo y la posibilidad de explicaciones comprensibles influyen directamente en que las recomendaciones sean consideradas y adoptadas (p. 17). En consecuencia, además de predecir gustos o afinidades, los sistemas deben presentar y justificar sus sugerencias de modo que favorezcan decisiones informadas y percibidas como creíbles y justas (p. 17)

Estas consideraciones adquieren rasgos particulares en el ámbito de los recursos humanos. A diferencia de dominios con interacciones masivas y frecuentes, la gestión del talento enfrenta fenómenos complejos y desafíos de datos escasez, sensibilidad y restricciones de equidad y legales que condicionan el diseño, el entrenamiento y la evaluación de modelos (Tambe et al., 2019, pp. 24–26). En este contexto, la propuesta de este trabajo se apoya principalmente en técnicas basadas en contenido, reforzadas con un enfoque híbrido, para analizar descripciones de puestos, currículums y evaluaciones con técnicas de procesamiento de lenguaje natural, mitigando así las limitaciones de los enfoques colaborativos tradicionales en contextos con baja disponibilidad de datos.

En los apartados siguientes se profundiza en los principales paradigmas de los sistemas de recomendación, se analizan los desafíos particulares de su aplicación en recursos humanos y se explica cómo la propuesta desarrollada en este trabajo los adapta para ofrecer sugerencias semánticas y prospectivas orientadas al desarrollo de carrera y la movilidad interna.

3.3.2 Filtrado colaborativo

Según Jannach et al. (2010, p. 13), el filtrado colaborativo es uno de los enfoques clásicos y más ampliamente estudiados en los sistemas de recomendación. Su lógica parte de una premisa simple: si dos personas han mostrado preferencias similares en el pasado, es probable que también

coincidan en el futuro. A partir de esta idea, el modelo utiliza la información proveniente de una comunidad de usuarios para predecir qué ítems podrían resultar atractivos para un usuario activo.

En la práctica, el filtrado colaborativo, como explican Jannach et al. (2010, pp. 13–15), se apoya en historiales de comportamiento, como calificaciones otorgadas a ítems o patrones de consumo derivados de la interacción con la plataforma. A diferencia de los métodos basados en contenido, este paradigma no necesita conocer las características internas de los ítems, sino que se fundamenta en las similitudes que emergen entre los usuarios. Dentro de este enfoque, la literatura distingue dos variantes principales: por un lado, el *user-based filtering*, que identifica un conjunto de “vecinos” para el usuario activo es decir, otros individuos que han manifestado gustos similares en el pasado y, a partir de esas coincidencias, proyecta qué ítems no explorados podrían ser relevantes para él. Un ejemplo clásico se observa en plataformas de streaming, donde se recomienda una película a un usuario porque personas con perfiles de visualización semejantes la disfrutaron previamente.

Por otro lado, el *item-based filtering* desplaza el foco hacia los ítems y evalúa cuáles suelen recibir valoraciones parecidas por parte de los usuarios. En lugar de comparar personas entre sí, este método determina qué productos tienden a ser consumidos en conjunto. Así, si un usuario calificó positivamente un libro, se le podrán recomendar otros títulos que, en la base de datos, aparecen frecuentemente asociados con evaluaciones similares. Este enfoque adoptado por empresas como Amazon para escalar recomendaciones en catálogos masivos ofrece ventajas en términos de eficiencia y estabilidad, ya que las relaciones entre ítems suelen ser más consistentes que las afinidades entre usuarios (Jannach et al., 2010, pp. 18–19).

3.3.3 Sistemas basados en contenido


Los sistemas de recomendación basados en contenido se apoyan en la idea de que un usuario tenderá a interesarse en ítems con características semejantes a aquellos que valoró positivamente en el pasado. En lugar de depender de los historiales de otros, construyen un perfil individual de usuario a partir de documentos o descripciones de ítems consumidos previamente, identificando atributos relevantes y comparándolos con los de nuevos objetos (Lops et al., 2011, p. 75).

La arquitectura típica incluye tres componentes principales: el analizador de contenido, que transforma información no estructurada en representaciones estructuradas de los ítems; el aprendiz

de perfiles, que generaliza las preferencias individuales a través de técnicas de aprendizaje supervisado; y el módulo de filtrado, que calcula la similitud entre los perfiles y los ítems disponibles para generar una lista ordenada de recomendaciones. Esta organización puede observarse en la figura 5 (Lops et al., 2011, p. 76).

Figura 5

Arquitectura general de un sistema de recomendación basado en contenido



Nota. Obtenido de *Content-Based Recommender Systems: State of the Art and Trends* (p. 76), por Lops et al., 2011, *Recommender Systems Handbook*.

Este proceso puede nutrirse de retroalimentación explícita (como calificaciones o comentarios) o implícita (acciones observadas del usuario), lo que permite ajustar y actualizar dinámicamente el perfil (Lops et al., 2011, pp. 77–78).

El enfoque presenta ventajas claras: independencia respecto de otros usuarios, posibilidad de recomendar ítems nuevos aún no evaluados por la comunidad y transparencia en las explicaciones, ya que se pueden señalar las características específicas que motivan cada recomendación (Lops et al., 2011, p. 78). No obstante, enfrenta limitaciones vinculadas a la calidad de las descripciones de los ítems y a la dificultad de capturar aspectos subjetivos o contextuales de la experiencia. Además, se observa la llamada falta de serendipia, es decir, la tendencia a recomendar únicamente ítems muy similares a los ya consumidos, lo que limita el descubrimiento de alternativas novedosas e inesperadas que podrían ser igualmente valiosas para el usuario (Lops et al., 2011, p. 78).

Aggarwal (2016) complementa esta visión al señalar que los sistemas basados en contenido se sustentan en dos fuentes: descripciones de los ítems en términos de atributos relevantes y perfiles de usuario contruidos a partir de retroalimentación explícita o implícita (p. 139). A diferencia de los métodos colaborativos, este paradigma se centra principalmente en el propio historial del usuario y en los atributos de los objetos preferidos, lo que lo convierte en una estrategia especialmente útil para recomendar ítems nuevos o con escasos datos de calificación (Aggarwal, 2016, p. 139).

3.3.4 Sistemas basados en conocimientos

Los sistemas basados en conocimiento generan recomendaciones a partir de información explícita sobre el usuario (requerimientos, preferencias, contexto) y sobre el dominio (atributos de los ítems, ontologías de características, restricciones y relaciones medios–fines). Burke (2002, pp. 1–2) señala que se diferencian de los enfoques colaborativos o de contenido porque no dependen de historiales extensos de calificaciones. En la misma línea, Felfernig y Burke (2008, p. 2) destacan que la clave reside en articular los requisitos del usuario con el conocimiento del dominio para producir recomendaciones fundamentadas.

A diferencia de los métodos colaborativos o basados en contenido, este paradigma no sufre el problema de *ramp-up*, ya que puede operar sin grandes volúmenes de valoraciones. Según Burke (2002, p. 2), esto lo vuelve especialmente útil para ítems complejos o de baja frecuencia de consumo. Asimismo, Felfernig y Burke (2008, pp. 1–2, 5) muestran su idoneidad en dominios como servicios financieros, configuraciones técnicas o telecomunicaciones, donde los usuarios llegan con intenciones concretas que deben satisfacerse mediante restricciones precisas.

Al modelar simultáneamente restricciones del usuario y del producto (p. ej., incompatibilidades o umbrales mínimos), estos sistemas no solo pueden explicar las decisiones, sino también proponer ajustes cuando no existen soluciones viables. Burke (2002, p. 21) enfatiza que este razonamiento mejora la confianza del usuario en el proceso, mientras que Felfernig y Burke (2008, pp. 3–5) muestran cómo los sistemas ajustan dinámicamente los requisitos para guiar el diálogo hacia alternativas viables.


Existen dos familias prominentes dentro de este paradigma. La recomendación basada en casos plantea el problema como una búsqueda de similitud con ejemplos representativos de los objetivos del usuario (Burke, 2002, pp. 1–2). Por su parte, la recomendación basada en

restricciones formula la tarea como satisfacción de restricciones, ofreciendo explicaciones y alternativas de ajuste cuando los requisitos resultan inconsistentes (Felfernig & Burke, 2008, pp. 3–5). En ambos casos, la interacción suele modelarse como un diálogo conversacional en el que los usuarios especifican y refinan sus requerimientos, incluso mediante críticas compuestas (“más barato y con mayor ancho de banda”) que aceleran la búsqueda de opciones (Felfernig & Burke, 2008, pp. 3–4).

La organización del conocimiento en estos sistemas se representa en la figura 6, que distingue los componentes sociales, individuales y de contenido, integrando consultas, restricciones, preferencias y contexto para generar recomendaciones justificadas (Felfernig & Burke, 2008, p. 2).

Figura 6

Fuentes de conocimiento en sistemas de recomendación



Nota. Obtenido de Constraint-based Recommender Systems: Technologies and Research Issues, por A. Felfernig y R. Burke, 2008.

Los sistemas basados en conocimiento resultan idóneos cuando se requiere una adecuación precisa a requisitos, explicabilidad y control sobre el espacio de soluciones. Burke (2002, p. 21) sostiene que son especialmente valiosos en dominios donde la decisión es costosa y el error inaceptable, mientras que Felfernig y Burke (2008, p. 1) los consideran un complemento natural de los enfoques colaborativos y de contenido en arquitecturas híbridas.

3.3.5 Sistemas híbridos

Los sistemas híbridos combinan dos o más técnicas de recomendación con el objetivo de aprovechar sus fortalezas y compensar sus debilidades. Burke (2002) explica que la hibridación surge porque ningún enfoque aislado resulta suficiente en todos los contextos, y que en la práctica la combinación de técnicas suele mejorar el desempeño (p. 1). En el mismo sentido, Adomavicius y Tuzhilin (2005) describen los híbridos como una vía para superar las limitaciones de los métodos colaborativos y de contenido, proponiendo diferentes formas de integración (pp. 740–741).

Entre las modalidades de hibridación se encuentran, según Burke (2002), los enfoques ponderados, donde se combinan las puntuaciones de distintos métodos; los conmutados, que cambian dinámicamente de técnica según cuál ofrezca mayor confianza en cada situación; los mixtos, que presentan simultáneamente los resultados de varios recomendadores; los de combinación de características, que tratan la información colaborativa como atributos adicionales en un sistema basado en contenido; los de tipo cascada, en los que una técnica realiza una primera selección y otra refina los resultados; y los de aumento de características, en los que la salida de un recomendador sirve de insumo para otro (pp. 6–8). En la misma línea, Adomavicius y Tuzhilin (2005) señalan que la combinación puede realizarse integrando predicciones de recomendadores separados, inyectando rasgos de contenido en métodos colaborativos, incorporando señales colaborativas en enfoques de contenido o bien construyendo modelos unificados que integren ambas perspectivas (pp. 740–741).

La motivación central de estos enfoques radica en abordar limitaciones recurrentes. Burke (2002, pp. 3–4) describe el denominado *ramp-up problem*, que se presenta cuando el sistema requiere una cantidad suficiente de datos antes de generar recomendaciones útiles. Este fenómeno se manifiesta como *new user problem* cuando un usuario nuevo no tiene suficientes valoraciones, o como *new item problem* cuando un ítem recién incorporado no puede recomendarse hasta reunir datos adecuados. Otro desafío frecuente es la *sparsity*, que ocurre cuando las valoraciones son dispersas y pocos usuarios coinciden en evaluar los mismos ítems, lo que dificulta la detección de patrones. A ello se suma el riesgo de sobreespecialización en los sistemas basados en contenido, que tienden a recomendar opciones demasiado similares a las ya conocidas, y las exigencias de ingeniería que requieren los sistemas basados en conocimiento para modelar reglas y restricciones.

En el ámbito de los recursos humanos, estas limitaciones adquieren especial relevancia. Tal como señalan Tambe et al. (2019, p. 3), los conjuntos de datos en RR. HH. suelen ser pequeños y

los eventos de interés poco frecuentes, lo que reduce la capacidad de los modelos predictivos para ofrecer resultados confiables. De manera coincidente, Otani et al. (2024, pp. 1–2) advierten que la heterogeneidad y escasez de datos públicos en este dominio restringen la generalización y el desempeño de las soluciones basadas en PLN. En este contexto, un sistema híbrido que combine enfoques basados en contenido y en conocimiento puede generar recomendaciones iniciales sólidas a partir de descripciones de puestos y competencias, mientras que la incorporación de un componente colaborativo —cuando existan datos suficientes sobre transiciones exitosas o retroalimentación de pares añade diversidad y capacidad de descubrimiento. Esta integración permite ofrecer recomendaciones más precisas, explicables y adaptadas a contextos organizacionales complejos, en línea con las exigencias de equidad y transparencia que caracterizan a la gestión del talento (Adomavicius & Tuzhilin, 2005, p. 742).

3.3.6 Evaluación de un sistema de recomendación

La evaluación de un sistema de recomendación puede abordarse de tres maneras principales. En primer lugar, mediante estudios con usuarios, donde se invita a personas a probar el sistema en un entorno controlado. En segundo lugar, a través de evaluaciones en línea, que consisten en probar variantes del sistema en un sitio real mediante experimentos A/B para observar cuál versión genera mejores resultados (por ejemplo, un aumento en la tasa de conversión). Finalmente, mediante evaluación *offline*, que utiliza datos históricos para entrenar y probar modelos en condiciones controladas y repetibles. En la práctica, esta última es la más utilizada en investigación debido a su bajo costo y facilidad de comparación, mientras que las pruebas en línea muestran mejor el impacto real, aunque requieren una base amplia de usuarios (Aggarwal, 2016, pp. 227–229).

