Insper

UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA POTENCIALIZAR PROPOSTAS COMERCIAIS (2024)

Enzo Fonteyne (enzof@al.insper.edu.br)
Livia Tanaka (liviat1@al.insper.edu.br)
Lucca Hiratsuca Costa (luccahc@al.insper.edu.br)
Luiz Felipe Lazzaron (luizfl@al.insper.edu.br)

Trabalho de Conclusão de Curso

Relatório do Projeto Final - Capstone

São Paulo - SP – Brasil
DEZEMBRO, 2024

Enzo Fonteyne
Livia Tanaka
Lucca Hiratsuca Costa
Luiz Felipe Lazzaron

UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA POTENCIALIZAR PROPOSTAS COMERCIAIS (2024)

Trabalho de Conclusão de Curso

Relatório do Projeto Final - Capstone

Relatório apresentado aos respectivos cursos de Graduação em Engenharia da Computação, Engenharia Mecatrônica e Ciência da Computação, como requisito parcial para a obtenção do título de Bacharel no respectivo curso.

Professor Orientador: Prof. Dr. Andre Luiz Maciel Santana

Coordenador TCC/Capstone: Prof. Dr. Luciano Pereira Soares

São Paulo - SP – Brasil
DEZEMBRO, 2024

Enzo Fonteyne
Livia Tanaka
Lucca Hiratsuca Costa
Luiz Felipe Lazzaron

INTELIGÊNCIA ARTIFICIAL PARA ESCALAR VENDAS E RESULTADOS

Relatório apresentado aos respectivos cursos de Graduação em Engenharia da Computação, Engenharia Mecatrônica e Ciência da Computação, como requisito parcial para a obtenção do título de Bacharel no respectivo curso.

Professor Orientador: Prof. Dr. André Luiz Maciel Santana

Banca Examinadora

Prof. Dr. André Luiz Maciel Santana
Prof. Dr. Michel Silva Fornaciali
Prof. Rafael Amoroso Marzolla
Insper

RESUMO

Este artigo apresenta o desenvolvimento de uma ferramenta baseada em IA projetada para aumentar a produtividade de equipes de vendas B2B, auxiliando na criação e avaliação de propostas comerciais. A solução, desenvolvida como parte de uma colaboração entre estudantes do Insper e uma empresa de tecnologia brasileira, utiliza IA para automatizar e otimizar diversos aspectos do processo de vendas. A ferramenta proposta integra-se com apresentações já estabelecidas e utiliza modelos de IA generativa para fornecer insights e sugestões, aprimorando a estrutura, clareza e relevância das propostas comerciais. A arquitetura da ferramenta é construída usando o framework LangChain, permitindo a integração de múltiplos modelos de linguagem e a implementação de técnicas avançadas de processamento de linguagem natural, incluindo RAG (Geração Aumentada por Recuperação) e ReACT (Framework de Raciocínio e Ação). A eficácia da solução foi validada por meio de protótipos e entrevistas com partes interessadas, confirmando seu potencial para impactar significativamente a qualidade das propostas e os resultados de vendas.

Palavras-chave: Inteligência Artificial, vendas B2B, avaliação de propostas, LangChain, IA generativa

ABSTRACT

This paper presents the development of an AI-based tool designed to enhance the productivity of B2B sales teams by assisting in the creation and evaluation of commercial proposals. The solution, developed as part of a collaboration between students from Insper and a Brazilian technology company, leverages AI to automate and optimize various aspects of the sales process. The proposed tool integrates with established presentation decks and utilizes generative AI models to provide insights and suggestions, improving the structure, clarity, and relevance of commercial proposals. The tool's architecture is built using the LangChain framework, allowing for the integration of multiple language models and the implementation of advanced natural language processing techniques, including RAG (Retrieval-Augmented Generation) and ReACT (Reasoning and Action Framework). The effectiveness of the solution was validated through prototyping and interviews with stakeholders, confirming its potential to significantly impact proposal quality and sales outcomes.

