



Máster de Formación Permanente en Inteligencia Artificial
Trabajo de Final de Máster (TFM)

Plan de investigación

Título

“La inteligencia artificial como herramienta estratégica para la mejora continua en
procesos de reclutamiento y selección”

Autor del TFM:

Fabián Andrés Espinosa Vásquez

UNIVERSIDAD EUROPEA DE VALENCIA

2024/2025

Tutor de TFG:

Prof. Víctor Manuel Yeste Moreno

AGRADECIMIENTOS

Quiero manifestar mi más honesto agradecimiento a mi tutor Víctor Manuel Yeste Moreno, por su apoyo, aporte de su conocimiento, y entrega total mediante el desarrollo de esta Trabajo de Fin de Máster. Su acompañamiento ha sido esencial para lograr sacar adelante esta meta.

Seguidamente le doy gracias a mi esposa, la cual ha sido parte fundamental de amor, motivación, comprensión y animo durante este proceso de desarrollo profesional; el estar a mi lado en cada paso de este camino, han sido pilar esencial para sacar adelante este reto académico.

De igual manera, doy gracias también a todo el cuerpo docente de la Universidad, por impartir sus conocimientos y sabiduría mediante experiencias vividas, compromiso total y paciencia en plenitud enfocado a fortalecer mi construcción educativa con una visión integral y actualizada.

No puedo olvidar agradecer a mis compañeros de formación, cada uno contribuyo a mi crecimiento profesional y maneras diferentes de ver la vida, sus ideas originales y formas de pensar me hacen creer que un mejor mundo nos espera.

Finalmente, a la inteligencia artificial, el cual fue eje central de este trabajo, además, por ser herramienta de innovación, dando apertura a nuevas posibilidades en el ámbito del reclutamiento y la mejora prolongada de los procesos organizativos y de selección.

RESUMEN

La digitalización de los procesos de reclutamiento ha provocado un aumento en el volumen y la complejidad de las candidaturas, lo que ha puesto a prueba la efectividad de los sistemas tradicionales y ha tenido un impacto negativo en la experiencia de los candidatos. Este Trabajo de Fin de Máster presenta el diseño, desarrollo e implementación de un sistema multiagente basado en inteligencia artificial, cuya finalidad es automatizar y perfeccionar las etapas más críticas del proceso de selección: primero, en la extracción organizada de los datos en los currículos que se envían en formatos PDF, WORD, o JPEG, así como en el análisis y filtrado inteligente de los candidatos.

El sistema que se propone se fundamenta en el uso de modelos de lenguaje de código abierto y en frameworks de orquestación, lo que garantiza aspectos clave como la privacidad, la explicabilidad y la escalabilidad. Esperando obtener una mejora significativa en la precisión del en la extracción organizada de los datos y proceso de coincidencia, así como una reducción en los tiempos de procesamiento de las candidaturas y un incremento en la satisfacción tanto de los reclutadores como de los candidatos. En este contexto, se abordan las limitaciones técnicas y éticas que aún persisten, así como las posibles líneas de desarrollo futuro, incluyendo la implementación de estrategias en modelos de código abierto, además, mitigar sesgos y la expansión de la metodología a entornos internacionales.

PALABRAS CLAVE

Inteligencia artificial, Experiencia del candidato, Procesamiento de lenguaje natural, Sistemas multiagente, Reclutamiento automatizado, PDF, WORD, JPEG, Modelos LLM de código abierto.

ABSTRACT

The digitization of recruitment processes has led to an increase in the volume and complexity of applications, which has tested the effectiveness of traditional systems and had a negative impact on the candidate experience. The Master's Thesis presents the design, development, and implementation of a multi-agent system based on artificial intelligence, whose purpose is to automate and refine the most critical stages of the selection process: first, in the organized extraction of data from resumes sent in PDF, WORD, or JPEG format, as well as in the analysis and intelligent filtering of candidates.

The proposed system is based on the use of open-source language models and orchestration frameworks, which guarantee key aspects such as privacy, explainability, and scalability. We expect to achieve a significant improvement in the accuracy of organized data extraction and matching processes, as well as a reduction in application processing times and an increase in satisfaction for both recruiters and candidates. In this context, we address the technical and ethical limitations that still exist, as well as possible lines of future development, including the implementation of strategies in open-source models, mitigating biases, and expanding the methodology to international environments.

KEYWORDS

Artificial intelligence, Candidate experience, Natural language processing, Multi-agent systems, Automated recruitment, PDF, WORD, JPEG, Open-source LLM models

Tabla de contenido

AGRADECIMIENTOS	3
RESUMEN.....	4
PALABRAS CLAVE.....	4
ABSTRACT	5
KEYWORDS	5
1. INTRODUCCIÓN	10
2. OBJETIVOS.....	12
2.1. Objetivo general	12
2.2. Objetivos específicos	12
3. PROBLEMA DE INVESTIGACIÓN.....	14
4. JUSTIFICACIÓN DE LA INVESTIGACIÓN: RELEVANCIA, ORIGINALIDAD Y CONTRIBUCIÓN A LA LITERATURA	19
5. MARCO TEÓRICO.....	20
5.1 Inteligencia Artificial: Fundamentos y Evolución.....	20
5.2 Inteligencia Artificial en los Recursos Humanos	21
5.3 Procesos tradicionales vs. digitalizados de selección de personal.....	22
5.4 Cribado automático de currículums: tecnología, desafíos y evolución	24
5.5 ¿Cómo funcionan los ATS?.....	25
5.6 Limitaciones de los sistemas ATS.....	26
5.7 Hacia un cribado inteligente: el papel de la IA	27
5.8 Agentes Inteligentes y Arquitectura Multiagente	27
5.9 Tipos de agentes y sus características.....	28
5.10 Propuesta de arquitectura multiagente para selección de personal.....	29
5.11 Coordinación e interoperabilidad	30
5.12 Sistemas Inteligentes en la Selección de Talento	31
5.13 Análisis semántico y PLN aplicado a CVs.....	31
5.14 Matching inteligente entre perfil y oferta	32
5.15 Generación automatizada de feedback al candidato.....	33
5.16 Casos reales y herramientas disponibles	34
5.17 Comparativa crítica: ATS tradicionales vs. Agentes Inteligentes	35
5.18 Limitaciones fundamentales de los ATS	35
5.19 Ventajas competitivas de los sistemas multiagente.....	36
5.20 Los beneficios de esta arquitectura reúnen lo presente:	36
5.21 Implicaciones estratégicas	37
6. METODOLOGÍA	39

6.1 Metodologías consideradas y elección de CRISP-DM(Q)	39
6.1.1 Aplicación del enfoque al sistema multiagente	40
6.1.2 Fases Metodológicas según CRISP-MD(Q)	41
6.1.3 Relación entre las fases y los agentes	42
6.2 Metodologías consideradas y elección de CRISP-DM(Q)	43
6.3 Aplicación del enfoque al sistema multiagente	43
6.4 Fases Metodológicas según CRISP-MD(Q)	44
6.5 Relación entre las fases y los agentes	45
6.6 Fase 1: Desarrollo del Agente 1 – Extracción y Autocompletado	47
6.6.1 Contexto y motivación	48
6.6.2 Enfoque	48
6.6.3 Interrogante de partida	48
6.6.4 Preguntas operativas	49
6.6.5 Justificación técnico-práctica	49
6.6.6 Objetivos operativos	50
6.6.7 Hipótesis de trabajo	50
6.6.8 Resultado esperado	51
6.7 Evaluación de la etapa	51
6.8 Herramientas y tecnologías empleadas	51
6.9 Backend y orquestación	51
6.10 Extracción y normalización	52
6.11 LLM en local (open-source)	52
6.12 Frontend y experiencia de usuario	53
6.13 Almacenamiento y versionado	53
6.14 Formulario inteligente	54
6.14.1 Procedimiento y estructura del formulario	55
6.14.2 Estructura de carpetas del formulario	56
6.14.3 Endpoints, schemas y rutas	57
6.14.4 Swagger (backend) y UX/UI (frontend)	58
6.15 Informe de resultados en la extracción de campos fijos	60
6.15.1 Resultados cuantitativos	60
6.15.2 Interpretación de los datos	62
6.15.3 Interpretación de los datos	63
6.15.3 Conclusión	64
6.15.3 Conclusión	64

6.16 Fase 2: Desarrollo del Agente 2 – Evaluación y Visualización de Candidatos.....	65
6.16.1 Objetivos de la fase.....	65
6.16.2 Herramientas y tecnologías empleadas.....	65
6.16.3 Flujo funcional y actividades principales	66
6.16.4 Métricas y criterios de calidad.....	67
6.16.5 Limitaciones y desafíos	67
6.17 Fase 3: Desarrollo del Agente 3 – Generación de Feedback Automatizado	68
6.17.1 Herramientas y tecnologías empleadas.....	69
6.17.2 Flujo funcional y actividades principales	69
6.17.3 Métricas y criterios de calidad.....	70
6.17.4 Limitaciones y desafíos	71
6.18 Proceso de integración de agentes	72
6.19 Pruebas funcionales y de interoperabilidad.....	73
6.20 Métricas globales de desempeño	74
6.21 Comparación con sistemas tradicionales.....	75
6.22 Experiencia de usuario y feedback	76
6.23 Hardware y software.....	77
6.24 Entorno de desarrollo.....	78
6.25 Visión general y arquitectura del sistema.....	78
6.26 Agente 1: Extracción y autocompletado de formularios	79
6.27 Tecnologías empleadas:.....	79
6.28 Justificación técnica:.....	80
6.29 Tabla resumen de tecnologías por agente.....	80
6.30 Justificación global de las elecciones técnicas	80
7 ANÁLISIS.....	81
7.1 Propósito de la evaluación.....	81
7.2 Definiciones de métricas	82
7.2.1 Experiencia / Educación (F1 por bloque).....	82
7.2.2 Teléfono (robustez).....	83
7.2.3 Latencia	83
7.2.4 Protocolo de evaluación.....	83
7.3 Resultados.....	84
8 CONCLUSIÓN	85
8.1 Viabilidad del enfoque híbrido y relación coste-beneficio.....	85
8.2 El verdadero “motor” de la calidad: Data Preparation y validaciones	86

8.3 La UI con políticas convierte precisión técnica en valor operativo	86
9 LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN.....	87
10 Impacto SOCIOECONÓMICO y sostenibilidad	88
10.1 Democratización tecnológica para pymes	88
10.2 Mercado laboral y calidad del empleo.....	88
10.3 Alineación con la Agenda 2030 (ODS).....	88
10.4 Ética, gobernanza y cumplimiento (UE)	89
10.4.1 GDPR – Decisiones automatizadas	89
10.4.2 Marcos internacionales de ética (UNESCO y OCDE)	90
10.5 Sostenibilidad ambiental (energía y huella)	90
10.6 Riesgos y medidas de mitigación	90
11 Declaración del uso de la Inteligencia Artificial.....	92
11.1 Herramientas empleadas y grado de asistencia	92
11.2 Contenido no asistido por IA.....	93
11.3 Protección de datos y confidencialidad	93
12 REFERENCIAS	94
13 ANEXOS.....	100
Anexo I.....	100
Anexo II.....	101
ÍNDICE DE TABLAS	102
ÍNDICE DE FIGURAS	103
ÍNDICE DE ACRÓNIMOS Y ABREVIACIONES.....	104

1. INTRODUCCIÓN

En un mercado global de constante evolución y altamente competitivo, las organizaciones tienen constantes desafíos a la necesidad de adaptarse constantemente a los avances tecnológicos para mejorar la eficiencia de sus procesos internos. En este contexto, la inteligencia artificial (IA) ha emergido como herramienta clave en la automatización y optimización de operaciones complejas en diversas áreas, una de ellas es la gestión de recursos humanos. Las soluciones de IA en RRHH se implementan en la automatización de tareas administrativas, como la gestión de permisos y la incorporación de empleados, hasta el soporte en decisiones estratégicas mediante el análisis de datos de comportamiento y compromiso de los empleados.

Gartner (s.f.) menciona cómo la IA está coexistiendo en los procesos de recursos humanos, haciendo que las operaciones sean más eficientes y liberando a los profesionales de RRHH para que se enfoquen en responsabilidades más estratégicas. Esto se logra a través de la optimización del proceso de contratación, donde la IA puede identificar talentos de diversos orígenes y reducir sesgos, así como en la gestión de habilidades habilitada por la IA, que proporciona datos dinámicos para informar sobre movilidad interna, adecuación de candidatos y necesidades de aprendizaje.

Ante esta constante evolución tecnológica, quizás uno de los retos más significativos se encuentra en el área de recursos humanos y su campo en el proceso de reclutamiento en las compañías que tradicionalmente han estado sujetos a altos niveles de subjetividad, demoras administrativas y una limitada capacidad de procesamiento cuando se manejan grandes volúmenes de candidaturas.

Los Sistemas de Seguimiento de Candidatos (ATS) que utilizan medianas y grandes organizaciones muchas veces tienen desventajas e inconvenientes por su diseño, que suele presentar limitaciones en términos de experiencia del usuario y flexibilidad, con procesos de aplicación tediosos, interfaces poco intuitivas y algoritmos de filtrado excesivamente estrictos que pueden excluir candidatos altamente calificados.

En este contexto, la inteligencia artificial (IA) emerge como una herramienta digital y disruptiva con el potencial de transformar radicalmente los procesos de reclutamiento a partir de la automatización en la cribación de cada curriculum hasta el análisis avanzado de grandes volúmenes de datos, la IA ofrece la posibilidad de optimizar cada etapa del ciclo de vida del reclutamiento.

Como resultado ante estos desafíos, el presente proyecto se enmarca en esta realidad y plantea una solución basada en el diseño de una arquitectura de multi-agentes inteligentes capaces de mejorar, automatizar y aportar valor estratégico al proceso de reclutamiento; articulándose en dos fases interconectadas, cada una gestionada por un agente especializado.

2. OBJETIVOS

2.1. Objetivo general

Desarrollar un sistema de reclutamiento digital basado en agentes inteligentes, los cuales estarán interconectados con el propósito de optimizar el proceso en el reclutamiento de candidatos que más se adapte a la oferta de empleo; mejorando la eficiencia operativa.

El sistema inicia con la aplicación a la vacante, seguidamente escogiendo los perfiles que más encajan con la oferta y finalizando en la selección de candidatos; estos resultados serán visualizados por medio de una interfaz de usuario, con herramientas como filtros, gráficos, así como la justificación de sus decisiones a través de explicaciones interpretables para el reclutador.

Finalmente, a través de la automatización y el análisis avanzado de datos, este sistema busca superar las limitaciones de los métodos tradicionales y de las plataformas (ATS), proporcionando una solución más estratégica, transparente, centrada en el candidato.

2.2. Objetivos específicos

1. Implementar un agente inteligente con la funcionalidad de extraer datos de forma automatizada, organizada y estructurada, además, con la capacidad de autocompletar y sugerir información faltante o errónea de currículums en formato PDF o Word y asignarlos automáticamente a un formulario de aplicación laboral, con una tasa mínima de precisión del 85%.
2. Evaluar la eficacia del segundo agente con capacidad de analizar y clasificar el total de las candidaturas, priorizando perfiles más afines a los requisitos de la oferta y generando visualizaciones justificadas para el reclutador.
3. Comparar el rendimiento del sistema propuesto frente a un ATS tradicional en términos de cribación y visualizaciones de candidatos, calidad de selección y la experiencia del

usuario, a través de métricas fundamentales para su comparativa como tiempo promedio por aplicación procesada y nivel de satisfacción del candidato.

3. PROBLEMA DE INVESTIGACIÓN

En los últimos años, el proceso de selección de personal se ha visto desbordado por el creciente volumen y diversidad de candidaturas que reciben las organizaciones. Tanto así que una sola oferta de empleo llega a recibir un promedio de 250 currículums, según datos de la industria (Hiring Branch, 2024). Esta sobrecarga genera inevitablemente una revisión superficial de los perfiles o currículums, donde la mayoría de los reclutadores, que en la mayoría de las veces trabajan contra reloj, llegando a analizar una fracción limitada de los candidatos. Esta práctica no solo incrementa la probabilidad de perder perfiles idóneos que no destacan a primera vista, sino que también crea un entorno propicio para perpetuar sesgos involuntarios.

A pesar de la proliferación de Sistemas de Seguimiento de Candidatos (ATS), desarrollados para mitigar este volumen, estos suelen depender de filtros automáticos basados en palabras clave y reglas estáticas (Teamtaylor, s.f.). Esta tecnología presenta limitaciones significativas en la comprensión semántica de las candidaturas solicitadas; un postulante puede ser descartado al no utilizar el término exacto que el sistema busca en pocas palabras, “las famosas keywords”, aunque posea la experiencia y las habilidades requeridas. La falta de transparencia en los criterios de descarte de estas herramientas a menudo convierte el proceso en una "caja negra", tanto para el candidato como para el propio reclutador al no entender como selecciona a los candidatos.

Los procesos manuales, por su parte permiten un análisis más matizado, y se vuelve ineficaz cuando presenta un alto volumen, volviendo este proceso ineficiente, costoso y propenso a errores humanos y sesgos subjetivos. Investigaciones en el contexto español han demostrado empíricamente la existencia de estos sesgos. Un estudio realizado por la Universidad Pompeu Fabra y la Universidad de Granada reveló que los candidatos con nombres de origen extranjero tienen un 30% menos de probabilidades de ser contactados para una entrevista en comparación con perfiles con currículums idénticos, pero nombres de origen local (RTVE, 2024). Esto evidencia cómo los prejuicios inconscientes pueden distorsionar la equidad del proceso de selección.

Sumado a lo anterior, la experiencia del candidato suele verse afectada negativamente. La mayoría de los postulantes no reciben feedback claro ni comprensible sobre el motivo de su descarte, y en la mayoría de las ocasiones ni les informan si siguen o no en el proceso el tal

llamado “ghosting” lo que genera frustración y una percepción negativa de la marca empleadora (Grupo Castilla, s.f.). De hecho, hasta un 60% de los candidatos abandonan procesos de solicitud por su complejidad o duración (Hiring Branch, 2024), lo que demuestra una desconexión entre las expectativas de los aspirantes y las prácticas de las empresas. Esta falta de comunicación y cuidado daña el *employer branding* y reduce el interés de talento cualificado en futuras oportunidades (Observatorio RH, 2023).

El avance reciente de la inteligencia artificial, y en particular de los modelos de lenguaje grandes (LLMs) y las arquitecturas multiagente, abre nuevas posibilidades para abordar estas limitaciones. A diferencia de los ATS tradicionales, los LLMs permiten un análisis semántico y contextual del contenido de un currículum, pudiendo inferir habilidades y competencias, aunque no estén explícitamente listadas (Wang et al., 2023). Por su parte, los sistemas multiagente permiten diseñar arquitecturas modulares donde agentes de IA especializados colaboran en distintas fases del proceso, desde el cribado inicial hasta la comunicación personalizada con el candidato, creando un flujo de trabajo más eficiente, robusto y transparente (Jennings & Wooldridge).

Sin embargo, la implementación práctica de estas soluciones, especialmente cuando se integran modelos de IA gratuitos y de código abierto, presenta retos técnicos y éticos significativos. como el manejo de datos personales contenidos en los currículums exige un riguroso cumplimiento de normativas de protección de datos como el GDPR, un desafío crucial al utilizar herramientas cuya gobernanza de datos no es totalmente transparente.

Por estas razones, surge la necesidad de investigar, diseñar y validar un sistema multiagente basado en IA que sea capaz de automatizar, optimizar y transparentar el proceso de selección de personal, mejorando tanto la eficiencia de los reclutadores como la experiencia de los candidatos, al tiempo que se establecen mecanismos de control para garantizar la equidad y la protección de datos.

A continuación, algunas opiniones reales en cuanto a la cribación por ATS y sin feedback al momento de ser descartados en el proceso de selección corroborando así lo anterior:

Figura 1. Testimonios reales sobre procesos de selección.



Miguel de la Rosa López • 3er+
Técnico de IT || Soporte IT || Técnico HelpDesk ||
6 días • 🔄

[+ Seguir](#)

Las entrevistas fantasma: ¿tanto cuesta mandar un correo?

Hace unas semanas hice una entrevista en la que, además de pasar por el proceso habitual, tuve que grabarme en vídeo respondiendo a preguntas predefinidas. Hasta ahí, bien. La empresa se comprometía a dar una respuesta, independientemente del resultado.

Pues aquí sigo esperando.

Es agotador cómo algunas empresas exigen dedicación, preparación y hasta pasar por procesos largos y fríos... para luego desaparecer sin decir ni un simple "gracias por tu tiempo, pero no encajas". ¿De verdad cuesta tanto mandar un correo automático?