En la evaluación *offline*, el primer aspecto a considerar es la capacidad predictiva del sistema. Para ello se emplean métricas de error como RMSE y MAE: la primera penaliza más severamente los errores grandes, mientras que la segunda ofrece un promedio del error absoluto, siendo más robusta frente a valores atípicos (Aggarwal, 2016, pp. 240–241). Es importante señalar que estas métricas tienden a reflejar principalmente el desempeño sobre ítems populares, dejando de lado el *long tail*, que también puede aportar valor. Una alternativa consiste en aplicar ponderaciones por ítem o usuario para equilibrar la evaluación (Aggarwal, 2016, p. 241).

Dado que los usuarios suelen interactuar con listas de recomendaciones, también se evalúa la calidad del *ranking*. Se emplean métricas clásicas como precisión, *recall* y F1 (Aggarwal, 2016, p. 252), junto con métricas más avanzadas como nDCG y MAP, que otorgan mayor peso a los aciertos en las primeras posiciones de la lista, proporcionando así una visión más realista de la utilidad de las recomendaciones (Jadon & Patil, 2024, p. 3).

Otros aspectos de interés incluyen la cobertura, que mide qué proporción de usuarios e ítems son alcanzados por el sistema; la novedad, entendida como la capacidad del recomendador para presentar ítems que resulten nuevos o previamente desconocidos para el usuario; la serendipia, que refleja su potencial para sorprender positivamente con resultados inesperados pero útiles; y la diversidad, orientada a evitar la redundancia entre los elementos sugeridos. Estos criterios complementan la precisión, garantizando que el sistema no solo sea correcto, sino también valioso desde la perspectiva del descubrimiento y la experiencia del usuario (Aggarwal, 2016, pp. 231–235).

Finalmente, Jadon y Patil (2024, pp. 2–3) proponen un marco integral de evaluación que organiza las métricas en cinco grandes grupos: similitud, selección de candidatos (cobertura, diversidad, novedad, serendipia), predicción (RMSE, MAE y afines), ranking (*Precision@k*, *Recall@k*, nDCG, MAP) y métricas de negocio (CTR, conversión, ingresos y *engagement*). Este enfoque permite alinear la evaluación con los objetivos reales de las organizaciones y valorar la eficacia del sistema no solo desde el punto de vista técnico, sino también estratégico, lo cual resulta especialmente relevante en el contexto de la presente propuesta.

Capítulo 4 – Propuesta De Intervención

4.1 Metodología

La presente propuesta se apoya en un enfoque mixto, que combina elementos del enfoque cuantitativo y del cualitativo para comprender el problema desde distintas perspectivas y proponer una intervención más completa. Según Hernández-Sampieri et al. (2014), este tipo de enfoque “implica la recolección y el análisis de datos cuantitativos y cualitativos, así como su integración y discusión conjunta, para realizar inferencias producto de toda la información recabada y lograr un mayor entendimiento del fenómeno bajo estudio” (p. 534).

En este trabajo, el componente cuantitativo se refleja en el análisis de información estructurada como perfiles, descripciones de puesto, evaluaciones de desempeño o registros de formación que permite observar patrones, medir resultados y obtener evidencia objetiva sobre el funcionamiento del sistema. Este tipo de análisis sigue la lógica secuencial y probatoria del enfoque cuantitativo, centrada en la medición y en la verificación empírica (Hernández-Sampieri et al., 2014, pp. 4–5).

Por su parte, el componente cualitativo se orienta a comprender las percepciones y experiencias de los usuarios respecto al sistema propuesto, especialmente en lo relativo a la utilidad, transparencia y confianza en las recomendaciones generadas. Este enfoque se materializa en la fase de evaluación (véase sección 4.2.1.5), mediante mecanismos de retroalimentación integrados en la interfaz, encuestas breves y observaciones derivadas de pruebas piloto con empleados y equipos de recursos humanos. A través de estos instrumentos, se busca captar la interpretación subjetiva de los usuarios sobre la pertinencia y claridad de las sugerencias ofrecidas, complementando la evidencia cuantitativa con una comprensión más profunda del contexto organizacional y de las motivaciones individuales. Tal como explican los autores, en la investigación cualitativa “la acción indagatoria se mueve de manera dinámica en ambos sentidos: entre los hechos y su interpretación” (Hernández-Sampieri et al., 2014, p. 7), lo que resulta relevante para explorar cómo las personas entienden y adoptan herramientas tecnológicas en sus procesos de desarrollo de carrera

4.2 Descripción

La presente propuesta plantea el diseño de un sistema inteligente de recomendación para el desarrollo de carrera y la gestión del talento interno, orientado a grandes organizaciones con estructuras complejas y una amplia diversidad de perfiles profesionales. Su objetivo principal será

ofrecer a los empleados una visión clara y personalizada de sus oportunidades de crecimiento, reduciendo las barreras de visibilidad que actualmente limitan la movilidad interna y afectan la retención del talento. Según el informe de Cornerstone y Lighthouse Research (2023, p. 18), los colaboradores que carecen de visibilidad sobre su futuro profesional son 61 % más propensos a planear su renuncia, lo que evidencia la importancia de implementar soluciones innovadoras que fortalezcan la movilidad interna.

El sistema se concibe como una plataforma modular, integrada al ecosistema de recursos humanos, que combinará técnicas de procesamiento de lenguaje natural con un motor de recomendación híbrido. Este motor será capaz de analizar información proveniente de currículums, descripciones de puestos, evaluaciones de desempeño, habilidades declaradas y preferencias profesionales, transformándola en representaciones semánticas comparables. De este modo, se buscará superar las limitaciones de los enfoques tradicionales basados únicamente en datos autodeclarados o taxonomías rígidas, incorporando un componente predictivo y adaptativo. Tal como señalan Madhumithaa et al. (2025, p. 134) y Huang et al. (2023, pp. 599–600), la personalización mediada por inteligencia artificial constituye un eje central para atender la diversidad de trayectorias y motivaciones presentes en la fuerza laboral contemporánea.

La propuesta incluirá un módulo de recomendación semántica y prospectiva, que no solo identificará las vacantes y proyectos internos más alineados con el perfil de cada colaborador, sino que también detectará brechas de habilidades y sugerirá capacitaciones específicas, trazando posibles trayectorias de desarrollo en el tiempo. Este componente se inspirará en los aportes de De Vos et al. (2022, pp. 1–2), quienes destacan el valor de modelar la carrera como una secuencia longitudinal de eventos, lo que permite generar proyecciones más realistas que los sistemas de recomendación estáticos.

El impacto esperado de esta intervención se reflejará en tres dimensiones principales. En primer lugar, los empleados obtendrán mayor autonomía y claridad sobre sus opciones de carrera, lo que contribuirá a fortalecer su motivación y sentido de pertenencia. En segundo lugar, la organización dispondrá de una estrategia más eficiente de asignación de talento, lo que permitirá reducir la rotación y aprovechar mejor el capital humano existente. Finalmente, los equipos de recursos humanos contarán con una herramienta que complementará sus funciones, proporcionando insumos objetivos y escalables para el acompañamiento de carrera.

4.2.1 Capacidades funcionales del sistema

El sistema propuesto contemplará un conjunto de capacidades funcionales diseñadas para guiar a los empleados en la identificación de oportunidades de carrera y en la construcción de trayectorias profesionales dentro de la organización. Estas capacidades describen qué debe hacer el sistema para cumplir con los objetivos planteados en la propuesta, asegurando que cada componente contribuya a mejorar la visibilidad, la equidad y la personalización en la gestión del talento.

A diferencia de los enfoques tradicionales centrados solo en la coincidencia con vacantes disponibles, el modelo integrará una visión más amplia y prospectiva, que abarcará la proyección de trayectorias futuras, la detección de brechas de competencias y la sugerencia de instancias de formación. Asimismo, se priorizará la transparencia y la explicabilidad de las recomendaciones, de modo que cada colaborador pueda comprender el sentido de los resultados generados y ajustarlos a sus propios objetivos de desarrollo profesional.

4.2.1.1 Recomendación de oportunidades internas

El sistema generará recomendaciones automáticas de vacantes, proyectos internos y programas de mentoría a partir de la información disponible en la organización. Para ello, aplicará técnicas de análisis semántico que permitirán comparar competencias, experiencias y requisitos de cada puesto con el perfil del empleado. Por ejemplo, al analizar la descripción de una vacante en gestión de proyectos y el historial de un colaborador con experiencia en coordinación de equipos, el sistema podrá identificar puntos de coincidencia y presentar la oportunidad como relevante.

A nivel técnico, esta funcionalidad se apoyará en modelos de procesamiento de lenguaje natural que transforman los textos en representaciones vectoriales, posibilitando la búsqueda de similitudes más allá de simples coincidencias léxicas. En particular, se prevé la utilización de modelos Sentence-BERT, una variante del modelo BERT entrenada con redes siamesas y tripletas, capaz de generar *sentence embeddings* semánticamente significativos y de realizar búsquedas por similitud de manera más eficiente que los enfoques tradicionales (Reimers & Gurevych, 2019, pp. 3982–3983). Esta arquitectura permite reducir drásticamente el tiempo de cómputo en tareas de búsqueda semántica y clasificación de textos, manteniendo la coherencia contextual en las representaciones vectoriales de cada frase.

4.2.1.2 Trayectorias prospectivas de carrera

Además de las sugerencias inmediatas, el sistema permitirá proyectar escenarios de crecimiento a futuro. Estas trayectorias mostrarán qué posiciones intermedias resultan estratégicas para que el colaborador alcance un rol más avanzado, indicando también las competencias adicionales requeridas en cada paso. Por ejemplo, un analista de datos podrá visualizar un camino hacia un rol de científico de datos, con etapas intermedias en proyectos de analítica avanzada. Desde el punto de vista técnico, esta funcionalidad se basará en el análisis de patrones históricos de movilidad interna dentro de la organización, combinados con reglas de negocio que definan rutas posibles y realistas de progresión profesional.

4.2.1.3 Detección de brechas de competencias y capacitaciones

El sistema identificará las brechas de competencias entre el perfil actual del colaborador y el perfil requerido en un puesto de interés. A partir de este diagnóstico, sugerirá instancias formativas, como cursos, certificaciones o programas internos, que contribuyan a cerrar esas diferencias. El proceso se sustentará en el mapeo de habilidades declaradas en currículums o evaluaciones con taxonomías internas y externas de competencias, generando recomendaciones alineadas tanto con la oferta de formación corporativa como con recursos educativos externos previamente integrados.

4.2.1.4 Explicabilidad de las recomendaciones

Cada recomendación generada por el sistema se acompañará de una explicación clara que detalle los motivos por los cuales se sugiere una vacante, proyecto o trayectoria específica. El sistema mostrará de forma transparente las competencias coincidentes entre el perfil del empleado y el puesto, las brechas detectadas y la influencia de las preferencias personales en el resultado final. Este componente tiene por objetivo fortalecer la confianza de los usuarios, facilitar la adopción organizacional y garantizar el uso responsable de la inteligencia artificial en la gestión del talento.

El *National Institute of Standards and Technology* (NIST, 2023), en su *Artificial Intelligence Risk Management Framework (AI RMF 1.0)*, establece que la explicabilidad constituye un principio esencial para promover la rendición de cuentas y la comprensión de los procesos algorítmicos. En línea con este enfoque, el sistema propuesto ofrecerá resultados no solo

personalizados, sino también comprensibles, permitiendo que cada decisión pueda rastrearse hasta sus causas y factores de influencia.

Desde el punto de vista técnico, la explicabilidad se implementará mediante la descomposición del puntaje final de recomendación en los elementos que intervienen en su cálculo: coincidencias semánticas entre el perfil y el puesto, brechas de habilidades detectadas, afinidad con las preferencias declaradas y reglas organizacionales aplicadas. De esta manera, cada recomendación podrá ser auditada y comprendida tanto por los usuarios como por los equipos de recursos humanos, contribuyendo a la transparencia del sistema.

Para lograr este nivel de interpretabilidad, se prevé la integración de técnicas model-agnósticas de Inteligencia Artificial Explicable (XAI), entre ellas LIME (*Local Interpretable Model-Agnostic Explanations*) y SHAP (*SHapley Additive Explanations*), ampliamente utilizadas en entornos de aprendizaje automático para explicar predicciones individuales.

En particular, LIME permite generar modelos locales simplificados que aproximan el comportamiento del modelo original en torno a una predicción específica, identificando qué variables tuvieron mayor influencia en ese resultado. Según Ribeiro et al. (2016), este enfoque contribuye a fortalecer la confianza de los usuarios, facilitar la comparación entre modelos y detectar posibles sesgos o errores. En el contexto de esta propuesta, LIME permitirá explicar por qué se recomienda una determinada vacante, destacando factores como la similitud semántica entre la descripción del puesto y el perfil del empleado o la relevancia de competencias específicas.