Keywords: Artificial Intelligence, B2B sales, proposal evaluation, LangChain, generative AI

1. APRESENTAÇÃO DOS RESULTADOS

Esta pesquisa, materializada no presente artigo **"Utilizando Inteligência Artificial para Potencializar Propostas Comerciais",** explora o uso da Inteligência Artificial (IA) para potencializar propostas comerciais, visando otimizar o processo de vendas em empresas de tecnologia. O estudo foi conduzido em parceria com uma empresa brasileira do setor, com o objetivo de desenvolver uma ferramenta baseada em IA que auxilie as equipes de vendas B2B na criação e avaliação de propostas comerciais mais eficazes. A solução proposta integra-se com apresentações já existentes e utiliza modelos de IA generativa para fornecer insights e sugestões, aprimorando a estrutura, clareza e relevância das propostas.

Os principais resultados da pesquisa demonstram o potencial da IA para automatizar e otimizar diversos aspectos do processo de vendas. A arquitetura da ferramenta, construída com o framework LangChain, permite a integração de múltiplos modelos de linguagem e a implementação de técnicas avançadas de processamento de linguagem natural, como RAG (Retrieval-Augmented Generation) e ReACT (Reasoning and Action Framework). A eficácia da solução foi validada por meio de prototipagem, entrevistas com stakeholders e testes, confirmando seu potencial para impactar positivamente a qualidade das propostas e os resultados de vendas. Este artigo, portanto, apresenta os materiais e métodos utilizados, os principais resultados e as conclusões desta pesquisa aplicada, que visa contribuir para o avanço do uso da IA no setor de vendas B2B.

1.1 Questões Éticas e Profissionais

Para o desenvolvimento do projeto, foi importante o comprometimento do grupo de tratar das questões éticas e profissionais atreladas ao problema a ser solucionado. As responsabilidades éticas desse projeto foram divididas em dois principais tópicos: a proteção dos dados e responsabilidade comercial do programa.

Quanto ao primeiro ponto, em um contexto em que dados são um dos recursos mais almejados no mercado, vale ressaltar a importância na cautela que é preciso ter em um projeto que lida com dados da empresa parceira, quanto das empresas abordadas por ela. Por isso, ao utilizar uma IA desenvolvida por uma empresa é essencial garantir que os dados fornecidos não sejam utilizados para o treinamento dos produtos em geral. Essa garantia visa proteger as informações das demais empresas e das propostas desenvolvidas.

Em relação ao segundo ponto, se deve levar em consideração o fato de que a possibilidade de a Inteligência alucinar traz riscos ao projeto. As alucinações de IA consistem na apresentação de conteúdos incorretos ou enganosos. Esses erros possuem diversas causas,

como insuficiência de dados de treinamento e vieses nos dados usados para treinar o modelo.

Com isso, o projeto possui um compromisso profissional e ético com de garantir a confidencialidade e segurança dos dados classificados como sensíveis pela empresa e a transparência sobre o processo do trabalho.

1.2 Normas Técnicas

A observação de normas técnicas é fundamental para a realização desse projeto. Sua importância se dá para que a pesquisa esteja coerente com os padrões dos projetos já existentes, bem como garantir sua qualidade. Nesse sentido, a consulta de normas técnicas brasileiras como a ABNT ou internacionais como a norma técnica ISO se faz necessária.

No contexto de Inteligência artificial, tem-se a recente norma técnica ABNT NBR ISO/IEC 42001:2024 que estabelece diretrizes essenciais para o desenvolvimento e implementação de IA auxiliando na definição de padrões que garantem a qualidade, a ética e uso apropriado dessa tecnologia. Dentre os tópicos presentes na norma ABNT NBR ISO/IEC 42001:2024, destaca-se:

1. **Governança de IA.** É importante atentar-se aos princípios de governança em sistemas de IA de modo que o desenvolvimento esteja aderente aos objetivos éticos e legais, promovendo transparência e responsabilidade.
2. **Gestão de Riscos.** Identificar, avaliar e mitigar possíveis riscos relacionados ao uso de IA incluindo riscos de segurança, privacidade e impacto social são necessários.
3. **Segurança e confiabilidade.** A norma define requisitos que garantem que a IA seja segura, confiável e resiliente, minimizando possíveis falhas ou ataques cibernéticos.
4. **Ética e transparência.** A norma enfatiza a necessidade de que a IA respeite valores éticos, promovendo justiça, não discriminação e transparência nas decisões que são tomadas de maneira automatizada.
5. **Proteção de Dados e Privacidade.** A norma define diretrizes de modo que as aplicações de IA respeitem as regulamentações internacionais e nacionais quanto a proteção de dados pessoais.
6. **Qualidade de dados.** A norma descreve a importância dos sistemas de IA sejam precisos e relevantes, evitando vieses e resultados não desejados.
7. **Avaliação e monitoramento contínuo.** A norma recomenda o monitoramento

contínuo das aplicações envolvendo IA para garantir que os requisitos estabelecidos anteriormente sejam respeitados ao longo do tempo.