No es solo por saber si pasas o no. Es por respeto al tiempo de los candidatos. Es por profesionalidad.

Si queremos procesos de selección más humanos, esto tiene que cambiar.

¿También os ha pasado? Me gustaría leer vuestras experiencias.

(Captura de pantalla. Soporte sobre procesos de selección más humanos)

Figura 2. Testimonios reales sobre procesos de selección.



Micaela Ayelen Velazquez • 3er+
 Operador de producción en Ferrero | Manipulación de alimentos
 2 semanas •

+ Seguir

ESTOY EN BÚSQUEDA LABORAL. Y no voy a mentir: el proceso es AGOTADOR.


Dedico horas a mejorar mi CV, a completar formularios eternos donde me piden que vuelva a escribir toda la información que ya está en mi currículum. Cada postulación es una mezcla de esperanza y ansiedad.

Pero lo más difícil no es la espera. Es el SILENCIO.

Mandás un CV y no sabés si alguien lo leyó. Hacés una entrevista y no te vuelven a escribir. Aplicás a decenas de ofertas y, en la mayoría, ni siquiera recibís un "gracias por postularte". Y entonces la duda empieza a meterse en la cabeza: ¿Estoy haciendo algo mal? ¿Hay algo en mí que no es suficiente?

Es un proceso estresante, que desgasta, que hace replantearse muchas cosas. Pero algo que aprendí en este camino es lo importante que es tener un sostén. En mi caso, es mi pareja, quien me recuerda mi valor cuando yo mismo lo pongo en duda. Pero puede ser cualquier persona en quien confíes: un amigo, un familiar, un colega. Alguien que te escuche, que te aliente y que te ayude a no perder el foco. Porque buscar trabajo no debería ser un camino solitario.

Si estás en la misma, te entiendo. Y si trabajás en selección, ojalá que este post sirva para recordar lo importante que es dar una respuesta, por mínima que sea. Porque del otro lado hay personas, no solo candidatos.


 11.367


655 comentarios • 725 veces compartido

(Captura de pantalla. Tiempos y respuesta en procesos de selección)

Figura 3. Testimonios reales sobre procesos de selección.

Sugerencias ... ×



israel Zambrano • 3er+
 Auxiliar Administrativo - Servicio al Cliente - Operación de caja bancaria...
 1 semana • 

+ Seguir

Cuando voy a las entrevistas, me dicen que les gusta mi perfil, mi experiencia, mi desempeño, mi forma de ser, el profesionalismo con la que manejo las preguntas y las respondo, que mi perfil se adapta y encaja con la vacante y las necesidades de la empresa.

Pero luego de la entrevista, ya sea está la 1ra o 2da viene un silencio, y luego me informan que se decidieron por otro candidato y que me desean éxito en mi búsqueda laboral




es cuándo yo me pregunto que hice mal, que pasó si todo parecía a ver ido bien ?

Esto es algo que a lo largó de estos 7 meses sin empleo, me ah sucedido reiterativas veces.

Es muy frustrante, y a veces siento no poder mas, la deudas se acumulan y la necesidad crece.

Estimados Reclutadores sean sinceros con sus candidatos, ayúdenos con el feedback para saber en que mejorar,

referir a un buen candidato con mucho potencial a otras vacantes, no les quita mas de 2 minutos.



 1476

225 comentarios • 59 veces compartido

(Captura de pantalla. Feedback necesario)

4. JUSTIFICACIÓN DE LA INVESTIGACIÓN: RELEVANCIA, ORIGINALIDAD Y CONTRIBUCIÓN A LA LITERATURA

Este estudio surge como respuesta a la necesidad apremiante de actualizar y perfeccionar los procesos de reclutamiento en un contexto caracterizado por una creciente digitalización y una competencia cada vez más intensa por atraer talento. La revisión de la literatura revela que, a pesar de la adopción generalizada de sistemas ATS, las organizaciones continúan enfrentando dificultades relacionadas con la eficiencia, la transparencia y la experiencia de los candidatos (Appvizer, 2025). Los modelos tradicionales suelen filtrar perfiles mediante reglas rígidas o la búsqueda de palabras clave, lo que a menudo resulta en la exclusión de potenciales talentos y genera frustración tanto en los responsables de reclutamiento como en los postulantes, afectando el proceso de manera significativa.

La singularidad de este Trabajo de Fin de Máster reside en el desarrollo de un sistema multiagente, modular y fundamentado en inteligencia artificial de código abierto, que integra de manera automatizada diversas funciones. Este sistema permite la extracción inteligente de datos a partir de currículums en formato PDF y WORD, así como el filtrado y clasificación de candidatos de forma transparente y comprensible. Además, genera retroalimentación automática y personalizada para cada perfil. Este enfoque supera las limitaciones de los sistemas ATS comerciales al poner énfasis en la explicabilidad, la personalización y la capacidad de adaptación, aspectos que la literatura actual sobre inteligencia artificial aplicada a recursos humanos considera fundamentales. (Molnar, 2022).

La principal aportación de esta investigación radica en la validación experimental de una arquitectura accesible, ética y escalable para el reclutamiento digital, diseñada con el propósito de ser replicada y adaptada para pequeñas y medianas organizaciones de diferentes sectores. Además, el trabajo de fin de máster proporciona una evaluación comparativa tanto cuantitativa como cualitativa frente a los métodos tradicionales, enriqueciendo así la literatura existente con resultados prácticos y propuestas de mejora en el ámbito del procesamiento del lenguaje natural y la experiencia del candidato.

5. MARCO TEÓRICO

5.1 Inteligencia Artificial: Fundamentos y Evolución

La Inteligencia Artificial por sus siglas (IA) comenzó con un enfoque totalmente teórico en la década de los 50 y ha evolucionado hasta convertirse en el presente como el cambio más disruptivo del siglo XXI. Su principal propósito es desarrollar sistemas informáticos basados en algoritmos capaces de realizar tareas que normalmente requieren inteligencia humana, algunos de estos ejemplos aplicables son el reconocimiento de patrones, toma de decisiones, la traducción de idiomas y la predicción de eventos futuros (Russell & Norvig, 2021). Esta tecnología abarca varios campos como el aprendizaje automático (machine learning), el aprendizaje profundo (Deep learning) el procesamiento del lenguaje natural (PLN), visión por computadora, agentes inteligentes y los sistemas expertos.

El aprendizaje profundo (deep learning) es una de las ramas más importantes en la historia reciente de la IA, ya que su uso ha permitido un salto cualitativo en la capacidad de los sistemas para aprender basándose en grandes volúmenes de datos sin intervención humana directa. Tal ha sido este avance que ha impulsado aplicaciones y herramientas exitosas en varios sectores como la salud, finanzas, comercio y administración pública (Pieffet, 2021; García Novoa & Hernández Rodríguez, 2024).

La AI se clasifica según su nivel de autonomía, capacidad de aprendizaje e inteligencia en tres categorías:

1. IA débil (Narrow AI): especializada en una tarea concreta un ejemplo concreto son los asistentes virtuales.
2. IA general (AGI): con la capacidad de igualar la inteligencia humana en múltiples sectores.
3. IA superinteligente: hipotética y superior a la inteligencia humana.

El crecimiento exponencial de esta tecnología genera debates éticos y jurídicos relevantes. Según lo cita Pérez-Ugena (2024) hace advertencias sobre el uso extensivo de sistemas autónomos en sectores como la salud, la justicia o la seguridad nacional plantea riesgos y vulnerabilidades sobre la privacidad de los datos, el respeto a los derechos fundamentales y la transparencia algorítmica. Debido a esto, organismos como lo menciona la UNESCO (2021) y la Unión Europea promueven marcos éticos y normativos dando prioridad a los principios como la no discriminación, y la supervisión humana que siempre debe estar presente.

La IA no es solo una tecnología emergente al alcance de todos, sino una infraestructura de innovación que transforma sectores económicos, sociales y políticos de forma radical. Es tal su impacto que exige una aproximación crítica y estratégica asegurando que su desarrollo sea beneficioso, equitativo y sostenible.

5.2 Inteligencia Artificial en los Recursos Humanos

La gestión del talento humano es una parte fundamental en las organizaciones, de ellos depende que las personas que contratan para diversas áreas sean candidatos que cumplan muy bien su rol, de esto depende el éxito o fracaso de una empresa. Sin embargo, la transformación digital basados en soluciones IA ha permitido automatizar tareas repetitivas, mejorando la objetividad en la toma de decisiones y personalizando las estrategias de desarrollo profesional.

En este contexto, la IA se presenta como aliada estratégica para los departamentos de Recursos Humanos (RRHH), especialmente en procesos de la selección de personal, evaluaciones de desempeño y la retención del talento (León Espinoza, 2024; Ramos Hernández et al., 2025).

La IA en RRHH se implementa mediante algoritmos de aprendizaje automático como el machine learning capaces de analizar grandes volúmenes de datos (por ejemplo, curriculums, informes de desempeño, encuestas de clima laboral) para identificar patrones de comportamiento, predicciones de rotación de personal, o incluso propensión al éxito en un cargo determinado. En el área de reclutamiento, estos sistemas automatizan el cribado de curriculums, predicen la idoneidad de un candidato y proporcionan retroalimentación inmediata (Naranjo Gaibor, 2025).

Existen plataformas como HireVue o Pymetrics que desarrollan e implementan modelos basados en IA para evaluar microexpresiones faciales, tonos de voz o respuestas escritas; por otro lado, soluciones como Recruitee o Personio incorporan módulos de IA para ordenar candidatos según su compatibilidad con la descripción del puesto (Personio, 2024).

Sin embargo, estas tecnologías también enfrentan desventajas importantes: **Sesgos algorítmicos:** si los datos de entrenamiento están sesgados, el sistema puede reproducir discriminaciones (género, edad, etnia).

1. Falta de transparencia: muchos modelos son cajas negras que dificultan explicar decisiones.
2. Resistencia organizacional: trabajadores y líderes pueden desconfiar de sistemas automatizados.

En este sentido, la IA se debe implementar y que aprenda de forma ética y responsable, en RRHH se debe considerar estándares internacionales como los propuestos por la UNESCO (2021), fomentar la auditabilidad de los algoritmos y garantizar siempre una supervisión humana en las decisiones clave.

La IA no va a sustituir al gestor de talento, pero sí le permite dedicar más tiempo a tareas estratégicas, dejando en manos de los algoritmos aquellas funciones repetitivas y de alto volumen. Así, se habilita una gestión más eficaz, orientada por datos, y potencialmente más justa.

5.3 Procesos tradicionales vs. digitalizados de selección de personal

Los procesos de selección de personal en las compañías siempre se han basado en un enfoque manual, donde el reclutador revisa cada una de las postulaciones de forma individual, analiza y ejecuta entrevistas presenciales para luego hacer una toma de decisiones basadas en su experiencia subjetiva. Si bien este enfoque permite cierta cercanía con el candidato, también implica limitaciones al momento de la eficiencia, estandarización y escalabilidad y más para empresas medianas y grandes (Observatorio de Recursos Humanos, 2025).

Con la masificación del acceso a internet y la creación de plataformas digitales de empleo, el número de candidatos por vacante se multiplica exponencialmente año tras año. Según iSmartRecruit (s.f.), el 40% de los responsables de selección revisan un currículum durante menos de 2 minutos, y hasta un 75% de los CV pueden ser descartados sin ser leídos completamente, incluso algunos ni los ven debido al volumen de currículums. Esto claramente ha impulsado la necesidad de automatizar el cribado inicial y racionalizar el proceso mediante herramientas tecnológicas.

En este contexto, emergen los Sistemas de Seguimiento de Candidatos (ATS), que permiten filtrar CVs según palabras clave, formación, experiencia previa o formato del documento. Plataformas como Workday, SAP SuccessFactors, Bizneo, han adoptado funcionalidades de análisis semántico, gestión automatizada de entrevistas y scoring de perfiles (Appvizer, 2025; Personio, 2024).

Sin embargo, aunque aportan beneficios, los ATS tradicionales presentan debilidades críticas: Primero, requieren que los candidatos adapten su CV a un formato específico para evitar ser descartados automáticamente. Segundo, penalizan a perfiles que no incluyen ciertas palabras clave exactas, aunque cumplan con los requisitos. Tercero, no explican las razones de descarte al candidato, generando frustración y desconfianza (Psico-Smart, 2024).

La digitalización del reclutamiento permite optimizar tiempos, reducir costos y aumentar la trazabilidad de los procesos, pero también hace evidente la necesidad de soluciones más inteligentes, empáticas, adaptables, usables, objetivas y no tan estrictas, como las que ofrece la inteligencia artificial aplicada en estos procesos.

Tabla 1. Comparación entre métodos tradicionales, sistemas ATS y sistemas multiagente basados en IA

Característica	Método tradicional	Sistema ATS	Sistema Multiagente con IA
Tiempo promedio por currículum	Método tradicional	<30 segundos (filtrado automático)	<10 segundos + razonamiento contextual
Evaluación semántica	Limitada, subjetiva	Básica, palabras clave	Completa: entidades, contexto y similitud
Retroalimentación al candidato	Manual (ocasional)	Genérica o inexistente	Personalizada, generada por el agente
Capacidad de escalar a >100 candidatos	Muy limitada	Media	Alta: procesamiento paralelo y distribuido
Transparencia en decisiones	Alta (humana)	Baja (filtro oculto)	Alta (razonamiento explicable del agente)
Experiencia del usuario	Alta (razonamiento explicable del agente)	Fría, poco interactiva	Amigable, guiada por agentes conversacionales

Fuente: Elaboración propia con base en Appvizer (2025), y Russell & Norvig (2021).

La presente tabla muestra como el ingreso de agentes inteligentes facilita la superación de las principales barreras de los métodos actuales, incluyendo los procesos manuales como automatizados. Al unir la capacidad de análisis semántico profundo con retroalimentación activa y procesamiento paralelo, los sistemas multiagente emerge con un avance estratégico hacia procedimientos más competentes, interpersonales y ajustables.

5.4 Cribado automático de currículums: tecnología, desafíos y evolución

La cribación de currículos (CV Screening) se considera una de las etapas más densas dentro del transcurso del reclutamiento, ya que obliga a que el número de candidatos sea limitado, escogiendo solo aquellos que cumplan con los requisitos mínimos del puesto. Cuando la demanda laboral está siendo muy exigente, esta fase tiene a realizar revisiones de un gran volumen de postulaciones para una sola vacante, lo que proporciona un gran desgaste de evaluación manual minucioso.

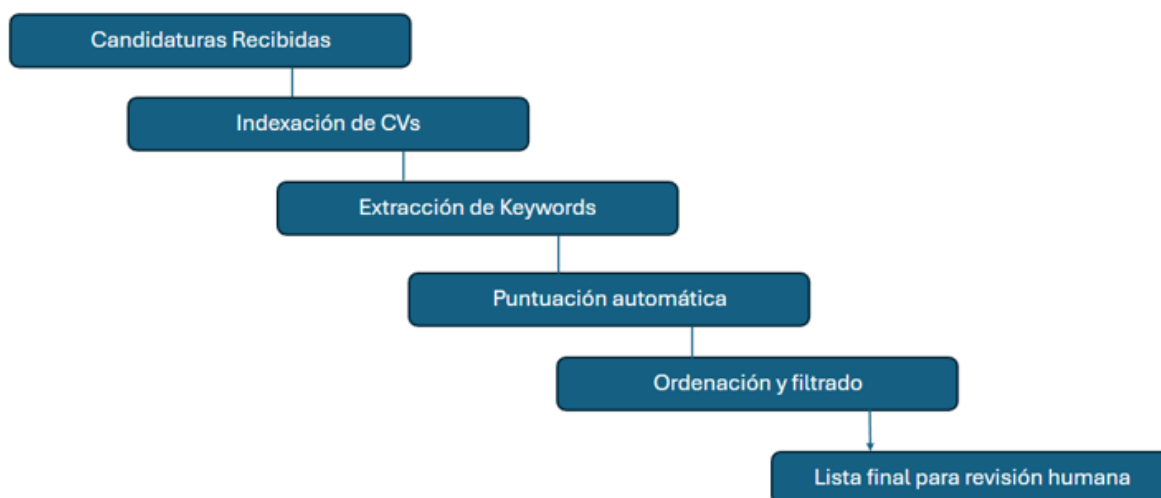
Con el fin de incrementar la eficiencia en el proceso de cribación, las organizaciones han incorporado Sistemas de Seguimiento de Candidatos (AST, por sus siglas en inglés), los cuales mecanizan la recepción, organización y filtrado inicial de candidaturas. Los presentes utilizan algoritmos que se encargan de encontrar simultaneidad entre palabras claves en el curriculum y los requisitos expuestos en la oferta laboral (10 software de reclutamiento para fichar al mejor talento en 2025).

5.5 ¿Cómo funcionan los ATS?

El funcionamiento básico de un ATS se centra en los siguientes pasos:

1. Indexación: El CV del candidato es escaneado y transformado a texto mediante OCR si es necesario.
2. Extracción de palabras clave: Se reconocen conceptos relacionados con la oferta vs las funciones desempeñadas en los cargos.
3. Ponderación y puntuación: Cada coincidencia con la oferta suma puntos para una puntuación total (scoring).
4. Clasificación: Los CV son organizados de mayor a menor puntuación para favorecer la revisión por parte del reclutador.
5. Filtrado automático: En algunos casos, los perfiles por debajo de cierto puntaje son descartados sin verificación humana (Teamtailor, s.f.)

Figura 4. Proceso de cribado automático mediante ATS



Fuente: Elaboración propia con base en Elementapp.Ai

5.6 Limitaciones de los sistemas ATS

A pesar de su manejo y utilización en el amplio proceso de selección dentro del área de contratación de Recursos Humanos, los ATS tradicionales destacan en varias limitaciones que pueden alterar la calidad del proceso de selección:

Sensibilidad exagerada al formato: Un CV mal organizado, hecho en plataformas de diseño como Canva o con formato no comprensible puede ser descartado automáticamente, sin importar la calidad del contenido que pueda contener este (Psico-Smart, 2024).

Falta de análisis contextual: Los ATS no son creados para comprender relaciones semánticas a profundidad, por lo que pueden fallar al encontrar sinónimos, trayectorias laborales no lineales o habilidades equivalentes.

Falsos negativos y sesgo algorítmico: Perfiles altamente competentes pueden ser excluidos por no incluir las palabras clave exactas. Esto reproduce sesgos y reduce la diversidad (Personio, 2024).

Experiencia deficiente del postulante: La mayoría de los ATS no otorgan retroalimentación al candidato. Esto genera frustración, alta percepción de injusticia y daña la marca empleadora (LinkedIn, 2024; Humansmart, 2024).

Un estudio del Observatorio de Recursos Humanos (2025)⁶ indica que más del 60% de los postulantes consideran negativa su experiencia al postularse en plataformas manejadas por ATS, especialmente por la falta de información sobre el estado de su solicitud.

5.7 Hacia un cribado inteligente: el papel de la IA

Mediante estas limitaciones, la integración de técnicas de IA permite adoptar cribado semántico e inteligente, basado en:

1. Análisis de contexto: rastreo de entidades clave, trayectorias profesionales no lineales y habilidades intercambiables (IBM, 2023; Gartner, 2024).
2. Explicabilidad: el sistema puede demostrar por qué un candidato fue seleccionado o descartado (Deloitte, 2025).
3. Retroalimentación automática: agentes inteligentes pueden producir mensajes personalizados a cada candidato no admitido (Human Resources Today, 2025).

Estas mejoras son factibles mediante el uso de agentes inteligentes especializados en el análisis de documentos, unificados en una arquitectura multiagente. Tal arquitectura no sustituirá el juicio humano, sino que lo complementa, facilitando al reclutador encaminarse a perfiles de alto potencial con una mayor rapidez, menor sesgo y mejor información (Accenture, 2024).