De manera complementaria, SHAP, basado en la teoría de juegos, asigna a cada característica de entrada su contribución marginal a la predicción de forma consistente y cuantitativa. Tal como señalan Lundberg y Lee (2017), el marco SHAP ofrece una descomposición más precisa de las decisiones del modelo, combinando precisión e interpretabilidad bajo un enfoque teórico unificado. En el presente sistema, SHAP permitirá visualizar el peso relativo de variables como las habilidades declaradas, las brechas detectadas o las preferencias profesionales, aportando trazabilidad y capacidad de auditoría al proceso de recomendación.

En la interfaz del sistema, las explicaciones se presentarán de forma clara y no intrusiva. Cada tarjeta de recomendación mostrará el nombre de la vacante sugerida, las habilidades coincidentes, las áreas a fortalecer y una breve justificación textual sobre los motivos de la sugerencia. Así, el usuario podrá identificar de manera visual qué aspectos de su perfil fueron considerados relevantes y cuáles debería desarrollar para avanzar hacia posiciones futuras.

La figura 7 ejemplifica este comportamiento, mostrando cómo el sistema presenta las coincidencias de habilidades, las áreas a fortalecer y una justificación breve de la recomendación. Este diseño refuerza la comprensión del usuario y su confianza en las decisiones del sistema

Figura 7

Recomendación explicada



Nota: Mockup que muestra cómo el sistema presenta las coincidencias de habilidades, las áreas a fortalecer y una breve justificación sobre los motivos de la recomendación. Imágenes generadas con IA de Canva. Fuente propia

4.2.1.5 Evaluación de resultados

El sistema propuesto incorpora una funcionalidad de evaluación orientada a recopilar información cuantitativa y cualitativa sobre la percepción de los usuarios respecto a las recomendaciones generadas. Este componente cumple un rol clave en la mejora continua del modelo, permitiendo retroalimentar su desempeño a partir de métricas objetivas y de la experiencia real de quienes interactúan con la plataforma.

La interfaz integra un módulo de retroalimentación contextual que se presenta junto a cada recomendación sugerida. A través de un formulario breve, el usuario puede valorar su nivel de satisfacción, la relevancia de la sugerencia y la utilidad de la explicación provista por el sistema. Esta funcionalidad contribuye a fortalecer la transparencia y la confianza, al mismo tiempo que ofrece datos valiosos para ajustar el modelo de IA y optimizar la personalización de futuras

recomendaciones. En la figura 8 se muestra un mockup representativo de esta funcionalidad dentro del entorno de usuario.

Figura 8

Interfaz de evaluación de recomendaciones

Desarrollo de Carrera
Dashboard de Recomendaciones

Ana Martínez
Product Manager

Recomendaciones Personalizadas

Oportunidades basadas en tu perfil y objetivos profesionales

Analista de Datos Senior 95% match

Departamento de Analytics

Gestión de proyectos Python avanzado SQL Tableau

Lidera proyectos de análisis de datos complejos y desarrolla insights estratégicos para la toma de decisiones empresariales.

Ver detalles Guardar

Líder de Producto Digital 87% match

Producto y Tecnología

Liderazgo Estrategia UX/UI Agile

Define la visión y estrategia de productos digitales, liderando equipos multidisciplinarios hacia objetivos de negocio.

Ver detalles Guardar

Evaluación de recomendaciones

¿Qué tan satisfecho estás con esta recomendación?

Muy insatisfecho ☐ ☐ ☐ ☐ ☐ Muy satisfecho

¿Qué tan relevante considerarás esta sugerencia?

Nada relevante ☐ ☐ ☐ ☐ ☐ Muy relevante

¿Te resultó útil la explicación proporcionada?

Nada útil ☐ ☐ ☐ ☐ ☐ Muy útil

Enviar evaluación

Tus respuestas ayudan a mejorar las recomendaciones futuras.

Nota. La interfaz ilustra la funcionalidad de retroalimentación del sistema, donde los usuarios pueden valorar la satisfacción, relevancia y utilidad de las recomendaciones recibidas. Imágenes generadas con IA de Canva. Fuente: Propia.

4.2.1.6 Preferencias y objetivos del usuario

El sistema no se limitará a analizar información histórica del empleado, sino que también incorporará sus intereses, metas profesionales y áreas de desarrollo. Cada colaborador podrá declarar hacia dónde desea orientar su carrera, ya sea hacia un rol de liderazgo, una especialización técnica o un cambio de área dentro de la organización.

Estas preferencias actuarán como un refuerzo de personalización que influirá directamente en las recomendaciones generadas. Por ejemplo, un empleado con perfil financiero que exprese interés en desarrollar competencias digitales recibirá sugerencias que combinen vacantes

vinculadas con análisis de datos y capacitaciones en herramientas tecnológicas. De este modo, las oportunidades reflejarán no solo la situación actual, sino también la dirección deseada, promoviendo trayectorias más significativas y motivadoras.

4.2.2 Arquitectura y tecnología

4.2.2.1 Arquitectura del sistema basado en microservicios


La arquitectura adoptada se inspira en el enfoque de microservicios, al estructurar el sistema como un conjunto de componentes independientes y especializados que se comunican mediante una capa de servicios basada en API. Este diseño favorece la escalabilidad, la resiliencia y la evolución modular del sistema, ya que cada componente —como la ingesta de datos, el procesamiento de lenguaje natural, el almacenamiento, el motor de recomendación o la capa de presentación— puede desplegarse y mantenerse de forma autónoma sin afectar la operatividad general.

De acuerdo con Atlassian (2025), una arquitectura de microservicios divide una aplicación en servicios implementables de manera independiente que interactúan a través de interfaces bien definidas, lo que mejora la velocidad de desarrollo y la flexibilidad del sistema. En la misma línea, Newman (2021) destaca que este paradigma promueve la modularidad y la escalabilidad al permitir que cada servicio cumpla una función específica del negocio y pueda evolucionar de manera aislada.

En la figura 9 se presenta la arquitectura general del sistema, donde se observa la interacción entre los módulos de ingesta, PLN, almacenamiento, recomendación, explicabilidad y presentación, todos articulados bajo una capa transversal de seguridad y observabilidad que asegura la trazabilidad y el cumplimiento de estándares de calidad y protección de datos.

Figura 9

Arquitectura del sistema de recomendación inteligente



Nota. Fuente: Elaboración propia.

En la base se encontrará el módulo de ingesta y gobierno de datos, encargado de recibir y normalizar la información proveniente de diversas fuentes organizacionales, como currículums, descripciones de puestos, evaluaciones de desempeño y catálogos de formación. Este módulo aplicará procesos de limpieza, estandarización y consolidación que garantizarán la coherencia y calidad de los datos utilizados por el sistema.

Sobre esta capa operará el módulo de procesamiento semántico, responsable de transformar los textos en representaciones numéricas mediante técnicas de procesamiento de lenguaje natural (PLN). A través de modelos de *embeddings* contextuales, el sistema podrá identificar similitudes entre descripciones escritas en lenguaje natural, reconociendo coincidencias entre habilidades, experiencias y requerimientos. De manera complementaria, este módulo extraerá competencias y las normalizará, reduciendo la ambigüedad generada por sinónimos o variaciones terminológicas.

El siguiente módulo corresponderá al almacenamiento e indexación, que integrará una base de datos relacional para los metadatos y un índice vectorial para las búsquedas por similitud semántica. Esta combinación permitirá recuperar información con rapidez y precisión, equilibrando trazabilidad, eficiencia y rendimiento.

Encima de esta capa se ubicará el motor de recomendación, núcleo del sistema, encargado de combinar distintos factores dentro de un modelo híbrido. A partir de la similitud semántica, la coincidencia de habilidades, las preferencias declaradas por el usuario y las reglas de elegibilidad definidas por la organización, el motor calculará un puntaje compuesto que determinará la pertinencia de cada oportunidad. A su vez, generará una explicación legible que detallará los motivos de la sugerencia y propondrá capacitaciones o acciones concretas para cerrar las brechas detectadas.

La capa de servicios de aplicación expondrá las funcionalidades del sistema mediante una API segura, que actuará como intermediaria entre el motor de recomendación y la interfaz del usuario. Este nivel gestionará la autenticación, la autorización y el control de acceso basado en roles (RBAC), garantizando la confidencialidad y protección de los datos personales conforme a las normativas vigentes.

Por último, la capa de presentación estará compuesta por un portal interno y un asistente conversacional que permitirán la interacción directa con los usuarios. El portal ofrecerá paneles personalizados donde los empleados podrán consultar sus oportunidades de desarrollo, trayectorias sugeridas y capacitaciones recomendadas; mientras que el asistente conversacional posibilitará realizar consultas rápidas en lenguaje natural.

Cada una de estas capas se complementará con servicios transversales de seguridad, auditoría y observabilidad, responsables de registrar el comportamiento del sistema, controlar los accesos y asegurar la transparencia en el proceso de recomendación.

Para la observabilidad técnica, se prevé el uso de herramientas como Prometheus y Grafana, que permitirán monitorear métricas operativas —como tiempos de respuesta, uso de recursos y frecuencia de ejecución del motor de recomendación—, así como detectar anomalías o degradaciones de rendimiento.

En cuanto a la trazabilidad de las recomendaciones, se emplearán registros detallados en un sistema centralizado de logs, basado en ELK Stack u OpenSearch, donde se almacenarán los factores relevantes de cada sugerencia, incluyendo las coincidencias semánticas detectadas, las

brechas de habilidades y el puntaje final calculado. Estos datos podrán ser auditados posteriormente por los equipos de recursos humanos o de tecnología, lo que garantizará la reconstrucción completa del razonamiento del sistema ante cualquier revisión o incidente.

4.2.2.2 Tecnologías empleadas

El sistema se desarrollará principalmente en Python, lenguaje seleccionado por su versatilidad y por el ecosistema maduro de bibliotecas orientadas a inteligencia artificial y procesamiento de lenguaje natural (PLN). El backend se implementará con el framework FastAPI, que ofrece alto rendimiento y una arquitectura basada en microservicios, lo cual facilitará la integración con otros sistemas corporativos y permitirá mantener una estructura modular y extensible.

Para el análisis semántico se emplearán modelos de *embeddings* preentrenados de Sentence-BERT, alojados en la plataforma Hugging Face, los cuales permitirán representar textos en vectores de alta dimensión capaces de capturar el significado contextual de las palabras. Este enfoque hará posible comparar descripciones de puestos y perfiles profesionales más allá de coincidencias literales, alcanzando una comprensión más cercana al lenguaje humano.

El almacenamiento se compondrá de dos estructuras complementarias: una base de datos PostgreSQL para los metadatos y un índice vectorial basado en pgvector o FAISS para las búsquedas por similitud. Esta configuración permitirá ejecutar consultas semánticas en tiempos sub-segundo, incluso ante volúmenes significativos de información, manteniendo la coherencia y trazabilidad de los datos.

El sistema se desplegará en contenedores Docker y será orquestado mediante Kubernetes, lo que asegurará portabilidad, escalabilidad horizontal y resiliencia frente a la demanda variable. La infraestructura podrá alojarse tanto en entornos cloud como on-premise, según las políticas de seguridad y cumplimiento de cada organización. Los archivos y datos no estructurados se almacenarán en servicios compatibles con S3, garantizando redundancia, integridad y alta disponibilidad.

El frontend se desarrollará en React, con autenticación integrada al inicio de sesión corporativo mediante OAuth 2.0 u OpenID Connect (OIDC). Esta integración no solo simplificará la experiencia del usuario, sino que también reforzará los controles de acceso y la protección de la información personal. Para la supervisión operativa se emplearán soluciones de observabilidad

como Prometheus y Grafana, junto con herramientas de registro centralizado como ELK Stack u OpenSearch, lo que permitirá auditar el comportamiento del sistema, monitorear métricas clave y detectar incidentes de manera temprana.

4.2.2.3 Interfaz de usuario

La interfaz del sistema estará diseñada para ofrecer una experiencia intuitiva, accesible y centrada en el usuario, alineada con los principios de usabilidad y accesibilidad digital establecidos por la *International Organization for Standardization* (2018). Según la norma ISO 9241-11:2018, la usabilidad se define como el grado en que un sistema permite a sus usuarios alcanzar objetivos específicos con efectividad, eficiencia y satisfacción, lo que orienta el diseño hacia la claridad y la optimización de la experiencia.

El portal corporativo constituirá el punto de acceso principal, desde el cual los empleados podrán visualizar sus oportunidades de desarrollo, trayectorias posibles y capacitaciones recomendadas. La información se presentará en paneles interactivos que faciliten la exploración visual de las opciones de carrera, priorizando una organización clara y jerárquica. Los equipos de recursos humanos y los mandos medios contarán, además, con vistas específicas que les permitirán consultar perfiles, identificar candidatos internos y analizar brechas de competencias, integrando así una visión estratégica del talento disponible en la organización.

El diseño general de la interfaz se basará en una navegación simple y consistente, con menús laterales, paneles personalizables y elementos visuales de rápida interpretación. Tal como sostiene Nielsen (1994), una interfaz verdaderamente usable debe ofrecer *consistencia, control y retroalimentación*, principios que guiarán la disposición de los componentes y las respuestas del sistema frente a las acciones del usuario.

Además del portal principal, el sistema incluirá un asistente conversacional basado en inteligencia artificial, que permitirá la interacción mediante lenguaje natural. A través de este componente, los empleados podrán realizar consultas como “¿qué vacantes se ajustan mejor a mi perfil?” o “¿qué formación necesito para avanzar hacia un puesto de coordinación?”. El asistente responderá con mensajes breves y contextualizados, ofreciendo una alternativa dinámica que complementa la navegación tradicional y refuerza la personalización de la experiencia.