.

Utilizando Inteligência Artificial para Potencializar Propostas Comerciais (2024)

Enzo F. K. Fonteyne, Livia Tanaka, Luiz F. Lazzaron and Lucca H. Costa, André L. M. Santana

***Abstract*— This paper presents the development of an AI-based tool designed to enhance the productivity of B2B sales teams by assisting in the creation and evaluation of commercial proposals. The solution, developed as part of a collaboration between students from Insper and a Brazilian technology company, leverages AI to automate and optimize various aspects of the sales process. The proposed tool integrates with established presentation decks and utilizes generative AI models to provide insights and suggestions, improving the structure, clarity, and relevance of commercial proposals. The tool's architecture is built using the LangChain framework, allowing for the integration of multiple language models and the implementation of advanced natural language processing techniques, including RAG (Retrieval-Augmented Generation) and ReACT (Reasoning and Action Framework). The effectiveness of the solution was validated through prototyping and interviews with stakeholders, confirming its potentiaral to significantly impact proposal quality and sales outcomes.**

***Keywords*— Artificial Intelligence, B2B sales, proposal evaluation, LangChain, generative AI**

I. INTRODUÇÃO

A pesquisa da IDC, intitulada *The Global Impact of Artificial Intelligence on the Economy and Jobs* [1], publicada em setembro de 2024, prevê que os gastos empresariais para adotar e utilizar Inteligência Artificial (IA) nas operações comerciais existentes, oferecendo melhores produtos/serviços para clientes empresariais e consumidores, terão um impacto econômico global cumulativo de US$ 19,9 trilhões até 2030, impulsionando 3,5% do PIB global em 2030 [1]. Além disso, a pesquisa também revela que os líderes empresariais, quase unanimemente (98%), veem a IA como uma prioridade para suas organizações [1].

Este artigo apresenta os principais resultados de uma pesquisa aplicada, em parceria com uma empresa de tecnologia brasileira, no contexto do uso de Inteligência Artificial (IA), para avaliar propostas comerciais. Para isso, serão apresentados os principais resultados do processo de implementação da solução, incorporando um ciclo de co- design que vai desde a identificação do problema até a avaliação da eficácia da solução desenvolvida.

A primeira etapa desta pesquisa consistiu em analisar o processo de vendas da empresa parceira para identificar tarefas, processos e oportunidades, nas quais uma aplicação de inteligência artificial poderia agregar valor. Para conduzir essa análise, utilizou-se o modelo de Dubinsky [2][3][4]. Este modelo define que um processo completo de vendas possui sete etapas, que são: (i) prospecção, (ii) pré-abordagem, (iii) abordagem, (iv) apresentação, (v) superação de objeções, (vi) fechamento e (vii) acompanhamento, cada uma dessas etapas possui um objetivo específico e contribuem de formas diferentes para o processo de vendas, uma etapa mal realizada pode comprometer todo o processo. Um estudo feito por Paschen, Wilson e Ferreira [4], discute como a inteligência artificial pode criar valor ao longo das sete etapas do processo de vendas de Dubinsky, otimizando processos e melhorando resultados comerciais. Bohanec, Kljajić Borštnar e Robnik- Šikonja [5] destacam que empresas que utilizam tomada de decisão baseada em dados são, em média, 5% mais produtivas e 6% mais lucrativas que seus concorrentes.

