



O USO DA INTELIGÊNCIA ARTIFICIAL NO RECRUTAMENTO E SELEÇÃO: EFICIÊNCIA OPERACIONAL VERSUS RISCOS DE VIESES E FALTA DE TRANSPARÊNCIA NAS DECISÕES AUTOMATIZADAS

MATEUS ICARO DA CUNHA CORRÊA

ANDRÉ LOGAN ALMEIDA DE MATOS

DAVI DE SOUZA LOPES

RESUMO

O presente trabalho propõe o desenvolvimento do RH.AI, um sistema de recrutamento e seleção baseado em Inteligência Artificial voltado a empresas do Polo Industrial de Manaus. O problema central investigado está na ineficiência dos processos manuais de triagem de currículos e na ocorrência de vieses nas decisões de seleção, fatores que comprometem tanto a produtividade do setor de Recursos Humanos quanto a equidade das contratações. O sistema contempla módulos de Processamento de Linguagem Natural para extração de informações curriculares, mecanismo de pseudonimização e segregação de dados sensíveis, motor de pontuação parametrizável e registro de auditoria das decisões automatizadas. A metodologia adotada é de natureza aplicada e exploratória, combinando revisão bibliográfica e análise de requisitos estruturada por meio de técnicas de elicitação, resultando na especificação de requisitos funcionais e não funcionais, modelagem de banco de dados relacional, diagrama de casos de uso e fluxograma de funcionamento. Os resultados esperados incluem redução no tempo de triagem, maior consistência nas avaliações e conformidade com a Lei Geral de Proteção de Dados, demonstrando a viabilidade técnica e ética da solução.

Palavras-chave: Inteligência Artificial. Recrutamento e Seleção. Processamento de Linguagem Natural. Engenharia de Software. Análise de Requisitos.

ABSTRACT

This work proposes the development of RH.AI, a recruitment and selection system based on Artificial Intelligence aimed at companies in the Manaus Industrial Hub. The central problem investigated is the inefficiency of manual CV screening processes and the occurrence of biases in selection decisions, factors that compromise both the productivity of the Human Resources sector and the equity of hiring. The system includes Natural Language Processing modules for extracting curricular information, a pseudonymization and segregation mechanism for sensitive data, a configurable scoring engine and an audit record of automated decisions. The methodology adopted is of an applied and exploratory nature, combining bibliographic review and structured requirements analysis through elicitation techniques, resulting in the specification of functional and non-functional requirements, relational database modeling, use case diagram and operating flowchart. Expected results include reduction in screening time, greater consistency in assessments and compliance with the General Data Protection Law, demonstrating the technical and ethical feasibility of the solution.

Keywords: Artificial Intelligence. Recruitment and Selection. Natural Language Processing. Software Engineering. Requirements Analysis.



1. INTRODUÇÃO

A transformação digital tem impulsionado mudanças profundas na forma como as organizações operam, influenciando diretamente seus processos internos e estratégias de gestão. Nesse cenário, a Inteligência Artificial (IA) se consolidou como uma das principais tecnologias responsáveis por essa evolução, possibilitando a automação de tarefas, a análise de grandes volumes de dados e o suporte à tomada de decisões em diferentes setores. Empresas do Polo Industrial de Manaus, inseridas em um ambiente de alta competitividade, têm buscado soluções que aumentem a eficiência operacional sem abrir mão de critérios éticos e de qualidade.

No setor de Recursos Humanos, a IA tem se destacado principalmente nos processos de recrutamento e seleção, historicamente marcados por elevada subjetividade e grande volume de trabalho manual. Sistemas inteligentes são capazes de analisar currículos, identificar padrões de compatibilidade e conduzir triagens iniciais com maior padronização e agilidade. Esse cenário é especialmente relevante em empresas com alto volume de contratações, onde o prazo de preenchimento de vagas impacta diretamente a produtividade das linhas de operação.

Contudo, o uso da IA nesse contexto traz desafios concretos. A dependência de dados históricos pode levar à reprodução de vieses, comprometendo a diversidade nas contratações. Um caso amplamente documentado ocorreu em 2018, quando a Amazon precisou descontinuar um sistema de recrutamento por IA que apresentava discriminação de gênero, favorecendo candidatos masculinos em virtude dos padrões presentes nos dados de treinamento. Esse episódio evidencia que tecnologias de IA, quando mal projetadas, perpetuam desigualdades já existentes nos processos que pretendem automatizar.

A problemática central deste trabalho consiste em compreender como um sistema de Inteligência Artificial voltado ao recrutamento pode ser projetado de forma a aumentar a eficiência operacional e garantir, ao mesmo tempo, transparência, equidade e conformidade legal nas decisões automatizadas.

O objetivo geral é especificar e propor o sistema RH.AI, detalhando sua arquitetura, requisitos, modelagem de dados e fluxo de funcionamento. Os objetivos específicos são: elicitar e documentar os requisitos funcionais e não funcionais do sistema; elaborar o diagrama de casos de uso e o fluxograma de funcionamento; modelar o banco de dados relacional; e descrever a arquitetura técnica e os mecanismos de comunicação em rede e segurança.

A fundamentação teórica está organizada em três capítulos. O primeiro aborda o uso da IA no recrutamento e seleção, com ênfase em seus benefícios, limitações e questões éticas. O segundo trata das técnicas de Aprendizado de Máquina e Processamento de Linguagem Natural aplicadas à análise de currículos. O terceiro apresenta os fundamentos de Engenharia de Software, com foco em análise de requisitos, modelagem UML, arquitetura de sistemas e tecnologias utilizadas na construção do sistema.

A relevância desta pesquisa está na contribuição prática ao desenvolvimento de soluções tecnológicas responsáveis na área de gestão de pessoas. Ao detalhar a especificação técnica com mecanismos integrados de mitigação de vieses e auditoria, o trabalho oferece um modelo replicável para organizações que desejam modernizar seus processos seletivos com embasamento técnico e ético.



2. CARACTERIZAÇÃO DA EMPRESA

A organização analisada é uma empresa de médio porte do segmento de manufatura localizada no Polo Industrial de Manaus, atuando há mais de quinze anos na fabricação de componentes eletrônicos destinados ao mercado nacional e internacional. Com aproximadamente 600 colaboradores distribuídos entre os setores de produção, engenharia, logística, qualidade e administrativo, a empresa mantém processos estruturados e certificações de qualidade reconhecidas, consolidando-se como fornecedora de grandes montadoras instaladas na região.

A estrutura de Recursos Humanos é composta por uma equipe dedicada às atividades de recrutamento, seleção, treinamento, desenvolvimento e gestão de benefícios. O principal desafio do setor está em garantir a reposição ágil de pessoal para atender às demandas das linhas de produção, que operam em regime de dois turnos. A alta rotatividade em alguns postos operacionais e a necessidade contínua de captação de mão de obra qualificada tornam os processos seletivos críticos para a manutenção da produtividade.

Atualmente, o recrutamento é conduzido de forma predominantemente manual, com os profissionais de RH realizando a triagem individual de currículos recebidos por e-mail e plataformas de emprego. Esse método, além de consumir grande volume de tempo da equipe, apresenta limitações quanto à padronização dos critérios de avaliação e à rastreabilidade das decisões. Em processos com alto número de candidaturas, frequentemente superiores a 200 inscrições por vaga, a análise manual compromete tanto a qualidade das avaliações quanto o prazo de contratação.