En la figura 10 se presenta un mockup conceptual del portal principal, donde se observan las secciones de recomendaciones personalizadas, trayectorias de crecimiento y capacitaciones sugeridas.

Figura 10

Interfaz de usuario




Nota: Mockup de la interfaz de usuario. Imágenes generadas con IA de Canva. Fuente propia

Por su parte, la figura 11 muestra el asistente de carrera conversacional integrado al entorno, que ejemplifica cómo el usuario puede interactuar con el sistema para recibir respuestas y sugerencias personalizadas.

Figura 11

Asistente de carrera conversacional



Nota: Mockup asistente de carrera conversacional. Imágenes generadas con IA de Canva. Fuente propia

4.3 Acciones a realizar

El plan se estructura en cinco etapas que reflejan el ciclo de vida de un proyecto de software: análisis y planificación, diseño, implementación, pruebas y despliegue. Cada etapa contempla acciones específicas orientadas a garantizar la viabilidad técnica, funcional y organizacional de la propuesta.

4.3.1 Análisis y planificación

Propósito general: analizar los requerimientos funcionales y técnicos del sistema, así como los recursos humanos y tecnológicos necesarios para su desarrollo, con el fin de establecer una base sólida para las etapas siguientes.

Actividades principales:

- Relevar las fuentes de información internas (currículums, descripciones de puestos, evaluaciones de desempeño y catálogos de formación) y definir los mecanismos de acceso, anonimización y actualización de los datos.
- Identificar las necesidades de los usuarios finales ,empleados, mandos medios y equipos de recursos humanos,mediante entrevistas y revisión de procesos actuales de movilidad interna.

-
- Evaluar los recursos disponibles: infraestructura de TI, capacidades del personal técnico y herramientas de desarrollo existentes.
 - Elaborar un cronograma preliminar del proyecto con las dependencias y plazos estimados.

Resultados esperados:

- Documento de requerimientos funcionales y técnicos.
- Informe de análisis de factibilidad.
- Cronograma inicial de desarrollo y recursos asignados.

4.3.2 Diseño

Propósito general: Definir la arquitectura del sistema, los componentes funcionales, la base de datos, la interfaz de usuario y los flujos de interacción entre los módulos.

Actividades principales:

- Elaborar el diseño arquitectónico final basado en el modelo modular propuesto, incluyendo las capas de ingesta, procesamiento semántico, recomendación, API y presentación.
- Diseñar los esquemas de base de datos y las estructuras de almacenamiento vectorial, considerando las relaciones entre perfiles, habilidades, vacantes y capacitaciones.
- Desarrollar los diagramas de flujo de información, casos de uso y prototipos de la interfaz de usuario, priorizando la usabilidad y la claridad visual.
- Definir los endpoints principales de la API y los protocolos de seguridad (OAuth2, JWT) para la autenticación y autorización.

Resultados esperados:

- Documento de diseño técnico y funcional.
- Diagramas arquitectónicos y de flujo de datos.
- Prototipos de interfaz y documentación de API.

4.3.3 Implementación

Propósito general: Desarrollar el sistema de recomendación semántica y los componentes asociados, garantizando la correcta integración entre módulos y la seguridad de los datos procesados.

Actividades principales:

- Implementar el backend utilizando Python y el framework FastAPI, integrando los módulos de procesamiento de lenguaje natural y el motor híbrido de recomendación.
- Configurar la base de datos PostgreSQL y el índice vectorial con pgvector o FAISS para realizar búsquedas semánticas eficientes.
- Desarrollar el frontend en React, conectado a la API y con autenticación mediante OAuth2 o OpenID Connect.
- Incorporar los modelos de embeddings preentrenados (Sentence-BERT) alojados en Hugging Face, adaptados al dominio de RRHH.
- Contenerizar los servicios con Docker y orquestarlos mediante Kubernetes, asegurando portabilidad y escalabilidad horizontal.
- Integrar servicios de registro y observabilidad con Prometheus, Grafana y ELK/OpenSearch.

Resultados esperados:

- Sistema funcional con módulos integrados.
- Código fuente documentado y versionado.
- Manual técnico preliminar.

4.3.4 Pruebas

Propósito general: Verificar la funcionalidad, estabilidad y usabilidad del sistema, garantizando la calidad y confiabilidad del producto antes de su implementación definitiva.

Actividades principales:

- Realizar pruebas unitarias y de integración sobre cada módulo del sistema (ingesta, procesamiento, recomendación y presentación).

-
- Ejecutar pruebas de rendimiento para evaluar tiempos de respuesta y consumo de recursos en distintos escenarios de carga.
 - Validar la precisión del motor de recomendación mediante casos de prueba que midan el nivel de coincidencia y la coherencia de las explicaciones generadas.
 - Llevar a cabo pruebas de usabilidad con un grupo reducido de usuarios internos, registrando observaciones y sugerencias de mejora.

Resultados esperados:

- Informe de pruebas con métricas, resultados y acciones correctivas.
- Versión estable del sistema lista para despliegue controlado.

4.3.5 Despliegue

Propósito general: Implementar el sistema en un entorno productivo controlado y establecer los lineamientos para su operación, mantenimiento y mejora continua.

Actividades principales:

- Desplegar los servicios en la nube corporativa o infraestructura on-premise, configurando balanceadores, certificados SSL y políticas de respaldo.
- Publicar el portal interno y el asistente conversacional, habilitando los accesos según roles definidos.
- Capacitar a los equipos de recursos humanos y soporte técnico sobre el uso y mantenimiento del sistema.
- Implementar mecanismos de monitoreo en tiempo real y definir indicadores de desempeño (precisión de recomendaciones, satisfacción de usuarios, frecuencia de uso).
- Elaborar un plan de mantenimiento y mejora continua basado en retroalimentación y análisis de métricas.

Resultados esperados:

- Sistema desplegado y operativo.
- Manual de usuario y guía de administración.

- Plan de mantenimiento y mejora continua.

4.4 Determinación de recursos necesarios

En este apartado se detallan los recursos humanos, materiales y económicos necesarios para la implementación del sistema inteligente de recomendación propuesto. Se busca asegurar la viabilidad técnica y operativa del proyecto en un horizonte de tiempo razonable, combinando eficiencia, escalabilidad y sostenibilidad.

4.4.1 Recursos

4.4.1.1 Recursos humanos

El desarrollo del sistema inteligente de recomendación requerirá de un equipo interdisciplinario compuesto por profesionales de distintas áreas, capaces de integrar conocimientos técnicos, metodológicos y funcionales. Dado que se trata de una solución basada en inteligencia artificial y procesamiento de lenguaje natural, será necesario contar con perfiles especializados tanto en ingeniería de software como en ciencia de datos, junto con profesionales del área de recursos humanos que garanticen la coherencia funcional del producto.

El equipo trabajará bajo una metodología ágil, que permita avanzar de manera iterativa y colaborativa, priorizando la entrega de resultados parciales en ciclos cortos de desarrollo. Esta modalidad favorece la comunicación entre los integrantes, la detección temprana de errores y la flexibilidad frente a eventuales ajustes en los requerimientos.

Entre los perfiles clave, se incluirá un líder de proyecto o Product Owner, encargado de planificar, coordinar y supervisar las distintas etapas, asegurando que los objetivos del sistema se mantengan alineados con las metas institucionales. Este rol será el nexo entre el equipo técnico y los responsables del área de Recursos Humanos de la organización.

Se contará también con un arquitecto técnico o Tech Lead, responsable del diseño general de la arquitectura, la selección de las tecnologías más adecuadas y la toma de decisiones técnicas estratégicas. Su participación será esencial para garantizar la escalabilidad y la seguridad del sistema.

El Data Engineer tendrá a su cargo la ingesta, limpieza y normalización de los datos provenientes de las distintas fuentes internas, tales como currículums, descripciones de puestos y

evaluaciones de desempeño. Su trabajo permitirá disponer de información coherente y estandarizada para alimentar el modelo de recomendación.

Por su parte, el especialista en inteligencia artificial y procesamiento de lenguaje natural (PLN) será el encargado de entrenar y ajustar el modelo semántico del sistema, utilizando embeddings contextuales como *Sentence-BERT* y técnicas de explicabilidad como *LIME* y *SHAP*. Este perfil resulta fundamental para garantizar la precisión de las recomendaciones y la transparencia en los resultados generados por el modelo.

El desarrollador backend implementará el motor de recomendación y las interfaces de programación (APIs) que conectan la lógica del sistema con la interfaz de usuario. Trabajará en conjunto con el desarrollador frontend, quien diseñará la interfaz visual del portal interno y del asistente conversacional, asegurando que el sistema resulte intuitivo, accesible y fácil de usar.

Asimismo, será necesario contar con un ingeniero DevOps, responsable de la automatización de los procesos de integración y despliegue (CI/CD), la gestión de los contenedores Docker y la orquestación del sistema en Kubernetes. Este rol garantizará la eficiencia operativa y la estabilidad de la aplicación durante su ejecución en entornos cloud.

El equipo se completará con un especialista en aseguramiento de calidad (QA), que se encargará de planificar y ejecutar pruebas funcionales, de rendimiento y de usabilidad antes del despliegue final, y con un diseñador UX/UI, que velará por la coherencia visual, la navegabilidad y la adecuación del diseño a los principios de usabilidad establecidos por la norma ISO 9241-11:2018.

Por último, un analista funcional o especialista en recursos humanos cumplirá la función de validar los flujos y las recomendaciones generadas, garantizando que los resultados sean útiles y comprensibles desde la perspectiva de la gestión del talento y el desarrollo de carrera.

En cuanto a la estimación de perfiles y dedicación, se tomarán como referencia las fuentes salariales del mercado tecnológico argentino publicadas por *iProfesional* (2025) y la *Encuesta de Sueldos IT Argentina 2025* elaborada por *OpenQube* (2025), que permiten contextualizar los rangos y niveles de especialización requeridos. Estas referencias se utilizarán más adelante, en la sección de costos del trabajo, para determinar el presupuesto estimado correspondiente a los recursos humanos

4.4.1.2 Recursos tecnológicos

El desarrollo del sistema inteligente de recomendación requiere una infraestructura tecnológica sólida y herramientas adecuadas para garantizar su rendimiento, seguridad y escalabilidad. Dado que el proyecto se basa en técnicas de procesamiento de lenguaje natural, análisis semántico y recomendación híbrida, es fundamental disponer de entornos de desarrollo que soporten alto procesamiento y permitan una integración fluida entre los distintos módulos del sistema.

En términos generales, la infraestructura se organizará bajo una arquitectura basada en microservicios, que favorecerá la modularidad y el mantenimiento independiente de cada componente. Este enfoque permitirá escalar de manera progresiva según la demanda y facilitar la incorporación de nuevas funcionalidades sin afectar el sistema principal.

Para el desarrollo e implementación del backend se utilizará el lenguaje Python, junto con el framework FastAPI, por su eficiencia, simplicidad y soporte nativo para arquitecturas asincrónicas. Python ofrece además un ecosistema maduro de bibliotecas orientadas a inteligencia artificial y procesamiento de lenguaje natural, como *Transformers*, *Sentence-Transformers* y *Scikit-learn*, lo cual resulta clave para el entrenamiento y la optimización del modelo semántico.

El módulo de análisis de texto se basará en modelos preentrenados alojados en la plataforma Hugging Face, particularmente en versiones adaptadas de *Sentence-BERT*, capaces de generar representaciones vectoriales que capturan el significado contextual de las frases. Este tipo de embeddings permitirá comparar descripciones de puestos y perfiles profesionales de manera precisa, incluso cuando utilizan terminologías diferentes (Reimers & Gurevych, 2019).

El almacenamiento de datos combinará una base de datos relacional PostgreSQL para los metadatos estructurados y un índice vectorial FAISS o pgvector para las búsquedas por similitud semántica. Esta configuración optimiza la consulta de grandes volúmenes de información textual, garantizando rapidez y trazabilidad.

El sistema se desplegará en contenedores Docker, orquestados mediante Kubernetes, lo que permitirá asegurar portabilidad, escalabilidad horizontal y resiliencia frente a la carga variable. Esta arquitectura posibilita tanto implementaciones en entornos cloud como en infraestructura on-premise, según las políticas de seguridad de cada organización.

Se hará uso de servicios en la nube de Amazon Web Services (AWS) para facilitar la colaboración y el almacenamiento centralizado de datos. Esta plataforma se selecciona por ofrecer

una infraestructura escalable, segura y de alta disponibilidad, ampliamente utilizada en entornos corporativos y de investigación.

En particular, el servicio Amazon S3 permitirá almacenar los archivos del proyecto — incluidos los modelos entrenados, los conjuntos de datos y los registros de ejecución— con soporte para copias de respaldo automáticas y recuperación ante fallos (*Amazon Web Services*, s.f.-a).

De manera complementaria, se prevé la utilización de Amazon DynamoDB para el almacenamiento de información dinámica, como perfiles de usuario, sesiones activas o historiales de recomendaciones. Su arquitectura sin servidor, baja latencia y escalabilidad nativa lo convierten en una opción adecuada para sistemas que requieren alta disponibilidad y respuesta en tiempo real (*Amazon Web Services*, s.f.-b).