Durante a etapa da apresentação do processo de vendas [2], a empresa deve demonstrar as características inovadoras do seu produto e quais problemas elas resolvem. Paschen, Wilson e Ferreira definem como "problem-solving characteristics" [4]. Para fazer isso, os vendedores devem moldar a apresentação de acordo com o perfil e necessidades do cliente, além de adaptar e alinhar a linguagem da proposta à sua audiência. No caso da empresa parceira, que atua no modelo *Business-to-Business* (B2B), (empresas que vendem produtos e serviços para outras empresas), as propostas comerciais enviadas são, muitas vezes, lidas e analisadas por mais de uma pessoa dentro da organização prospectada. Muitas vezes essas propostas são avaliadas por pessoas de cargos gerenciais até C-level, especialmente Chief Technology Officers (CTO's), portanto, é importante que as propostas tenham uma linguagem e comunicação adequada a esses públicos, deixando clara as contribuições do produto/serviço à empresa e aprofundando na parte técnica da solução para que esses leitores mais especializados possam compreender melhor o valor da proposta apresentada. Nguyen et al. [6] corroboram essa abordagem, destacando que os vendedores devem atuar como "*knowledge brokers*" (intermediários de conhecimento) e "*resource navigators*" (navegadores de recursos), adaptando suas estratégias e materiais para cada tipo de relacionamento com o cliente. A aplicação de sistemas de IA no processo de vendas pode impactar a forma como os profissionais da área desenvolvem e entregam suas apresentações [7].

Sinha, Shastri e Lorimer [7], discutem como a IA Generativa está melhorando o setor ao automatizar tarefas administrativas, melhorar a personalização das interações com os clientes e oferecer suporte avançado aos gerentes de vendas. A IA Generativa reduz o tempo gasto em tarefas como redação de e-mails, organização de notas e atualização de *Customer Relationship Managements* (CRMs), melhora as recomendações personalizadas e permite que vendedores adaptem suas abordagens em tempo real, além de oferecer relatórios mais poderosos e insights sobre documentos e apresentações de vendas [7], [4]. Exemplos de soluções disponíveis no mercado que utilizam IA Generativa para aumentar a performance nas empresas incluem o Sales Copilot da Microsoft [8], o Salesforce Einstein AI [9], AI Sales da Dialpad AI [10], Clay [11] e Avoma [12]. Essas ferramentas, mostram como a IA pode transformar processos e aumentar a eficiência nas operações de vendas e atendimento ao cliente.

Diante desse cenário, a presente pesquisa busca

responder à seguinte pergunta: "Como a utilização de IA generativa, combinada com frameworks como LangChain e ReACT, pode auxiliar na otimização da criação e avaliação de propostas comerciais em empresas de tecnologia?".

Para responder a essa questão, primeiramente, foi preciso compreender as etapas que constituem um processo de vendas e estudar casos de como outras empresas estão utilizando IA para melhorar etapas deste processo, buscou-se mapear o processo de vendas da empresa parceira e procurar pontos de melhoria onde soluções envolvendo tecnologias IA poderiam agregar valor, para isso, uma série de testes foram realizados com os funcionários [13]. Os resultados obtidos nessa etapa permitiram definir o escopo inicial do projeto, que tem por objetivo desenvolver uma solução utilizando IA para avaliar a qualidade das propostas comerciais produzidas pela empresa e propor melhorias para os vendedores durante o processo de criação das propostas.

II. Revisão da Literatura

A. Inteligência Artificial

A inteligência artificial (IA) é um campo da ciência da computação focado no desenvolvimento de algoritmos que possibilitam que máquinas realizem tarefas que exigem inteligência humana [14]. Estas tarefas incluem processamento de linguagem natural, reconhecimento de padrões, tomada de decisões e aprendizado contínuo [15], [16]. Dentro do universo da IA, destacam-se duas vertentes principais: o *machine learning* (ML) e o *deep learning* (DL). O ML é uma subárea da IA que enfatiza o desenvolvimento de algoritmos capazes de aprender e melhorar automaticamente por meio da experiência [17]. Esta abordagem inclui métodos de aprendizado supervisionado, onde os algoritmos são treinados com dados rotulados, e não supervisionado, que busca identificar padrões em dados não rotulados [18]. O *deep learning*, por sua vez, é uma ramificação mais recente do ML que utiliza redes neurais artificiais, inspiradas na estrutura do cérebro humano, para processar grandes volumes de dados e extrair características complexas de forma automatizada [14], [19]. Esta metodologia é particularmente eficaz no tratamento de dados de alta dimensionalidade, como imagens e vídeos, permitindo aplicações inovadoras em áreas como visão computacional e processamento de linguagem natural [20].

B. Inteligência Artificial Generativa

A inteligência artificial generativa (IAG) é um ramo dos modelos de DL que utiliza *deep generative models* (DGMs) para criar novos conteúdos a partir de dados existentes, o que oferece uma vasta possibilidade de aplicações em diversos setores. Diferente dos modelos discriminativos citados anteriormente (ML e DL), que se concentram em entender a relação entre entradas e saídas, os DGMs aprendem a estrutura subjacente dos dados, permitindo a geração de amostras que imitam dados reais [21]. Com o uso de redes neurais, esses modelos avançaram significativamente em termos de qualidade, impulsionando a chamada IA generativa e possibilitando aplicações como a geração de texto, imagens e outros tipos de dados [14], [22], [23].