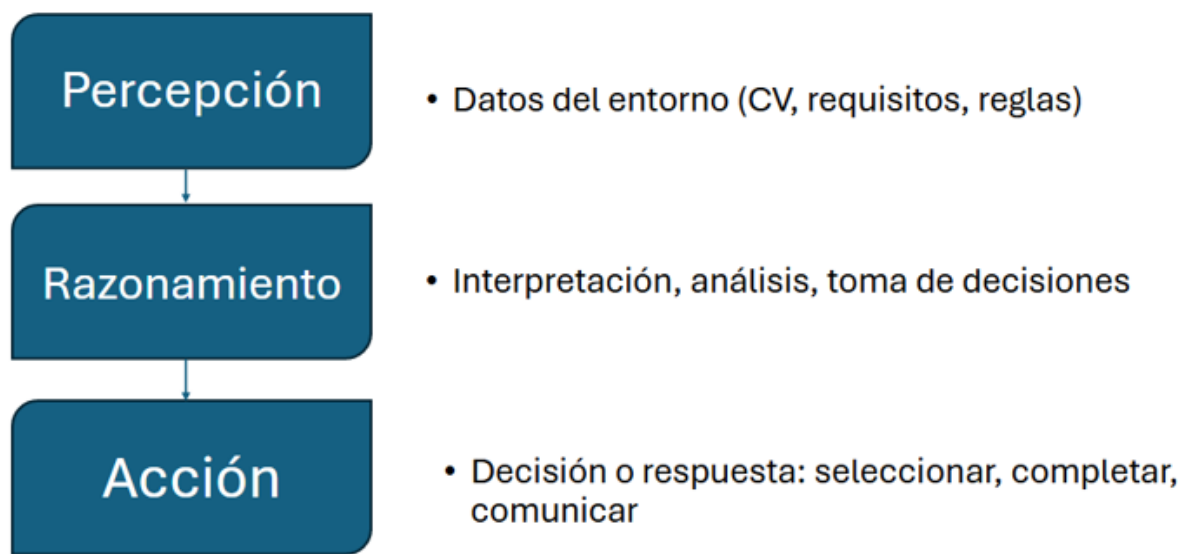
5.8 Agentes Inteligentes y Arquitectura Multiagente

La idea de agente inteligente emerge a partir del campo de la Inteligencia Artificial como un ente capaz de comprender su entorno, entender sobre él y proceder de manera autónoma para llevar a cargo uno o varios objetivos propuestos. (Russell y Norvig 2021) expone

un agente como “cualquier cosa que puede percibir su entorno a través de sensores y actuar sobre ese entorno mediante actuadores”.

Estos agentes no se ejecutan solamente como líneas de código estáticas, sino que contienen un periodo activo de operación basado en la percepción, el razonamiento y la acción, conocido como ciclo de percepción-decisión-acción, representado en la siguiente figura:

Figura 5. Ciclo básico de un agente inteligente



Fuente: Adaptado de Russell y Norvig (2022).

5.9 Tipos de agentes y sus características

En cuanto a su diversidad, los agentes pueden etiquetarse en numerosos tipos:

1. Agentes reactivos simples: atienden a estímulos inmediatos sin preservar memoria.
2. Agentes basados en modelos: custodia un modelo interno del mundo.
3. Agentes con objetivos: ejecuta su función de acuerdo con metas definidas.

4. Agentes con capacidad de aprendizaje: perfecciona su desempeño con el tiempo (agentes adaptativos).

Este diseño abarca una arquitectura multiagente, esto quiere decir que incluye un sistema compuesto por múltiples agentes enfocados y especializados, los cuales interactúan entre sí para dar solución de manera conjunta a un problema complejo: en este caso el proceso de selección de personal. Esta arquitectura es escalable, distribuida y modular, lo cual permite dividir tareas según objetivos funcionales (*AI agents solutions*, 2025).

5.10 Propuesta de arquitectura multiagente para selección de personal

La siguiente figura presenta la arquitectura conceptual propuesta para este proyecto, la cual está compuesta por tres agentes:

Figura 6. Arquitectura multiagente para la selección automatizada de candidatos.



Fuente: Elaboración propia.

Tabla 2. Funciones y beneficios de los agentes propuestos

Agente	Funciones principales	Beneficios esperados
Agente 1	Extracción de datos del CV y autocompletado	Reduce errores, mejora UX, acelera el proceso de postulación
Agente 2	Evaluación masiva de candidatos y generación de ranking	Optimiza decisiones del reclutador, aplica criterios objetivos
Agente 3	Generación de retroalimentación automatizada	Mejora la experiencia del candidato, fomenta procesos más humanos

Fuente: Elaboración propia.

5.11 Coordinación e interoperabilidad

Dentro de un conjunto multiagente, la coordinación entre agentes es clave. Esto puede ser un éxito mediante:

1. cambio de mensajes (protocolo ACL o APIs internas).
2. Un “agente orquestador” que coordine flujos y tareas.
3. Bases de datos o memoria compartida que contienen información global del proceso. (Russel & Norvig, 2021).

Para el presente proyecto, se ofrece una coordinación descentralizada, donde uno a uno de los agentes activa en cierta etapa determinada de flujo, pero al mismo tiempo tiene la capacidad de interactuar con los datos generados por los anteriores. El presente modelo

disminuye los cuellos de botella, donde permite colaborar de manera paralela y aumenta la tolerancia a errores.

5.12 Sistemas Inteligentes en la Selección de Talento

La admisión de sistemas inteligentes dentro del proceso de selección ha proporcionado un cambio a fondo respecto en la forma en que las organizaciones identifican, valorar y fidelizar el talento humano. A diferencia de los ATS convencionales, los sistemas inteligentes contienen técnicas avanzadas de inteligencia artificial (IA) como procesamiento de lenguaje natural (PLN), machine learning y análisis semántico, dando paso a un análisis más a fondo y contextualizada con respecto al perfil del candidato (Revista de climatología Vol.24 - 2024)

5.13 Análisis semántico y PLN aplicado a CVs

El procesamiento del lenguaje natural (PLN) da oportunidad a que los sistemas comprendan, interpreten y generen lenguaje humano. Implementado al reclutamiento, el PLN abre el análisis a currículums escritos en lenguaje natural para determinar:

1. Categorías relevantes: nombre, universidad, cargos, empresas, años de experiencia.
2. Habilidades técnicas y blandas.
3. Historia laboral (línea de tiempo y evolución).
4. Simultaneidad semántica con los requisitos del puesto (sinónimos, conceptos relacionados).

Herramientas como Ollama, spaCy, BERT (Jacob Devlin, 2019) o GPT-4 (OpenAI, 2023), han dejado ver un avance a niveles superiores en cuanto a tareas de análisis semántico a fondo, traspasando los filtros clásicos por palabras clave. Estos modelos no solamente

dejan ver conceptos, sino que también se puede apreciar su significado en contexto, lo que da paso a que se pueda detectar habilidades transmisibles o formulaciones no convencionales de experiencia.

5.14 Matching inteligente entre perfil y oferta

El matching comprendido entre un CV y una oferta de empleo, ha dejado de ser una actividad de coincidencia literal (palabras clave) a un desarrollo complejo el cual evalúa diversas vertientes:

1. Coexistencia de habilidades.
2. Experiencia precedente en sectores similares.
3. Competencia de crecimiento y aprendizaje.
4. Nivel de adecuación cultural (cultural fit).

Modelos de clasificación supervisada o sistemas de recomendación, como XGBoost (Chen & Guestrin, 2016), LightGBM (Ke et al., 2017) o redes neuronales, pueden entrenarse para pronosticar la alta probabilidad de resultado favorable de un candidato, empleando bases de datos históricas de contrataciones exitosas. Los presentes sistemas otorgan la automatización del ranking de candidatos, ofreciendo a los perfiles más a fin para revisión humana.

5.15 Generación automatizada de feedback al candidato

Una de las tantas labores innovadoras y socialmente apreciadas que pueden asignarse a los sistemas inteligentes, es la reproducción de retroalimentación personalizada para aquellos candidatos descartados de cierto proceso de selección. Lastimosamente esta operatividad no se encuentra dentro de los ATS actuales.

Por medio de las técnicas de generación de lenguaje natural (NLG), prototipos como GPT-5, están entrenados para otorgar escritos explicando lo siguiente:

1. Las razones por las que el perfil no fue seleccionado.
2. Áreas de mejora para futuras postulaciones.
3. Recursos recomendados (formación, experiencia, herramientas).

Esta propuesta, el agente 3 realizaría la ejecutaría, fomentando más que un proceso de selección habitual, una experiencia humana y formativa por parte de la entidad empleadora, donde al mismo tiempo está generando que la imagen de la organización mejore y sea vista de forma positiva ante los postulantes. Varios estudios informan que para los candidatos es sumamente valioso recibir una retroalimentación constructiva, aun mas no siendo contratados por la compañía a la que se postularon para determinado cargo (LinkedIn, 2017).

Tabla 3. Comparación entre funciones actuales y funciones mejoradas con IA

Función del proceso de selección	Método actual	Mejora con IA y PLN
Análisis de CV	Filtro por palabras clave	Comprensión semántica contextual
Matching con oferta	Ponderación Básica	Modelos de predicción y clasificación
Comunicación con candidato	Respuestas automáticas genéricas	Feedback personalizado con NLG
Identificación de potencial oculto	Revisión humana limitada	Detección de habilidades transferibles

Fuente: Elaboración propia con base en Devlin et al. (2019)

5.16 Casos reales y herramientas disponibles

Algunas plataformas que ya aplican sistemas inteligentes en selección incluyen:

1. HireVue: usa análisis de video y voz para evaluar entrevistas grabadas.
2. Pymetrics: evalúa candidatos con juegos cognitivos y modelos predictivos.
3. Eightfold.ai: aplica IA para mapear carreras y predecir progresión laboral.
4. Recrutee / Personio: incorporan funciones de IA en su ATS para análisis y priorización.

Estas plataformas han demostrado mejoras significativas en eficiencia y calidad de contratación, aunque no siempre ofrecen explicabilidad, retroalimentación transparente o la

modularidad que se busca lograr con una arquitectura multiagente personalizada como la que propone este trabajo.

5.17 Comparativa crítica: ATS tradicionales vs. Agentes Inteligentes

La digitalización en el amplio proceso de selección ha originado adelantos significativos en eficiencia operativa, principalmente a partir de los Sistemas de Seguimiento de Candidatos (ATS). Estas plataformas otorgan la posibilidad de motorizar el filtrado de currículos, ordenar postulaciones, tramitar entrevistas y coordinar comunicaciones con los aspirantes (Personio, 2023; Personio, 2024).

A pesar de ello, los ATS conservadores manifiestan limitaciones estructurales, los cuales hacen percibirlos inadecuados para asumir por completo las necesidades del procesamiento de reclutamiento en la actualidad, fundamentalmente cuando se refiere a la flexibilidad, adaptabilidad y personalización. Aquí es donde aparecen los sistemas de inteligencia artificial sustentada en agentes, donde marca un gran diferencial invariable.

5.18 Limitaciones fundamentales de los ATS

Aun cuando los ATS y su funcionalidad ha sido significativa en cuanto al procesamiento de grandes niveles de datos, su orientación se determina en reglas fijas, como la simultaneidad de palabras clave lógica determinista. Lo anterior involucra lo siguiente:

1. Existe la certeza de que haya candidatos valiosos descartados, por no tener los términos esperados.
2. No da respuesta alguna de ninguna de sus decisiones, lo que lastimosamente deja mucho que desear en cuanto a la confianza del usuario.
3. No brinda feedback a los aspirantes, proporcionando una experiencia totalmente negativa para el usuario y así mismo para la marca empleadora.

Adicionalmente, varios ATS suprimen currículums no compatibles para máquinas, promoviendo que los candidatos se enfoquen más en “vencer al algoritmo” que en ofrecer un perfil auténtico.

5.19 Ventajas competitivas de los sistemas multiagente

Respecto a las limitaciones existentes, los sistemas multiagente basados en inteligencia artificial ofrecen soluciones flexibles, modulares e inteligentes. Dicho sistema está diseñado para que cada agente tenga asignada una función específica, ya sea en la extracción de datos, análisis o retroalimentación, contando con la autonomía necesaria para comunicarse con los demás agentes. De esta manera, se facilita la creación de una visión integral y ordenada del proceso de selección.

5.20 Los beneficios de esta arquitectura reúnen lo presente:

1. Comprensión semántica a fondo: los agentes tienen la facilidad de aplicar PLN para descifrar el contenido de los CVs más allá de palabras clave.
2. Procesamiento cotejo: pueden estimar cientos de candidatos de manera paralela.
3. Transparencia: las decisiones pueden ser claras y explícitas, gracias a sistemas de razonamiento lógico o creación natural de lenguaje.
4. Feedback automático y personalizado: Otorgar una experiencia de manera positiva para el aspirante, teniendo en cuenta la situación donde es o no seleccionado.
5. Escalabilidad: El procesamiento puede ser adaptativo con simplicidad, a diversos contextos, sectores o niveles de complejidad.

Tabla 4. Comparación crítica entre ATS tradicionales y sistemas multiagente con IA

Dimensión evaluada	ATS tradicional	Sistema multiagente con IA
Tipo de procesamiento	Basado en reglas y palabras clave	Semántico, contextual e inteligente
Flexibilidad	Baja. Dependiente del formato del CV	Alta. Detectas entidades clave incluso en formatos desordenados
Capacidad de escalado	Media. Limitado por la infra estructura	Alta. Procesamiento distribuido y concurrente
Trasparencia de decisiones	Opaca. No justifica descartes	Alta. Puede explicar porque elije o rechaza
Feedback al candidato	Inexistente o genérico	Personalizado y formativo
Adaptabilidad a diferentes cargos	Requiere configuración manual	Aprende con datos históricos y puede auto ajustarse
Experiencia del usuario (UX)	Rígida y automatizada	Interactiva y empática

Fuente: Elaboración propia con base en Humansmart (2025)

5.21 Implicaciones estratégicas

La transición desde un método fundamentado en ATS y una infraestructura multiagente con inteligencia artificial no solo representa un avance significativo en el ámbito tecnológico, sino que también refleja una profunda transformación a nivel estratégico. Los sistemas inteligentes tienen el potencial de contribuir de manera significativa a:

1. Aumentar la calidad del talento seleccionado, al valorar competencias ocultas o emergentes. (Gartner, s.f. 2024)
2. Disminuir los tiempos y costos de contratación, sin poner en riesgo la calidad. (Santaella, R. 2025.)
3. Otorgar una experiencia de forma humana, en conjunto con la ética y transparencia.

4. Ubicar a la empresa como un referente en innovación y digitalización del talento.

De manera similar, este enfoque permite integrar valores esenciales como los principios de equidad, diversidad e inclusión, al reducir los sesgos cognitivos presentes en los métodos tradicionales y promover una organización de la información que facilite la toma de decisiones justas y fundamentadas.

6. METODOLOGÍA

Este Trabajo de Fin de Máster presenta un enfoque centrado en la innovación tecnológica, con un carácter experimental y orientado hacia aplicaciones futuras. Se fundamenta en la necesidad de validar un sistema inteligente funcional que optimice los procesos de selección de talento. La justificación de este enfoque radica en que el objetivo principal es diseñar una solución concreta, basada en inteligencia artificial y arquitectura multiagente, que pueda ser probada, evaluada y, en caso de ser pertinente, reproducida en diversos entornos reales relacionados con la gestión de recursos humanos.

En este tipo de diseños, la metodología seleccionada debe facilitar tanto el inicio del desarrollo continuo y en constante evolución del sistema, como la evaluación de su rendimiento, su capacidad de adaptación y su coherencia con los objetivos prácticos y comerciales establecidos (Innoq, B. 2025).

6.1 Metodologías consideradas y elección de CRISP-DM(Q)

Mediante lo presente, se consideraron diversas metodologías suficientemente reconocidas en el campo de la inteligencia artificial y el análisis de los datos, que para este proyecto serían los currículums:

1. CRISP-DM: Como metodología, incluye descripciones de las fases normales de un proyecto, las tareas necesarias en cada fase y una explicación de las relaciones entre las tareas, además, como modelo de proceso, CRISP-DM ofrece un resumen del ciclo vital de minería de datos. (IBM).
2. Design Science Research (DSR): Basada en la justificación precisa y científica de artefactos tecnológicos, de gran ayuda en la investigación teórica pero poco adaptativa en cuanto a prototipos funcionales y graduables (Hevner et al., 2004).
3. KDD Process: Apropiado para hallar patrones en enormes volúmenes de datos, pero no muy recomendado para proyectos enfocados en la construcción modular de sistemas inteligentes (Fayyad et al., 1996).

Finalmente, se decidió adoptar el marco CRISP-DM(Q), específicamente diseñada para abordar esquemas de aprendizaje automático y sistemas inteligentes.

Este enfoque incorpora una gestión integral de la calidad y un proceso de aprobación continua a lo largo de todas las etapas del ciclo de vida del sistema. Tales características resultan fundamentales para garantizar la reproducibilidad de soluciones multiagente y, al mismo tiempo, mantener una alineación constante con los objetivos prácticos y éticos del proyecto (Innoq, B. 2025).

6.1.1 Aplicación del enfoque al sistema multiagente

El modelo CRISP-MD(Q) será adaptado en cada una de las fases de desarrollo de los tres agentes inteligentes que componen el esquema del sistema:

1. Agente 1: encargado de la extracción y estructuración automática de datos desde CVs en PDF, WORD y del autocompletado de formularios mediante modelos de lenguaje de código abierto.
2. Agente 2: responsable de la evaluación, filtrado y visualización de candidatos, aplicando técnicas de análisis semántico y ranking inteligente.
3. Agente 3: se encargará en la generación automática y explicativa de feedback para los candidatos no seleccionados.

Cada agente será desarrollado y corroborado de manera modular y siguiendo las fases iterativas de CRISP-MD(Q), otorgando así la supervisión sobre la calidad, flexibilidad y evaluación de resultados en función de métricas detalladas de rendimiento y experiencia de usuario (Innoq, B. 2025).

6.1.2 Fases Metodológicas según CRISP-MD(Q)

La metodología CRISP-MD(Q) ordena el proceso de desarrollo de sistemas de inteligencia artificial en seis (6) fases iterativas, esto permite que se genere una planificación controlada, ajustes permanentes y validación sistemática del desempeño. Las fases son las siguientes:

1. Comprensión del negocio: Define el objetivo y el valor que se quiere generar. Traduce necesidades en KPIs concretos y priorizados, también, fija el alcance y riesgos para evitar “scope creep” y decisiones difusas.
2. Comprensión de los datos: Identifica fuentes, formatos y calidad de los datos disponibles. Explora patrones, sesgos y huecos que afectarán la solución. Documenta supuestos y limitaciones para orientar las siguientes fases
3. Preparación de datos: Estudio e interpretación, limpieza, normalización y transforma los datos disponibles (CVs en PDF o WORD, formularios, historiales de procesos anteriores) y ofertas similares para hacerlos utilizables. Integra fuentes, resuelve valores faltantes y crea características o estructuras útiles. Deja un dataset listo y trazable con versiones y reglas claras.
4. Diseño de la solución de IA: Elección y configuración de los modelos, arquitecturas y algoritmos más apropiados para cada agente, incorporando herramientas open source, modelos de lenguaje y frameworks de orquestación.
5. Evaluación del sistema: Legitimar del rendimiento de cada agente y del sistema en su conjunto, empleando métricas técnicas (precisión, recall, tiempo de respuesta) y de experiencia de usuario.
6. Implementación: Integra la solución en el entorno objetivo con monitoreo y logging. Define procesos de operación, mantenimiento y gobierno de datos/modelos. Cierra con documentación, evidencias y un plan de mejora continua.

6.1.3 Relación entre las fases y los agentes

Dentro del contexto de este Trabajo de Fin de Máster, cada una de las etapas del proceso CRISP-ML(Q) se aplica de manera adaptada a los tres actores principales del sistema. De este modo, se garantiza tanto el desarrollo modular como la integración funcional y la evaluación integral del sistema en su conjunto.

Tabla 5. Fases de CRISP-ML(Q) con los multiagentes

Fase CRISP-MD(Q)	Agente 1: Extracción y Autocompletado	Agente 2: Evaluación y Visualización	Agente 3: Feedback Automatizado
Comprensión del negocio	¿Qué datos extraer y cómo presentarlos?	¿Cómo definir criterios de ajuste óptimos?	¿Qué feedback esperan los usuarios y cómo personalizarlo?
Comprensión de los datos	Análisis de PDFs, estructuras de CV	Análisis de campos clave y atributos de vacantes	Revisión de históricos de comunicación y feedback
Preparación de datos	Limpieza de textos y normalización	Estandarización de variables y features	Estructuración de mensajes y plantillas
Diseño de la solución	Selección de LLM open source, Ollama y spaCy	Algoritmos de matching y ranking, visualizaciones	Modelos de lenguaje generativo para NLG
Construcción	Desarrollo de flujo de extracción y diálogo	Integración de modelos, dashboards y filtros	Desarrollo de generador automático de feedback
Evaluación	Precisión de extracción, UX de usuario	Tasa de acierto en ranking, justificación	Claridad, utilidad y personalización del feedback
Implementación	Despliegue frontend y backend del agente	Integración con sistemas de gestión	Activación del envío automático a usuarios
Calidad	Control de errores, logs, ética	Trazabilidad y explicabilidad de decisiones	Transparencia, respeto y mejora continua

Fuente: Elaboración propia

La presente tabla recopila la forma en que las fases de CRISP-MD(Q) guían la construcción, integración y evaluación de cada uno de los agentes, asegurando una alineación congruente y aprobada en todo el transcurso de desarrollo del sistema multiagente (Innoq, B. 2025).