A empresa tem demonstrado interesse crescente na adoção de soluções tecnológicas para seus processos internos, tendo implementado recentemente sistemas de gestão integrada nas áreas de produção e logística. O setor de Recursos Humanos, contudo, ainda carece de ferramentas digitais adequadas para as etapas iniciais do recrutamento, representando uma oportunidade clara de modernização alinhada aos objetivos estratégicos da organização.

A implementação da solução proposta visa suprir essa lacuna, otimizando a triagem de candidatos, reduzindo a subjetividade das decisões e promovendo maior transparência nas etapas iniciais do processo seletivo, garantindo que a empresa mantenha sua capacidade de atração e retenção de talentos.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Inteligência Artificial aplicada ao recrutamento e seleção

Recrutar bem é difícil. Um profissional de RH que analisa duzentos currículos em um único dia começa a tomar decisões diferentes das que tomaria nas primeiras dezenas: a fadiga introduz inconsistências, a repetição reduz a atenção a detalhes e fatores irrelevantes (como o nome do candidato ou a escola onde estudou) acabam pesando na triagem de forma não intencional. Quando empresas de tecnologia passaram a substituir parte desse processo por algoritmos, a justificativa era clara: máquinas não se cansam, não têm preconceitos conscientes e podem aplicar critérios idênticos a milhares de candidatos ao mesmo tempo.

O que esse argumento ignorava ficou evidente em 2018, quando a Amazon descontinuou um sistema de triagem de currículos desenvolvido ao longo de anos. O algoritmo, treinado com dados históricos de contratações anteriores, aprendeu a penalizar currículos que continham o termo 'feminino', a exemplo de 'clube de xadrez feminino', por identificar que homens eram



contratados com maior frequência nas áreas técnicas da empresa. O sistema não estava com defeito; estava funcionando exatamente como projetado, reproduzindo fielmente o padrão humano que existia nos dados (O'NEIL, 2016). Esse episódio tornou-se referência na literatura sobre vieses algorítmicos porque demonstrou algo importante: quando dados históricos refletem discriminação, automatizar decisões com base nesses dados não elimina o viés; pelo contrário, amplifica-o.

Cappelli (2019) examinou precisamente esse paradoxo ao analisar práticas de contratação modernas: ferramentas que prometem objetividade frequentemente transferem a subjetividade humana para o nível dos dados de treinamento, tornando-a menos visível e, portanto, mais difícil de contestar. Do ponto de vista dos candidatos, uma rejeição por algoritmo é quase impossível de questionar: não há um recrutador para conversar, nem critério declarado. Isso levanta questões que vão além da tecnologia e chegam ao campo dos direitos.

No Brasil, essas questões ganharam contorno legal com a Lei Geral de Proteção de Dados (LGPD, Lei 13.709/2018). O artigo 20 estabelece que os titulares têm direito a explicações sobre decisões tomadas exclusivamente com base em tratamento automatizado, incluindo as que afetem seus interesses. Essa exigência transforma a inexplicabilidade, entendida como a capacidade de um sistema justificar suas decisões de forma inteligível, de boa prática em obrigação legal. A Comissão Europeia (2019), ao definir os princípios para sistemas de IA confiáveis, chega a conclusão semelhante: sistemas opacos que tomam decisões sobre pessoas não são apenas eticamente problemáticos, são tecnicamente incompletos.

Essas tensões definiram as escolhas de projeto da solução desenvolvida neste trabalho. O módulo de anonimização existe porque os dados processados pelos algoritmos de PLN não devem conter informações que permitam que vieses demográficos se manifestem. O módulo de auditoria existe porque a LGPD exige rastreabilidade das decisões automatizadas. A supervisão humana não é uma concessão às limitações da IA; trata-se de um requisito de arquitetura. Construir o sistema sem entender essas restrições seria, no mínimo, juridicamente arriscado.

3.2 Aprendizado de Máquina e Processamento de Linguagem Natural

Currículos são documentos desestruturados. Diferentemente de um formulário padronizado, um currículo pode descrever a mesma experiência de dezenas de maneiras distintas: 'desenvolvedor backend', 'programador server-side' e 'engenheiro de software com foco em APIs REST' podem se referir a perfis muito próximos ou completamente diferentes, dependendo do contexto de cada empresa e trajetória profissional. Fazer triagem em escala significa resolver um problema de compreensão de linguagem natural: identificar o que é relevante em um texto livre, sem saber exatamente como esse texto foi escrito.

O aprendizado de máquina aborda esse problema de uma perspectiva fundamentalmente diferente da programação convencional. Em vez de codificar explicitamente as regras para identificar um 'desenvolvedor Python sênior', treina-se um modelo com exemplos e deixa-se que o algoritmo aprenda quais padrões textuais correspondem a quais perfis. Mitchell (1997) formalizou esse princípio de forma direta: um programa aprende quando sua performance em uma tarefa melhora com a experiência, sem ter sido explicitamente programado para aquela tarefa. No contexto de triagem de currículos, 'experiência' são os dados históricos de contratações e 'performance' é a capacidade de identificar candidatos compatíveis com uma vaga.



Antes de qualquer classificação, os currículos precisam ser convertidos em representações numéricas que o algoritmo possa processar. O Processamento de Linguagem Natural oferece as ferramentas para essa conversão: a tokenização divide o texto em unidades mínimas; o reconhecimento de entidades nomeadas (NER) identifica automaticamente nomes de empresas, cargos e habilidades; e modelos de word embeddings como o Word2Vec (MIKOLOV et al., 2013) representam cada palavra como um vetor numérico de modo que termos semanticamente próximos ocupem posições próximas nesse espaço. Isso permite ao sistema identificar que 'liderança de times' e 'gestão de equipes' expressam competências equivalentes, sem que essa equivalência precise ser programada manualmente.

Modelos baseados em word embeddings tradicionais têm uma limitação relevante: a representação de uma palavra é fixa independentemente do contexto em que aparece. 'Java', por exemplo, recebe o mesmo vetor seja numa frase sobre programação ou sobre café. Arquiteturas como o BERT, de Devlin et al. (2018), resolveram esse problema com mecanismos de atenção bidirecional: o modelo considera simultaneamente o que vem antes e depois de cada token para determinar seu significado contextual. Para análise de currículos, isso faz diferença prática: 'líder de projeto' em uma startup tech e em uma equipe de logística pressupõem conjuntos de competências distintos. O sistema utiliza um modelo BERT pré-treinado e ajustado para o português, dado que modelos treinados originalmente em inglês apresentam desempenho inferior em textos brasileiros.

A biblioteca spaCy (HONNIBAL; MONTANI, 2017) foi selecionada para o estágio de pré-processamento e extração de entidades por razões que vão além do desempenho técnico: ela oferece modelos para português, integração direta com pipelines de aprendizado de máquina e API consistente que facilita a manutenção do código. A alternativa mais citada academicamente, o NLTK, é mais completa como ferramenta de pesquisa mas menos otimizada para produção. Em um sistema que processará centenas de currículos por hora, a diferença de velocidade entre as duas bibliotecas tem implicação direta no RNF01, que estabelece o limite de cinco segundos por currículo processado.

3.3 Engenharia de Software: requisitos, modelagem, arquitetura e tecnologias

Sistemas que apoiam decisões sobre pessoas precisam ser auditáveis, modificáveis e compreensíveis por quem os mantém. Essa exigência vai além do cuidado técnico habitual no desenvolvimento de software, sendo consequência direta do que o sistema faz. Se um erro no módulo de pontuação resultar em candidatos qualificados sendo sistematicamente filtrados por um critério incorreto, é necessário que esse problema seja detectável, rastreável até sua origem e corrigível sem desmontar todo o sistema. A Engenharia de Software, enquanto disciplina, existe para tornar isso possível (SOMMERVILLE, 2019). As práticas de levantamento de requisitos, modelagem e arquitetura descritas aqui não são formalidades acadêmicas; são as ferramentas que permitem construir um sistema que pode ser entendido, testado e evoluído.

