

# Mapeamento de Campos entre Sistemas Genéricos e APIs REST de CRMs

Isaac Silva  
NEOXs TECH  
São Paulo/SP, Brazil  
isaacorcine37@gmail.com

Heitor Costa  
Universidade Federal de Lavras  
Lavras/MG, Brazil  
heitor@ufla.br

## Resumo

O mapeamento de campos entre sistemas de software legados e APIs REST de CRMs é uma etapa crítica em projetos de integração, geralmente manual, custosa e suscetível a erros. Neste trabalho, é apresentada uma solução utilizada na empresa NEOXS TECH, especializada em integrações B2B, que avalia o uso de inteligência artificial generativa (IA Gen), comparando os modelos ChatGPT-4o, Gemini 2.0 Flash e BLACKBOX AI em três plataformas amplamente utilizadas: HubSpot, RD Station e Pipedrive. A metodologia baseia-se em um conjunto padronizado de campos de negócio, um *prompt* unificado e um gabarito derivado da documentação oficial das APIs, com avaliação por meio de *precision*, *recall* e *F1-Score*. Os resultados mostram que as IAs Gen podem reduzir o esforço manual e acelerar o processo de mapeamento, embora haja variação de desempenho entre modelos e plataformas. Esses achados permitem orientar a escolha de ferramentas e o uso combinado delas, com validação humana, contribuindo para maior eficiência e qualidade na integração de sistemas.

## Palavras-chave

IA Gen, Mapeamento de Campos, Integração de CRM

## 1 Introdução

A integração de dados entre sistemas legados, planilhas e plataformas de CRM (*Customer Relationship Management*), com base em APIs (*Application Programming Interfaces*) REST (*Representational State Transfer*) [5], é um problema recorrente na indústria de software. Em projetos de migração, consolidação de CRMs ou orquestração de múltiplas plataformas, uma etapa crítica é o mapeamento de campos entre o modelo de dados “genérico” (por exemplo, planilhas ou ERPs - *Enterprise Resource Planning*) e o modelo de dados específico exposto pelas APIs dos CRMs. Essa atividade, em geral, é manual, intensiva em esforço, depende de conhecimento especializado de cada API e é suscetível a erros que podem comprometer a qualidade dos dados e o funcionamento das integrações. Nesse contexto, ferramentas de inteligência artificial generativa (IA Gen) [4, 6], como ChatGPT-4o<sup>1</sup>, BLACKBOX AI<sup>2</sup> e Gemini 2.0 Flash<sup>3</sup>, têm se destacado como apoio a tarefas complexas de interpretação textual e técnica, incluindo a análise de documentação, a geração de código e a automação de processos. No entanto, há uma lacuna de evidências empíricas sobre o desempenho dessas ferramentas em tarefas específicas de integração de sistemas de software, como o mapeamento de campos entre sistemas genéricos e as APIs REST de CRMs.

Neste trabalho, é apresentado um estudo desenvolvido a partir do contexto operacional da NEOXS TECH<sup>4</sup>, que avalia comparativamente o desempenho de três IAs Gen na tarefa de mapeamento de campos em três CRMs amplamente utilizados (HubSpot<sup>5</sup>, RD Station<sup>6</sup> e Pipedrive<sup>7</sup>), por meio de medidas *textitprecision*, *recall* e *F1-Score*. Os resultados contribuem com subsídios práticos para equipes de engenharia de software e de integração que desejam incorporar IA Gen a seus fluxos de trabalho, validando a eficácia da abordagem em um ambiente corporativo real e alinhando-se ao foco de transferência de tecnologia e de impacto industrial.

A estrutura deste artigo está organizada da seguinte forma. Na Seção 2, discute-se a importância prática do problema de mapeamento de campos entre sistemas de software genéricos e APIs REST de CRMs. Na Seção 3, apresenta-se a relevância da solução. Na Seção 4, detalha-se a aplicabilidade da solução. Na Seção 5, destacam-se os indicadores de sucesso. Na Seção 6, sintetizam-se os principais achados e apontam-se direções para trabalhos futuros.