6.2 Metodologías consideradas y elección de CRISP-DM(Q)

Mediante lo presente, se consideraron diversas metodologías suficientemente reconocidas en el campo de la inteligencia artificial y el análisis de los datos, que para este proyecto serían los currículums:

1. CRISP-DM: Como metodología, incluye descripciones de las fases normales de un proyecto, las tareas necesarias en cada fase y una explicación de las relaciones entre las tareas, además, como modelo de proceso, CRISP-DM ofrece un resumen del ciclo vital de minería de datos. (IBM).
2. Design Science Research (DSR): Basada en la justificación precisa y científica de artefactos tecnológicos, de gran ayuda en la investigación teórica pero poco adaptativa en cuanto a prototipos funcionales y graduables (Hevner et al., 2004).
3. KDD Process: Apropriado para hallar patrones en enormes volúmenes de datos, pero no muy recomendado para proyectos enfocados en la construcción modular de sistemas inteligentes (Fayyad et al., 1996).

Finalmente, se decidió adoptar el marco CRISP-DM(Q), específicamente diseñada para abordar esquemas de aprendizaje automático y sistemas inteligentes. Este enfoque incorpora una gestión integral de la calidad y un proceso de aprobación continua a lo largo de todas las etapas del ciclo de vida del sistema. Tales características resultan fundamentales para garantizar la reproducibilidad de soluciones multiagente y, al mismo tiempo, mantener una alineación constante con los objetivos prácticos y éticos del proyecto (Innoq, B. 2025).

6.3 Aplicación del enfoque al sistema multiagente

El modelo CRISP-MD(Q) será adaptado en cada una de las fases de desarrollo de los tres agentes inteligentes que componen el esquema del sistema:

1. Agente 1: encargado de la extracción y estructuración automática de datos desde CVs en PDF, WORD y del autocompletado de formularios mediante modelos de lenguaje de código abierto.
2. Agente 2: responsable de la evaluación, filtrado y visualización de candidatos, aplicando técnicas de análisis semántico y ranking inteligente.
3. Agente 3: se encargará en la generación automática y explicativa de feedback para los candidatos no seleccionados.

Cada agente será desarrollado y corroborado de manera modular y siguiendo las fases iterativas de CRISP-MD(Q), otorgando así la supervisión sobre la calidad, flexibilidad y evaluación de resultados en función de métricas detalladas de rendimiento y experiencia de usuario (Innoq, B. 2025).

6.4 Fases Metodológicas según CRISP-MD(Q)

La metodología CRISP-MD(Q) ordena el proceso de desarrollo de sistemas de inteligencia artificial en seis (6) fases iterativas, esto permite que se genere una planificación controlada, ajustes permanentes y validación sistemática del desempeño. Las fases son las siguientes:

1. Comprensión del negocio: Define el objetivo y el valor que se quiere generar. Traduce necesidades en KPIs concretos y priorizados, también, fija el alcance y riesgos para evitar “scope creep” y decisiones difusas.
2. Comprensión de los datos: Identifica fuentes, formatos y calidad de los datos disponibles. Explora patrones, sesgos y huecos que afectarán la solución. Documenta supuestos y limitaciones para orientar las siguientes fases

3. Preparación de datos: Estudio e interpretación, limpieza, normalización y transforma los datos disponibles (CVs en PDF o WORD, formularios, historiales de procesos anteriores) y ofertas similares para hacerlos utilizables. Integra fuentes, resuelve valores faltantes y crea características o estructuras útiles. Deja un dataset listo y trazable con versiones y reglas claras.
4. Diseño de la solución de IA: Elección y configuración de los modelos, arquitecturas y algoritmos más apropiados para cada agente, incorporando herramientas open source, modelos de lenguaje y frameworks de orquestación.
5. Evaluación del sistema: Legitimar del rendimiento de cada agente y del sistema en su conjunto, empleando métricas técnicas (precisión, recall, tiempo de respuesta) y de experiencia de usuario.
6. Implementación: Integra la solución en el entorno objetivo con monitoreo y logging. Define procesos de operación, mantenimiento y gobierno de datos/modelos. Cierra con documentación, evidencias y un plan de mejora continua.

6.5 Relación entre las fases y los agentes

Dentro del contexto de este Trabajo de Fin de Máster, cada una de las etapas del proceso CRISP-ML(Q) se aplica de manera adaptada a los tres actores principales del sistema. De este modo, se garantiza tanto el desarrollo modular como la integración funcional y la evaluación integral del sistema en su conjunto.

Tabla 6. Fases de CRISP-ML(Q) con los multiagentes

Fase CRISP-MD(Q)	Agente 1: Extracción y Autocompletado	Agente 2: Evaluación y Visualización	Agente 3: Feedback Automatizado
Comprensión del negocio	¿Qué datos extraer y cómo presentarlos?	¿Cómo definir criterios de ajuste óptimos?	¿Qué feedback esperan los usuarios y cómo personalizarlo?
Comprensión de los datos	Análisis de PDFs, estructuras de CV	Análisis de campos clave y atributos de vacantes	Revisión de históricos de comunicación y feedback
Preparación de datos	Limpieza de textos y normalización	Estandarización de variables y features	Estructuración de mensajes y plantillas
Diseño de la solución	Selección de LLM open source, Ollama y spaCy	Algoritmos de matching y ranking, visualizaciones	Modelos de lenguaje generativo para NLG
Construcción	Desarrollo de flujo de extracción y diálogo	Integración de modelos, dashboards y filtros	Desarrollo de generador automático de feedback
Evaluación	Precisión de extracción, UX de usuario	Tasa de acierto en ranking, justificación	Claridad, utilidad y personalización del feedback
Implementación	Despliegue frontend y backend del agente	Integración con sistemas de gestión	Activación del envío automático a usuarios
Calidad	Control de errores, logs, ética	Trazabilidad y explicabilidad de decisiones	Transparencia, respeto y mejora continua

Fuente: Elaboración propia

La presente tabla recopila la forma en que las fases de CRISP-MD(Q) guían la construcción, integración y evaluación de cada uno de los agentes, asegurando una alineación congruente y aprobada en todo el transcurso de desarrollo del sistema multiagente (Innoq, B. 2025).

Dentro del contexto de este Trabajo de Fin de Máster, cada una de las etapas del proceso CRISP-ML(Q) se aplica de manera adaptada a los tres actores principales del sistema. De este modo, se garantiza tanto el desarrollo modular como la integración funcional y la evaluación integral del sistema en su conjunto.

Tabla 7. Fases de CRISP-ML(Q) con los multiagentes

Fase CRISP-MD(Q)	Agente 1: Extracción y Autocompletado	Agente 2: Evaluación y Visualización	Agente 3: Feedback Automatizado
Comprensión del negocio	¿Qué datos extraer y cómo presentarlos?	¿Cómo definir criterios de ajuste óptimos?	¿Qué feedback esperan los usuarios y cómo personalizarlo?
Comprensión de los datos	Análisis de PDFs, estructuras de CV	Análisis de campos clave y atributos de vacantes	Revisión de históricos de comunicación y feedback
Preparación de datos	Limpieza de textos y normalización	Estandarización de variables y features	Estructuración de mensajes y plantillas
Diseño de la solución	Selección de LLM open source, Ollama y spaCy	Algoritmos de matching y ranking, visualizaciones	Modelos de lenguaje generativo para NLG
Construcción	Desarrollo de flujo de extracción y diálogo	Integración de modelos, dashboards y filtros	Desarrollo de generador automático de feedback
Evaluación	Precisión de extracción, UX de usuario	Tasa de acierto en ranking, justificación	Claridad, utilidad y personalización del feedback
Implementación	Despliegue frontend y backend del agente	Integración con sistemas de gestión	Activación del envío automático a usuarios
Calidad	Control de errores, logs, ética	Trazabilidad y explicabilidad de decisiones	Transparencia, respeto y mejora continua

Fuente: Elaboración propia

La presente tabla recopila la forma en que las fases de CRISP-MD(Q) guían la construcción, integración y evaluación de cada uno de los agentes, asegurando una alineación congruente y aprobada en todo el transcurso de desarrollo del sistema multiagente (Innoq, B. 2025).

6.6 Fase 1: Desarrollo del Agente 1 – Extracción y Autocompletado

Esta fase es la parte más elaborada del proyecto, el objetivo es la extracción correcta de los datos para los demás agentes, adoptando un estudio exploratorio aplicado sobre la extracción automática de información desde currículos (CVs) para autocompletar un formulario de postulación. Se compara un pipeline híbrido en local, basado en reglas + NER + LLM en inferencia vía Ollama, frente a alternativas puras por reglas NER y frente a modelos comerciales (como referencia externa, sin enviar datos a terceros). El interés es práctico (tiempo, errores y experiencia de usuario) e ingenieril (calidad de la extracción, latencia y trazabilidad), con énfasis en pymes con limitaciones presupuestarias.

6.6.1 Contexto y motivación

En procesos de atracción de talento, los currículos (CVs) llegan en múltiples formatos (PDF/DOCX, una o dos columnas, tablas, plantillas de diseño) que dificultan transformar el contenido en datos confiables para formularios y sistemas internos. La variabilidad del layout introduce errores (por ejemplo, confundir un semestre “2018-2” con un teléfono) y aumenta el tiempo de tecleo y revisión. Frente a ello, este trabajo aborda la extracción automática de información desde CVs para autocompletar un formulario de postulaciones, con control de calidad y trazabilidad por campo.

6.6.2 Enfoque

El estudio adopta un enfoque exploratorio aplicado y compara un pipeline híbrido en ejecución local que combina reglas, NER (Named Entity Recognition) y un LLM en modo fallback (a través de Ollama) frente a alternativas puras por reglas/NER y, como referencia externa, frente a modelos comerciales. El interés es doble:

1. Práctico: reducir fricción y errores al completar el formulario (campos fijos) y estructurar bloques complejos (Experiencia/Educación).
2. Ingenieril: medir calidad (exactitud y F1), latencia y trazabilidad, manteniendo el procesamiento on-prem (privacidad).

6.6.3 Interrogante de partida

¿Hasta qué punto un pipeline híbrido local puede alcanzar una *calidad útil* ($\geq 85\%$ en campos fijos y $\geq 75\%$ F1 en experiencia/educación), preservando los datos *on-prem*? La noción de *calidad útil* se define operacionalmente como:

1. Campos fijos (nombre, apellidos, email, teléfono, ciudad, país): $\geq 85\%$ de exactitud por campo, de modo que el usuario corrija lo mínimo.

2. Experiencia/Educación: ≥ 75 % F1 por bloque (empresa/título/fechas para experiencia laboral; para educación tener en cuenta institución/grado/fechas), aceptando que la UI solicite confirmación en casos ambiguos.

6.6.4 Preguntas operativas

1. ¿Qué incremento aporta el LLM fallback respecto a reglas+NER en CVs con layouts difíciles (dos columnas, tablas, plantillas de diseño)?
2. ¿Cuánto contribuyen las limpiezas y normalizaciones “fechas; teléfono en (formato E.164); ciudades/país” a reducir falsos positivos y a mejorar F1?
3. ¿Cuál es la latencia p50/p90 del flujo E2E en local y su aceptabilidad para autocompletado interactivo?
4. ¿En qué medida la UI con políticas (Auto / Revisar / Confirmar) disminuye errores silenciosos y el tiempo total de completado?

6.6.5 Justificación técnico-práctica

La literatura y la práctica muestran que la mayor porción de la mejora en extracción proviene de la preparación de datos (parsing fiable de texto y coordenadas, normalizaciones y validadores), mientras que NER y LLM refuerzan casos contiguos (cabeceras, instituciones, fechas rotas, líneas partidas). Un pipeline híbrido permite:

1. Aprovechar lo determinístico (regex, validadores, catálogos) en campos fijos.
2. Usar NER para anclar PERSON/ORG/LOC/DATE cuando el layout es irregular.
3. Recurrir al LLM solo cuando reglas+NER no bastan, con prompts cerrados y esquema JSON para evitar alucinaciones y con filtros posteriores (excluir ítems sin empresa/fecha o eventos no laborales).

4. Exponer la incertidumbre en la UI mediante Auto / Revisar / Confirmar, convirtiendo ambigüedad en decisiones explícitas del usuario.

6.6.6 Objetivos operativos

1. Diseñar e instrumentar un pipeline con limpieza, normalizaciones (fechas, E.164, ciudades/país), reglas, NER y LLM fallback, más políticas de UI (Auto/Revisar/Confirmar) y trazabilidad por campo (valor, fuente, confianza).
2. Definir y medir métricas: exactitud por campo fijo; F1 por bloque en EXP/EDU; tasa de falsos positivos y % en E.164 para teléfono; latencia p50/p90; y métricas de UX (tiempo y # de clics por estado) en prueba formativa.
3. Ejecutar las variantes B0–B3 (Reglas; Reglas+NER; Reglas+LLM; Reglas+NER+LLM), en el mismo conjunto de CVs y con preprocesado/seeds controlados, y reportar hallazgos/limitaciones.

6.6.7 Hipótesis de trabajo

1. (campos fijos). Un pipeline con parsing robusto + normalizaciones + reglas, apoyado por NER en cabecera, alcanza ≥ 85 % de exactitud sin depender sistemáticamente del LLM.
2. (EXP/EDU). La combinación Reglas+NER más LLM con prompts cerrados mejora el F1 frente a Reglas/NER puros en layouts complejos, pudiendo llegar a ≥ 75 % en F1 por bloque.
3. (UI). Se basa en el diseño optimizado y amigable para el usuario incluyendo la política Auto / Revisar / Confirmar reduce errores silenciosos y tiempos de corrección frente a un autocompletado “opaco”.

6.6.8 Resultado esperado

El resultado esperado es una metodología reproducible (pipeline + métricas + prompts + políticas de UI) que muestre qué componentes aportan más a la calidad, dónde fallan (layouts específicos) y cómo mitigarlo (normalizaciones, ventanas de contexto, filtros anti-ruido, confirmación en UI). Esto ofrece una base sólida para que equipos técnicos y de RR. HH. escalen la solución o la integren con sus sistemas.

6.7 Evaluación de la etapa

Determinar en condiciones locales y con recursos abiertos, la calidad de extracción y el impacto en experiencia de usuario del autocompletado inteligente de un formulario desde un CV.

Midiendo la exactitud en campos fijos y falsos positivos de teléfono (número en formato E.164). También, comparando enfoques: Reglas+NER (spaCy), LLMs open-source (Ollama) y modelos comerciales (ChatGPT/Gemini). Como parte importante es el prototipo del front con políticas (Auto/Revisar/Confirmar) que reduzca tiempo y errores en la postulación, finalizando con la documentación en los criterios de adopción (coste, privacidad, mantenibilidad, latencia) para decisiones técnicas. (Yin et al., 2023).

6.8 Herramientas y tecnologías empleadas

Para asegurar que el agente sea de código abierto, ligero y eficiente, se eligieron herramientas de la comunidad open source ampliamente validadas tales como Ollama, spaCy, fastapi, uvicorn, pdfplumber, pypdf, python-docx, langdetect, phonenumberslite, pycountry, Babel, rapidfuzz.

6.9 Backend y orquestación

Se implementó FastAPI ya que su valor es ofrecer velocidad de desarrollo, documentación automática y fácil integración con librerías de IA. El endpoint único facilita aislar la Fase 1 para evaluación y demo.

1. Python 3.11 + FastAPI + Uvicorn: Permite exponer /applications/analyze con tipado (Pydantic) y Swagger para pruebas reproducibles.

2. Procesamiento de documentos: PDF/Word → texto; soporte de segmentación por columnas (XY-cut) y orden de texto.

6.10 Extracción y normalización

La mayor parte de los errores prácticos se corrigen antes del LLM: limpieza OCR, fechas y validación de teléfono. Esto mejora la precisión y reduce la dependencia del modelo generativo.

1. spaCy es `_core_news_md` (NER) para PERSON/ORG/GPE; prioridad al encabezado del CV para nombres y apellidos.
2. Heurísticas/Reglas: `phonenumbers` (E.164), `dateparser` (meses y semestres), `rapidfuzz` (deduplicación EXP/EDU), `unidecode` (normalización), además de filtros anti-falsos positivos (p. ej., excluir `20\d{2}` y `YYYY-1/2` como teléfonos).
3. Segmentación EXP/EDU: palabras clave (Universidad/Escuela/Liceo que sería para el campo de la Educación; Docente/Instructor/Coordinador, etc. Para el campo de la Experiencia.

6.11 LLM en local (open-source)

La ventaja de utilizar modelos open-source en local es que ofrece coste cero por consulta, privacidad y control (versiones/prompts). La desventaja es menos robustez que modelos comerciales, compensada con reglas y confirmación en UI.

1. Ollama gestiona modelos como Mistral 7B y Llama-3 8B en inferencia (sin entrenamiento), usados solo como fallback para estructurar bloques desordenados (p. ej., bullets sueltos de experiencia).

2. Prompts cerrados y temperatura baja para minimizar invenciones; límites de longitud y guard-rails.

6.12 Frontend y experiencia de usuario

El frontend actúa como control de calidad humano. La política por campos en el formulario reduce errores silenciosos y cuantifica el beneficio real (tiempo/errores) de la extracción.

1. React + Vite + TypeScript + Tailwind + shadcn/ui.
2. Burbujas de política por campo: Auto (confianza alta), Revisar (ambigüedad), Confirmar (riesgo).
3. Botón “Aceptar sugerencia” por campo, registro de acción y telemetría de tiempo/clics.

6.13 Almacenamiento y versionado

Investigación exploratoria y demo local. Permite auditar decisiones y resultados sin complejidad de infraestructura, además de revisar la base de datos (DB) de ofertas y de los aplicantes.

1. JSON/SQLite local para trazas, métricas y “gold set”.
2. Versionado de prompts y del pipeline (SemVer), feature flags para activar/desactivar capas.

6.14 Formulario inteligente

Al desarrollar un formulario inteligente mejora la experiencia de usuario al reducir fricciones: como el tiempo dedicado al aplicar a la oferta, ya que muchas personas en búsqueda de empleo quieren optimizar tiempo por oferta aplicada, y no llenar formularios eternos y que la final tenga que adjuntar su CV donde está la misma información como se muestra en la “*tabla 6*”, la intención es que el aplicante tenga menos tecleo y, por tanto, menos abandonos. Las burbujas de estado (Auto / Revisar / Confirmar) comunican claramente qué se autocompleta y qué requiere intervención, lo que incrementa la confianza y el sentido de control. Además, el autocompletado validado (email y teléfono en formatos correctos) favorece la accesibilidad y disminuye errores de formato.

Para Recursos Humanos, el beneficio es operativo: los datos llegan normalizados (nombres, teléfono en E.164, país/ciudad estandarizados), listos para ser analizados por cuadros de BI, o si se implementa la arquitectura multiagente, en este caso los datos los recibe el agente dos para su posterior análisis, evitando retrabajo y “idas y vueltas” por correcciones. La respuesta incluye trazabilidad—fuente y nivel de confianza por campo.

En organización y estructuración, la experiencia y la educación se devuelven en JSON fácilmente reducible a tablas, habilitando análisis de cohortes, brechas y cronologías. A futuro, una base de datos de ofertas permite activar campos variables (p. ej., portafolio, certificaciones) según el rol, y la estandarización resultante simplifica la interoperabilidad con plataformas de empleo y los flujos internos de la organización.

Tabla 8. Comparativa formularios tradicionales vs propuesto

Postulación tradicional

Nombre legal
Nombre(s) de pila *

Primer apellido *

Segundo apellido *

Tengo un nombre preferido
☐
Dirección
 Nombre de vía

 Código postal *

 Ciudad *

 Provincia *

Postulación propuesta

para unirse a nuestro equipo de la plataforma Fusion by Devoted. Como miembro clave del equipo de diseño de productos, diseñarás experiencias intuitivas y escalables que faciliten la colaboración fluida, la entrega de contenido y la visibilidad del flujo de trabajo. Buscamos específicamente a alguien con experiencia en plataformas de tipo marketplace o productos multifacéticos, con un profundo conocimiento de cómo equilibrar las necesidades de los equipos internos y los usuarios externos en un ecosistema creativo y dinámico.

Responsabilidades principales

- Actuar como parte interesada en el diseño, ayudando a dar forma a las características que brindan valor real a los usuarios de la plataforma.
- Diseñar y mantener un lenguaje visual coherente e intuitivo en toda la experiencia del producto Fusion.
- Crear flujos de usuario, wireframes, prototipos y diseños de UI finales para interfaces ricas en datos.
- Colaborar estrechamente con equipos de producto, ingeniería y multifuncionales para ofrecer experiencias de alta calidad.
- Realizar investigaciones de usuarios y aplicar el pensamiento de diseño para resolver desafíos complejos de UX.