O levantamento de requisitos é frequentemente descrito como a etapa em que os desenvolvedores 'coletam' o que o cliente quer. Na prática, é uma atividade de descoberta mútua: o cliente nem sempre sabe exatamente o que quer até começar a articular o problema, e os desenvolvedores só entendem os limites técnicos do que é pedido quando ouvem os requisitos sendo formulados. Pressman e Maxim (2021) distinguem requisitos funcionais, que descrevem o que o sistema deve fazer, dos não funcionais, que definem como o sistema deve se comportar. Para este projeto, essa distinção teve consequências arquiteturais concretas: o requisito de processar um currículo em até cinco segundos (RNF01) levou à decisão de isolar



o pipeline de PLN em servidor dedicado; e o RNF04, de conformidade com a LGPD, tornou o módulo de anonimização obrigatório desde a concepção do sistema.

A UML surgiu nos anos 1990 como tentativa de padronizar a comunicação entre equipes de desenvolvimento que desenhavam sistemas de formas incompatíveis. Booch, Rumbaugh e Jacobson (2005) argumentam que o valor da linguagem não está na precisão formal, mas na capacidade de criar um vocabulário compartilhado. O diagrama de casos de uso apresentado na seção 5.6 foi construído não como exercício de documentação, mas para tornar explícito um ponto que inicialmente não era óbvio: as permissões de Recrutador e Administrador se sobrepõem em algumas funcionalidades mas com níveis de acesso distintos; deixar isso implícito teria resultado em um modelo de autenticação inadequado.

A escolha da arquitetura em camadas não foi apenas a opção mais comum, mas a mais adequada dado o conjunto de restrições do projeto. Fowler (2002) descreve as vantagens desse padrão em termos de isolamento de mudanças: alterações em uma camada não se propagam para as demais, desde que as interfaces entre elas sejam mantidas. No contexto deste sistema, isso importa especialmente porque o módulo de PLN, a parte mais provável de ser atualizada com novos modelos de linguagem, precisa ser substituível sem afetar a API nem o banco de dados. A separação entre camada de processamento e camada de aplicação foi uma decisão arquitetural motivada por essa necessidade de evolução incremental.

O Modelo Entidade-Relacionamento, proposto por Chen (1976), permanece útil porque força uma decisão que nenhuma outra etapa do projeto torna explícita: como os conceitos do domínio se relacionam entre si, antes de qualquer decisão de implementação. No caso deste sistema, o processo de modelagem revelou o problema discutido na seção 5.8: a necessidade da tabela associativa CANDIDATURA para representar corretamente o relacionamento M:N entre candidatos e vagas. A normalização até a terceira forma normal, tratada por Date (2004) e Elmasri e Navathe (2019), é o critério formal que torna esse tipo de problema detectável antes de causar inconsistências difíceis de rastrear em produção.

As decisões de stack tecnológico seguem uma lógica de conjunto, não de escolhas independentes. O backend em Python com FastAPI (RAMÍREZ, 2021) foi escolhido porque a biblioteca spaCy e os modelos BERT também são Python, de modo que ter o pipeline de PLN e a API na mesma linguagem elimina uma camada de integração e simplifica o debugging. O React.js no frontend (BANKS; PORCELLO, 2020) é a escolha consolidada para interfaces web interativas com dados dinâmicos, como o dashboard de ranking que os recrutadores utilizarão. Não são tecnologias experimentais, o que representa uma vantagem em um sistema corporativo de RH, onde estabilidade e facilidade de manutenção por equipes futuras pesam mais do que adotar a última tendência.

Na camada de dados, a combinação de PostgreSQL, Redis e armazenamento compatível com o protocolo S3 reflete necessidades distintas. O PostgreSQL gerencia os dados relacionais do sistema: candidatos, vagas, triagens e auditorias, com as garantias transacionais que operações sensíveis exigem. O Redis (CARLSON, 2013) complementa essa estrutura como cache de sessões ativas e resultados de scoring recentemente computados: consultar o Redis é ordens de magnitude mais rápido do que reconsultar o banco de dados para cada requisição de um recrutador navegando pelo dashboard. Para os arquivos de currículo, o armazenamento compatível com S3 (serviço consolidado da AWS para objetos em nuvem, com alta durabilidade e escalabilidade) separa os dados binários dos dados relacionais, evitando que o banco seja sobrecarregado com objetos grandes e simplificando as políticas de retenção e exclusão de dados conforme exigido pela LGPD.



4. METODOLOGIA

O presente trabalho caracteriza-se como pesquisa de natureza aplicada, pois tem como objetivo propor uma solução tecnológica concreta para um problema identificado no contexto organizacional. Quanto à abordagem, é qualitativa na dimensão de análise bibliográfica e levantamento de requisitos, e técnica na etapa de especificação e modelagem do sistema. O procedimento adotado é o estudo de caso, concentrado em uma empresa de manufatura eletrônica do Polo Industrial de Manaus cujo processo de recrutamento apresenta as características descritas neste trabalho.

A revisão bibliográfica compreendeu a consulta a artigos científicos, livros técnicos e relatórios institucionais sobre Inteligência Artificial, Processamento de Linguagem Natural, vieses algorítmicos, LGPD e Engenharia de Software. As bases de dados consultadas incluíram IEEE Xplore, ACM Digital Library, Google Scholar e repositórios acadêmicos nacionais. Os critérios de seleção priorizaram publicações dos últimos dez anos, com exceção de obras clássicas de referência nas áreas de aprendizado de máquina e engenharia de software.

O levantamento de requisitos foi conduzido por meio de observação direta do processo de recrutamento da empresa e entrevistas com profissionais do setor de RH. As informações coletadas foram organizadas em requisitos funcionais e não funcionais seguindo a estrutura proposta por Pressman e Maxim (2021). Cada requisito foi classificado quanto ao nível de prioridade com base em sua criticidade para o funcionamento essencial do sistema.

5. PROPOSTA DE MELHORIA

5.1 Visão Geral do Sistema

O RH.AI é um sistema web de recrutamento e seleção baseado em Inteligência Artificial, projetado para automatizar as etapas iniciais do processo seletivo com foco em eficiência, equidade e rastreabilidade. A solução é composta por quatro módulos principais: o módulo de anonimização, responsável pela remoção de atributos sensíveis antes da análise; o módulo de PLN, responsável pela extração de informações e cálculo de compatibilidade com os requisitos da vaga; o módulo de chatbot, que conduz a triagem inicial dos candidatos pré-selecionados; e o módulo de auditoria, que registra todas as decisões geradas com suas respectivas justificativas.

O sistema adota o paradigma de aplicação web multicamadas, acessível por navegadores em dispositivos desktop e mobile. Os candidatos interagem com a plataforma por meio de um portal público de submissão de currículos e participação no chatbot de triagem. Os recrutadores acessam um dashboard protegido por autenticação, no qual visualizam o ranking de candidatos, os scores calculados e os relatórios de desempenho das vagas. Os administradores dispõem de um painel de configuração para gerenciar parâmetros da IA, usuários e logs de auditoria.