## 2 Relevância

A ausência de estudos sistemáticos sobre o uso de IA Gen no mapeamento de campos em APIs REST de CRM cria um vácuo entre o potencial dessas ferramentas e seu uso efetivo em cenários críticos de integração. Empresas que migram ou integram CRMs[3] frequentemente investem tempo significativo de profissionais especializados na compreensão da documentação das APIs, na identificação de entidades (*deals*, *organizations*, *contacts*, etc.) e na definição dos nomes exatos dos campos a serem utilizados. Na rotina de projetos da NEOXS TECH, especializada em integrações B2B (*Business-to-Business*), essa fricção técnica tradicionalmente se traduz em custos elevados de alocação de engenheiros de software sêniores em tarefas repetitivas e no aumento do *time-to-market* das soluções. Decisões baseadas apenas em experimentação informal podem levar a escolhas inadequadas de ferramentas, atrasos em projetos e riscos de inconsistência de dados. Ao utilizar um problema real e recorrente na indústria (mapeamento de campos entre planilhas/sistemas software legados e CRMs) e avaliá-lo quantitativamente com IAs Gen e APIs reais, o trabalho preenche essa lacuna. Assim, é apresentado, com dados mensuráveis, em que medida modelos amplamente disponíveis conseguem apoiar essa tarefa, quais limitações apresentam e como essas evidências podem orientar decisões técnicas mais fundamentadas. A relevância deste trabalho está em: i) tratar um problema concreto da indústria; ii) avaliar ferramentas amplamente utilizadas na prática; e iii) traduzir os resultados em medidas objetivas, reutilizáveis em outros contextos de integração.

<sup>1</sup><https://openai.com/pt-BR/index/hello-gpt-4o/>

<sup>2</sup><https://www.blackbox.ai/>

<sup>3</sup><https://gemini.google.com/app>

<sup>4</sup><https://neoxs.com.br/>

<sup>5</sup><https://br.hubspot.com/>

<sup>6</sup><https://www.rdstation.com/>

<sup>7</sup><https://www.pipedrive.com/pt>

### 3 Impacto e Benefícios

Os resultados indicam que as IAs Gen podem atuar como “aceleradores” do processo de mapeamento de campos, reduzindo esforço manual e servindo como ponto de partida para especialistas humanos. Os principais benefícios potenciais para a indústria incluem: i) Redução do tempo de configuração de integrações e migrações entre CRMs, pela geração automática de sugestões de mapeamento; ii) Diminuição da dependência de conhecimento profundo da documentação de cada API, padronizando o processo de exploração de campos; iii) Mitigação de riscos de erros humanos em configurações de integração, com consequente melhoria na qualidade dos dados; e iv) O mesmo processo pode ser replicado para diferentes clientes, domínios de dados e plataformas de CRM (escalabilidade).

Do ponto de vista quantitativo, nota-se que o impacto depende do modelo de IA Gen e da API em questão. Em HubSpot, ChatGPT obteve  $F1\text{-Score} = 0,67$ , superando Gemini ( $F1\text{-Score} = 0,44$ ) e BLACKBOX AI ( $F1\text{-Score} = 0,33$ ). Em RD Station, os três modelos apresentaram desempenho intermediário, com  $F1\text{-Score}$  entre 0,42 e 0,58. Em Pipedrive, o desempenho foi elevado para todos, com destaque para Gemini ( $F1\text{-Score} = 0,82$ ), seguido de ChatGPT e BLACKBOX AI ( $F1\text{-Score} = 0,75$ ). Na prática, esses resultados permitem que organizações escolham conscientemente quais modelos utilizar em cada contexto, adotando estratégias como usar o modelo com melhor  $F1\text{-Score}$  em determinado CRM, combinar modelos ou incorporar a IA Gen apenas como apoio inicial, com revisão obrigatória por especialistas. Para a NEOXS TECH, essas evidências numéricas guiam diretamente a arquitetura de seus novos componentes de integração, otimizando custos de API e assertividade técnica.