Para la gestión del proyecto se utilizará Jira Software en su versión Standard, ya que permite un número de usuarios superior al ofrecido por la versión gratuita, brinda funciones avanzadas de control de acceso y facilita la planificación ágil mediante tableros *Scrum* y *Kanban*. Esta herramienta mejora la trazabilidad de tareas, la visibilidad de avances y la coordinación del equipo, ofreciendo soporte técnico directo y almacenamiento ampliado, ideal para proyectos con múltiples participantes (Atlassian, s.f.).

En cuanto al control de versiones, se optará por GitLab en su versión Premium, que incluye funcionalidades avanzadas de revisión de código, integración continua (CI/CD), monitoreo de *pipelines* y control de lanzamientos. Estas características incrementan la productividad del equipo y aseguran la calidad y la seguridad del software desarrollado (GitLab, s.f.).

Desde el punto de vista del hardware, se requerirán estaciones de trabajo de gama media a alta para los integrantes del equipo técnico, equipadas con procesadores multinúcleo, al menos 16 GB de memoria RAM y unidades de almacenamiento sólido (SSD). Para las tareas de entrenamiento o ajuste de modelos se prevé el uso de unidades de procesamiento gráfico (GPU), como las NVIDIA T4 o equivalentes, que brindan un rendimiento óptimo para el cálculo de embeddings y la inferencia de modelos de lenguaje.

El entorno de desarrollo incluirá también sistemas de monitoreo y observabilidad como Prometheus y Grafana, que permitirán visualizar métricas de rendimiento y consumo de recursos, así como herramientas de registro centralizado como ELK Stack u OpenSearch, orientadas a la trazabilidad y la auditoría del sistema.

4.5 Costos

En este apartado se presenta una estimación del presupuesto necesario para el desarrollo del sistema inteligente de recomendación. Los valores expresados son referenciales y buscan reflejar un escenario realista y sustentable en el contexto del mercado tecnológico argentino. Para su elaboración se consultaron las páginas oficiales de los productos y servicios utilizados, así como fuentes periodísticas y comunitarias especializadas que publican información salarial actualizada del sector. Todos los montos se expresan en dólares estadounidenses (USD), considerando una cotización del dólar MEP de 1 USD = 1.532,50 ARS vigente al 8 de octubre de 2025.

4.5.1 Hardware

El equipamiento técnico representa una inversión inicial fundamental para asegurar la capacidad de procesamiento y la estabilidad del sistema durante su desarrollo. En esta etapa se prevé contar con tres niveles de estaciones de trabajo, ajustadas a las necesidades específicas de cada rol dentro del equipo.

En primer lugar, se contemplan dos estaciones de alta performance, destinadas a tareas de entrenamiento de modelos y pruebas de procesamiento semántico. Cada una incluirá una GPU NVIDIA T4 o equivalente, ampliamente utilizada en entornos de aprendizaje automático por su equilibrio entre rendimiento y eficiencia energética (*NVIDIA Corporation*, s.f.-a). Estas estaciones contarán además con un procesador multinúcleo, 32 GB de memoria RAM y una unidad de estado sólido (SSD), con un costo estimado de 3 000 USD por unidad, lo que representa un total de 6 000 USD.

Por otro lado, se proyectan cuatro estaciones de trabajo estándar para los desarrolladores backend, frontend y DevOps. Estas configuraciones, equipadas con procesadores AMD Ryzen 7, reconocidos por su buen desempeño multicore en entornos de desarrollo de software (*Advanced Micro Devices*, s.f.), junto con 16 GB de RAM y almacenamiento SSD, alcanzan un costo aproximado de 1 500 USD cada una, es decir, 6 000 USD en total.

Finalmente, se suman dos equipos administrativos, utilizados para tareas de documentación, control de versiones y gestión general del proyecto, con un costo promedio de 800 USD por equipo, que equivale a 1 600 USD.

De este modo, el costo total estimado en hardware asciende a 13 600 USD, conforme a precios medios de mercado relevados en portales especializados como *Amazon* (2025). Como se

observa en la tabla 2, esta inversión cubre de forma equilibrada las necesidades de cómputo de todas las áreas involucradas.

Tabla 2

Estimación de costos de hardware

Tipo de equipo	Cantidad	Costo unitario(USD)	Total(USD)
Alta performance (GPU)	2	3000	6000
Estandar de desarrollo	4	1500	6000
Administrativo	2	800	1600
Costo total			13600

Nota. Elaboración propia.

4.5.2 Licencias de software y servicios

El desarrollo del sistema requiere herramientas colaborativas y servicios en la nube que garanticen una gestión ágil, segura y trazable de cada etapa del proyecto. Estas soluciones permiten mantener la coordinación del equipo, preservar la integridad de los datos y optimizar los tiempos de desarrollo mediante entornos flexibles y escalables.

Para la coordinación del trabajo en equipo se utilizará Jira Software, en su versión *Standard*, cuyo costo anual ronda los 1 300 USD para grupos de hasta quince usuarios. Dado el horizonte temporal de diez meses previsto para el proyecto, se estima un gasto proporcional de 1083,33 USD (*Atlassian*, s.f.).

En cuanto al control de versiones, se optará por GitLab Premium, que ofrece funcionalidades avanzadas de integración continua (CI/CD), revisión de código y seguimiento de entregas. Este plan tiene un valor de 29 USD mensuales por usuario; considerando un equipo de cinco integrantes durante diez meses, el costo total asciende a 1450 USD (*GitLab*, s.f.).

Para el almacenamiento de archivos y bases de datos se emplearán los servicios Amazon S3 y Amazon DynamoDB, reconocidos por su confiabilidad, escalabilidad y bajo nivel de mantenimiento.

En el caso de Amazon S3, el costo promedio es de 2,30 USD por cada 100 GB mensuales, lo que permite almacenar modelos, datasets y registros del proyecto de forma segura (*Amazon Web Services*, s.f.-a).

Por su parte, Amazon DynamoDB ofrece una estructura sin servidor con un costo estimado de 5 USD por 20 GB al mes, ideal para administrar datos dinámicos como sesiones, historiales y configuraciones del sistema (*Amazon Web Services*, s.f.-b). En conjunto, ambos servicios representarían un gasto aproximado de 73USD durante el período de desarrollo.

Finalmente, se contempla la utilización de una licencia Figma Professional para el diseño colaborativo de interfaces, dado que este plan ofrece acceso completo a las herramientas de diseño, prototipado y documentación del equipo. Según la información oficial de la plataforma, el plan *Professional* tiene un costo de 16 USD mensuales por usuario en modalidad *Full seat*, lo que permite contar con funcionalidades avanzadas de bibliotecas compartidas y modos de desarrollo integrados (*Figma*, 2025). Considerando un período de diez meses, el gasto estimado asciende a 160USD.

Los costos de licencias y servicios, detallados en la tabla 3, ascienden a 2766,33 USD. Esta inversión permite disponer de un entorno colaborativo moderno, con herramientas consolidadas en la industria tecnológica y orientadas a garantizar la eficiencia y calidad del proceso de desarrollo.

Tabla 3

Estimación de costos de licencias y servicio

Herramienta/servicio	Costo (USD)
Jira software	1083,33
(standard)	
Gitlab premium	1450,00

Amazon S3	23,00
DynamoDB	50,00
Figma profesional(full seat)	160,00
Total	2766,33

Nota. Elaboración propia con base en *Atlassian* (s.f.), *GitLab* (s.f.), *Amazon Web Services* (s.f.-a, s.f.-b) y *Figma* (2025).

4.5.3 Capital humano

El componente más relevante del presupuesto corresponde a los recursos humanos, dado que el desarrollo del sistema requiere perfiles técnicos y especializados en ingeniería de software, ciencia de datos e inteligencia artificial.

La estimación de costos se realizó en base a los valores publicados por *iProfesional* (2025) sobre los sueldos en el sector tecnológico argentino y la Encuesta de Sueldos IT Argentina 2025 elaborada por OpenQube (2025). Ambos informes sitúan los salarios promedio del sector entre 1 800 y 3 500 USD mensuales, dependiendo del nivel de experiencia y responsabilidad del rol.

De acuerdo con *iProfesional* (2025), los salarios de un Product Owner o líder de producto se encuentran entre 3 000 000 y 5 000 000 de pesos argentinos, lo que equivale aproximadamente a 3 200 USD mensuales, considerando un tipo de cambio MEP de 1 532,50 ARS por dólar (*Dólar Hoy*, 2025). En el caso de los desarrolladores backend y especialistas DevOps, los sueldos oscilan entre 1 800 y 2 200 USD, mientras que los diseñadores UX/UI perciben valores cercanos a 2 000 USD mensuales, según la misma fuente.

Por su parte, *Teclab* (2025) señala que los perfiles de QA o tester de software promedian entre 2 300 y 2 400 USD mensuales, mientras que la Encuesta OpenQube (2025) indica que los roles de data engineer y especialista en procesamiento de lenguaje natural (PLN) pueden alcanzar valores de hasta 3 200 USD mensuales, dada su alta demanda en proyectos de inteligencia artificial.

A partir de estos datos, se estimó un promedio general de 2 500 USD mensuales por profesional, ajustando ligeramente según el nivel técnico de cada posición. El equipo contempla los siguientes perfiles: Product Owner, Arquitecto Técnico, Ingeniero de Datos, Especialista en IA y PLN, Desarrolladores Backend y Frontend, Ingeniero DevOps, QA Tester, Diseñador UX/UI y Analista Funcional o especialista en Recursos Humanos.

Como se detalla en la tabla 4, la inversión total estimada en recursos humanos asciende a 252 000 USD.

Tabla 4

Estimación de costos de capital humano

Rol	Costo mensual(USD)	Duración(meses)	Total(USD)
Product Owner	3200	10	32000,00
Arquitecto Técnico	3000	10	30000,00
Ingeniero de Datos	3200	10	32000,00
Especialista IA / PLN	3200	10	32000,00
Desarrollador Backend	2000	10	20000,00
Desarrollador Frontend	2000	10	20000,00
Ingeniero DevOps	2200	10	22000,00
QA Tester	2400	10	24000,00
Diseñador UX / UI	2000	10	20000,00
Analista Funcional / HR	2000	10	10000,00

Total estimado	252000,00
-----------------------	------------------

Nota. Elaboración propia con base en *iProfesional* (2025), *Teclab* (2025) y *OpenQube* (2025).

4.5.4 Costo total

El costo total del proyecto integra los tres componentes desarrollados previamente: hardware (sección 4.4.1), licencias y servicios (sección 4.4.2) y capital humano (sección 4.4.3). Como se aprecia en la tabla 5, la inversión estimada asciende a 268 366,33 USD, resultado de sumar 13 600 USD en equipamiento, 2 766,33 USD en licencias y servicios, y 252 000 USD en recursos humanos.

Tabla 5

Costos total de la propuesta

Categoría	Costo (USD)
Hardware	13600,00
Licencias y servicios	2766,33
Capital humano	252000,00
Total	268366,33

Nota. Elaboración propia a partir de las Tablas 2, 3 y 4.

4.6 Determinación del cronograma

4.6.1 Justificación

El cronograma se elaboró considerando la complejidad técnica del sistema propuesto, la disponibilidad de recursos humanos y tecnológicos, y las dependencias naturales entre las actividades del ciclo de vida del proyecto. Se establece una planificación total de 40 semanas (10 meses), distribuidas en cinco fases principales: análisis y planificación, diseño, implementación, pruebas y despliegue (véase Figura 14).

La primera fase, *Análisis y planificación*, tiene una duración estimada de 6 semanas y comprende el relevamiento de requerimientos funcionales y técnicos, entrevistas con personal del área de Recursos Humanos, la auditoría de infraestructura y herramientas disponibles, y la definición del mapa de datos junto con las políticas de anonimización. Esta etapa concluye con la aprobación formal de requerimientos, que constituye el hito de cierre de la fase.

La segunda fase, *Diseño*, también se extiende durante 6 semanas e incluye la definición de la arquitectura final del sistema, el modelado de datos (PostgreSQL con pgvector/FAISS), el diseño de la API y los mecanismos de seguridad (OAuth2/JWT), el prototipado de interfaces UI/UX en Figma y la documentación técnica y funcional. El cierre de esta etapa se marca con el hito Design Freeze, que asegura la validación de todos los componentes de diseño antes del desarrollo.

La tercera fase, *Implementación*, constituye el núcleo del proyecto y se desarrolla durante 17 semanas. Comprende la construcción del backend en FastAPI con control de acceso basado en roles (RBAC), la configuración de la base de datos e índice semántico, la implementación del pipeline NLP con embeddings y normalización, el desarrollo del motor híbrido de recomendación con explicabilidad (XAI), el frontend en React, la contenerización mediante Docker y Kubernetes, y la incorporación de monitoreo y observabilidad (Prometheus, Grafana, ELK).

Esta fase culmina con la integración y optimización final del MVP (Producto Mínimo Viable), hito clave que representa la primera versión completamente funcional del sistema.

La cuarta fase, *Pruebas*, tiene una duración de 6 semanas y abarca las pruebas unitarias, de integración, rendimiento y carga, así como los ensayos de usabilidad y accesibilidad. Durante esta fase se libera una versión beta interna, destinada a la validación por parte de los equipos de RR.HH y usuarios piloto, seguida de una etapa de ajustes y correcciones antes de pasar al entorno productivo.