A especificação técnica do sistema foi realizada por meio da elaboração do diagrama de casos de uso em notação UML, o fluxograma de funcionamento, a proposta de arquitetura em camadas e o modelo entidade-relacionamento do banco de dados. Os diagramas foram construídos com base nos requisitos levantados e nas práticas de modelagem descritas por Booch, Rumbaugh e Jacobson (2005). A conformidade com a LGPD foi verificada em cada módulo, garantindo que as decisões de projeto atendam aos princípios de minimização de dados, transparência e rastreabilidade.



5.2 Análise de Requisitos

A análise de requisitos é a etapa central da Engenharia de Software que antecede o desenvolvimento de qualquer solução computacional. Ela consiste na identificação, documentação e validação das necessidades dos usuários e do sistema, com o objetivo de estabelecer um acordo claro sobre o que deve ser construído antes que qualquer linha de código seja escrita. Para o RH.AI, o processo de análise foi conduzido por meio de observação direta do processo de recrutamento da empresa estudada, combinada com entrevistas estruturadas com dois profissionais do setor de RH, seguindo a abordagem proposta por Pressman e Maxim (2021).

Os requisitos foram classificados em dois grupos: funcionais, que descrevem os comportamentos e serviços esperados do sistema, como o processamento de currículos e a geração de rankings; e não funcionais, que estabelecem restrições de qualidade como desempenho, segurança, escalabilidade e conformidade legal. Essa distinção é essencial para orientar decisões de arquitetura e tecnologia, pois os requisitos não funcionais frequentemente determinam escolhas estruturais que afetam todo o sistema (SOMMERVILLE, 2019).

Para cada requisito funcional, foi definida uma prioridade (alta, média ou baixa) com base em sua criticidade para o funcionamento essencial do sistema. Requisitos de alta prioridade compõem o escopo mínimo viável (Minimum Viable Product) da solução, sem os quais a proposta não atende ao problema identificado. Requisitos de média prioridade ampliam a utilidade da plataforma e devem ser implementados nas primeiras iterações após a versão inicial. Já os de baixa prioridade representam melhorias incrementais para versões futuras.

Para os requisitos não funcionais, cada item foi associado a um tipo de qualidade de software conforme o modelo ISO/IEC 25010, que categoriza atributos como desempenho, confiabilidade, segurança, usabilidade e manutenibilidade. Essa categorização facilita a rastreabilidade entre os requisitos e as decisões de projeto tomadas nas seções de arquitetura e banco de dados a seguir.

Durante a análise de requisitos, identificou-se uma tensão arquitetural entre RF03 e RF10 que exigiu revisão conceitual. RF03 exige que dados pessoais sensíveis sejam tratados antes da análise automatizada; RF10 exige relatórios de diversidade. Se os dados de gênero e faixa etária fossem deletados logo na entrada do pipeline, por meio da anonimização que a LGPD define como processo irreversível em seu Art. 5, XII, seria matematicamente impossível computar métricas de equidade posteriormente. A solução adotada distingue três conceitos distintos: a anonimização irreversível (dados identificadores como nome e CPF, removidos do texto antes do PLN); a pseudonimização (Art. 13, §4 da LGPD), na qual os atributos demográficos são criptografados e armazenados em tabela segregada de acesso restrito; e o mascaramento de interface, que garante que o recrutador jamais veja dados demográficos individuais. O motor de estatísticas, acessível apenas ao Administrador, computa métricas de diversidade de forma agregada sobre a tabela METADADOS_DEMOGRAFICOS, nunca sobre perfis individuais.

5.3 Requisitos Funcionais

Quadro 01. Requisitos Funcionais do Sistema RH.AI

Código	Descrição	Prioridade
RF01	O sistema deve permitir o cadastro de vagas com critérios de seleção parametrizáveis.	Alta
RF02	O sistema deve receber e armazenar currículos nos formatos PDF e DOCX.	Alta
RF03	O sistema deve pseudonimizar dados pessoais sensíveis antes da análise automatizada: dados identificadores (nome, CPF) são removidos do texto; atributos demográficos (gênero, faixa etária) são cifrados com AES-256 e armazenados em tabela segregada METADADOS_DEMOGRAFICOS de acesso restrito.	Alta
RF04	O sistema deve extrair automaticamente competências, experiências e formação dos currículos por PLN.	Alta
RF05	O sistema deve calcular um score de compatibilidade para cada candidato com base nos critérios da vaga.	Alta
RF06	O sistema deve conduzir entrevistas iniciais automatizadas via interface de chatbot.	Alta
RF07	O sistema deve apresentar ao recrutador um ranking dos candidatos com justificativas geradas pela IA.	Alta
RF08	O sistema deve registrar todas as decisões e justificativas em log de auditoria persistente.	Alta
RF09	O sistema deve notificar os candidatos sobre o status da candidatura por e-mail.	Média
RF10	O sistema deve gerar relatórios agregados de diversidade e equidade, acessíveis apenas ao Administrador, com base nos dados cifrados da tabela METADADOS_DEMOGRAFICOS — nunca expondo atributos demográficos individuais na camada de apresentação do recrutador.	Média

Fonte: Elaborado pelos autores (2026)



5.4 Requisitos Não Funcionais

Quadro 02. Requisitos Não Funcionais do Sistema RH.AI

Código	Descrição	Tipo
RNF01	O sistema deve processar um currículo em no máximo 5 segundos após o recebimento.	Desempenho
RNF02	O sistema deve ter disponibilidade mínima de 99,5% ao mês.	Confiabilidade
RNF03	Os dados pessoais devem ser armazenados com criptografia em repouso.	Segurança
RNF04	O sistema deve atender integralmente à LGPD (Lei 13.709/2018).	Conformidade
RNF05	A interface deve seguir as diretrizes WCAG 2.1 de acessibilidade web.	Usabilidade
RNF06	A arquitetura deve suportar até 10.000 candidaturas simultâneas sem degradação.	Escalabilidade
RNF07	O código deve seguir padrões de documentação e possuir cobertura mínima de testes de 70%.	Manutenção

Fonte: Elaborado pelos autores (2026)

5.5 Arquitetura do Sistema

A plataforma adota arquitetura em quatro camadas, conforme representado na Figura 01. A camada de apresentação é desenvolvida em React.js e disponibiliza três interfaces distintas: o portal do candidato, o dashboard do recrutador e o painel administrativo. A comunicação com o backend ocorre exclusivamente por chamadas seguras à API REST.

A camada de processamento concentra os módulos de inteligência do sistema. O módulo de PLN utiliza a biblioteca spaCy em conjunto com um modelo BERT fine-tuned para extração de entidades e cálculo de compatibilidade semântica. O motor de pontuação aplica pesos parametrizáveis a cada critério configurado pelo recrutador, produzindo um score normalizado de 0 a 100. O módulo de pseudonimização, distinto da anonimização irreversível prevista na LGPD, executa duas operações simultâneas: extrai os atributos demográficos do candidato (gênero e faixa etária inferíveis do currículo), cifra-os com AES-256 e os armazena na tabela segregada METADADOS_DEMOGRAFICOS, de acesso exclusivo ao motor de estatísticas; e remove do texto os dados identificadores (nome, CPF, endereço, foto) antes de enviá-lo ao pipeline de PLN. O recrutador nunca tem acesso a dados demográficos individuais; apenas o Administrador visualiza estatísticas agregadas de diversidade.

A camada de dados é composta pelo PostgreSQL, para armazenamento estruturado das entidades do sistema, e pelo Redis, utilizado como cache de sessões e de resultados de scoring já computados, reduzindo o tempo de resposta nas consultas mais frequentes. Os arquivos de currículo enviados pelos candidatos são armazenados em serviço compatível com o protocolo



S3, que, como descrito na fundamentação teórica, oferece escalabilidade e alta durabilidade para armazenamento de objetos.