### 4 Descrição da Aplicabilidade da Solução

Nesta seção, descreve-se a metodologia adotada, concebida para ser facilmente replicável em ambientes de indústria. O fluxo metodológico segue um “protocolo” para avaliar e utilizar IA Gen no mapeamento de campos (Figura 1):

- **Definição do conjunto de campos de negócio.** A primeira etapa consistiu em explicitar o problema de integração de forma agnóstica em relação à tecnologia, a partir da perspectiva típica de uma planilha ou de um sistema de software legado. A partir do histórico de requisições de clientes da NEOXS TECH, foi definido um conjunto de dez campos de negócio representativos e recorrentes em projetos de sincronização de dados B2B: Nome do Cliente, Vendedor, ID da Oportunidade, Valor da Oportunidade, Data de Abertura da Oportunidade, Data de Conclusão da Oportunidade, Fase da Oportunidade, Informações sobre o Cliente (Regional de Vendas, Segmento, Número de Funcionários), Quantidade de contatos (pessoas diferentes) no cliente dentro de uma oportunidade, Interações realizadas com o cliente em uma oportunidade (visitas, reuniões, ligações, eventos). O sistema genérico a partir do qual se originam os dados de mapeamento consiste em uma plataforma SaaS (*Software as a Service*) típica de modelo B2B, amplamente utilizada no mercado corporativo. Essa arquitetura lida essencialmente com entidades transacionais e cadastrais padronizadas e normalizadas (como cadastros de clientes, oportunidades de venda e dados de vendedores). Por ser um modelo normalizado e pautado em boas práticas consolidadas no mercado B2B, a

API e a modelagem desse sistema genérico não são responsáveis por confundir ou induzir IA Gen ao erro. A raiz das inconsistências e desvios de mapeamento reside na variação semântica e na especificidade dos nomes de campos nativos adotados arbitrariamente por cada uma das APIs receptoras de CRM (HubSpot, RD Station e Pipedrive);

- **Elaboração de um *prompt* (Figura 2) padronizado.** Seguindo as boas práticas consolidadas de engenharia de prompts [2], e com esses campos definidos, elaborou-se um *prompt* único que (i) explica que a tarefa é mapear os campos da planilha para a documentação da API REST de um determinado CRM, (ii) pede explicitamente o nome descritivo, o nome do campo exatamente como aparece na API e a entidade (*deal*, *organization*, *contact*, *lead*, *custom\_field*, etc.), (iii) lista os dez campos de negócio e os itens derivados (regional, segmento e número de funcionários) e (iv) dá exemplos de entidades aceitáveis (*deals*, *contacts*, *organizations*). O *prompt* é o mesmo para todas as execuções, variando apenas o nome do CRM (HubSpot, RD Station ou Pipedrive), garantindo comparabilidade das respostas entre IAs Gen e entre CRMs. O *prompt* final apresentado na Figura 2 não foi elaborado em uma única execução, mas fruto de um processo iterativo de engenharia de *prompts* por tentativa e erro. Em iterações iniciais mais abertas, observou-se que as IAs Gen tendiam a gerar respostas excessivamente verbosas, a sugerir *endpoints* inexistentes (alucinações) ou a omitir o formato exato das entidades. O *prompt* foi refinado sucessivamente ao adicionar restrições explícitas de formatação, fornecer exemplos de entidades válidas e limitar os campos obrigatórios. Optou-se por não fornecer contexto específico sobre o negócio ou os sistemas internos da empresa, com o objetivo de testar o desempenho puramente *zero-shot* e generalista de IAs Gen diante de terminologias de mercado conhecidas;
- **Seleção e configuração das IAs Gen.** A seleção das três IAs Gen baseou-se no interesse operacional da NEOXS TECH em avaliar a viabilidade técnica e financeira de ferramentas com diferentes perfis de arquitetura, custos e propósitos no mercado atual. A escolha consistiu em uma amostragem estratégica: i) ChatGPT-4o, modelo multimodal de uso geral e de estado da arte; ii) BLACKBOX AI, concebida especificamente para o apoio à programação e aos sistemas de software; e iii) Gemini 2.0 Flash, modelo projetado para alta eficiência energética, baixa latência e escalabilidade. Avaliar esses perfis permitiu mensurar como as IAs Gen se compararam às IAs Gen generalistas em uma tarefa de semântica de negócios. Essas IAs Gen foram utilizadas por meio de interfaces de *chat*, em contas individuais, sem *fine-tuning* ou configurações avançadas, de modo a refletir um uso típico por equipes de integração, garantindo que o protocolo testado simulasse exatamente o dia a dia e as restrições das ferramentas dos desenvolvedores da NEOXS TECH. Para cada CRM, o *prompt* foi enviado integralmente e a resposta foi coletada sem intervenções intermediárias. Para cada IA Gen, a sequência foi a mesma: primeiro HubSpot, depois RD Station e, por fim, Pipedrive, na mesma sessão de uso. Esse procedimento se aproxima da forma como um profissional realizaria múltiplas integrações no mesmo dia e permite