Arrostra tu CV
 O [haz clic aquí](#) para seleccionar
 Solo sube archivos en formato PDF o Word
 Peso máximo 25MB
 Hoja de vida Juan Quevedo.pdf x

Archivo OK.

Analizar CV **Cancelar**

Nombre(s) Juan Apellido(s) Quevedo

Email ja.quevedo16 ¿Confirmas tu teléfono +57 +573183955571?

Indicativo teléfono Puedes editar el indicativo si no es correcto.

+57 +573183955571

País España Ciudad Bogotá

¿Ves los datos invertidos? Intercambiar nombre(s) -- apellido(s)

Enviar postulación (v1.3)

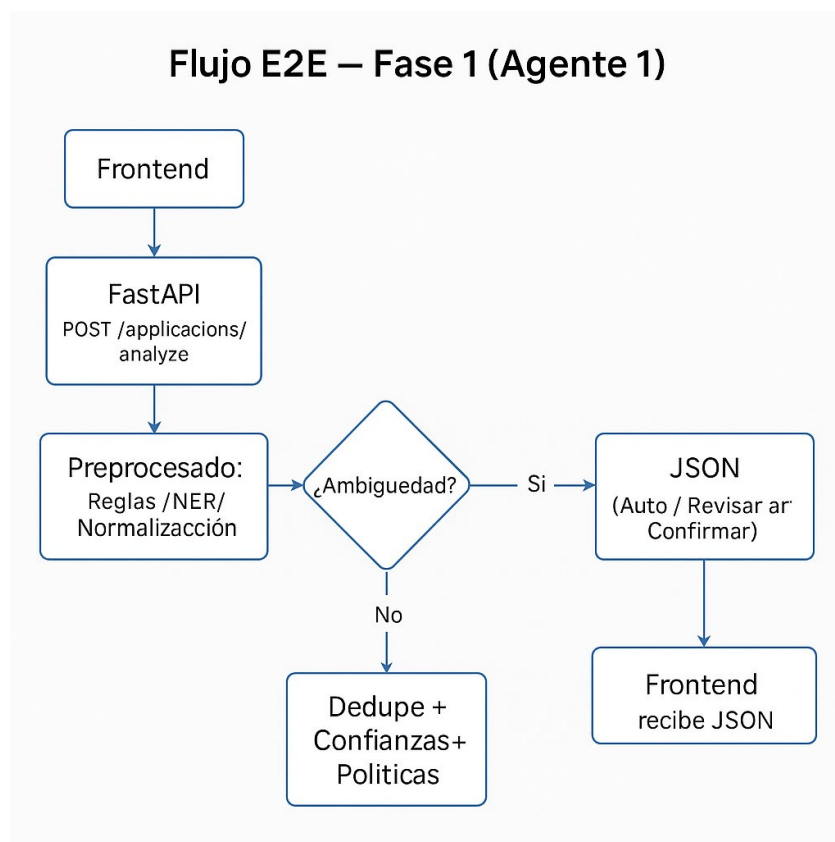
Análisis listo: Hoja de vida Juan Quevedo.pdf

Fuente: Elaboración propia

6.14.1 Procedimiento y estructura del formulario

Esta fase se organiza como un flujo E2E (end-to-end): donde el frontend permite subir el CV en los formatos permitidos y ya mencionados con anterioridad, se llama al endpoint FastAPI /applications/analyze, donde el backend ejecuta el pipeline de extracción: preprocesado (limpieza OCR/XY-cut), reglas y NER para campos fijos, normalización (fechas, teléfono E.164) y, solo si hay ambigüedad, el LLM como fallback para ordenar Experiencia/Educación; luego hace de duplicación, calcula confianzas y asigna políticas (Auto/Revisar/Confirmar) antes de devolver un JSON estructurado. En el front, ese JSON se mapea al formulario: los campos con alta confianza se autocompletan y el resto se muestran como sugerencias con burbujas y botón “Aceptar”. La estructura del proyecto separa responsabilidades: en backend, routes/ (endpoints), schemas/ (Pydantic), services/ (extractor, normalizadores, validadores, dedupe) y Swagger para probar contratos; en frontend, componentes de upload, mapeo analysisMapping y UI de SuggestionPill. Todo el proceso queda trazado mediante mensajes/flags en la respuesta, favoreciendo pruebas, auditoría y futuras iteraciones.

Figura 7. Flujo de extremo a extremo

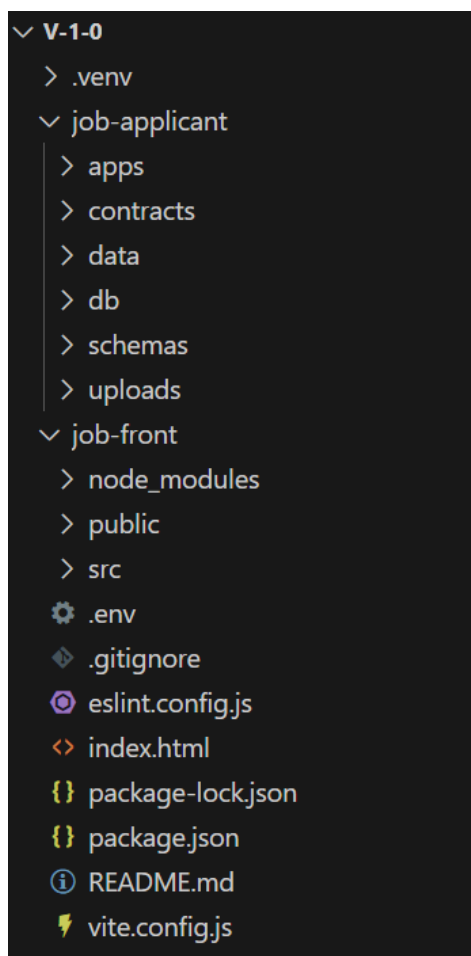


Fuente: Elaboración propia a partir de la arquitectura propuesta y la documentación técnica de LlamaIndex y LangChain (LlamaIndex, 2024; LangChain, 2024).

6.14.2 Estructura de carpetas del formulario

La estructura de carpetas separa funcionalidades para que el desarrollo sea mantenible, trazable y escalable: en el backend (apps/api/) routes/ define los endpoints (POST /applications/analyze), los schemas/ tipa las entradas/salidas con Pydantic, y services/ concentra la lógica (extractor, normalizadores de fechas/teléfono, XY-cut, dedupe), mientras main_lite.py expone FastAPI y Swagger para pruebas. En el frontend, los componentes de upload gestionan la subida y llamada al API, analysisMapping traduce el JSON a políticas por campo, y la UI (SuggestionPill) muestra burbujas Auto/Revisar/Confirmar. Este orden permite probar cada capa por separado, acelerar depuración y documentar fácilmente el flujo E2E.

Figura 8. Estructura de carpetas



Captura de pantalla. Estructura del proyecto visto en VSCode Backend y Frontend

6.14.3 Endpoints, schemas y rutas

El endpoint central es POST /applications/analyze, expuesto por FastAPI y documentado en Swagger, donde el front envía el CV y recibe un JSON con fields (campos) (valores, confianza, candidatos), experience, education y messages. Las rutas (en routes/) agrupan los controladores de cada endpoint y crean la llamada a los servicios de extracción/normalización; los schemas (en schemas/, Pydantic) definen y validan el contrato de entrada/salida, los tipos, formatos (ejemplo teléfono E.164), valores requeridos—garantizando compatibilidad del front y respuestas con códigos HTTP claros (200/4xx/5xx). Esta separación


permite probar el contrato en Swagger, detectar errores temprano y evolucionar la API sin romper el flujo E2E.

POST /applications/analyze: recibe file (PDF/Word) y opcional offerDescription. Devuelve: fields: { names, surnames, email, phone{raw,dial,iso2}, country, city, confidence, candidates}experience[] y education[]: títulos/empresa/institución con fechas normalizadas messages[]: trazas (p. ej., “XY-cut activado”, “LLM fallback: OK”).

6.14.4 Swagger (backend) y UX/UI (frontend)

El Swagger: facilita probar con documentos reales y revisar la forma exacta del JSON; mientras que la UI: hace que cada campo muestre una burbuja con política y ofrece Aceptar sugerencia para auto completado; confirmación para always (teléfonos dudosos) y revisión para ambigüedades (nombres desde email/top).

Figura 9. Swagger



Captura de pantalla. Backend para extracción de datos

Figura 10. Formulario frontend

Aplica ahora y construyamos juntos tu futuro

full-time Jornada freelance Contrato 2+ años Experiencia

Descripción de la oferta

Buscamos un diseñador UI/UX con una sólida experiencia en productos para unirse a nuestro equipo de la plataforma Fusion by Devoted. Como miembro clave del equipo de diseño de productos, diseñarás experiencias intuitivas y escalables que faciliten la colaboración fluida, la entrega de contenido y la visibilidad del flujo de trabajo. Buscamos específicamente a alguien con experiencia en plataformas de tipo marketplace o productos multifacéticos, con un profundo conocimiento de cómo equilibrar las necesidades de los equipos internos y los usuarios externos en un ecosistema creativo y dinámico.

Responsabilidades principales

- Actuar como parte interesada en el diseño, ayudando a dar forma a las características que brindan valor real a los usuarios de la plataforma.
- Diseñar y mantener un lenguaje visual coherente e intuitivo en toda la experiencia del producto Fusion.
- Crear flujos de usuario, wireframes, prototipos y diseños de UI finales para interfaces ricas en datos.
- Colaborar estrechamente con equipos de producto, ingeniería y multifuncionales para ofrecer experiencias de alta calidad.
- Realizar investigaciones de usuarios y aplicar el pensamiento de diseño para resolver desafíos complejos de UX.

Aplica por esta oferta

Arrastra tu CV
O [haz clic aquí](#) para seleccionar

Solo sube archivos en formato PDF o Word
Peso máximo 25MB

Hoja de vida Juan Quevedo.pdf x

Archivo OK.

Analizar CV Cancelar

Nombre(s) Apellido(s)
Juan Quevedo

Email
ja.quevedo16@hotmail.com

Indicativo Teléfono
+57 +573183955571

País Ciudad
Colombia Bogotá

¿Ves los datos invertidos? Intercambiar nombre(s) ↔ apellido(s)

Enviar postulación (v1.3)

Análisis listo: Hoja de vida Juan Quevedo.pdf

Captura de pantalla. Frontend formulario Job-applicant.

6.15 Informe de resultados en la extracción de campos fijos

Se evaluó la extracción de campos fijos (nombres, apellidos, e-mail, ciudad, país y teléfono) sobre 25 CVs. Para cada documento se comparó la predicción del sistema con su GOLD (verdad-terreno) alineada por id. La métrica principal fue exactitud (coincidencia 1/0 tras normalizar acentos, mayúsculas y espacios) y, como complemento, cobertura (porcentaje de documentos en los que el sistema produce un valor no vacío). En teléfono se añadieron dos métricas: “match cuando hay GOLD” (comparación por dígitos) y % de formato E.164 en la predicción.

6.15.1 Resultados cuantitativos

1. Exactitud (promedio por campo, cuando hay predicción y GOLD comparables):
Nombres 100%, Apellidos 100%, Email 100%, Ciudad 100%, País 100%.
Interpretación: cuando el sistema logra detectar el campo, acierta sistemáticamente frente al GOLD en este conjunto.

2. Cobertura de predicción (porcentaje de CVs con valor no vacío):
Nombres 96%, Apellidos 92%, Email 88%, Ciudad 48%, País 68%, Teléfono 80%.
Interpretación: el cuello de botella no es la precisión, sino la cobertura. El sistema trae casi siempre nombre/apellidos/email, pero cae en Ciudad (48%) y País (68%).

3. Teléfono:
GOLD con teléfono 80%, Predicción con teléfono 80%, Match cuando hay GOLD 100% (por dígitos), Predicción en E.164 64%.
Interpretación: cuando hay teléfono, el número coincide en dígitos (100%), pero sólo el 64% sale ya normalizado a E.164; falta estandarización de formato.

Figura 11. Exactitud por campo fijo




Figura 12. Cobertura de predicción por campo





Figura 13. Métricas de teléfono



Fuente: las cifras provienen del archivo gold_eval_FIXED.xlsx (hoja Summary_Fixed). Las coincidencias de texto aplican normalización de acentos y espacios; el match de teléfono compara solo dígitos para evitar falsos negativos por guiones o espacios.

6.15.2 Interpretación de los datos

1. Precisión alta donde hay señal clara. La combinación de heurísticas de cabecera (zona superior + spans con mayor tamaño), reglas y validaciones hace que, cuando el campo está presente y legible, la predicción coincida con el GOLD. Esto explica los 100% de exactitud por campo.
2. Cobertura limitada en ubicación geográfica. La caída en Ciudad (48%) y País (68%) se alinea con lo observado al explorar los CVs:
 - Layouts de dos columnas / estilo Canva suelen colocar PII en paneles laterales con iconos, bullets o tipografías diferentes. Es común que ciudad/país no estén en la

cabecera principal y queden “dispersos” o incrustados en secciones (experiencia, educación) donde las reglas no los priorizan.

- Variantes léxicas (Bogotá/Bogota, CDMX/México) y acentos añaden ruido si no hay un gazetteer (catálogo) de normalización.
- Ambigüedad: aparece “Colombia” en varios bloques (educación/empresa) sin estar explícito como “residencia actual”.

3. Teléfono: misma cifra, distinto formato. El 100% de match por dígitos vs. 64% E.164 muestra que el sistema lee correctamente el número, pero no siempre lo formatea con “+código-país”. Este punto es fácil de mejorar con una normalización post-proceso consistente (reglas por país + detección del código nacional).
4. Calidad del GOLD y consistencia del dato. En algunos CVs el encabezado mezcla nombre + cargo en la misma línea; si el GOLD conserva ese patrón, y el extractor también, la coincidencia sube. Esto subraya la importancia de una guía de anotación clara (qué es “apellido” frente a “rol/cargo”).

6.15.3 Interpretación de los datos

1. Nombre/Apellidos “contaminados” por el cargo o una etiqueta (“Electronic Engineer”) cuando el CV combina ambos en un mismo renglón grande. Mitigación: más peso a pistas de filename/email y penalización de tokens de rol en la línea de cabecera.
2. Ciudad/País omitidos en CVs con panel lateral o iconografía (no texto plano). Mitigación: usar coordenadas XY + reglas de zonas laterales, y un gazetteer de topónimos ES/CO.
3. Teléfono sin “+” o con espacios/guiones → no cumple E.164. Mitigación: normalizar siempre a E.164 y mostrar ambos (crudo y normalizado) en el JSON/UI.

6.15.3 Conclusión

1. En campos fijos, el pipeline demuestra precisión muy alta cuando encuentra la señal; el reto es aumentar cobertura, sobre todo en Ciudad/País.
2. El teléfono está bien detectado en contenido (match por dígitos), pero requiere forzar salida E.164 para integraciones con ATS/BI.
3. La UI con estados Auto/Revisar/Confirmar es clave: donde la cobertura es débil, la UI debe pedir confirmación o sugerir candidatos (p. ej., “Bogotá” detectada en experiencia vs. en cabecera).

6.15.3 Conclusión

1. Ubicación (Ciudad/País):
 - Añadir gazetteer ES/LatAm (lista de ciudades/país) + fuzzy-match;
 - Regla de prioridad de cabecera (primer tercio de la 1ª página) y panel lateral identificado por coordenadas;
 - Si hay múltiples candidatos, marcar Revisar en UI con 2–3 opciones.
2. Teléfono:
 - Normalizar a E.164 por defecto (+57... en CO), conservar phone_raw y exponer ambos en el JSON;
 - Validar longitud/estructura y marcar Revisar si no cumple.
3. Nombre/Apellidos:
 - Penalizar tokens de cargo y símbolos (“:”) en la línea de mayor tamaño;
 - Usar filename/email como ancla (si filename contiene “Nombre Apellido”, subir confianza).

4. Instrumentación y UX:

- Registrar confianza por campo y activar UI “Confirmar” cuando sea baja;
- Log de candidatos (top-3) para ahorrar tecleo en revisión.

6.16 Fase 2: Desarrollo del Agente 2 – Evaluación y Visualización de Candidatos

6.16.1 Objetivos de la fase

El propósito de esta etapa consiste en desarrollar un agente que sea capaz de analizar de manera efectiva la base de datos generada por el Agente 1, filtrar y clasificar a los candidatos de forma inteligente, considerando su compatibilidad con la oferta laboral. Asimismo, este agente debe ofrecer visualizaciones claras y explicativas que faciliten la interpretación por parte del reclutador. Además, es fundamental que pueda fundamentar las razones detrás de las decisiones de selección o descarte, promoviendo así una toma de decisiones más informada y aumentando la transparencia en todo el proceso (Albassam, W. A. 2023).

6.16.2 Herramientas y tecnologías empleadas

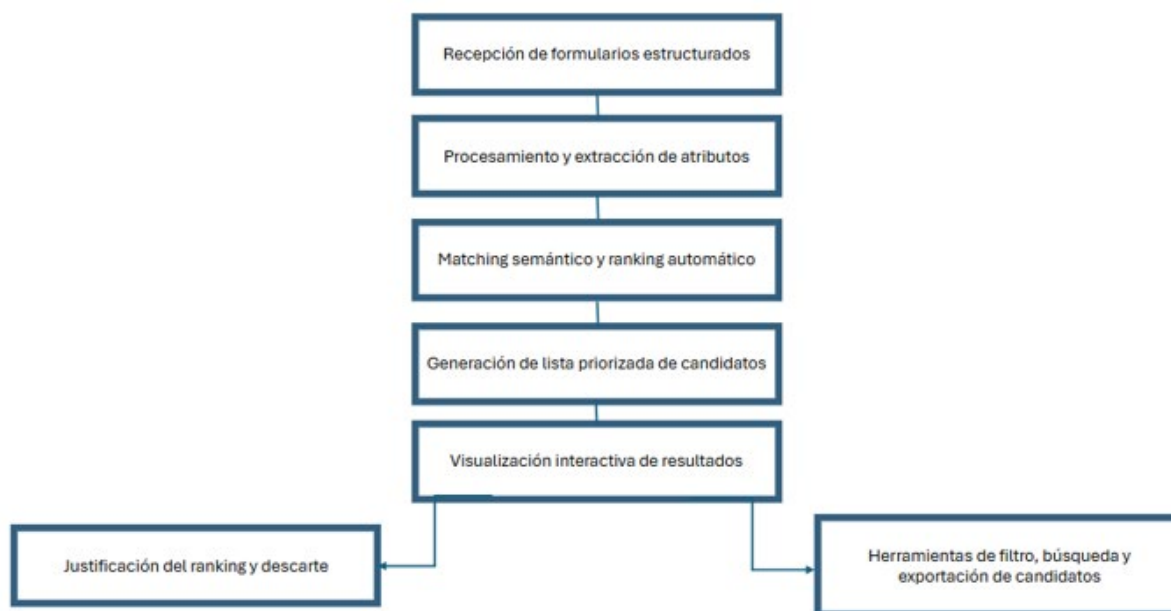
Tabla 9. Componentes tecnológicos Agente 2

Componente	Herramienta/Tecnología	Justificación y referencia
Análisis y ranking de candidatos	scikit-learn, XGBoost, LightGBM	Bibliotecas robustas para clasificación y ranking automatizado. (Pedregosa et al., 2011)
Procesamiento semántico y similitud	Sentence Transformers, spaCy	Análisis avanzado de similitud textual y extracción de entidades (Reimers & Gurevych, 2019)
Visualización de datos	Plotly, Streamlit, Dash	Herramientas open source para visualización interactiva de resultados (Plotly, 2024)
Orquestación y backend	FastAPI, LangChain	Integración modular, API REST y control de flujo entre agentes (LangChain, 2024)
Explicabilidad de decisiones	SHAP, LIME	Frameworks para interpretar y explicar resultados de modelos de IA (Molnar, 2022)

Fuente: Elaboración propia

6.16.3 Flujo funcional y actividades principales

Figura 14. Diagrama de flujo del agente 2: evaluación y visualización



Fuente: Elaboración propia

6.16.4 Métricas y criterios de calidad

Tabla 10. Métricas Agente 2

Métrica	Definición
Precisión del ranking	Proporción de candidatos correctamente priorizados
Recall/sensibilidad	Capacidad del sistema para no omitir candidatos válidos
Explicabilidad	Nivel de claridad en las razones de selección/descarte
Tiempo de procesamiento	Duración media desde ingreso de datos hasta visualización final
Satisfacción del reclutador	Evaluación cualitativa (encuesta, NPS) sobre utilidad y facilidad

Fuente: Elaboración propia

6.16.5 Limitaciones y desafíos

Datos incompletos o poco estructurados: Afectan la precisión del análisis semántico y el ranking automático (Albassam, W. A. 2023).