Figura 01. Arquitetura em Camadas do Sistema RH.AI

Fonte: Elaborado pelos autores (2026)

5.6 Diagrama de Casos de Uso

O diagrama de casos de uso do sistema, apresentado na Figura 02, identifica três atores principais: o Candidato, o Recrutador e o Administrador. O Candidato interage com a plataforma por meio dos casos de uso de cadastro de currículo, participação na triagem via chatbot e consulta ao status da candidatura. O Recrutador pode criar e gerenciar vagas, visualizar o ranking de candidatos triados, revisar decisões geradas pela IA e acessar relatórios de desempenho das suas vagas. O Administrador é responsável pelo gerenciamento de usuários e permissões, configuração dos parâmetros da IA e acesso aos logs completos de auditoria.

Os relatórios do sistema são segmentados por perfil de acesso. O Recrutador acessa relatórios de desempenho das suas vagas, contendo dados de pontuação, ranking e taxas de aprovação por etapa. O Administrador tem acesso exclusivo aos relatórios de diversidade, calculados de forma agregada a partir da tabela METADADOS_DEMOGRAFICOS, sem que qualquer dado demográfico individual seja exibido. Essa separação de responsabilidades está implementada no controle de acesso baseado em perfis (RBAC) gerenciado pelo módulo de autenticação.




Figura 02. Diagrama de Casos de Uso do Sistema RH.AI

Fonte: Elaborado pelos autores com auxílio do Claude AI(2026)

5.7 Fluxo de Funcionamento do Sistema

O fluxo de operação da plataforma, representado na Figura 03, inicia quando o candidato acessa o portal web e submete seu currículo em formato PDF ou DOCX. Imediatamente após o recebimento, o módulo de pseudonimização executa duas operações em paralelo: os atributos demográficos identificáveis no documento (gênero e faixa etária) são cifrados com AES-256 e persistidos na tabela segregada METADADOS_DEMOGRAFICOS, acessível somente pelo motor de estatísticas com permissão de Administrador; os dados identificadores diretos (nome, CPF, endereço e foto) são removidos do texto, que segue para o processamento como conteúdo pseudonimizado. Essa separação é o que torna o RF10 tecnicamente viável sem contradizer o RF03: os dados demográficos não são destruídos, são isolados e protegidos.

O texto pseudonimizado é encaminhado ao módulo de PLN, que extrai automaticamente competências técnicas, experiências profissionais, formação acadêmica e certificações. Com



base nesses dados, o motor de pontuação calcula o score de compatibilidade com os critérios parametrizados para a vaga. Caso o score seja igual ou superior ao limiar mínimo configurado pelo recrutador, o candidato é encaminhado para o chatbot de triagem; caso contrário, a candidatura é arquivada e o candidato recebe notificação automática por e-mail.

Ao final do processo, o recrutador visualiza no dashboard o ranking dos candidatos aprovados com as justificativas da IA, sem qualquer referência a dados demográficos individuais. Toda ação, tanto as geradas pela IA quanto as decisões dos recrutadores, é persistida no log de auditoria. O motor de relatórios, disponível apenas ao Administrador, acessa a tabela METADADOS_DEMOGRAFICOS de forma agregada para produzir os indicadores de diversidade exigidos pelo RF10, garantindo que o sistema cumpra simultaneamente os princípios de equidade e proteção de dados da LGPD.

Figura 03. Fluxograma de Funcionamento do Sistema RH.AI




Figura 03. Fluxograma de Funcionamento do Sistema RH.AI

Fonte: Elaborado pelos autores com auxílio do Claude AI (2026)

5.8 Modelagem do Banco de Dados



Os bancos de dados possuem papel fundamental no funcionamento de sistemas corporativos modernos, permitindo o armazenamento, organização e recuperação de informações de forma estruturada e segura. Em sistemas que processam dados pessoais e profissionais, a modelagem adequada do banco é crítica para garantir integridade das informações, desempenho nas consultas e conformidade com as exigências legais de proteção de dados.

A normalização é um processo fundamental no projeto de bancos de dados relacionais que busca organizar as tabelas de forma lógica, eliminando redundâncias e garantindo consistência nos dados armazenados. Segundo Date (2004), uma tabela está na terceira forma normal (3FN) quando não possui dependências transitivas entre seus atributos, ou seja, cada coluna não chave depende exclusivamente da chave primária da tabela. A aplicação da 3FN reduz anomalias de inserção, atualização e exclusão, tornando o banco mais robusto ao longo do ciclo de vida do sistema.

A linguagem SQL (Structured Query Language) é o padrão utilizado para realizar operações de inserção, consulta, atualização e remoção de dados em sistemas gerenciadores de banco de dados relacionais. Além das operações básicas, os SGBDs permitem controlar permissões de acesso, definir restrições de integridade referencial por meio de chaves estrangeiras e executar transações atômicas que garantem consistência mesmo em caso de falhas (ELMASRI; NAVATHE, 2019).

A segurança dos dados armazenados é um requisito não funcional crítico para sistemas que tratam informações pessoais e profissionais. O banco de dados da solução proposta utiliza criptografia em repouso para proteger os dados, e o acesso ao SGBD é restrito à camada de aplicação por rede interna isolada, sem exposição direta à internet. Registros de auditoria são armazenados em tabela dedicada com controle de acesso diferenciado, garantindo que o histórico de decisões não possa ser alterado por usuários comuns.

O modelo entidade-relacionamento do sistema é composto por dez entidades principais, conforme a Figura 04. O relacionamento entre candidatos e vagas é do tipo muitos para muitos (M:N): um candidato pode se inscrever em múltiplas vagas ao longo do tempo e, inversamente, uma vaga pode receber candidaturas de múltiplos profissionais. Para representar corretamente esse relacionamento em conformidade com a Terceira Forma Normal, foi introduzida a tabela associativa CANDIDATURA, com chave composta pelas chaves estrangeiras `id_candidato` e `id_vaga`. Sem essa tabela, seria necessário inserir a FK da vaga diretamente em CANDIDATO, criando um vínculo rígido 1:N que impediria o mesmo profissional de se candidatar a mais de uma vaga sem duplicar seu cadastro, quebrando a integridade referencial e violando os princípios de normalização.

A entidade CANDIDATO armazena os dados de cadastro do profissional sem qualquer referência direta a vagas, permitindo que um mesmo registro seja reutilizado em múltiplas candidaturas ao longo do tempo. A entidade CANDIDATURA registra cada inscrição individual, associando um candidato a uma vaga específica com data e status próprios. A entidade EMPRESA centraliza os dados das organizações que utilizam a plataforma, mantendo relacionamentos de um para muitos com as entidades VAGA e RECRUTADOR. Cada vaga pode ter múltiplos CRITERIO_VAGA associados, que definem os critérios de pontuação e seus pesos para a triagem automatizada.

A entidade TRIAGEM registra o resultado da análise automatizada de cada candidatura, referenciando diretamente a entidade CANDIDATURA por meio da chave estrangeira `id_candidatura`. Essa abordagem garante que o histórico de triagens esteja sempre vinculado a uma combinação específica de candidato e vaga, preservando a rastreabilidade mesmo quando



o mesmo profissional participa de processos seletivos distintos. Caso o candidato avance para a etapa do chatbot, cada interação é registrada em ENTREVISTA_CHAT, mantendo o histórico de perguntas, respostas e scores parciais.