Finalmente, la quinta fase, *Despliegue*, con una duración de 5 semanas, incluye la preparación del entorno productivo (seguridad, backups, monitoreo), el Go-Live controlado por áreas, la capacitación de usuarios y la documentación final. La fase culmina con el hito Hypercare y cierre del proyecto, que implica el soporte post-implementación y el seguimiento inicial de los indicadores de desempeño (KPIs) del sistema.

Cabe destacar que el proyecto contempla la ejecución paralela de tareas en distintas fases, lo que responde a la naturaleza multidisciplinaria del equipo y a la adopción de un enfoque ágil e iterativo.

4.6.2 Diagrama de Gannt


Para facilitar la visualización del cronograma completo, el diagrama de Gannt se presenta estructurado según las cinco fases del proyecto: análisis y planificación, diseño, implementación, pruebas y despliegue.

Cada bloque temporal muestra la duración estimada de las tareas, la secuencia de actividades y los hitos principales que marcan la evolución del desarrollo (véase figura 12).

El gráfico permite identificar y entender con claridad las tareas que se ejecutan en paralelo, así como la dependencia entre las distintas fases del ciclo de vida del sistema

Figura 12

Diagrama de Gannt completo de la propuesta



Nota. Elaboración Propia en base al Plan del Proyecto

Como se observa en la figura 13, la fase de análisis y planificación tiene una duración de seis semanas e incluye el relevamiento funcional y técnico, las entrevistas con los equipos de Recursos Humanos, la auditoría de infraestructura y la definición de políticas de anonimización.

El primer hito corresponde al Kickoff del proyecto, donde se formalizan los acuerdos de acceso a datos y se definen los lineamientos generales del desarrollo.

El hito de cierre de esta fase es la aprobación formal de los requerimientos, que valida el alcance funcional y da paso a la etapa de diseño.

Figura 13

Diagrama de Gannt en la etapa de análisis y planificación

Fase	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6
Análisis y planificación						
Kickoff + acuerdos de acceso a datos						
Relevamiento funcional y técnico						
Entrevistas con RRHH y empleados						
Auditoría de infraestructura y herramientas						
Mapa de datos + políticas de anonimización						
Aprobación de requerimientos						

Nota. Elaboración Propia en base al Plan del Proyecto

La figura 14 detalla la fase de diseño, con una duración de seis semanas, que abarca la definición de la arquitectura del sistema, el modelado de datos, el diseño de la API, la creación de prototipos UI/UX y la documentación técnica y funcional.

El hito principal de esta fase es el *Design Freeze*, que representa la validación final de las especificaciones de diseño antes del inicio del desarrollo.

Figura 14

Diagrama de Gannt en la etapa de diseño

Fase	Semana 7	Semana 8	Semana 9	Semana 10	Semana 11	Semana 12
Diseño						
Arquitectura final del sistema						
Modelo de datos (PostgreSQL + pgvector/FAISS)						
Diseño de API y seguridad (OAuth2/JWT)						
Prototipos UI/UX en Figma						
Documentación técnica y funcional						
Design Freeze						

Nota. Elaboración Propia en base al Plan del Proyecto

En la figura 15 se presenta la fase de implementación, con una duración de diecisiete semanas, que constituye el núcleo central del desarrollo.

Incluye la construcción del backend, el pipeline de procesamiento semántico, el motor híbrido de recomendación, la interfaz de usuario y la integración de contenedores y monitoreo.

El hito clave de esta fase es el MVP Integrado, que indica la consolidación de un producto funcional listo para pruebas internas

Figura 15

Diagrama de Gantt en la etapa de implementación

Fase	Semana 13	Semana 14	Semana 15	Semana 16	Semana 17	Semana 18	Semana 19	Semana 20	Semana 21	Semana 22	Semana 23	Semana 24	Semana 25	Semana 26	Semana 27	Semana 28	Semana 29
Implementación																	
Backend (FastAPI, auth, RBAC)																	
Configuración DB + índice semántico																	
Pipeline NLP (embeddings + normalización)																	
Motor híbrido de recomendación + XAI																	
Frontend (React) – vistas principales																	
Contenerización + K8s + CI/CD																	
Monitoreo/observabilidad (Prometheus/Grafana/ELK)																	
Integración y optimización final																	
MVP Integrado																	

Nota. Elaboración Propia en base al Plan del Proyecto

Como se aprecia en la figura 16, la fase de pruebas tiene una duración de seis semanas e incluye ensayos unitarios, de integración, rendimiento, usabilidad y accesibilidad.

El hito correspondiente es la versión beta interna, que marca la validación técnica y funcional del sistema antes del despliegue productivo.

Figura 16

Diagrama de Gannt en la etapa de pruebas

Fase	Semana 30	Semana 31	Semana 32	Semana 33	Semana 34	Semana 35
Pruebas						
Pruebas unitarias e integración						
Pruebas de rendimiento y carga						
Usabilidad y accesibilidad						
Ajustes y correcciones						
Beta interna						

Nota. Elaboración Propia en base al Plan del Proyecto

Finalmente, la Figura 17 presenta la fase de despliegue, con una duración de cinco semanas.

Incluye la preparación del entorno productivo, el Go-Live controlado por áreas, la capacitación de usuarios y el monitoreo inicial de indicadores.

El hito de cierre es el *Hypercare*, que representa el acompañamiento post-despliegue y la finalización formal del proyecto.

Figura 17

Diagrama de Gannt en la etapa de despliegue

Fase	Semana 30	Semana 31	Semana 32	Semana 33	Semana 34	Semana 35	Semana 36	Semana 37	Semana 38	Semana 39	Semana 40
Despliegue											
Preparación de productivo (seguridad/backups/monitor.)											
Go-Live controlado por áreas											
Capacitación + documentación											
Monitoreo + KPIs iniciales											
Hypercare / Cierre											

Nota. Elaboración Propia en base al Plan del Proyecto

4.7 Factores externos condicionantes

El desarrollo e implementación del sistema inteligente de recomendación no se realiza en un entorno aislado, sino que está influido por una serie de factores externos que pueden afectar su ejecución, sostenibilidad y adopción. Este apartado tiene por objetivo identificar dichos factores, analizar su posible impacto y proponer estrategias que permitan mitigarlos o transformarlos en oportunidades para el proyecto.

4.7.1 Factores tecnológicos

La velocidad con la que evolucionan los modelos de inteligencia artificial y las herramientas de procesamiento de lenguaje natural representa un desafío constante. Nuevos frameworks, librerías o APIs pueden volver obsoletos ciertos componentes en períodos relativamente cortos. A esto se suma la dependencia de servicios externos como Hugging Face, AWS o GitLab, que pueden modificar sus políticas o costos de uso (Gartner, 2025).

Frente a ello, el diseño del sistema contempla una arquitectura desacoplada, basada en microservicios, que permite sustituir o actualizar módulos específicos sin comprometer la integridad del conjunto.

4.7.2 Factores legales y éticos

El tratamiento de datos personales constituye un aspecto central del proyecto. En Argentina, la Ley N.º 25.326 de Protección de Datos Personales (2000) establece los principios de licitud, consentimiento informado, finalidad y seguridad en el manejo de información sensible (Portal Oficial del Estado Argentino, s.f.). Dado que el sistema propuesto analiza información

laboral como trayectorias, evaluaciones y descripciones de puesto—, resulta indispensable cumplir con los requisitos legales vigentes y con los estándares éticos internacionales.

Adicionalmente, el uso de algoritmos en procesos de desarrollo de carrera plantea riesgos asociados a la transparencia y al sesgo algorítmico, especialmente si las recomendaciones pudieran influir en decisiones de promoción o capacitación. Por otro lado, la incorporación de técnicas de explicabilidad (*Explainable Artificial Intelligence*, XAI) y la anonimización de datos son medidas fundamentales para asegurar la equidad, la auditabilidad y la confianza de los usuarios (Jobin, Ienca & Vayena, 2019, pp. 7-8).

4.7.3 Factores organizacionales y culturales

La adopción de herramientas basadas en inteligencia artificial dentro de las organizaciones puede verse condicionada por aspectos estructurales y culturales. Entre ellos se incluyen la persistencia de jerarquías rígidas, la resistencia al cambio y la falta de alineación entre las estrategias tecnológicas y los objetivos de gestión del talento. Estas condiciones pueden dificultar la integración efectiva de soluciones basadas en datos en las rutinas operativas de las áreas de Recursos Humanos.

De acuerdo con el informe *Global Human Capital Trends 2024* de Deloitte, muchas organizaciones reconocen los cambios necesarios para adaptarse al futuro del trabajo, pero experimentan una brecha entre el conocimiento de las transformaciones requeridas y su implementación efectiva, fenómeno que la consultora denomina *the knowing-doing gap* (Deloitte, 2024). Este desfase responde, en gran medida, a limitaciones de liderazgo, capacidad operativa y gestión del cambio, lo que puede retrasar la adopción de modelos de decisión basados en evidencia y el uso cotidiano de la analítica de personas.

Para mitigar este riesgo, se propone un enfoque de implementación participativa, apoyado en pilotos graduales y comunicación estratégica. La capacitación continua de los equipos de Recursos Humanos, junto con la creación de espacios de retroalimentación y aprendizaje colaborativo, puede favorecer la apropiación institucional del sistema.

4.7.4 Factores sociales y competitivos

En el plano social, la adopción de la inteligencia artificial continúa enfrentando desafíos vinculados a la confianza y la aceptación pública. La Comisión Europea destaca que, si bien la IA

ofrece un enorme potencial para transformar la ciencia, los servicios públicos y la productividad empresarial, su implementación debe centrarse en generar confianza y garantizar beneficios tangibles para las personas y la sociedad en su conjunto (European Commission, 2025). Persisten, de igual forma, percepciones ambivalentes respecto a su impacto, especialmente en torno a la automatización de tareas y la evaluación del desempeño, lo que puede generar reticencia en determinados sectores.

Por ello, será importante comunicar que el sistema propuesto no reemplaza las decisiones humanas, sino que actúa como un asistente estratégico para el desarrollo profesional, orientado a la equidad de oportunidades y la mejora de la experiencia del trabajador.

4.8 Factores internos condicionantes

Además de los factores externos, el éxito del sistema también dependerá de las condiciones internas de la organización que lo implemente. En este sentido, hay aspectos que pueden jugar tanto a favor como en contra del proyecto, y que conviene tener en cuenta desde el inicio.

Uno de los más importantes es la infraestructura tecnológica disponible. La propuesta se apoya en herramientas modernas de inteligencia artificial y procesamiento de lenguaje natural, por lo que requiere entornos estables, seguros y con buena capacidad de procesamiento. Si la organización no cuenta con servidores adecuados, políticas claras de respaldo o entornos de prueba, la puesta en marcha podría demorarse o presentar limitaciones técnicas.

También resulta clave el nivel de madurez digital del área de Recursos Humanos, que será la principal usuaria del sistema. Si el equipo está poco familiarizado con herramientas analíticas o con el uso de datos para la toma de decisiones, será necesario acompañar la implementación con instancias de formación. Un proceso de capacitación progresivo, enfocado en el uso práctico de la plataforma y en la interpretación de los resultados, puede marcar la diferencia en la adopción y el aprovechamiento real del sistema.

Otro factor determinante es el apoyo del liderazgo y la alineación con la estrategia institucional. Cuando la dirección respalda el proyecto y lo integra en sus objetivos de desarrollo del talento, la adopción se vuelve mucho más fluida. En cambio, si se percibe como una iniciativa aislada del área técnica o de RR. HH., corre el riesgo de diluirse o perder continuidad.

Por último, es necesario considerar la disponibilidad de tiempo y recursos del equipo interno. Implementar un sistema de este tipo requiere dedicación para tareas de configuración,

pruebas y mejora continua. Contar con una planificación realista, que contemple los tiempos de cada etapa y las responsabilidades asignadas, ayuda a sostener el proyecto sin generar sobrecarga operativa.

Por lo tanto, los factores internos pueden convertirse en aliados o en obstáculos según cómo se gestionen. Identificarlos a tiempo y abordarlos de forma planificada ayuda a que la organización no solo adopte una nueva tecnología, sino que también fortalezca su cultura de aprendizaje y de toma de decisiones basadas en datos.

Conclusiones

El desarrollo de este trabajo permitió examinar un problema que atraviesa a muchas organizaciones actuales: la dificultad que enfrentan los empleados para identificar oportunidades de crecimiento y proyectar su trayectoria profesional dentro de estructuras laborales cada vez más complejas. A partir de esta problemática, se avanzó en el diseño de una solución tecnológica orientada a mejorar esa visibilidad y a acompañar los procesos de movilidad interna mediante un análisis más profundo y sistemático de la información disponible.

La solución planteada se apoya en técnicas que permiten identificar vínculos entre las habilidades de cada empleado y los requisitos de distintas posiciones, con el propósito de brindar sugerencias claras y fundamentadas. Un elemento central del enfoque adoptado es que las recomendaciones no sustituyen la decisión humana, sino que funcionan como una guía que facilita la planificación profesional y reduce la incertidumbre respecto de las alternativas disponibles.