Sesgo en los algoritmos: Si el dataset histórico está sesgado, el agente podría reproducir discriminaciones inadvertidas (Molnar, 2022).

Limitación en visualización avanzada: Aunque las librerías son potentes, la complejidad de interpretación puede aumentar con la cantidad de candidatos.

Explicabilidad limitada: Aunque herramientas como SHAP y LIME son útiles, no siempre logran traducir toda la lógica del modelo de forma comprensible para todos los usuarios (Molnar, 2022).

Dependencia del input del Agente 1: Errores o inconsistencias previas pueden afectar el rendimiento general del Agente 2.

6.17 Fase 3: Desarrollo del Agente 3 – Generación de Feedback Automatizado

El propósito de esta etapa consiste en diseñar un agente inteligente que produzca mensajes automáticos, personalizados y explicativos dirigidos a los candidatos no seleccionados. La retroalimentación debe fundamentarse en los criterios de descarte establecidos por el Agente 2, siendo clara, constructiva y orientada a ofrecer una comunicación transparente. Además, su objetivo es contribuir a mejorar la experiencia del usuario y fortalecer la percepción positiva de la marca empleadora (Mendis, R).

6.17.1 Herramientas y tecnologías empleadas

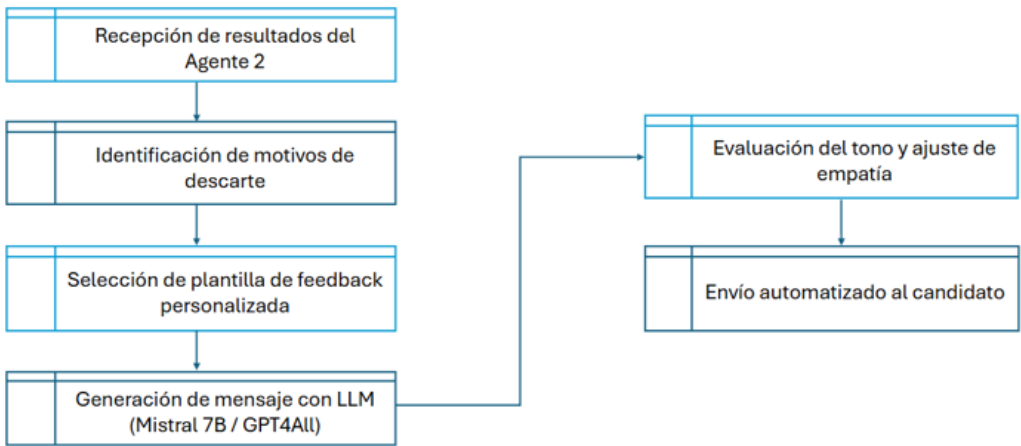
Tabla 11. Componentes tecnológicos Agente 3

Componente	Herramienta/Tecnología	Justificación y referencia
Generación de lenguaje natural	GPT4All, Mistral 7B, Llama 3, Phi-2	LLMs ligeros, open source, eficientes para generación automatizada de texto (Mistral AI, 2024)
Orquestación y flujo conversacional	LangChain	Modularidad y manejo de interacciones secuenciales (LangChain, 2024)
Plantillas y lógica de mensajes	Jinja2, Prompt engineering	Personalización de feedback según causa de descarte (OpenAI Cookbook, 2024)
Evaluación de tono y empatía	Perspective API, análisis de sentimiento	Garantiza un lenguaje respetuoso y constructivo (Perspectiveapi.com, 2024)

Fuente: Elaboración propia

6.17.2 Flujo funcional y actividades principales

Figura 15. Diagrama de flujo del Agente3: generación de feedback automatizado



Fuente: Elaboración propia basada en la arquitectura propuesta y la documentación de LangChain, Mistral AI y Perspective API (LangChain, 2024; Mistral AI, 2024; Google AI, 2024).

6.17.3 Métricas y criterios de calidad

Tabla 12. Métricas Agente 3

Métrica	Definición
Grado de personalización	Porcentaje de mensajes que contienen referencias explícitas al perfil o candidatura
Claridad del feedback	Evaluación (encuesta) de comprensión y utilidad del mensaje
Nivel de empatía y respeto	Análisis automático de tono (Perspective API) y revisión manual
Tasa de apertura/respuesta	Porcentaje de candidatos que leen y/o responden el mensaje
Tiempo de generación y envío	Tiempo medio entre el descarte y la recepción del feedback

Fuente: Elaboración propia

Tabla 13. Ejemplo de estructura de feedback automatizado

Motivo de descarte	Fragmento de feedback generado
Falta de experiencia específica	Lamentablemente, para esta vacante se requiere experiencia comprobada en X, que no hemos encontrado en su perfil.
Inadecuación del nivel de estudios	El puesto exige titulación universitaria específica, la cual no se identifica en su CV.
Competencias técnicas insuficientes	Hemos valorado positivamente su perfil, pero buscamos dominio avanzado en Y, que es imprescindible para este cargo.
Ajuste limitado a la cultura organizacional	Nuestro análisis sugiere que su perfil podría encajar mejor en contextos con diferente enfoque de valores o cultura.
Postulación extemporánea	Recibimos su postulación una vez cerrado el proceso de selección.

Fuente: Elaboración propia

6.17.4 Limitaciones y desafíos

Diversidad de causas de descarte: No siempre es sencillo identificar automáticamente una razón específica y comunicarla de forma precisa y ética.

Riesgo de lenguaje genérico o impersonal: Los modelos pueden generar mensajes percibidos como poco empáticos si las plantillas o prompts no están bien diseñados (Google AI, 2024).

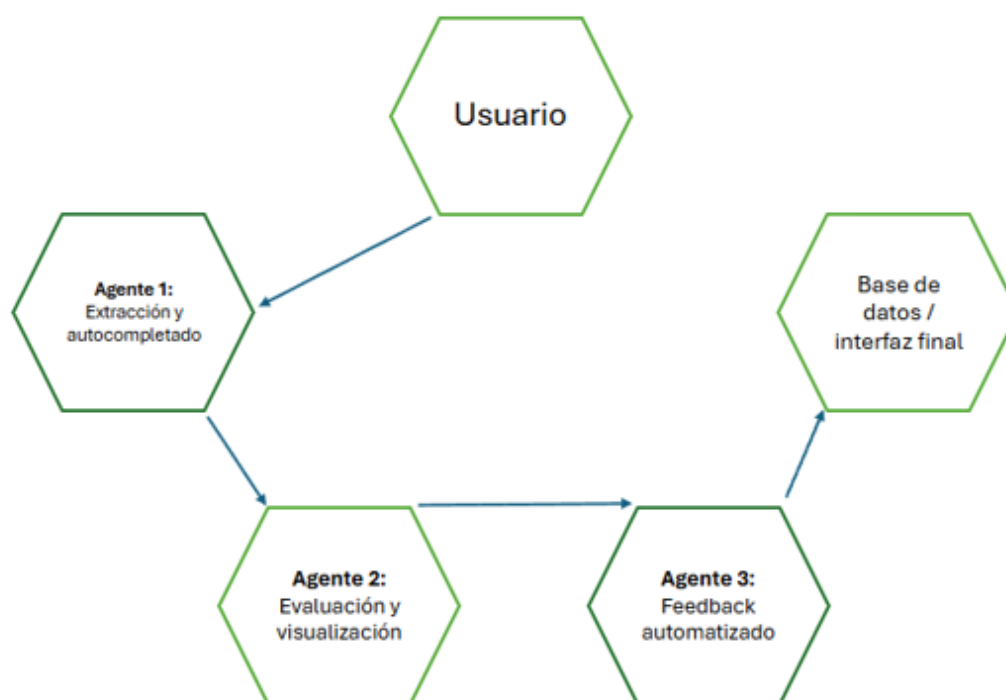
Retos legales y de protección de datos: El feedback debe evitar información sensible o discriminatoria y cumplir la legislación vigente.

Dependencia de la calidad del input: La pertinencia y utilidad del feedback dependen de la información estructurada por los agentes anteriores.

6.18 Proceso de integración de agentes

La integración del sistema multiagente requiere una supervisión meticulosa de la comunicación y el flujo de datos entre los tres agentes principales: extracción y autocompletado, evaluación y visualización, así como la generación de retroalimentación. Este proceso demanda la definición precisa de interfaces estandarizadas, formatos adecuados para el intercambio de información y la coordinación de procesos tanto secuenciales como paralelos, según sea necesario (Briva-Iglesias, V. 2025).

Figura 16. Arquitectura de integración de los agentes del sistema multiagente



Fuente: Elaboración propia a partir de la propuesta metodológica y modelos de referencia en sistemas multiagente (Briva-Iglesias, V. 2025).

6.19 Pruebas funcionales y de interoperabilidad

El proceso de integración requiere la realización de pruebas funcionales y de interoperabilidad para asegurar que los diferentes agentes interactúen de manera adecuada y que la transmisión de información sea eficiente en todo el sistema. Estas evaluaciones comprenden:

Pruebas unitarias: corroboración del correcto rendimiento de cada agente de manera independiente.

Pruebas de integración: Evaluación de la comunicación y transferencia de datos entre agentes.

Pruebas end-to-end: Simulación de casos de uso reales desde la carga de un CV hasta la generación de feedback.

Pruebas de regresión: Aseguran que nuevas modificaciones no originen errores en funcionalidades ya adoptadas (Sandler, G. M. T. 2012).

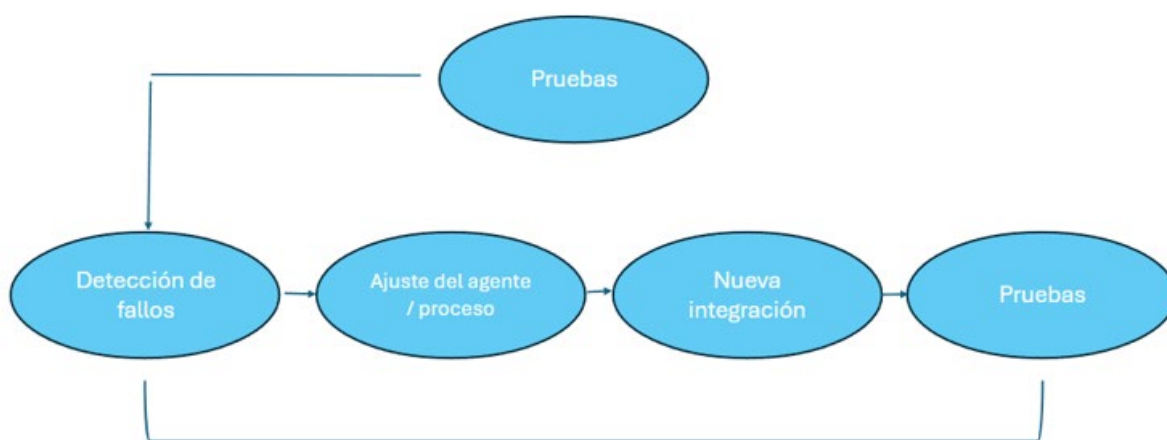
Tabla 14. Resumen de pruebas funcionales implementadas en la integración del sistema.

Tipo de prueba	Objetivo	Herramienta recomendada	Resultados esperados	Referencia
Pruebas unitarias	Validar funciones clave de cada agente	pytest, unittest	100% de funciones clave superadas	(Sandler, G. M. T. 2012)
Pruebas de integración	Verificar el flujo de datos entre agentes	Postman, pytest	Transferencia sin pérdidas ni errores	(Sandler, G. M. T. 2012)
Pruebas end-to-end	Simular todo el proceso como lo vive el usuario	Selenium, manual, Playwright	Resultados coherentes y feedback correcto	(Sandler, G. M. T. 2012)
Pruebas de regresión	Detectar errores por cambios en el código	pytest, GitHub Actions	Funcionamiento estable tras cada cambio	(Sandler, G. M. T. 2012)

Fuente: Elaboración propia

A través de cada ciclo de pruebas, se llevan a cabo ajustes iterativos en los agentes o en el flujo de integración, con el propósito de corregir errores, perfeccionar los tiempos de respuesta, mejorar la experiencia del usuario y reforzar la trazabilidad de las decisiones tomadas por el sistema (Innoq, B. 2025).

Figura 17. Ciclo de integración y ajuste en sistemas multiagente



Fuente: Elaboración propia con base en el ciclo de mejora continua en CRISP-ML(Q) (Innoq, B. 2025)

6.20 Métricas globales de desempeño

Para garantizar la efectividad y utilidad del sistema multiagente, se definen métricas globales que permiten una evaluación integral tanto del rendimiento técnico como de la satisfacción de los usuarios finales. Estas métricas deben ser claramente medibles, fácilmente replicables y comparables con los estándares establecidos en el sector, con el propósito de asegurar una valoración precisa y coherente del funcionamiento del sistema (Innoq, B. 2025).

Tabla 15. Métricas globales de desempeño del sistema multiagente

Métrica	Descripción	Método de medición
Precisión total del sistema	Porcentaje de coincidencias correctas en matching y clasificación	Evaluación cruzada con expertos humanos
Tasa de autocompletado efectiva	% de campos de formulario completados correctamente	Logs del sistema y feedback de usuarios
Tiempo promedio de procesamiento	Tiempo desde la carga de CV hasta feedback final	PCronometría del sistema en entorno real
Satisfacción del usuario	Valoración global por parte de candidatos y reclutadores	Encuestas
Explicabilidad y transparencia	Nivel de comprensión de la justificación de decisiones	Encuestas
Cumplimiento de privacidad	Grado de cumplimiento de GDPR/Ley de Datos	Auditoría legal y técnica

Fuente: Elaboración propia

6.21 Comparación con sistemas tradicionales

Para evaluar el valor añadido del sistema desarrollado, se propone una comparación con los sistemas tradicionales (ATS comerciales y procesos manuales) en base a indicadores clave.

Tabla 16. Comparación del sistema multiagente con ATS tradicional y proceso manual

Criterio	Sistema propuesto (Multiagente)	ATS tradicional	Proceso manual
Precisión de matching	Alta, con explicabilidad	Moderada, poco explicable	Variable, depende del revisor
Tiempo de procesamiento	Rápido y automatizado	Rápido, pero limitado por filtros	Lento y propenso a errores
Satisfacción del usuario	Elevada (candidato y reclutador)	Nula (nada de feedback)	Variable, pero mayor interacción
Transparencia y feedback	Explicaciones automáticas y detalladas	Limitado o inexistente	Alta, pero subjetiva
Cumplimiento legal	Fácil de adaptar y auditar	Variable, depende del proveedor	Depende de formación

Fuente: Elaboración propia

6.22 Experiencia de usuario y feedback


Se realizarán pruebas con usuarios y encuestas dirigidas tanto a candidatos como a reclutadores, con el objetivo de evaluar la usabilidad, utilidad y percepción general del sistema. Entre los instrumentos recomendados se incluyen:

Encuestas tipo Likert.

Entrevistas cualitativas.

Test de tareas (usabilidad).

Figura 18. Ejemplo de flujo de feedback del usuario final



Fuente: Elaboración propia

6.23 Hardware y software

El desarrollo y la experimentación de sistemas multiagente requieren el empleo de recursos tecnológicos especializados que garanticen un rendimiento eficiente, además de facilitar la escalabilidad y la reproducibilidad de los experimentos realizados. La elección de herramientas de código abierto y de ejecución local proporciona un mayor control sobre la protección de la privacidad de los datos y permite adaptar el sistema de acuerdo con las necesidades particulares del proyecto (Innoq, B. 2025).

Tabla 17. Recursos tecnológicos utilizados en el desarrollo del sistema

Recurso	Especificación / Software	Función principal	Referencia
Portátil de desarrollo	ASUS i9-14900H, 32GB RAM, SSD 1TB	Ejecución local de los agentes y modelos	Propia
Sistema operativo	Windows 11	Entorno de desarrollo principal	Propia
Backend / Modelos IA	Python 3.11, FastAPI, LangChain, LlamaIndex	Orquestación de agentes y lógica de flujo	LangChain, 2024; LlamaIndex, 2024
Modelos de lenguaje	Mistral 7B, GPT4All, Llama 3, Phi-2	Extracción, matching y generación de feedback	Mistral AI, 2024
Infraestructura LLM local	llama.cpp, Ollama	Correr modelos LLM en hardware convencional	Ollama, 2024
Frontend / Visualización	Streamlit, Plotly, Dash	Visualización de resultados para el reclutador	Plotly, 2024
Extracción de texto PDF	PyMuPDF, pdfplumber, unstructured	Procesamiento y estructuración inicial de datos	pdfplumber, 2023
Repositorio de código	GitHub	Control de versiones y colaboración	GitHub, 2024

Fuente: Elaboración propia

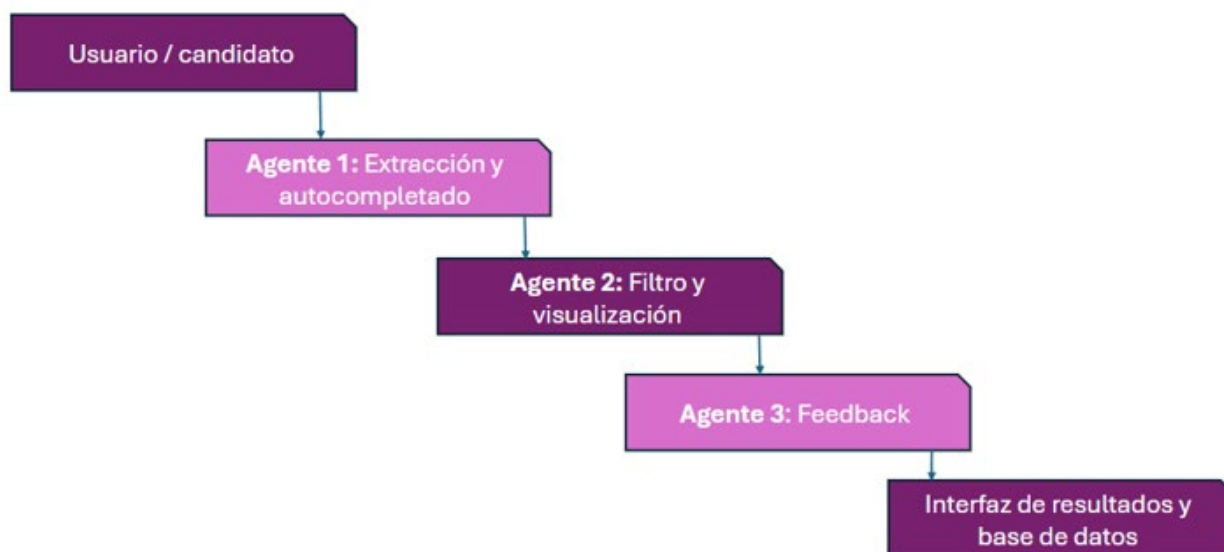
6.24 Entorno de desarrollo

La integración y puesta en funcionamiento del sistema se llevan a cabo en un entorno de desarrollo reproducible, utilizando entornos virtuales de Python (como .venv o conda) para garantizar la compatibilidad y estabilidad de las librerías. La utilización de sistemas de control de versiones (Git/GitHub) permite gestionar de manera eficiente los cambios y facilitar la colaboración entre los distintos miembros del equipo.

6.25 Visión general y arquitectura del sistema

El sistema propuesto está compuesto por tres agentes inteligentes interconectados, cada uno responsable de una etapa particular en el proceso de reclutamiento automatizado. Esta estructura modular favorece una mayor escalabilidad, facilita el mantenimiento y ofrece la flexibilidad necesaria para adaptarse a diversos contextos y organizaciones (Wooldridge, 2002).

Figura 19. Diagrama de arquitectura del sistema multiagente



Fuente: Elaboración propia

6.26 Agente 1: Extracción y autocompletado de formularios

Función: Extrae información relevante de currículums en formato PDF y la asigna de manera automática a los campos correspondientes en un formulario de solicitud.

6.27 Tecnologías empleadas:

1. Extracción: PyMuPDF, pdfplumber, unstructured, OCR
2. Procesamiento semántico: Mistral 7B, Llama 3, LangChain
3. Consulta contextual: LlamaIndex, SpaCy

6.28 Justificación técnica:

Se eligen modelos de lenguaje de baja complejidad y herramientas de código abierto con el propósito de asegurar su funcionamiento de manera local y salvaguardar la protección de la privacidad de los datos. Este enfoque integral combina técnicas de extracción estructurada y comprensión semántica, buscando optimizar la precisión y fomentar una automatización eficiente (Yang, Y., Mistral AI, 2024).