Figura 04. Modelo Entidade-Relacionamento (MER) do Sistema RH.AI

Fonte: Elaborado pelos autores com auxílio do Claude AI(2026)

5.9 Comunicação em Rede, PLN e Segurança

O HTTP (HyperText Transfer Protocol) é o protocolo de comunicação base da web, responsável pela troca de mensagens entre clientes e servidores. O HTTPS é sua versão segura, que adiciona uma camada de criptografia fornecida pelo protocolo TLS (Transport Layer Security). O TLS 1.3, versão mais recente do padrão, realiza o estabelecimento de conexão segura em menos etapas que versões anteriores, reduzindo a latência e eliminando algoritmos criptográficos considerados inseguros (TANENBAUM; WETHERALL, 2011). Toda comunicação entre o frontend e o backend da solução proposta utiliza exclusivamente HTTPS com TLS 1.3, garantindo que os dados transmitidos não possam ser interceptados ou modificados em trânsito.

O REST (Representational State Transfer) é um estilo arquitetural para sistemas distribuídos proposto por Roy Fielding em sua tese de doutorado. Ele define um conjunto de restrições para o projeto de serviços web, incluindo a ausência de estado nas requisições (stateless), a identificação de recursos por URIs e o mapeamento de operações para os métodos HTTP padrão: GET para leitura, POST para criação, PUT para atualização e DELETE para remoção.



Serviços que seguem essas restrições são denominados RESTful e são amplamente adotados na integração de sistemas web por sua simplicidade e interoperabilidade (FIELDING, 2000). Toda a camada de aplicação do sistema expõe uma API RESTful que serve tanto o frontend quanto possíveis integrações futuras com outros sistemas de RH.

O JWT (JSON Web Token) é um padrão aberto definido pela RFC 7519 para transmissão segura de informações entre partes como um objeto JSON assinado digitalmente. Um token JWT é composto por três partes codificadas em Base64URL: o cabeçalho (header), que especifica o algoritmo de assinatura; o payload, que contém as declarações (claims) sobre o usuário e suas permissões; e a assinatura, que garante a integridade do token (JONES; BRADLEY; SAKIMURA, 2015). A autenticação da solução utiliza tokens JWT: após o login, o servidor gera um token assinado com chave secreta, que é enviado no cabeçalho Authorization de cada requisição subsequente. Esse mecanismo elimina a necessidade de consultas ao banco de dados para validar sessões, reduzindo a latência.

O pipeline de PLN é executado em um servidor dedicado de processamento, isolado da camada de aplicação para garantir que o processamento intensivo não impacte a responsividade da API. O pipeline inicia com o pré-processamento do texto, seguido pela extração de entidades nomeadas com o modelo spaCy pt_core_news_lg para o português. Na etapa de análise semântica, o modelo BERT fine-tuned gera embeddings contextualizados das competências identificadas, que são comparados com os embeddings dos requisitos da vaga por similaridade de cosseno, métrica que mede o ângulo entre dois vetores em um espaço multidimensional, independentemente de sua magnitude. O resultado é uma pontuação de compatibilidade semântica que supera em precisão os métodos baseados em palavras-chave.

O AES (Advanced Encryption Standard) é um algoritmo de criptografia simétrica adotado como padrão pelo Instituto Nacional de Padrões e Tecnologia dos Estados Unidos (NIST) em 2001. Em sua variante com chave de 256 bits, o AES-256 oferece segurança considerada suficiente para dados classificados como sigilosos, sendo amplamente adotado em soluções comerciais e governamentais (NIST, 2001). Os dados pessoais armazenados no banco de dados da solução são cifrados com AES-256 em repouso, garantindo que o acesso físico ao servidor de armazenamento não resulte em exposição dos dados dos candidatos.

O bcrypt é uma função de derivação de chave criptográfica projetada especificamente para o hashing de senhas, incorporando um fator de custo ajustável que torna o processamento deliberadamente lento, dificultando ataques de força bruta e por dicionário. Desenvolvido por Niels Provos e David Mazières em 1999, o bcrypt é amplamente recomendado pela comunidade de segurança para o armazenamento seguro de credenciais (PROVOS; MAZIÈRES, 1999). As senhas dos usuários do sistema são armazenadas exclusivamente como hashes bcrypt com fator de custo 12, tornando cada tentativa de ataque computacionalmente custosa.

A conformidade com a LGPD requer distinção precisa entre três conceitos frequentemente confundidos no desenvolvimento de sistemas. A anonimização, definida pelo Art. 5, XII da LGPD, é um processo irreversível: após sua aplicação, os dados não podem mais ser associados a um titular, nem mesmo pelo responsável pelo tratamento. Dados verdadeiramente anonimizados deixam de ser dados pessoais para fins legais. A pseudonimização, prevista no Art. 13, §4, é reversível: o dado é transformado de forma que só pode ser identificado com o uso de informação adicional mantida separadamente sob controle técnico e organizacional. O mascaramento de interface, por sua vez, é apenas uma decisão de exibição: o dado existe no banco, mas não é apresentado na tela para determinados perfis de



usuário. No sistema proposto, aplica-se anonimização irreversível sobre dados identificadores diretos (nome, CPF, endereço) no texto enviado ao PLN; pseudonimização com criptografia AES-256 sobre atributos demográficos armazenados em METADADOS_DEMOGRAFICOS; e mascaramento de interface para garantir que recrutadores não acessem dados demográficos individuais. O módulo de auditoria atende ao Art. 20, assegurando ao titular o direito de contestar decisões automatizadas com base em justificativas rastreáveis.

6. PLANEJAMENTO DA PROPOSTA

6.1 Provisionamento de Infraestrutura e Containerização

A viabilidade operacional do sistema depende diretamente do ambiente em que é executado. Modelos de PLN como o BERT, embora eficientes em inferência, exigem recursos de hardware incompatíveis com servidores compartilhados de uso geral: o modelo base do BERT em português ocupa aproximadamente 500 MB de memória RAM apenas para ser carregado, sem contar o overhead de inferência sob múltiplos currículos simultâneos. O spaCy, por sua vez, requer modelos de linguagem que não podem ser instalados em ambientes multi-tenant sem conflitos de dependência.

A solução adotada é a containerização via Docker. Cada módulo do sistema é empacotado como container independente com suas dependências isoladas e versionadas: a API REST (FastAPI), o pipeline de PLN (BERT + spaCy), o banco de dados (PostgreSQL), o cache (Redis) e o armazenamento de objetos (AWS S3). Essa abordagem elimina o problema clássico de incompatibilidade entre ambientes: o mesmo container executado no desenvolvimento e na produção produz resultados idênticos. O orquestramento dos containers em produção pode ser feito via AWS ECS (Elastic Container Service), que fornece escalonamento automático conforme o volume de candidaturas, ou via Docker Compose em servidores físicos dedicados, opção comum em indústrias do PIM que operam com infraestrutura local por requisitos de compliance corporativo.

Antes da entrada em produção, uma etapa formal de Security Hardening precede a liberação ao usuário final: configuração de grupos de segurança de rede, emissão e renovação automática de certificados TLS, injeção de variáveis de ambiente sensíveis via AWS Secrets Manager ou equivalente local, e rotação periódica das chaves de assinatura JWT. Esse conjunto de medidas transforma a infraestrutura em uma extensão das garantias de segurança já descritas na arquitetura do sistema.