En el plano técnico, se planteó una arquitectura distribuida compuesta por servicios independientes, donde cada módulo cumple una función específica dentro del proceso de recomendación. Esta estructura integra un motor de recomendación híbrido, componentes de análisis semántico y un módulo de explicabilidad de resultados. El sistema se apoya en representaciones vectoriales de documentos y perfiles, junto con algoritmos de similitud que permiten comparar habilidades y requisitos con precisión. El diseño desacoplado facilita la actualización individual de cada módulo, permite escalar los procesos de cálculo según la demanda y habilita la incorporación progresiva de nuevas fuentes de datos o modelos de lenguaje más avanzados. A su vez, se identificaron factores internos y externos que pueden influir en su adopción, destacándose la necesidad de contar con infraestructura adecuada, políticas de gobierno de datos y una cultura organizacional que favorezca la transparencia y el uso responsable de herramientas tecnológicas.

La propuesta se nutrió de los hallazgos analizados en el Estado del Arte, donde distintas investigaciones demostraron el potencial del procesamiento de lenguaje natural y de la inteligencia artificial explicable para optimizar la gestión del talento. Este marco permitió consolidar un diseño adaptable y aplicable a contextos organizacionales reales. No obstante, futuras líneas de desarrollo

deberán orientarse a validar el modelo con datos reales y a fortalecer los mecanismos de retroalimentación continua que mejoren la precisión de las recomendaciones.

El valor principal de esta propuesta radica en demostrar que la inteligencia artificial puede ser una aliada estratégica del desarrollo humano dentro de las organizaciones. Más que automatizar decisiones, el sistema se plantea como un asistente que amplía la comprensión de las trayectorias, promueve la autonomía de las personas y favorece una gestión del talento más justa y basada en evidencia.

Futuras líneas de trabajo

A partir de esta propuesta surgen distintas oportunidades para seguir desarrollando y validando el sistema en contextos reales. Estas líneas representan una continuidad natural del proyecto, orientada a consolidar su validez práctica y a profundizar su aporte al desarrollo de carrera dentro de las organizaciones.

Validación en entornos organizacionales. Una primera línea de trabajo consiste en poner a prueba el modelo en empresas que cuenten con programas de desarrollo profesional activos. El propósito es observar su comportamiento con datos reales y analizar su impacto en indicadores como la movilidad interna, la satisfacción de los empleados y la retención del talento. Llevar adelante pilotos en entornos controlados permitiría identificar aciertos y oportunidades de mejora, a partir de evidencia concreta y medible.

Aprendizaje adaptativo y actualización continua. Otra línea apunta a que el sistema evolucione de manera dinámica a medida que cambian las competencias, los perfiles o las necesidades del negocio. Para lograrlo, se podrían explorar mecanismos de aprendizaje incremental y retroalimentación constante, de modo que el modelo mantenga su coherencia y actualidad sin requerir nuevos procesos completos de entrenamiento cada vez que se incorporan datos.

Integración con herramientas corporativas. También resulta valioso avanzar hacia la integración del sistema con plataformas ya existentes, como portales de aprendizaje, sistemas de evaluación del desempeño o soluciones de gestión del talento. Esta articulación permitiría reunir información de diferentes fuentes y ofrecer una visión más completa de la trayectoria de cada persona dentro de la organización.

Dimensión cultural y ética. Por último, una línea de trabajo especialmente relevante consiste en analizar las implicancias culturales y éticas que conlleva incorporar tecnología en los procesos de desarrollo profesional. Comprender cómo los empleados perciben la presencia de algoritmos en decisiones que involucran su crecimiento, y cómo se construye la confianza hacia

estas herramientas, permitirá diseñar políticas más participativas, transparentes y coherentes con los valores de cada organización.

Acrónimos

AI RMF	Artificial Intelligence Risk Management Framework
AWS	Amazon Web Services
BERT	Bidirectional Encoder Representations from Transformers
BoW	Bag of Words
CF	Collaborative Filtering
CI/CD	Continuous Integration / Continuous Deployment
CTR	Click Through Rate
DEI	Diversity, Equity and Inclusion
ELK	Elasticsearch
ESA	Explicit Semantic Analysis
ETL	Extract, Transform, Load
FAISS	Facebook AI Similarity Search
GPU	Graphics Processing Unit
I+D	Investigación y Desarrollo
IDF	Inverse Document Frequency
ISO	International Organization for Standardization
JWT	JSON Web Token
LIME	Local Interpretable Model-Agnostic Explanations
LSI	Latent Semantic Indexing
MAE	Mean Absolute Error
MAP	Mean Average Precision
MLM	Masked Language Modeling
MVP	Minimum Viable Product
myOTM	My Open Talent Market
NIST	National Institute of Standards and Technology
NLP	Natural Language Processing
NSP	Next Sentence Prediction

OIDC	OpenID Connect
OTM	Open Talent Market
PLN	Procesamiento de Lenguaje Natural
QA	Quality Assurance
RBAC	Role-Based Access Control
REST	Representational State Transfer
RMSE	Root Mean Square Error
SBERT	Sentence-BERT
SHAP	SHapley Additive exPlanations
SR	Social Regularization
SVD	Singular Value Decomposition
TF	Term Frequency
TF-IDF	Term Frequency
UI	User Interface
XAI	Explainable Artificial Intelligence

Anexos

Anexo I. Implementación técnica del modelo de recomendación

El presente anexo complementa los apartados 4.2.1.1, 4.2.1.2 y 4.2.1.3 de la propuesta de intervención, brindando un mayor nivel de detalle técnico sobre la implementación conceptual del modelo de recomendación semántica.

A continuación, se presentan ejemplos de código y resultados de ejecución que ilustran el funcionamiento de los componentes centrales del modelo. Los fragmentos fueron desarrollados en lenguaje python, utilizando bibliotecas contemporáneas de procesamiento de lenguaje natural y aprendizaje automático entre ellas *sentence-transformers*, *NumPy* y *pandas*. Las figuras incluidas no representan una aplicación operativa completa, sino una demostración conceptual destinada a exponer la lógica del sistema y su potencial de implementación.

El proceso inicia con la normalización de las habilidades extraídas de los currículos y descripciones de puestos. En esta etapa, el sistema unifica sinónimos y expresiones equivalentes para asegurar la coherencia terminológica antes de proceder al análisis semántico. La figura 18 muestra un ejemplo de código que realiza este procedimiento de estandarización mediante un diccionario de sinónimos.

Figura 18

Ejemplo de extracción y normalización de habilidades


```
skills_normalization.py X
skills_normalization.py
1 # skills_normalization.py
2 # Este módulo podría integrarse como microservicio independiente
3 # dentro del pipeline de preprocesamiento (ETL de habilidades).
4 # from fastapi import FastAPI # Posible exposición como endpoint REST
5 # import redis # Para cachear resultados y optimizar rendimiento
6
7
8 import re
9
10 SINONIMOS = {
11     "gestión de proyectos": {"project management", "coordinación de proyectos", "pm"},
12     "sql": {"t-sql", "postgres", "mysql"},
13     "python": {"programación en python", "py"},
14     "etl": {"data pipelines", "integración de datos"},
15     "liderazgo": {"leadership", "jefatura de equipo"},
16 }
17 # Nota: en una implementación real, esta función podría llamarse desde
18 # un flujo de ingesta automatizado (Airflow o Celery) para procesar perfiles a gran escala.
19
20 def normalizar_skills(texto: str) -> set[str]:
21     t = texto.lower()
22     t = re.sub(r"[~a-záéíóúñ0-9\s-]", " ", t)
23     halladas = set()
24     for canon, alias in SINONIMOS.items():
25         variantes = {canon, *alias}
26         if any(re.search(rf"{re.escape(v)}\b", t) for v in variantes):
27             halladas.add(canon)
28
29     return halladas
30
```

Nota. El fragmento muestra el proceso de estandarización de habilidades mediante la unificación de sinónimos antes del análisis semántico. Fuente: Elaboración propia.

Posteriormente, el sistema convierte los textos normalizados en representaciones vectoriales mediante el modelo *Sentence-BERT*, lo que permite comparar descripciones diferentes en función de su significado y no solo de coincidencias literales. Este procedimiento posibilita medir la afinidad conceptual entre un perfil y un puesto. La figura 19 presenta el código correspondiente a esta operación, donde se genera el embedding y se calcula la similitud por coseno entre los vectores resultantes.

Figura 19

Ejemplo de código para el cálculo de similitud semántica entre perfil y puesto



```

semantic_similarity.py x
semantic_similarity.py
1 # semantic_similarity.py
2 # Este módulo aplica embeddings contextuales con Sentence-BERT.
3 # import faiss # Para búsquedas semánticas a gran escala
4 # o pgvector en PostgreSQL como base de datos vectorial persistente.
5
6
7 from sentence_transformers import SentenceTransformer, util
8
9 modelo = SentenceTransformer("all-MiniLM-L6-v2")
10
11 # Nota: los embeddings pueden cachearse en disco o en base de datos vectorial
12 # (pgvector o FAISS) para evitar recomputación y mejorar el rendimiento.
13
14
15 def embed(texto: str):
16     return modelo.encode(texto, normalize_embeddings=True)
17
18 def similitud_semantica(perfil_txt: str, puesto_txt: str) -> float:
19     vp, vj = embed(perfil_txt), embed(puesto_txt)
20     return float(util.cos_sim(vp, vj).item())
21

```

Nota. El código implementa el cálculo de similitud por coseno utilizando representaciones vectoriales generadas con la librería *sentence-transformers*. Fuente: Elaboración propia.

Con los valores de similitud obtenidos, el modelo combina distintos factores —similitud semántica, coincidencia de competencias y preferencias del usuario, para generar un puntaje híbrido explicable que determina la pertinencia de la recomendación. En la figura 20 se muestra el fragmento de código que implementa este cálculo y produce una justificación textual comprensible, destacando las coincidencias y brechas de habilidades detectadas.

Figura 20

Ejemplo de código para la generación del puntaje híbrido y la explicación de recomendaciones

```

hybrid_ranking.py x
# hybrid_ranking.py
# Módulo central del motor de recomendación híbrido.
# En producción podría exponerse como servicio independiente mediante FastAPI.
4
5
6
7 > def cobertura_skills(skills_perfil: set[str], skills_puesto: set[str]) -> float:-
11
12 def recomendar(perfil_txt: str, puesto_txt: str, skills_req: set[str], prefs: set[str] = None):
13     """
14     Combina tres factores para generar un puntaje híbrido:
15     - similitud semántica (Sentence-BERT embeddings)
16     - cobertura de competencias (Jaccard u otra métrica)
17     - ajuste a preferencias del usuario (ponderación personalizada)
18     Los pesos ( $\alpha$ ,  $\beta$ ,  $\gamma$ ) pueden ajustarse según validaciones empíricas.
19     Este diseño mantiene trazabilidad para explicabilidad (XAI).
20     """
21     sp = normalizar_skills(perfil_txt)
22     sj = skills_req
23     sem = similitud_semantica(perfil_txt, puesto_txt)
24     cov = cobertura_skills(sp, sj)
25     pref = cobertura_skills(prefs or set(), sj)
26
27     score = 0.60*sem + 0.25*cov + 0.15*pref
28
29     explicacion = {
30         "coinciden": sorted(list(sp & sj)),
31         "faltantes": sorted(list(sj - sp)),
32         "componentes": {
33             "semantica": round(sem, 3),
34             "cobertura_skills": round(cov, 3),
35             "ajuste_preferencias": round(pref, 3),
36         },
37     }
38     return round(score, 3), explicacion
39

```

Nota. El fragmento integra criterios semánticos, de habilidades y preferencias declaradas para generar un puntaje reproducible y explicable. Fuente: Elaboración propia.

Finalmente, el sistema traduce las brechas identificadas en recomendaciones formativas personalizadas, vinculando las habilidades faltantes con las opciones de capacitación disponibles en el catálogo de la organización.

La figura 21 muestra el código que implementa esta funcionalidad, completando así el ciclo de recomendación

Figura 21

Ejemplo de código para las sugerencias de capacitaciones a partir de brechas de habilidades

```

training_recommendations.py •
training_recommendations.py
1 # training_recommendations.py
2 # Este módulo traduce brechas de habilidades en sugerencias formativas.
3 # En una versión ampliada, podría integrarse con APIs externas de LMS
4 # (Learning Management Systems) como Moodle, Cornerstone o Udemy Business.
5
6
7 CATALOGO = {
8     "gestión de proyectos": ["Curso interno: Fundamentos de PM", "Certificación: Scrum Master"],
9     "etl": ["Taller: ETL con Python", "Curso: Airflow básico"],
10    "liderazgo": ["Programa interno de liderazgo", "Mentoría de líderes"],
11    "sql": ["SQL Avanzado (Postgres)"],
12    "python": ["Python para Analítica de Datos"],
13 }
14
15 def sugerir_capacitaciones(skills_faltantes: list[str]) -> dict[str, list[str]]:
16     return {s: CATALOGO.get(s, []) for s in skills_faltantes}
17

```

Nota. El sistema vincula las brechas detectadas con cursos o programas formativos registrados en el catálogo institucional. Fuente: Elaboración propia.

Por último, la figura 22 presenta la salida de ejecución del modelo de recomendación en consola. En ella pueden observarse las coincidencias entre el perfil y el puesto, las brechas detectadas y las capacitaciones sugeridas.