identificar hipóteses sobre os possíveis efeitos do histórico de interações na qualidade das respostas:

- **Construção do gabarito (oráculo) a partir da documentação oficial.** Em paralelo ao uso das IAs Gen, foi construído um gabarito de referência (oráculo) para cada CRM, exclusivamente a partir de suas documentações oficiais de API: i) **HubSpot**: mapeamentos para *dealname*, *hubspot\_owner\_id*, *id*, *amount*, *createdate*, *closedate*, *dealstage*, *state*, *industry*, *numberofemployees*, *num\_associated\_contacts*, *num\_contacted\_notes*; ii) **RD Station**: mapeamentos para *name* (*organizations*), *user*, *id*, *amount\_total*, *created\_at*, *closed\_at*, *deal\_stage*, *custom\_fields*, *organization\_segments*, *contacts*, *interactions*; e iii) **Pipedrive**: mapeamentos para *org\_id*, *user\_id*, *id*, *value*, *add\_time*, *close\_time*, *stage\_id*, campos customizáveis em *organizations*, *people\_count* e *activities\_count*;
- **Comparação sistemática e classificação das respostas.** Cada resposta das IAs Gen é comparada ao gabarito, classificando cada sugestão como: i) **Verdadeiro Positivo (TP)**: campo e entidade corretamente mapeados; ii) **Falso Positivo (FP)**: campo sugerido que não corresponde ao gabarito (nome ou entidade incorretos); e **Falso Negativo (FN)**: campo presente no gabarito que não foi corretamente sugerido pela IA Gen. Esse gabarito representa “a resposta correta” esperada para cada um dos dez campos, incluindo a escolha da entidade apropriada (por exemplo, informações do cliente em *companies/organizations* e medidas de funil em *deals*);
- **Coleta das respostas das IAs e normalização.** Para cada combinação (IA Gen, CRM), foi obtida uma tabela de mapeamento sugerida pela IA Gen: i) Nome descritivo (como a IA entendeu o campo de negócio); ii) Nome do campo na API (string literal retornada); e iii) Entidade ou objeto relacionado. Antes da comparação, as respostas foram normalizadas por meio da uniformização de letras maiúsculas/minúsculas nos nomes de campos, da remoção de variações irrelevantes entre plural e singular e da desconsideração de comentários ou explicações textuais não estruturadas. Não houve correção semântica manual (por exemplo, não se ajustou um campo para que coincidissem com o gabarito). O objetivo foi avaliar diretamente o que a IA Gen propôs;
- **Critérios de acerto (TP), erro (FP) e omissão (FN).** Com as respostas normalizadas, aplicou-se um critério objetivo de comparação: i) Verdadeiro Positivo (TP), quando o par (campo na API, entidade) sugerido pela IA Gen coincide com o par correspondente no gabarito para aquele campo de negócio; ii) Falso Positivo (FP), quando a IA Gen sugere um campo/entidade que não está no gabarito para aquele campo de negócio, ou introduz campo extra sem correspondência; e iii) Falso Negativo (FN), quando um campo de negócio existente no gabarito não foi mapeado corretamente pela IA Gen (campo diferente, entidade diferente ou ausência de sugestão). Sugestões de “campo personalizado” genérico foram consideradas incorretas em relação ao gabarito, pois o objetivo era verificar a capacidade do modelo de localizar os campos nativos corretos nas APIs REST;
- **Cálculo das medidas.** Para cada combinação (IA Gen, CRM), foi calculado: i) *Precision* [1], mede a proporção de mapeamentos corretos entre os mapeamentos sugeridos pela IA