6.2 Calibração do Motor de Pontuação com Dados Históricos

Um motor de pontuação que começa a operar sem dados de referência produz resultados arbitrários. Os pesos de cada critério precisam ser calibrados para refletir o que o RH da empresa-alvo considera relevante, critério que pode diferir significativamente de padrões genéricos de mercado. Uma indústria de manufatura eletrônica do PIM tipicamente valoriza certificações específicas (ISO 9001, IPC-A-600, NR-12) e experiência com processos como montagem SMT ou controle estatístico de processo (CEP) de formas que algoritmos não treinados nesse domínio não capturam sem orientação explícita.

A fase de calibração estrutura-se em três etapas. Primeiramente, o setor de RH da empresa fornece um conjunto de currículos históricos com desfecho conhecido (contratado ou não contratado). Recomenda-se um mínimo de 200 documentos para que o conjunto seja



representativo. Esses currículos passam pelo pipeline de PLN com os parâmetros iniciais do sistema, gerando scores que são comparados às decisões históricas reais por meio de métricas de classificação como precisão (precision), revocação (recall) e F1-score. As divergências alimentam um ciclo iterativo de ajuste de pesos e critérios, conduzido em conjunto com os gestores de RH, até que a acurácia de classificação atinja o patamar acordado, sugerido em 75% como linha de base mínima.

Todos os currículos históricos passam pelo módulo de pseudonimização antes do processamento, garantindo que dados pessoais de candidatos antigos não sejam expostos. O objetivo da calibração não é replicar o padrão histórico de contratações, que pode carregar vieses consolidados ao longo do tempo, mas fixar um ponto de partida auditável que o RH refine com critérios explícitos.

6.3 Integração com Sistemas Legados do PIM

As indústrias do Polo Industrial de Manaus operam com sistemas de gestão de pessoas já consolidados. Entre os ERPs de RH mais adotados nesse segmento estão o Totvs RM, o Senior Sistemas e o Sólides, cada um com estruturas de dados e capacidades de integração distintas. Antes da entrada em produção do sistema, é necessária uma etapa de mapeamento e homologação de endpoints, na qual a equipe de implantação levanta, junto ao setor de TI da empresa, quais dados de candidatos já existem no ERP e de que forma podem ser encaminhados ao novo sistema.

A abordagem preferencial de integração é via webhooks. Ao cadastrar uma nova vaga no ERP, um evento é disparado automaticamente para o endpoint correspondente do sistema, que cria o registro da vaga com os critérios parametrizáveis. Ao confirmar uma candidatura, a informação é replicada ao ERP via API, mantendo o histórico consolidado nos dois sistemas sem duplicação manual. Para arquivos PDF e DOCX já armazenados no ERP, define-se um endpoint de ingestão em lote que aceita requisições com arquivos em multipart/form-data, permitindo a importação de candidaturas históricas ou simultâneas sem intervenção manual.

A homologação de endpoints é conduzida em ambiente de staging, separado do ambiente de produção, durante o qual as integrações são validadas com dados reais pseudonimizados. Cada endpoint é documentado seguindo o padrão OpenAPI, gerado automaticamente pelo FastAPI, o que facilita a comunicação técnica com o time de TI da empresa parceira e reduz significativamente o tempo de integração com o legado. O resultado dessa etapa é um contrato de integração formal, assinado pelas equipes de desenvolvimento e de TI da empresa, que define os formatos de troca, os SLAs de disponibilidade dos endpoints e o protocolo de resolução de falhas de sincronização.

7. RESULTADOS ESPERADOS

O RNF01 estabelece um teto de cinco segundos para processamento e pontuação de cada currículo. Considerando o volume de candidaturas típico de processos seletivos no PIM (frequentemente acima de 200 inscrições por vaga em poucos dias), esse desempenho representa a diferença entre uma triagem concluída em minutos e um processo que consumiria dias de trabalho manual. A arquitetura baseada em containers Docker com orquestração via AWS ECS deve garantir escalonamento horizontal sem degradação perceptível durante picos de envio simultâneo, atendendo ao RNF06, que estabelece suporte a até dez mil candidaturas simultâneas. O cache Redis complementa esse cenário ao reduzir o tempo de resposta nas



consultas ao dashboard do recrutador, mantendo a experiência responsiva mesmo sob carga elevada.

O resultado esperado para vieses algorítmicos é mitigação e monitoramento contínuo, não eliminação. O'Neil (2016) demonstra que modelos de Machine Learning herdaram os padrões dos dados históricos com os quais foram treinados: um sistema de triagem calibrado com o histórico de contratações de uma empresa carregará, em alguma medida, os critérios implícitos presentes nessas decisões passadas. O sistema proposto atua reduzindo vetores específicos de viés identificáveis: o módulo de pseudonimização remove dados identificadores que ativam preconceitos inconscientes durante a análise automatizada; os critérios de pontuação são explicitados e parametrizados pelo recrutador, tornando auditável a fundamentação de cada decisão; e o log de auditoria permite rastrear padrões sistemáticos de exclusão que possam indicar vieses não intencionais. O monitoramento contínuo dos relatórios de diversidade (RF10) fecha esse ciclo: a equipe de RH detecta distorções emergentes nos resultados e aciona o processo de recalibração descrito na seção 6.2 antes que se consolidem.

O resultado prático do fluxo de pseudonimização pode ser descrito em termos de engenharia de dados: o recrutador visualiza no dashboard apenas scores e competências, sem acesso a quaisquer atributos demográficos individuais, mascaramento de interface que neutraliza o vetor de viés humano consciente ou inconsciente na fase de triagem. No banco de dados, as tags demográficas são cifradas com AES-256 e persistidas na tabela segregada `METADADOS_DEMOGRAFICOS`, de acesso restrito ao motor de estatísticas com perfil Administrador. Esse design resolve a tensão entre RF03 e RF10 identificada na análise de requisitos: métricas de diversidade como a proporção de candidatos triados por gênero ou faixa etária são computadas sobre dados reais sem expor nenhuma informação demográfica individual, atendendo simultaneamente ao Art. 5, XII da LGPD, que exige tratamento adequado de dados sensíveis no pipeline de análise automatizada, e ao Art. 13, §4, que permite a pseudonimização com retenção segregada de dados para finalidades legítimas e declaradas.

A separação em camadas com interfaces bem definidas permite evolução incremental sem refatorações de alto risco, consequência direta das decisões arquiteturais documentadas. O motor de pontuação pode ser atualizado com modelos de linguagem mais precisos à medida que a empresa acumula dados calibrados, sem alterar a API REST nem o esquema do banco de dados. A documentação OpenAPI gerada automaticamente pelo FastAPI reduz o custo de integração com novos sistemas legados do PIM, benefício diretamente vinculado à estratégia de integração descrita na seção 6.3. A conformidade com a LGPD verificada desde a concepção arquitetural reduz o risco jurídico perante a Autoridade Nacional de Proteção de Dados (ANPD), cuja atuação fiscalizatória no setor industrial brasileiro tem se intensificado desde a plena vigência da lei, tornando a rastreabilidade de decisões automatizadas não apenas uma vantagem técnica, mas uma necessidade de governança.

8. CONSIDERAÇÕES FINAIS

O presente trabalho entregou uma especificação arquitetural robusta para um sistema de recrutamento e seleção baseado em Inteligência Artificial voltado ao contexto do Polo Industrial de Manaus. O que foi produzido pode ser descrito com precisão: um mapeamento de dez requisitos funcionais e sete não funcionais categorizados conforme ISO/IEC 25010; um modelo entidade-relacionamento com dez entidades em conformidade com a Terceira



Forma Normal, incluindo a tabela associativa CANDIDATURA e a tabela segregada METADADOS_DEMOGRAFICOS; diagramas UML de casos de uso e fluxograma de funcionamento; uma arquitetura em quatro camadas com stack tecnológico definido; e um planejamento de implantação com estratégias de containerização, calibração com dados históricos e integração com ERPs do segmento industrial. O trabalho posiciona-se, portanto, como um blueprint técnico validado e pronto para a fase de desenvolvimento, e não como um sistema implementado cujos resultados possam ser empiricamente verificados.