Figura 22

Salida de ejecución del modelo de recomendación

```

(.venv) damianl-ltm7hmy:tf damian.lopez$ python3 main.py

=== Resultado de la recomendación ===
Puntaje final: 0.48
Coinciden: ['gestión de proyectos', 'liderazgo', 'python', 'sql']
Faltantes: ['etl']

=== Capacitaciones sugeridas ===
etl: Taller: ETL con Python, Curso: Airflow básico

```

Nota. Elaboración propia

Anexo II. Esquema de base de datos y flujo de información


El presente anexo amplía la sección 4.2.2.1 de la propuesta, en la cual se describió la arquitectura general del sistema inteligente de recomendación. Su finalidad es mostrar de manera la estructura lógica de la base de datos y el flujo de información que conecta los módulos del sistema. El modelo se diseñó siguiendo principios de integridad referencial, normalización y

escalabilidad, a fin de asegurar la coherencia entre los datos estructurados y los procesados mediante técnicas semánticas.

Como se observa en la figura 23, la base de datos está compuesta por cuatro entidades principales: Perfil, Puesto, Recomendación y Capacitación. Las tablas Perfil y Puesto almacenan información sobre empleados y posiciones laborales, respectivamente, mientras que la tabla Recomendación vincula ambas a partir de los resultados generados por el motor híbrido. La tabla *Capacitación* conserva el catálogo de cursos y programas formativos asociados a las brechas detectadas. Además del nivel relacional, el sistema incluye una base vectorial (*pgvector* o *FAISS*) utilizada para las búsquedas por similitud semántica a partir de los embeddings generados por Sentence-BERT.

Figura 23

Esquema lógico de la base de datos del sistema de recomendación




Nota. Elaboración Propia

El flujo de información que integra estos componentes se desarrolla en etapas sucesivas, desde la ingesta de datos hasta la generación de recomendaciones. Primero se incorporan los perfiles, descripciones de puesto y catálogos de formación desde las fuentes organizacionales.

Luego, los textos se normalizan para unificar terminología y reducir ambigüedad. Posteriormente, el módulo semántico transforma las descripciones en representaciones vectoriales y calcula su similitud. Con estos resultados, el motor híbrido genera las recomendaciones personalizadas y las registra en la base de datos junto con las sugerencias formativas. Finalmente, la información procesada se presenta en la interfaz del sistema y alimenta el módulo de retroalimentación de usuarios, tal como se ilustra en la figura 24.

Figura 24

Flujo de información entre los módulos del sistema



Nota. Elaboración Propia

Anexo III. Vistas ampliadas de la interfaz del sistema de recomendación


Este anexo amplía la descripción presentada en la sección 4.2.2.4, ofreciendo ejemplos visuales complementarios que muestran cómo se materializan los principios de diseño de

usabilidad, accesibilidad, consistencia visual y personalización en el sistema propuesto. Desde la perspectiva del empleado, se ilustran las vistas principales asociadas a recomendaciones, trayectorias y acompañamiento conversacional.

Como se observa en la figura 25, la vista principal organiza las recomendaciones en tarjetas que muestran el puesto sugerido, las habilidades coincidentes, las áreas a fortalecer y una breve justificación textual. Esta disposición prioriza la legibilidad y permite comparar oportunidades de desarrollo de manera directa.


Figura 25

Vista principal del panel de recomendaciones



Nota: Mockup principal. Imágenes generadas con IA de Canva. Fuente propia

En la figura 26 se presenta la vista de trayectoria y desarrollo profesional, donde el usuario visualiza un recorrido compuesto por etapas intermedias hacia un rol objetivo. Cada etapa detalla competencias requeridas, nivel actual y acciones sugeridas de formación.


Figura 26*Vista ampliada de trayectoria y desarrollo profesional*

Nota. Mockup conceptual. Imágenes generadas con IA de Canva. Fuente propia

Por último, la figura 27 muestra el asistente conversacional integrado en el portal. El usuario puede formular consultas en lenguaje natural y recibir respuestas breves, contextualizadas y accionables, vinculadas con recomendaciones, trayectorias o cursos disponibles. La ventana del asistente se ubica de manera no intrusiva y mantiene la coherencia visual del entorno.

Figura 27

Asistente conversacional integrado al sistema



Nota. Mockup conceptual. Imágenes generadas con IA de Canva. Fuente propia

Referencias

Link de drive a libros/artículos utilizados en las citas:

<https://drive.google.com/drive/folders/1lkiK1Pk380DX00Fk6-NPB2tpeq5jyn6B?usp=sharing>

Chiavenato, I. (2009). *Gestión del talento humano* (3.^a ed.). McGraw-Hill.

<https://gc.scalahed.com/recursos/files/r161r/w24756w/gestion-del-talento-humano-chiavenato.pdf>

Greenhaus, J. H., Callanan, G. A., & Godshalk, V. M. (2018). *Career management for life* (5th ed.).

Huang, X., Yang, F., Zheng, J., & Wu, Y. (2023). *Personalized human resource management via HR analytics and artificial intelligence: Theory and implications*.

https://www.researchgate.net/publication/370567830_Personalized_human_resource_management_via_HR_analytics_and_artificial_intelligence_Theory_and_implications

Mercy. (2025). *The role of AI-driven HR chatbots in enhancing employee experience and organizational efficiency*.

Otani, N., Bhutani, N., & Hruschka, E. R. (2024). *Natural language processing for human resources: A survey*. <https://arxiv.org/abs/2410.16498>

Tambe, P., Cappelli, P., & Yakubovich, V. (2019). Artificial intelligence in human resources management: Challenges and a path forward. <https://doi.org/10.1177/0008125619867910>

Gurusamy, V., & Kannan, S. (2014). Preprocessing techniques for text mining

Vijayarani, S., Ilamathi, M. J., & Nithya, M. (2015). Preprocessing techniques for text mining – An overview.

Hernández, M., & Gómez, J. (2013). *Aplicaciones de procesamiento de lenguaje natural*. Revista Politécnica, 32(1), 87–96.

https://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/32/pdf

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. <https://arxiv.org/abs/1810.04805>

Guan, Z., Yang, J. Q., Yang, Y., Zhu, H., & Li, W. (2024). JobFormer: Skill-aware job recommendation with semantic-enhanced transformer. <https://arxiv.org/html/2404.04313v1>

De Vos, S., De Smedt, J., Verbruggen, M., & Verbeke, W. (2022). *Internal placement: Job recommender systems with social regularization*. https://feast-ecmlpkdd.github.io/archive/2022/papers/FEAST2022_paper_4436.pdf

Aspen Institute. (2023). Case study: Upskilling for career mobility at PepsiCo. Future of Work Initiative. <https://www.aspeninstitute.org/wp-content/uploads/2025/05/Case-Study-UpSkilling-for-Career-Mobility-at-Pepsico.pdf>

Bersin, J., & Enderes, K. (2022). The open talent marketplace: Schneider Electric's experience. Josh Bersin Academy / Deloitte Insights. https://resources.gloat.com/wp-content/uploads/TM-22_10-Schneider-Electric-Pioneers-the-Talent-Marketplace-Case-Study-3.pdf

IBM. (2021). Welcome to the Watson Career Coach Trial: Administrator guide (trial version). IBM Documentation. <https://www.ibm.com/docs/en/SSYKAV?topic=version-welcome-watson-career-coach-trial>

Team Draup. (2025, mayo 13). Rethinking skills for AI with Draup's data-rich talent intelligence platform. Draup. <https://draup.com/talent/blogs/rethinking-skills-for-ai-with-draups-data-rich-talent-intelligence-platform>

Patil, R., Boit, S., Gudivada, V., & Nandigam, J. (2023). A survey of text representation and embedding techniques in NLP <https://ieeexplore.ieee.org/abstract/document/10098736>

-
- Cornerstone, & Lighthouse Research. (2023). *2023 Global Talent Mobility Report*. Lighthouse Research & Advisory. <https://www.cornerstoneondemand.com/resources/article/2023-talent-mobility-download/>
- LinkedIn. (2025). *Workplace Learning Report 2025: The rise of career champions*. LinkedIn Learning. <https://learning.linkedin.com/resources/workplace-learning-report>
- Quantum Workplace. (2025). *Career pathing and internal mobility guide*. Quantum Workplace. <https://www.quantumworkplace.com/future-of-work/career-pathing>
- Ricci, Francesco & Rokach, Lior & Shapira, Bracha. (2011). *Recommender Systems Handbook*
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2010). *Recommender systems: An introduction*.
- Lops, P., de Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. En F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor (Eds.), *Recommender systems handbook* (pp. 73–105). Springer.
- Aggarwal, C. C. (2016). *Recommender systems: The textbook*. <https://doi.org/10.1007/978-3-319-29659-3>
- Felfernig, A., & Burke, R. (2008). Constraint-based recommender systems: Technologies and research issues
- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. <https://doi.org/10.1109/TKDE.2005.99>
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. In *Proceedings of the International Conference on Artificial Intelligence*
- Jadon, A., & Patil, A. (2024). *A comprehensive survey of evaluation techniques for recommendation systems* <https://arxiv.org/abs/2312.16015>

-
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence embeddings using Siamese BERT-networks. <https://doi.org/10.18653/v1/D19-1410>
- National Institute of Standards and Technology. (2023). Artificial Intelligence Risk Management Framework <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>
- International Organization for Standardization. (2018). ISO 9241-11:2018 Ergonomics of human-system interaction. <https://www.iso.org/standard/63500.html>
- Nielsen, J. (1994). 10 usability heuristics for user interface design. Nielsen Norman Group. <https://www.nngroup.com/articles/ten-usability-heuristics/>
- Ribeiro, M., Singh, S., & Guestrin, C. (2016). "Why Should I Trust You?": Explaining the Predictions of Any Classifier. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 1135–1144. <https://arxiv.org/abs/1602.04938>
- iProfesional. (2025, 15 de febrero). *Los buenos sueldos que pagan las empresas de software en Argentina y los tres perfiles más buscados*. <https://www.iprofesional.com/management/422473-excelente-sueldo-que-pagan-empresas-software-en-argentina-2025>
- OpenQube. (2025, febrero). *Encuesta de Sueldos IT Argentina 2025.01*. <https://sueldos.openqube.io/encuesta-sueldos-2025.01>
- Atlassian. (s.f.). Plan Jira Software Cloud Standard: la solución para equipos en crecimiento. <https://www.atlassian.com/es/software/jira/standard>
- AWS. (s.f.-a). Amazon S3. <https://aws.amazon.com/es/s3/>
- AWS. (s.f.-b). Servicio de bases de datos no relacionales: Amazon DynamoDB. <https://aws.amazon.com/es/pm/dynamodb>

Advanced Micro Devices. (s.f.). *Ryzen 7 desktop processors*.

<https://www.amd.com/en/products/processors/desktops/ryzen.html>

NVIDIA Corporation. (s.f.-a). *NVIDIA T4 Tensor Core GPU*. [https://www.nvidia.com/en-](https://www.nvidia.com/en-us/data-center/tesla-t4/)

[us/data-center/tesla-t4/](https://www.nvidia.com/en-us/data-center/tesla-t4/)

Amazon. (2025). Precios de componentes y estaciones de trabajo. <https://www.amazon.com>

GitLab. (s.f.). GitLab Premium. <https://about.gitlab.com/pricing/>

Teclab. (2025). ¿Qué hace y cuánto gana un Quality Assurance?

<https://teclab.edu.ar/general/que-hace-y-cuanto-gana-un-quality-assurance/>

Gartner. (2025). *Top Strategic Technology Trends 2025*. Gartner Research.

<https://www.gartner.com/en/articles/top-technology-trends-2025>

Deloitte. (2024). *Global Human Capital Trends 2024: Prioritizing human performance in the boundaryless world of work*. Deloitte Insights

<https://www.deloitte.com/us/en/insights/topics/talent/human-capital-trends/2024/prioritizing-human-performance.html>

European Commission. (2025). *Artificial Intelligence*. [https://digital-](https://digital-strategy.ec.europa.eu/en/policies/artificial-intelligence)

[strategy.ec.europa.eu/en/policies/artificial-intelligence](https://digital-strategy.ec.europa.eu/en/policies/artificial-intelligence)

Jobin, A., Ienca, M., & Vayena, E. (2019). Artificial Intelligence: the global landscape of ethics guidelines <https://arxiv.org/pdf/1906.11668>

Madhumithaa, N., Sharma, A., Adabala, S. K., Siddiqui, S., & Kothinti, R. R. (2025).

Leveraging AI for personalized employee development: A new era in human resource management. Advances in Consumer Research, 2(1), 134–141. <https://acr-journal.com/>

Atlassian. (2025). *Arquitectura de microservicios*. Atlassian.

<https://www.atlassian.com/es/microservices/microservices-architecture>

Hall, D. T. (2002). *Careers in and out of organizations*. Sage Publications.

<https://sk.sagepub.com/book/mono/preview/careers-in-and-out-of-organizations.pdf>

Hernández-Sampieri, R., Fernández Collado, C., & Baptista Lucio, M. P. (2014).. *Metodología de la investigación (6ª ed.)*. McGraw-Hill.

Laurano, M. (2023). *The new era of internal mobility: Driving value through skills, metrics, and a talent-first approach*. Aptitude Research. https://www.apitudereseach.com/wp-content/uploads/2023/06/Apt_NewInternalMobility_Report-0323_Final.pdf

Williamson, J., & Carroll, D. (2023, November 20). *How to start smart with a talent marketplace*. MIT Sloan Management Review. <https://sloanreview.mit.edu/article/how-to-start-smart-with-a-talent-marketplace/>