Gen. Em integração de sistemas, *precision* alta significa que a IA Gen “erra pouco” nos campos que sugere; ii) *Recall* [1], mede a proporção de mapeamentos corretos recuperados pela IA Gen em relação aos mapeamentos que deveriam ser encontrados. *Recall* alto indica que a IA Gen “cobre bem” o conjunto de campos relevantes, o que é importante para não deixar campos não mapeados; e iii) *F1-score* [7], combina *precision* e *recall* em um único indicador. É especialmente útil quando falsos positivos e falsos negativos são “problemáticos”.

Do ponto de vista da aplicabilidade na indústria, essa metodologia pode ser replicada com novos CRMs, novos campos de negócio ou novas IAs Gen, bastando adaptar o conjunto de campos, construir novos gabaritos e reaplicar o protocolo de *prompt*, coleta, normalização e cálculo de medidas. É importante ressaltar (Figura 1) que o fator humano desempenha um papel duplo e indispensável no processo. Durante a fase experimental, a validação e o cálculo sistemático de medidas (*precision*, *recall* e *F1-Score*) exigiram uma análise manual rigorosa baseada no gabarito das APIs. Sob a ótica da produção industrial, o uso de IA Gen não visa substituir o analista, mas atuar como um acelerador cognitivo de alta produtividade. O profissional deixa de ler documentação extensa de APIs do “zero” para atuar como um auditor crítico das propostas sugeridas pela IA. Essa abordagem mitiga riscos de alucinação e de inconsistência no ambiente produtivo, preservando o ganho de tempo proporcionado pela automação no mapeamento.




Figura 1: Metodologia

## 5 Indicadores de Sucesso

Com base na metodologia descrita, obtiveram-se os resultados apresentados na Tabela 1. Esses números podem ser transformados em critérios de aceitação em projetos reais: i) Definir um *F1-Score* mínimo (por exemplo, 0,70) para considerar as sugestões da IA “aceitáveis” como base de trabalho para especialistas humanos; ii) Priorizar modelos com maior *F1-Score* para cada CRM (por exemplo, ChatGPT para HubSpot, Gemini para Pipedrive); e iii) Monitorar *precision* e *recall* ao longo do tempo, à medida que os *prompts* se refinam e os *feedbacks* humanos são incorporados. Além das medidas quantitativas, o trabalho identificou indicadores qualitativos, tais como, (i) redução do esforço manual na leitura de documentação e no mapeamento, (ii) padronização do processo de integração entre diferentes clientes e projetos e (iii) possibilidade de reutilizar gabaritos e *prompts* como ativos organizacionais. Embora os resultados quantitativos forneçam uma medida de assertividade, a análise qualitativa dos erros (Falsos Positivos) revelou um padrão comportamental comum entre as IAs Gen avaliadas. O erro mais frequente consistiu na tendência delas sugerirem nomenclaturas

genéricas ou padrões universais de mercado, em vez de identificarem os campos exatos documentados na API específica de cada CRM. Por exemplo, no campo de negócio “Vendedor”, as IAs Gen sugeriram à plataforma RD Station o termo owner (que é o campo nativo e correto na API da HubSpot), enquanto o oráculo da API do RD Station é a propriedade user. Esse comportamento indica que, na ausência de certeza, as IAs Gen optam pela alternativa estatisticamente mais provável no domínio geral de vendas, o que justifica a necessidade de uma revisão humana final.