As contribuições técnicas mais relevantes do trabalho estão nas decisões de projeto que resolvem problemas não triviais de Engenharia de Software. A distinção arquitetural entre anonimização irreversível, pseudonimização e mascaramento de interface, aplicada ao pipeline de dados do sistema, resolve a contradição entre RF03 e RF10 que seria indetectável em uma especificação menos rigorosa: dados demográficos são cifrados e segregados na tabela METADADOS_DEMOGRAFICOS, permitindo a geração de relatórios de diversidade sem expor atributos individuais ao recrutador nem violar os artigos 5 e 13 da LGPD. A introdução da tabela associativa CANDIDATURA corrige o relacionamento M:N entre candidatos e vagas que, modelado erroneamente como 1:N, impediria o mesmo profissional de se candidatar a mais de uma vaga sem duplicação de cadastro. Essas decisões documentadas fazem parte do artefato entregue e constituem referência técnica para a equipe que der continuidade ao projeto.

É necessário delimitar com honestidade o que este trabalho não estabeleceu. A eficácia real do módulo de PLN não pode ser afirmada sem implementação, execução e medição empírica: permanece em aberto se o modelo BERT ajustado para o português, sem treinamento adicional em jargão industrial do PIM, produzirá scores úteis para vagas de operador de linha SMT ou técnico de estamparia. A efetividade da mitigação de vieses depende da qualidade e representatividade do conjunto de calibração fornecido pelo RH da empresa, variável que este trabalho não controla. A escalabilidade sob dez mil candidaturas simultâneas (RNF06) é uma meta de projeto suportada por escolhas arquiteturais justificadas, mas que exige testes de carga em ambiente real para ser validada. Reconhecer esses limites não diminui a contribuição do trabalho; pelo contrário, define com clareza o ponto de partida para quem der continuidade.

Três direções técnicas se destacam para a continuidade do projeto. O fine-tuning do modelo BERT com corpus industrial do PIM: modelos de linguagem pré-treinados em português geral, como o BERTimbau, são treinados predominantemente sobre textos jornalísticos e enciclopédicos, vocabulário distante dos jargões técnicos de manufatura eletrônica. Termos como SMD, montagem THT, PCBA, estamparia progressiva, injeção plástica de precisão, CEP e IPC-A-610 têm semânticas específicas que o modelo base não captura com fidelidade. A construção de um corpus rotulado com currículos e descrições de vagas do setor industrial de Manaus, seguida de uma etapa de fine-tuning supervisionado, deve elevar significativamente a precisão do motor de pontuação para o contexto-alvo. Uma segunda frente prioritária é a criptografia homomórfica aplicada à tabela METADADOS_DEMOGRAFICOS. A criptografia homomórfica, disponível em bibliotecas como Microsoft SEAL e OpenFHE, permite realizar operações matemáticas diretamente sobre dados cifrados, sem que seja necessário descriptografá-los. Aplicada ao módulo de estatísticas, essa técnica eliminaria a necessidade de decifrar as tags demográficas para computar médias e proporções, reduzindo a superfície de exposição de dados sensíveis mesmo em caso de acesso não autorizado ao servidor de processamento. Fechando o quadro, um ciclo completo de testes de aceitação com o setor de RH da empresa parceira, comparando



as decisões de triagem geradas pelo sistema com as decisões históricas humanas por meio das métricas de precisão, revocação e F1-score definidas na fase de calibração, produzindo evidências empíricas que validem ou refutem as premissas de desempenho estabelecidas neste trabalho.

REFERÊNCIAS

- AMAZON WEB SERVICES. Amazon S3: object storage documentation. Seattle: AWS, 2023.
- BANKS, A.; PORCELLO, E. Learning React: modern patterns for developing React apps. 2. ed. Sebastopol: O'Reilly Media, 2020.
- BOOCH, G.; RUMBAUGH, J.; JACOBSON, I. UML: guia do usuário. 2. ed. Rio de Janeiro: Campus, 2005.
- CAPPELLI, P. Your approach to hiring is all wrong. Harvard Business Review, maio-jun. 2019.
- CARLSON, J. L. Redis in action. Shelter Island: Manning Publications, 2013.
- CHEN, P. P. The entity-relationship model: toward a unified view of data. ACM Transactions on Database Systems, v. 1, n. 1, p. 9-36, 1976.
- DATE, C. J. Introdução a sistemas de bancos de dados. Rio de Janeiro: Elsevier, 2004.
- DEVLIN, J.; CHANG, M.; LEE, K.; TOUTANOVA, K. BERT: pre-training of deep bidirectional transformers for language understanding. arXiv, 2018. Disponível em: arxiv.org/abs/1810.04805. Acesso em: 10 jan. 2026.
- ELMASRI, R.; NAVATHE, S. B. Sistemas de banco de dados. 7. ed. São Paulo: Pearson, 2019.
- EUROPEAN COMMISSION. Ethics guidelines for trustworthy AI. Brussels: European Commission, 2019.
- FIELDING, R. T. Architectural styles and the design of network-based software architectures. Tese (Doutorado) — University of California, Irvine, 2000.
- FOWLER, M. Patterns of enterprise application architecture. Boston: Addison-Wesley, 2002.
- HONNIBAL, M.; MONTANI, I. spaCy 2: natural language understanding with Bloom embeddings, convolutional neural networks and incremental parsing. 2017. Disponível em: spacy.io. Acesso em: 10 jan. 2026.
- IEEE. IEEE standard glossary of software engineering terminology. New York: IEEE, 1990.
- JONES, M.; BRADLEY, J.; SAKIMURA, N. RFC 7519: JSON Web Token (JWT). IETF, 2015.
- LGPD. Lei n. 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais. Brasília: Presidência da República, 2018.
- McKINSEY & COMPANY. The state of AI in 2023. New York: McKinsey & Company, 2023.

MIKOLOV, T.; SUTSKEVER, I.; CHEN, K.; CORRADO, G.; DEAN, J. Distributed representations of words and phrases and their compositionality. *Advances in Neural Information Processing Systems*, v. 26, 2013.

MITCHELL, T. M. *Machine learning*. New York: McGraw-Hill, 1997.

NIST. FIPS 197: Advanced Encryption Standard (AES). Gaithersburg: NIST, 2001.

O'NEIL, C. *Weapons of math destruction: how big data increases inequality and threatens democracy*. New York: Crown, 2016.

PRESSMAN, R. S.; MAXIM, B. R. *Engenharia de software: uma abordagem profissional*. 9. ed. Porto Alegre: AMGH, 2021.

PROVOS, N.; MAZIÈRES, D. A future-adaptable password scheme. In: *USENIX Annual Technical Conference*, 1999, Monterey. *Proceedings...* Berkeley: USENIX, 1999.

RAMÍREZ, S. FastAPI documentation. 2021. Disponível em: fastapi.tiangolo.com. Acesso em: 10 jan. 2026.

SOMMERVILLE, I. *Engenharia de software*. 10. ed. São Paulo: Pearson, 2019.

TANENBAUM, A. S.; WETHERALL, D. *Redes de computadores*. 5. ed. São Paulo: Pearson, 2011.