6.29 Tabla resumen de tecnologías por agente

Tabla 18. Tecnologías clave empleadas en cada agente del sistema

Agente	Función principal	Tecnologías utilizadas
Agente 1	Extracción y autocompletado	PyMuPDF, pdfplumber, Mistral 7B, LlamaIndex, LangChain
Agente 2	Filtro y visualización	scikit-learn, XGBoost, Sentence Transformers, Plotly, SHAP
Agente 3	Feedback automático	Mistral 7B, GPT4All, Jinja2, Perspective API, LangChain

Fuente: Elaboración propia

6.30 Justificación global de las elecciones técnicas

La arquitectura modular brinda la ventaja de posibilitar la ampliación o sustitución autónoma de agentes, conforme a las necesidades específicas de la organización. La adopción de modelos de código abierto y herramientas que operan en hardware convencional garantiza no solo la accesibilidad y la protección de la privacidad, sino también el cumplimiento de las normativas legales vigentes. Asimismo, la integración con frameworks como LangChain y LlamaIndex facilita la coordinación y el enriquecimiento progresivo de las capacidades de cada agente, permitiendo una evolución constante y adaptada a los requerimientos en desarrollo.

7 ANÁLISIS

Si bien esta parte debería estar enfocada al comportamiento de cada uno de los agentes en las 3 fases, su eje central va a ser: El agente 1 ya que, si no se desarrolla a cabalidad en el proceso de la extracción de los datos y compararlo con la oferta para generar campos variables, y guardarlos en una base de datos SQLite de manera organizada y estructurada, no tendría buenos resultados al momento de la selección de los candidatos, afectando además al agente 3, que no enviaría un feedback a los candidatos descartados, volviendo inservible el proyecto de selección con AI.

Por esta razón, esta sección estará dedicada al análisis de los resultados en el desarrollo del agente 1, métricas a evaluar, resultados, limitantes, las desventajas y recomendaciones futuras.

7.1 Propósito de la evaluación

El objetivo de esta fase no es “ganar un benchmark” con un sistema cerrado, sino entender con evidencia qué tan bien funcionan, en condiciones locales y con recursos abiertos, las distintas estrategias de extracción de los datos que para este proyecto son los CVs para autocompletar un formulario de postulación. La evaluación se centra en cuatro ejes:

1. Calidad de campos fijos.
2. Estructuración de los campos fijos (Nombres, Apellidos, correo electrónico, teléfono, ciudad y país) y los otros campos variables dependiendo de la oferta laboral como lo son: Experiencia/Educación (EXP/EDU).
3. Robustez en la detección de teléfono país y ciudad.
4. El impacto en UX. Además, se registra la latencia del sistema y se comparan variantes del pipeline con complejidad incremental.

7.2 Definiciones de métricas

Se evalúan Nombre(s), Apellidos, Email, Teléfono (E.164), País y Ciudad. La métrica base es exactitud (porcentaje de aciertos), con normalizaciones previas para evitar penalizaciones espurias:

1. Nombres y apellidos: comparación case-insensitive, normalización de acentos y tolerancia a uno o dos espacios; en apellidos compuestos se acepta equivalencia si las últimas 1–2 palabras coinciden tras normalizar.
2. Email: coincidencia exacta más validación de formato
3. Teléfono: se considera acierto si el valor final está en E.164 correcto (p. ej., +573209612563) y corresponde a uno de los números presentes en el CV.
4. País y ciudad: normalizados (acentos y variantes obvias) contra un catálogo básico.

La exactitud global de campos fijos es el promedio porcentual en la correcta extracción de los campos fijos. Esta decisión de métrica balancea campos fáciles (email) con otros más difíciles (nombres compuestos).

7.2.1 Experiencia / Educación (F1 por bloque)

Se mide la capacidad de estructurar experiencia y educación en entradas (bloques) con atributos mínimos. La métrica es F1 (armónica de precisión y recall) a nivel de bloque, considerada match cuando:

1. En Experiencia: (empresa \approx AND título \approx) con similitud de texto $\geq 0,85$ (medida difusa) y fechas que coinciden tras normalización (tolerancia ± 1 mes o semestre mapeado).

2. En Educación: (institución - y grado/área) con la misma regla y fechas normalizadas. Se hace micro-promedio sobre todos los bloques del conjunto de prueba. Este criterio evita inflar la métrica con coincidencias parciales sin coherencia temporal.

7.2.2 Teléfono (robustez)

Dos indicadores: El primero es tasa de falsos positivos (% de detecciones de teléfono que en realidad son rangos de fechas, semestres u otros números), cuanto menor, mejor y segundo, el porcentaje de resultados devueltos en E.164 válido sobre el total de CVs con teléfono presente —cuanto mayor, mejor—. La validación E.164 se apoya en una librería especializada.

7.2.3 Latencia

Se reporta latencia end-to-end (desde el envío del CV hasta la recepción del JSON) y, cuando sea posible, latencias por componente: preprocesado, reglas/NER, fallback LLM y serialización. En entornos locales, la latencia depende del hardware; por ello se reporta como referencia, no como KPI rígido.

7.2.4 Protocolo de evaluación

Variantes B0–B3. Se comparan cuatro configuraciones del pipeline, manteniendo el mismo preprocesado y normalizaciones para aislar el efecto de cada capa:

1. B0: Reglas puras. Regex de email/teléfono, normalización de fechas (meses y semestres), heurísticas EXP/EDU (palabras clave).
2. B1: Reglas + NER (spaCy). Se añade NER para PERSON/ORG/GPE, priorizando cabecera del CV para nombres/apellidos y reforzando la detección de empresas/instituciones.
3. B2: Reglas + LLM. Se usa LLM (open-source) sin NER como fallback para estructurar bloques ambiguos (prompts cerrados).

4. B3: Reglas + NER + LLM. Pipeline híbrido; LLM solo si, tras reglas + NER, persiste ambigüedad.

7.3 Resultados

Se analizaron 25 Currículos mostrando los siguientes resultados y los campos fijos (exactitud). El baseline Reglas+NER logra 82%. Con LLMs open-source en fallback (Mistral 7B) se eleva a 100%. Los comerciales (Gemini) marcan también un 100%.

En EXP/EDU (F1 por bloque). Los open-source bajan a un 32% y los comerciales tienen una precisión del 99%. Esto se debe a los formatos de los CVs que los hacen en Canvas en su mayoría o utilizan programas de diseño, esto dificulta la extracción de la experiencia y la educación, aún con reglas heurísticas podría mejorar la extracción si es notorio la extracción de un CV plano versus uno con diseño.

8 CONCLUSIÓN

Este proyecto nace con un enfoque comercial y de escalabilidad, pero en la implementación aparecen limitantes y preguntas: usar modelos gratuitos impone compromisos en precisión, latencia y soporte. Aun así, esta elección abre una puerta real para pequeñas y medianas empresas con presupuestos ajustados y áreas de RR. HH. reducidas: permite validar el caso de uso, medir impacto en tiempos y errores, operando con coste cero por consulta y mayor control de privacidad.

Como punto de partida, el stack open-source ofrece una base funcional y auditable sobre la cual crecer. A medida que el proyecto lo justifique, puede expandirse hacia modelos más complejos o de pago, obteniendo así, mayor robustez multiformato, contexto y soporte sin perder lo ya construido: se migra por capas (validadores → NER → LLM), manteniendo contratos de datos. Así, la ruta es progresiva, escalando con inversión dirigida donde el retorno sea claro.

8.1 Viabilidad del enfoque híbrido y relación coste-beneficio

La evidencia exploratoria indica que un pipeline híbrido que combina reglas, NER (spaCy) y un LLM en inferencia como fallback puede alcanzar un rendimiento casi cercano al de modelos pagos en los campos fijos del formulario (Nombre, Apellidos, Email, Teléfono en E.164, País, Ciudad). Este resultado es especialmente relevante en contextos con restricciones de presupuesto, privacidad y dependencia de proveedores: el procesamiento local (open-source) implica costo cero por consulta, control sobre versiones/prompts y mayor capacidad para auditar el flujo. Si bien los modelos comerciales mantienen ventaja en robustez y contexto, la brecha práctica se reduce cuando el pipeline se diseña con calidad desde la base (limpieza, normalización, validación y duplicación) e implementando una UX que gestione la ambigüedad.

8.2 El verdadero “motor” de la calidad: Data Preparation y validaciones

Los mayores saltos de precisión no provienen de “modelos más grandes”, sino de Data Preparation:

1. Separación de tokens pegados por OCR.
2. Normalización de fechas (incluidos semestres YYYY-1/2 → 02/08).
3. Validación estricta de teléfono en formato E.164, con filtros anti-fechas para evitar falsos positivos.
4. Heurísticas para clasificar EXP/EDU más por patrones y contexto que por simples palabras. Estas acciones pre-LLM disminuyen ruido y elevan la línea de base sobre la que cualquier componente generativo puede aportar. En otras palabras: el LLM suma, pero no sustituye la ingeniería de datos ni los validadores.

8.3 La UI con políticas convierte precisión técnica en valor operativo

La interfaz con políticas (Auto/Revisar/Confirmar) traslada la incertidumbre a un punto de decisión claro para el usuario. Los campos con alta confianza se autocompletan (Auto), y los dudosos piden revisión o confirmación. Esta lógica evita errores silenciosos y reduce la fricción: se observa una disminución sustancial del tiempo de completado y del número de correcciones manuales. La lección es estratégica: sin una UI que explique qué se autocompletó y por qué, la mejora algorítmica no siempre se traduce en adopción y satisfacción.

9 LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

Las limitaciones técnicas y metodológicas de la diversidad en los formatos de los CVs: La variedad en la organización de los currículums presenta desafíos para lograr una extracción completamente precisa, particularmente en aquellos documentos que han sido escaneados o que contienen tablas o imágenes complejas.

Sesgos algorítmicos: A pesar de la utilización de modelos de explicabilidad, existe la posibilidad de que los algoritmos hereden sesgos presentes en los datos históricos, lo cual puede afectar la equidad y justicia del sistema.

Dependencia del hardware local: El desempeño puede verse restringido en dispositivos que no cuenten con recursos adecuados, incluso cuando los modelos seleccionados son de naturaleza liviana.

Tamaño y diversidad de la muestra: Las pruebas se llevaron a cabo en un entorno controlado, lo que implica que la posible generalización de los resultados dependerá de su validación mediante conjuntos de datos más amplios y representativos de diversas características.

Las futuras líneas de trabajo buscan implementar módulos OCR avanzados con el fin de optimizar la extracción de datos en currículos que contienen imágenes y gráficos complejos.

Elaborar estrategias para la mitigación de sesgos mediante la aplicación de técnicas de equidad en la inteligencia artificial, acompañadas de un proceso de auditoría continua (Molnar, 2022).

Llevar a cabo pruebas en entornos reales e internacionales, fomentando la inclusión de diferentes idiomas y culturas de los usuarios para garantizar una mayor representatividad y adaptabilidad.

10 IMPACTO SOCIOECONÓMICO Y SOSTENIBILIDAD

Se pretende evaluar el impacto potencial del sistema multiagente propuesto sobre personas, organizaciones y ecosistemas tecnológicos, y lo alinea con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030. El análisis se basa en el diseño y evidencias del prototipo (pipeline híbrido Reglas+NER+LLM, autocompletado con políticas por campo y operación local con modelos open-source), así como en marcos internacionales (UN/UNESCO, OCDE) y el marco regulatorio de la UE (AI Act).

10.1 Democratización tecnológica para pymes

El enfoque local y open-source reduce el costo por consulta, incrementa el control de versiones/prompts y refuerza la privacidad de los candidatos, aspectos críticos en organizaciones con restricciones de presupuesto y cumplimiento. El diseño modular facilita adoptar gradualmente componentes comerciales cuando se requiera mayor robustez, manteniendo el núcleo trazable y auditable.

10.2 Mercado laboral y calidad del empleo

La literatura sugiere que la IA puede reconfigurar tareas (no solo sustituirlas), afectando perfiles administrativos y potenciando funciones analítico-estratégicas. Los estudios de la OIT describen exposición heterogénea a la IA generativa; la mayor parte del impacto previsto es complementario (enriquecimiento de tareas), más que una sustitución neta, si existen salvaguardas de formación y rediseño de roles.

10.3 Alineación con la Agenda 2030 (ODS)

La Agenda 2030 establece 17 ODS interdependientes. La digitalización responsable contribuye a productividad sostenible, inclusión y transparencia en la contratación. Mapeamos el proyecto a los ODS más pertinentes.

Tabla 19. Objetivos desarrollo sostenible

Objetivos de Desarrollo Sostenible	Contribución del sistema	Acciones de diseño ya presentes / propuestas
ODS 8 Trabajo decente y crecimiento	Menos tareas repetitivas en RR.HH. Tiempos de pre-cribado menores	Autocompletado con políticas. Datos normalizados; trazabilidad
ODS 9 Industria, innovación e infraestructura	Solución modular y open-source operable en hardware convencional.	Arquitectura por agentes; fallback LLM; versionado de prompts.
ODS 5 Igualdad de género	Controles de sesgo y revisión humana en casos sensibles.	Política “tratamiento de datos” obliga intervención humana; evaluación de paridad.)
ODS 12 Producción/consumo responsables	Eficiencia de cómputo (modelos ligeros locales) y medición energética.	Cuantización/CPU-first cuando sea viable; telemetría de energía.

Fuente: Elaboración propia basado en la Agenda 2030 (ODS)

10.4 Ética, gobernanza y cumplimiento (UE)

Las aplicaciones de IA en empleo/recursos humanos están clasificadas como alto riesgo en el Reglamento (UE) 2024/1689 (AI Act), lo que impone obligaciones de gestión de riesgos, calidad de datos, documentación técnica, transparencia, supervisión humana y ciberseguridad. El diseño del prototipo ya incorpora varios de estos principios (trazabilidad por campo, intervención humana vía políticas). Recomendación: mantener expediente técnico y pruebas de robustez/sesgo por versión.

10.4.1 GDPR – Decisiones automatizadas

El art. 22 GDPR reconoce el derecho a no ser objeto de decisiones basadas únicamente en tratamiento automatizado con efectos jurídicos o significativos, así como a obtener intervención humana y a impugnar la decisión. Operativamente: toda recomendación del sistema debe ser asistida, con trazas para justificar el criterio y un flujo de revisión humana en los casos marcados como “Confirmar el uso de la tecnología y tratamiento de los datos”.

10.4.2 Marcos internacionales de ética (UNESCO y OCDE)

La Recomendación de la UNESCO (2021) exige medidas para minimizar resultados discriminatorios a lo largo del ciclo de vida de los sistemas de IA; los Principios de la OCDE (2019) promueven IA fiable e innovadora que respete derechos humanos y valores democráticos. En la práctica: evaluaciones de sesgo recurrentes, documentación de datos y explicabilidad por diseño.

10.5 Sostenibilidad ambiental (energía y huella)

La demanda eléctrica de centros de datos alcanzó el 1,5% del consumo mundial (≈ 415 TWh) en 2024, con crecimiento anual del 12% desde 2017. Un escalado acrítico de IA puede aumentar la huella; por ello, la eficiencia debe ser un requisito, no un añadido. Medidas recomendadas para este proyecto: modelos compactos y cuantizados, inferencia bajo demanda, lotes/colas para cargas pico.

El enfoque local con LLMs ligeros evita costes de red y transferencias de datos personales a terceros, y puede ser más eficiente para cargas moderadas; no obstante, debe medirse frente a alternativas cloud (GPUs compartidas) para validar la opción con datos de consumo real.

10.6 Riesgos y medidas de mitigación

1. Sesgos y discriminación. Riesgo de disparidades por formato de CV, idioma o atributos proxy.

Medidas: muestreo estratificado, tests de paridad por campo, límites conservadores en autocompletado de datos sensibles, revisión humana obligatoria y documentación de errores por plantilla (ej., CVs “de diseño”).

2. Privacidad y cumplimiento. Tratamiento de datos personales y decisiones automatizadas.

Medidas: minimización y retención limitada, registro de consentimiento, canal de impugnación de decisiones y “human-in-the-loop” en casos que puedan “afectar significativamente”.

3. Sostenibilidad energética. Aumento de consumo por cargas IA.
Medidas: métricas Wh/CV, colas por lotes, cuantización, horarios valle, preferencia por infra con garantías de renovables cuando se externalice.
4. Exclusión digital. Candidatos con CVs no estandarizados o con limitaciones de accesibilidad.
Medidas: plantillas accesibles, canales alternativos de postulación, detección temprana de CVs “difíciles” y solicitud guiada de confirmación/corrección.
5. Dependencia tecnológica. Bloqueos por proveedores o modelos concretos.
Medidas: núcleo open-source trazable, interfaces estables y capacidad de intercambiar LLMs, con comparativas periódicas de calidad-coste.
6. Exclusión digital. Candidatos con CVs no estandarizados o con limitaciones de accesibilidad.
Medidas: plantillas accesibles, canales alternativos de postulación, detección temprana de CVs “difíciles” y solicitud guiada de confirmación/corrección.
7. Dependencia tecnológica. Bloqueos por proveedores o modelos concretos.
Medidas: núcleo open-source trazable, interfaces estables y capacidad de intercambiar LLMs, con comparativas periódicas de calidad-coste.

11 DECLARACIÓN DEL USO DE LA INTELIGENCIA ARTIFICIAL

Yo, Fabián Andrés Espinosa Vásquez, declaro que soy el autor de este trabajo. Cualquier asistencia de IA se usó como apoyo bajo mi supervisión y criterio, y no compromete la originalidad ni la integridad académica del documento. Asumo la responsabilidad por los contenidos, resultados y conclusiones aquí presentados.

Esta declaración sustenta la medida y para qué se emplearon herramientas de inteligencia artificial (IA) durante la redacción y/o edición de este Trabajo de Fin de Máster. Distingue entre el uso de IA como apoyo a la escritura y el uso de IA como parte del prototipo técnico evaluado en el trabajo, dejando claro que la autoría, selección de contenidos, interpretación de resultados y conclusiones corresponden totalmente al autor.

11.1 Herramientas empleadas y grado de asistencia

La demanda eléctrica de centros de datos alcanzó el 1,5% del consumo mundial (≈ 415 TWh) en 2024, con crecimiento anual del 12% desde 2017. Un escalado acrítico de IA puede aumentar la huella; por ello, la eficiencia debe ser un requisito, no un añadido. Medidas recomendadas para este proyecto: modelos compactos y cuantizados, inferencia bajo demanda, lotes/colas para cargas pico.

Como soporte de corrección ortográfica, y mejora de redacción se recurrió de forma puntual a asistentes de escritura/codificación basados en IA, no para la generación automática del contenido principal. El prototipo del sistema (pipeline híbrido Reglas+NER+LLM, ejecución local con modelos open-source se describe en la sección de metodología y constituye el objeto de estudio del TFM, no una herramienta de ghostwriting

Tabla 20. Asistencia con IA

A desarrollar	Descripción	Nivel de asistencia IA
Estructuración del TFM	Propuestas de índice, orden y titulación de apartados.	Nulo. Se sabía el orden, acorde a las directrices de la Universidad
Mejora de estilo y claridad	Reformulación de frases para fluidez, corrección gramatical y uniformidad terminológica.	Moderado. (edición humana final).
Tablas/figuras	Sugerencias de formatos para tablas y gráficos.	Leve. Sólo para verificación, de contenido
Fragmentos de código	Creación de código	Moderado -alto. Para corrección de errores y sugerencias.
Tratamiento de datos	Análisis de los 32 Currículos.	Nulo. Los CVs fueron reales

Fuente: Elaboración propia

11.2 Contenido no asistido por IA

1. La Revisión bibliográfica principal, selección de fuentes y citado (formato, enlaces y verificación de accesos).
2. Diseño experimental, recogida de evidencias y análisis de resultados (métricas, tablas y discusión).
3. Toda salida sugerida por IA fue revisada, contrastada y editada por el autor para asegurar exactitud, coherencia y originalidad.
4. No se han incluido citas inventadas ni datos no verificados; cualquier referencia procede de fuentes reales comprobadas y aparece en el apartado de Referencias.
5. Se mantuvo trazabilidad de versiones y cambios relevantes, especialmente en el prototipo (prompts, reglas, configuraciones).

11.3 Protección de datos y confidencialidad

Los documentos y ejemplos usados en pruebas de la fase 1 son Cvs reales, postulantes a la vacante de Unity Developer de la empresa OWOLS.com en Bogotá Colombia, se siguieron principios de minimización y privacidad. La ejecución local con modelos open-source evitó transferencias innecesarias de datos a terceros, alineándose con las consideraciones de privacidad descritas en la metodología y arquitectura del sistema.