Considerando a documentação da API REST do(a) (XXXXX), mapeie os seguintes campos para os respectivos endpoints, propriedades e objetos adequados dentro da plataforma. Indique os nomes exatos das propriedades utilizadas pela API, especificando também a qual entidade pertencem (ex.: `leads`, `deals`, `contacts`, etc).

Os campos a serem mapeados são:

- Nome do Cliente
- Vendedor
- ID da Oportunidade
- Valor da Oportunidade
- Data de Abertura da Oportunidade
- Data de Conclusão da Oportunidade
- Fase da Oportunidade
- Informações sobre o Cliente:
  - Regional de Vendas
  - Segmento
  - Número de funcionários
- Quantidade de contatos (pessoas diferentes) no cliente dentro de uma oportunidade
- Interações realizadas com o cliente em uma oportunidade (Visitas presenciais, Reuniões online, Ligações, Eventos)

Para cada campo, informe:

- Nome descritivo
- Nome do campo na API
- Entidade (ex: `deal`, `lead`, `custom_field`)

Figura 2: Prompt Utilizado

Tabela 1: Comparação de desempenho dos modelos

| Sistema    | Modelo      | TP | FP | FN | Prec | Rec  | F1   |
|------------|-------------|----|----|----|------|------|------|
| HubSpot    | ChatGPT     | 8  | 4  | 4  | 0,67 | 0,67 | 0,67 |
|            | Gemini      | 6  | 9  | 6  | 0,40 | 0,50 | 0,44 |
|            | BLACKBOX AI | 4  | 8  | 8  | 0,33 | 0,33 | 0,33 |
| RD Station | ChatGPT     | 7  | 5  | 5  | 0,58 | 0,58 | 0,58 |
|            | Gemini      | 6  | 6  | 6  | 0,50 | 0,50 | 0,50 |
|            | BLACKBOX AI | 5  | 7  | 7  | 0,42 | 0,42 | 0,42 |
| Pipedrive  | ChatGPT     | 9  | 3  | 3  | 0,75 | 0,75 | 0,75 |
|            | Gemini      | 9  | 1  | 3  | 0,90 | 0,75 | 0,82 |
|            | BLACKBOX AI | 9  | 3  | 3  | 0,75 | 0,75 | 0,75 |

6 Conclusão

O trabalho apresentado evidenciou que IAs Gen podem apoiar de forma efetiva o mapeamento de campos entre sistemas genéricos e APIs REST de CRMs, desde que utilizadas em uma abordagem metodológica estruturada e com validação sistemática. A combinação de *prompts* padronizados, gabaritos construídos a partir das documentações oficiais e uso de medidas consolidadas (*precision*, *recall* e *F1-Score*) permitiu comparar objetivamente o desempenho de três modelos (ChatGPT-4o, BLACKBOX AI e Gemini 2.0 Flash) em três plataformas de CRM amplamente adotadas (HubSpot, RD Station e Pipedrive). Os resultados mostram que não há um modelo universalmente superior: ChatGPT apresentou desempenho mais equilibrado em HubSpot e RD Station, enquanto Gemini 2.0 Flash se destacou em Pipedrive, sobretudo em termos de *precision* e *F1-Score*. BLACKBOX AI, por sua vez, obteve valores inferiores na maioria dos cenários, sugerindo que sua especialização em desenvolvimento de sistemas de software não se traduz automaticamente em melhor desempenho em tarefas de mapeamento de campos de CRM. Esses achados reforçam a importância de avaliações contextualizadas por API e por domínio, em vez de escolhas genéricas de IA Gen para integrações críticas.