12 REFERENCIAS

Abellás Rodríguez, U. (2024). Aplicacion de la Inteligencia Artificial a los procesos de Recursos Humanos. Repositorio Institucional de la Universidad Pontificia Comillas. <https://repositorio.comillas.edu/xmlui/handle/11531/79452>

Aguirre, M. F. (2022, 3 de junio). 10 software de reclutamiento para fichar al mejor talento en 2025. Appvizer. <https://www.appvizer.es/revista/recursos-humanos/reclutamiento/software-de-reclutamiento>

Aguirre, M. F. (2024, diciembre). Top 8 software de selección de personal 2025 [Comparativa de ATS]. Appvizer. <https://www.appvizer.es/revista/recursos-humanos/reclutamiento/software-de-seleccion-de-personal>

AI agents solutions. (s.f.). IBM. Recuperado el 7 de septiembre de 2025, de <https://www.ibm.com/solutions/ai-agents>

AI in HR: Position Your Organization for Success. (2024, enero). Gartner. <https://www.gartner.com/en/human-resources/topics/artificial-intelligence-in-hr>

AI Principles overview. (s.f.). OECD.AI. Recuperado el 7 de septiembre de 2025, de <https://oecd.ai/en/ai-principles>

Albassam, W. A. (2023). The power of artificial intelligence in recruitment: An analytical review of current AI-based recruitment strategies. International Journal of Professional Business Review, 8(6), e02089. <https://doi.org/10.26668/businessreview/2023.v8i6.2089>

Art. 22 GDPR – Automated individual decision-making, including profiling. (s.f.). General Data Protection Regulation (GDPR). Recuperado el 7 de septiembre de 2025, de <https://gdpr-info.eu/art-22-gdpr/>

Artificial Intelligence: A Modern Approach, 4th US ed. (2022, agosto). Berkeley.edu. <https://aima.cs.berkeley.edu/>

ATS - all you need to know. (s.f.). Elementapp.Ai. Recuperado el 7 de septiembre de 2025, de <https://elementapp.ai/eng/ats-all-you-need-to-know>

ATS (Applicant Tracking System): la herramienta perfecta para agilizar procesos de selección. (2022, 2 de noviembre). Personio. <https://www.personio.es/glosario/ats-sistema-de-gestion-de-candidatos/>

Briva-Iglesias, V. (2025). Are AI agents the new machine translation frontier? Challenges and opportunities of single- and multi-agent systems for multilingual digital communication. arXiv. <http://arxiv.org/abs/2504.12891>

Brunner, D., Larger, L., & Soriano, M. C. (2021). Nonlinear photonic dynamical systems for unconventional computing. arXiv. <http://arxiv.org/abs/2107.08874>

Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. En Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>

Cobar, A. J. (2025, 14 de enero). Ventajas y desventajas de los procesos automatizados. Sepiia. <https://sepiia.run/blog/ventajas-y-desventajas-de-los-procesos-automatizados/>

Cómo mejorar la experiencia del candidato con un ATS. (s.f.). LinkedIn Talent Solutions. Recuperado el 7 de septiembre de 2025, de <https://business.linkedin.com/es-es/talent-solutions/resources/talent-engagement/using-an-ats-to-improve-candidate-experience>

Costa, M. C. (2024, 16 de junio). El test del currículum falso: ¿hay sesgos racistas en el mercado laboral? RTVE.es. <https://www.rtve.es/television/20240616/test-curriculum-falso-sesgos-racistas-mercado-laboral/16146028.shtml>

Daugherty, P., & Burden, A. (2025, 5 de febrero). Technology trends 2024. Accenture. <https://www.accenture.com/mu-en/insights/technology/technology-trends-2024>

Deloitte. (2025). 2025 global Human Capital Trends. Deloitte Insights. <https://www.deloitte.com/us/en/insights/topics/talent/human-capital-trends.html>

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional Transformers for language understanding. arXiv. <http://arxiv.org/abs/1810.04805>

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019, junio). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. En Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers) (pp. 4171-4186). Association for Computational Linguistics. <https://aclanthology.org/N19-1423/>

El uso de inteligencia artificial en la selección de personal. (s.f.). Psico-smart.com. Recuperado el 27 de mayo de 2025, de <https://psico-smart.com/articulos/articulo-el-uso-de-inteligencia-artificial-en-la-seleccion-de-personal-34168>

Enabling online conversations. (s.f.). Perspective API. Recuperado el 7 de septiembre de 2025, de <https://perspectiveapi.com/>

Estrada, G. C. T., Coronado, M. L. F., Soria, Y. T. B., Jimenez, S. C., Cristobal, J. E. T., Camargo, M. R. S., Taipe, M. A. V., Aparicio, S. S. P., Luis, J., & Briceno, B. (s.f.). Inteligencia artificial en la gestion de los recursos humanos. Revista de Climatología, 24, 2082–2092. <https://doi.org/10.59427/rcli/2024/v24cs.2082-2092>

EY & IBM. (2023, 3 de octubre). EY and IBM launch artificial intelligence solution designed to help increase productivity and drive efficiencies within HR. IBM Newsroom. <https://newsroom.ibm.com/2023-10-10-EY-and-IBM-launch-artificial-intelligence-solution-designed-to-help-increase-productivity-and-drive-efficiencies-within-HR>

Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. AI Magazine, 17(3), 37–54. <https://doi.org/10.1609/aimag.v17i3.1230>

García Novoa, C., & Hernández Rodríguez, F. (Dirs.). (2024). Estudios sobre inteligencia artificial y economía digital. Aranzadi / Dykinson. <https://www.dykinson.com/libros/estudios-sobre-inteligencia-artificial-y-economia-digital/9788411629058/>

Generative AI and Jobs: A global analysis of potential effects on job quantity and quality. (2023, 21 de agosto). International Labour Organization. <https://www.ilo.org/publications/generative-ai-and-jobs-global-analysis-potential-effects-job-quantity-and>

Ghudasara, A. (2025, 6 de marzo). Top 11 recruitment metrics to stay ahead in 2025. iSmartRecruit. <https://www.ismartrecruit.com/blog-recruitment-metrics-measure-recruitment-performance>

GitHub. (s.f.). GitHub · Build and ship software on a single, collaborative platform. Recuperado el 7 de septiembre de 2025, de <https://github.com/>

Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design Science in Information Systems Research. MIS Quarterly, 28(1), 75–105. <https://doi.org/10.2307/25148625>

Hiring Branch & da Silva, C. N. (2024, 11 de diciembre). 25+ high-volume recruiting statistics to supercharge your 2025 hiring strategy. Hiringbranch.com. <https://www.hiringbranch.com/blog/25-high-volume-recruiting-statistics-to-supercharge-your-2025-hiring-strategy>

Humansmart. (2025, 5 de junio). ¿Qué estrategias implementar para maximizar la eficiencia de un ATS en la selección de talento? <https://blogs.es/articulo-que-estrategias-implementar-para-maximizar-la-eficiencia-de-un-ats-en-la-seleccion-de-talento-53204>

IBM. (2021, 17 de agosto). SPSS Modeler Subscription. Ibm.com. <https://www.ibm.com/docs/es/spss-modeler/saas?topic=guide-introduction-crisp-dm>
Innoq, B. (2025, 24 de marzo). CRISP-ML(Q). The ML Lifecycle Process. Ml-ops.org. <https://ml-ops.org/content/crisp-ml>

Inteligencia artificial en Recursos Humanos: tendencias y aplicaciones. (2023, 7 de julio). Personio. <https://www.personio.es/glosario/inteligencia-artificial-recursos-humanos/>

International Energy Agency. (s.f.). The transformative potential of AI depends on energy. Iea.org. Recuperado el 7 de septiembre de 2025, de <https://www.iea.org/reports/energy-and-ai/executive-summary>

Introduction to LangChain. (s.f.). Langchain.com. Recuperado el 7 de septiembre de 2025, de <https://python.langchain.com/docs/introduction/>

Jennings, N. R., & Wooldridge, M. (1998). Agent Technology: Foundations, Applications, and Markets. Springer-Verlag.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. En *Advances in Neural Information Processing Systems* 30 (pp. 3146–3154). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf

León Espinoza, L. A. (2024). Inteligencia Artificial en la Gestión de Recursos Humanos: Tendencias y Perspectivas. *Business Innova Sciences*, 5(1), 58-84. <https://doi.org/10.5281/zenodo.13308360>

Lewis, G. (2017, diciembre). How to give constructive feedback to candidates and hiring managers. LinkedIn Business. <https://www.linkedin.com/business/talent/blog/talent-acquisition/how-to-give-constructive-feedback-to-candidates-and-hiring-managers>

Li, Y., Bubeck, S., Eldan, R., Del Giorno, A., Gunasekar, S., & Lee, Y. T. (2023). Textbooks Are All You Need II: phi-1.5 technical report. arXiv. <http://arxiv.org/abs/2309.05463>

LlamaIndex Documentation. (s.f.). Llamaindex.Ai. Recuperado el 7 de septiembre de 2025, de <https://docs.llamaindex.ai/en/stable/>

Los 7 mejores software de reclutamiento [2024]. (2024, 14 de agosto). Personio. <https://www.personio.es/glosario/software-de-reclutamiento/>

Mendis, R. (s.f.). 5 Ways AI is Transforming Talent Acquisition. Human Capital Institute. Recuperado el 7 de septiembre de 2025, de <https://www.hci.org/webcast/5-ways-ai-transforming-talent-acquisition>

Mistral 7B. (2023, 27 de septiembre). Mistral.Ai. <https://mistral.ai/news/announcing-mistral-7b>

Molnar, C. (s.f.). Interpretable machine learning. Github.Io. Recuperado el 6 de julio de 2025, de <https://christophm.github.io/interpretable-ml-book/>

Montréal, J. (2025, 4 de julio). Employee career path: stages and a complete guide to improving it. Appvizer. <https://www.appvizer.com/magazine/hr/workforce-mgt/employee-journey>

Ollama Search. (s.f.). Ollama.com. Recuperado el 29 de junio de 2025, de <https://ollama.com/search>

OpenAI. (2023, marzo). GPT-4 Technical Report. <https://cdn.openai.com/papers/gpt-4.pdf>
Pdfplumber. (s.f.). PyPI. Recuperado el 7 de septiembre de 2025, de <https://pypi.org/project/pdfplumber/>

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Louppe, G., Prettenhofer, P., Weiss, R., Weiss, R. J., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.

Pérez-Ugena, M. (2024). La inteligencia artificial: definición, regulación y riesgos para los derechos fundamentales. *Estudios de Deusto*, 72(1), 307-337. <https://revista-estudios.revistas.deusto.es/article/view/3108>

Personio. (2024). IA en RRHH: Una guía completa. <https://www.personio.es/glosario/inteligencia-artificial-recursos-humanos/>

Plotly. (s.f.). Plotly Python Graphing Library. Plotly.com. Recuperado el 7 de septiembre de 2025, de <https://plotly.com/python/>

Psico-smart.com. (2025, 3 de junio). ¿Qué limitaciones tienen las pruebas de personalidad en el ámbito laboral y cómo pueden afectar la evaluación de candidatos? <https://blogs-es.psico-smart.com/articulo-que-limitaciones-tienen-las-pruebas-de-personalidad-en-el-ambito-laboral-y-como-pueden-afectar-la-evaluacion-de-candidatos-102269>

Recommendation on the Ethics of Artificial Intelligence. (2024, 26 de septiembre). Unesco.org. <https://www.unesco.org/en/articles/recommendation-ethics-artificial-intelligence>

Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence and amending Regulations (EC) No 300/2008, (EU) No 167/2013, (EU) No 168/2013, (EU) 2018/858, (EU) 2018/1139 and (EU) 2019/2144 and Directives 2006/42/EC, 2013/53/EU and (EU) 2020/1828 (Artificial Intelligence Act). (2024, 13 de junio). EUR-Lex. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>

Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence embeddings using Siamese BERT-networks. arXiv. <http://arxiv.org/abs/1908.10084>

Russell, S. J., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach (4th ed.). Pearson. <https://aima.cs.berkeley.edu/>

Sáenz, M. (2025, 30 de julio). El funnel de reclutamiento necesita un rebranding: la escucha al empleado empieza antes de que lo sea. ORH | Observatorio de Recursos Humanos. <https://www.observatoriorh.com/orh/el-funnel-de-reclutamiento-necesita-un-rebranding-la-escucha-al-empleado-empieza-antes-de-que-lo-sea.html>

Sandler, G. M. T. (2012). The Art of Software Testing (3rd ed.). John Wiley & Sons, Inc.
Santaella, R. (2025, 20 de enero). La IA en la selección de personal: innovación y consideraciones éticas. Máster en Big Data & Inteligencia Artificial de la Universidad de Málaga. <https://www.bigdata.uma.es/la-ia-en-la-seleccion-de-personal-innovacion-y-consideraciones-eticas/>

Set, W. D. (2025, 7 de enero). The future of onboarding: Key trends every HR leader needs to know for 2025. Human Resources Today. <https://www.humanresourcetoday.com/frs/27753049/the-future-of-onboarding--key-trends-every-hr-leader-needs-to-know-for-2025/email>

Text generation and prompting Learn how to prompt a model to generate text. (s.f.). OpenAI. Recuperado el 7 de septiembre de 2025, de <https://platform.openai.com/docs/guides/text?api-mode=responses>

Textos legislativos. (s.f.). Artificialintelligenceact.Eu. Recuperado el 7 de septiembre de 2025, de <https://artificialintelligenceact.eu/es/el-acto>

UNESCO. (2021). Recommendation on the Ethics of Artificial Intelligence. <https://unesdoc.unesco.org/ark:/48223/pf0000380455>

United Nations. (s.f.). The 17 goals. Sdgs.un.org. Recuperado el 7 de septiembre de 2025, de <https://sdgs.un.org/goals>

van Dort, S. (2024, 29 de febrero). ¿Qué es un sistema de seguimiento de candidatos? La herramienta imprescindible de RRHH. Teamtailor.com. <https://www.teamtailor.com/es/content-hub/que-es-un-sistema-de-seguimiento-de-candidatos-la-herramienta-imprescindible-de-recursos-humanos/>

Vega, A. C. (2025, 4 de febrero). El impacto de la IA en el empleo: seis claves para 2025. ORH | Observatorio de Recursos Humanos. <https://www.observatoriorh.com/iaigual/el-impacto-de-la-ia-en-el-empleo-seis-claves-para-2025.html>

Wooldridge, M. (2002). An Introduction to Multi Agent Systems. John Wiley & Sons.

Yang, Y., Wu, Z. N., Yang, Y., Lian, S., Guo, F., & Wang, Z. (s.f.). A Survey of Information Extraction Based on Deep Learning. ResearchGate. Recuperado el 7 de septiembre de 2025, de https://www.researchgate.net/publication/363894835_A_Survey_of_Information_Extraction_Based_on_Deep_Learning

Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., ... Wen, J.-R. (2023). A survey of large language models. arXiv. <http://arxiv.org/abs/2303.18223>

13 ANEXOS

ANEXO I



Miguel de la Rosa López • 3er+

Técnico de IT || Soporte IT || Técnico HelpDesk ||

6 días • 🌐

[+ Seguir](#)

Las entrevistas fantasma: ¿tanto cuesta mandar un correo?

Hace unas semanas hice una entrevista en la que, además de pasar por el proceso habitual, tuve que grabarme en vídeo respondiendo a preguntas predefinidas. Hasta ahí, bien. La empresa se comprometía a dar una respuesta, independientemente del resultado.

Pues aquí sigo esperando.

Es agotador cómo algunas empresas exigen dedicación, preparación y hasta pasar por procesos largos y fríos... para luego desaparecer sin decir ni un simple "gracias por tu tiempo, pero no encajas". ¿De verdad cuesta tanto mandar un correo automático?

No es solo por saber si pasas o no. Es por respeto al tiempo de los candidatos. Es por profesionalidad.

Si queremos procesos de selección más humanos, esto tiene que cambiar.

¿También os ha pasado? Me gustaría leer vuestras experiencias.

Captura de pantalla plataforma LinkedIn. fotografía soporte sobre inconformidad con el proceso de cribación y selección mediante ATS

ANEXO II

**Micaela Ayelen Velazquez** • 3er+

Operador de producción en Ferrero | Manipulación de alimentos

2 semanas •

[+ Seguir](#)

ESTOY EN BÚSQUEDA LABORAL. Y no voy a mentir: el proceso es AGOTADOR.

Dedico horas a mejorar mi CV, a completar formularios eternos donde me piden que vuelva a escribir toda la información que ya está en mi currículum. Cada postulación es una mezcla de esperanza y ansiedad.

Pero lo más difícil no es la espera. Es el SILENCIO.

Mandás un CV y no sabés si alguien lo leyó. Hacés una entrevista y no te vuelven a escribir. Aplicás a decenas de ofertas y, en la mayoría, ni siquiera recibís un "gracias por postularte". Y entonces la duda empieza a meterse en la cabeza: ¿Estoy haciendo algo mal? ¿Hay algo en mí que no es suficiente?

Es un proceso estresante, que desgasta, que hace replantearse muchas cosas. Pero algo que aprendí en este camino es lo importante que es tener un sostén. En mi caso, es mi pareja, quien me recuerda mi valor cuando yo mismo lo pongo en duda. Pero puede ser cualquier persona en quien confíes: un amigo, un familiar, un colega. Alguien que te escuche, que te aliente y que te ayude a no perder el foco. Porque buscar trabajo no debería ser un camino solitario.

Si estás en la misma, te entiendo. Y si trabajás en selección, ojalá que este post sirva para recordar lo importante que es dar una respuesta, por mínima que sea. Porque del otro lado hay personas, no solo candidatos.

11.367

655 comentarios • 725 veces compartido

Captura de pantalla plataforma LinkedIn. fotografía soporte sobre inconformidad con el proceso de cribación y selección mediante ATS

ÍNDICE DE TABLAS

- Tabla 1: Comparación entre métodos tradicionales, sistemas ATS y sistemas multiagente basados en IA
- Tabla 2: Funciones y beneficios de los agentes propuestos
- Tabla 3: Comparación entre funciones actuales y funciones mejoradas con IA
- Tabla 4: Comparación crítica entre ATS tradicionales y sistemas multiagente con IA
- Tabla 5: Fases de CRISP-ML(Q) con los multiagentes
- Tabla 6. Fases de CRISP-ML(Q) con los multiagentes
- Tabla 7: Fases de CRISP-ML(Q) con los multiagentes
- Tabla 8. Comparativa formularios tradicionales vs propuesto
- Tabla 9. Componentes tecnológicos Agente 2
- Tabla 10. Métricas Agente 2
- Tabla 11. Componentes tecnológicos Agente 3
- Tabla 12. Métricas Agente 3
- Tabla 13. Ejemplo de estructura de feedback automatizado
- Tabla 14. Resumen de pruebas funcionales implementadas en la integración del sistema.
- Tabla 15. Métricas globales de desempeño del sistema multiagente
- Tabla 16. Comparación del sistema multiagente con ATS tradicional y proceso manual
- Tabla 17. Recursos tecnológicos utilizados en el desarrollo del sistema
- Tabla 18. Tecnologías clave empleadas en cada agente del sistema
- Tabla 19. Objetivos desarrollo sostenible
- Tabla 20. Asistencia con IA

ÍNDICE DE FIGURAS

- Figura 1. Testimonios reales sobre procesos de selección
- Figura 2. Testimonios reales sobre procesos de selección.
- Figura 3. Testimonios reales sobre procesos de selección.
- Figura 4. Proceso de cribado automático mediante ATS
- Figura 5. Ciclo básico de un agente inteligente
- Figura 6. Arquitectura multiagente para la selección automatizada de candidatos.
- Figura 7. Flujo de extremo a extremo
- Figura 8. Estructura de carpetas
- Figura 9. Swagger
- Figura 10. Formulario frontend
- Figura 11. Exactitud por campo fijo
- Figura 12. Cobertura de predicción por campo
- Figura 13. Métricas de teléfono
- Figura 14. Diagrama de flujo del agente 2: evaluación y visualización
- Figura 15. Diagrama de flujo del Agente3: generación de feedback automatizado
- Figura 16. Arquitectura de integración de los agentes del sistema multiagente
- Figura 17. Ciclo de integración y ajuste en sistemas multiagente
- Figura 18. Ejemplo de flujo de feedback del usuario final
- Figura 19. Diagrama de arquitectura del sistema multiagente

ÍNDICE DE ACRÓNIMOS Y ABREVIACIONES

Iniciales	Español	Inglés
IA	Inteligencia Artificial	Artificial Intelligence
RRHH	Recursos Humanos	Human resources
ATS	Sistema de seguimiento de candidatos	Applicant Tracking System
OS	Código abierto	Open Source
FO	Plataformas de orquestación	Orchestration Frameworks
FB	Retroalimentación	Feedback
CVs	Currículos	Currículos
E2E	End to end	End to end
NER	Reconocimiento de Entidades con Nombre	Named Entity Recognition
LLM	Gran Modelo de Lenguaje	Large Language Model