Do ponto de vista da indústria, o trabalho indica que o uso de IA Gen é particularmente promissor como primeira etapa para a

sugestão de mapeamentos, a ser seguida de revisão e refinamento por especialistas humanos. Essa combinação tende a reduzir esforço manual, acelerar projetos de migração e integração e padronizar processos entre diferentes clientes e plataformas, sem abrir mão do controle sobre a qualidade dos dados. Ao mesmo tempo, os resultados indicam que, em APIs mais complexas ou menos familiares aos modelos, a supervisão humana continua essencial para evitar erros de configuração em produção. Durante a condução dos experimentos, os mapeamentos foram realizados em sequência (HubSpot, RD Station, Pipedrive) na mesma conta para cada IA Gen, o que pode ter influenciado o processo de aprendizado adaptativo dos modelos. Essa sequência e persistência de sessão podem ter contribuído para o desempenho superior observado, em especial de Gemini no Pipedrive, levantando a hipótese de que o histórico de interações impacta o nível de acerto das IAs Gen. Futuras análises podem considerar explicitamente a continuidade de sessão como uma variável experimental.

Como trabalhos futuros, destacam-se: i) a exploração e o teste comparativo de modelos recentes do mercado, como novas gerações da família GPT, Gemini Pro e modelos de código aberto ajustados (*fine-tuned*), garantindo a atualização contínua do procedimento proposto; ii) a investigação do impacto do histórico de interação e da reutilização de sessões no desempenho das IAs Gen; iii) o estudo de estratégias de combinação de modelos e ciclos de *feedback* humano contínuo; iv) a criação de medidas para mensurar o nível de aprendizagem das IAs Gen ao longo do tempo em cenários de múltiplos mapeamentos; e v) a condução de estudos empíricos qualitativos para coletar *feedbacks* sistemáticos de clientes B2B atendidos pela NEOXS TECH no processo de *onboarding*, avaliando suas necessidades práticas e mensurando a percepção de valor no *time-to-market* dos projetos de integração. Assim, este trabalho pode evoluir de um experimento pontual a um componente estável de *pipelines* de integração, contribuindo para uma adoção segura, eficiente e baseada em evidências de IAs Gen na indústria de software. Como desdobramento prático desse esforço, a NEOXS TECH integrou esse protocolo ao seu ecossistema interno de ferramentas, estimando uma redução no esforço de descoberta de APIs durante o *onboarding* de novos clientes B2B.

Disponibilidade de Artefatos

Os artefatos deste trabalho são de propriedade da NEOXS TECH e não podem ser disponibilizados publicamente por questões de confidencialidade comercial.

Referências

[1] DIGITALOCEAN. 2025. *Deep learning metrics: precision, recall, accuracy*. <https://www.digitalocean.com/community/tutorials/deep-learning-metrics-precision-recall-accuracy> Acesso em: 26 maio 2026.

[2] IBM. 2024. *O que é engenharia de prompts?* <https://www.ibm.com/br-pt/think/topics/prompt-engineering> Acesso em: 26 maio 2026.

[3] Philip Kotler and Kevin Lane Keller. 2024. *Administração de Marketing* (16. ed. ed.). Pearson / Bookman, São Paulo / Porto Alegre.

[4] M. A. Melo and P. S. Bassani. 2023. Inteligência artificial generativa: aplicações e contextos. In *Anais do IV RIEOnLIFE e VIII WLC Minas Gerais*. <https://eventos.ifmg.edu.br/RIEWLC/6518af37e7d7c.pdf> Acesso em: 26 maio 2026.

[5] Red Hat. 2025. *O que é uma API?* <https://www.redhat.com/pt-br/topics/api/what-are-application-programming-interfaces> Acesso em: 26 maio 2026.

[6] Stuart Russell and Peter Norvig. 2010. *Artificial Intelligence: A Modern Approach* (3rd ed.). Prentice Hall, Upper Saddle River.

[7] C. J. Van Rijsbergen. 1979. *Information Retrieval* (2nd ed.). Butterworths, London.