Os IAGs são capazes de produzir saídas que não são determinísticas, ou seja, para a mesma entrada, eles podem gerar resultados diferentes a cada execução. Essa característica é fundamentalmente diferente dos modelos discriminativos tradicionais, que são projetados para fornecer previsões consistentes e replicáveis para entradas idênticas [14].

O não-determinismo nos modelos generativos é uma consequência direta de sua abordagem probabilística. Esses modelos, são treinados para aprender a distribuição de probabilidade dos dados de treinamento, permitindo-lhes gerar novas amostras que são estatisticamente semelhantes aos dados reais [21]. Essa abordagem é poderosa porque permite a criação de conteúdo variado e criativo [23]. Entretanto, a variabilidade nas saídas dos modelos generativos nem sempre é vista como uma vantagem. No contexto de avaliação das propostas comerciais, a consistência e a coerência das avaliações são critérios essenciais que garantem a credibilidade da avaliação feita pelo modelo. Nesse contexto de aplicação, o não-determinismo deve ser mitigado, afinal, uma mesma proposta comercial deve receber sempre a mesma avaliação.

Por outro lado, o não-determinismo pode ser positivo para oferecer sugestões de melhorias na proposta. Uma vez identificados os trechos que podem ou devem ser melhorados na proposta comercial, o modelo pode oferecer mais de uma sugestão de alteração para o mesmo trecho de texto, ampliando o leque de opções e ideias do vendedor para a proposta comercial.

C. Inteligência Artificial aplicada a Negócios

A IA aplicada a negócios refere-se a sistemas computacionais capazes de automatizar atividades físicas e digitais, identificar e interpretar padrões em volumes de dados, além de aumentar o engajamento de funcionários e clientes [24], [25]. No seguimento de vendas, é possível usar IA para analisar histórico de dados internos e externos em tempo real, coletar dados econômicos e ambientais e analisá-los para gerar valor para o time de vendas ao transformar esses dados em conhecimento [26].

Conforme Dwivedi et al. [27], e ilustrado na Figura 1, para implementar IA generativa no contexto de negócios, é importante considerar os seguintes passos: (i) definir claramente os objetivos empresariais, identificando as áreas de maior potencial para aplicação da IA; (ii) preparar os dados, garantindo que o modelo utilize referências de qualidade para sua construção; (iii) selecionar um modelo de linguagem de grande escala, (do inglês, *Large Language Model*, LLM) mais adequado, considerando as opções mais avançadas disponíveis; (iv) integrar gradualmente a IA aos processos, garantindo compatibilidade com o sistema vigente; (v) monitorar e aprimorar o desempenho, a fim de ajustar o modelo com base em métricas e feedbacks pré-definidos; e
(vi) considerar aspectos éticos e legais, assegurando a privacidade, buscando eliminar vieses do modelo e a transparência na forma como a IA realiza os procedimentos.

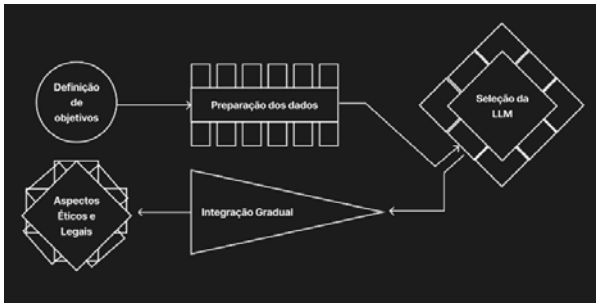

Fig. 1. Etapas de implementação de IA Generativa em contextos de negócio.

O processo de implementação exige uma abordagem estratégica e cuidadosa, desde a definição de objetivos claros até a consideração de aspectos legais e éticos.

D. IA Generativa no processo de vendas

O processo de vendas B2B tradicional é composto por várias etapas críticas para o sucesso das vendas [2], e a inteligência artificial, quando aplicada de forma correta, pode oferecer contribuições em cada uma delas. Segundo Paschen, Wilson e Ferreira [4], a IA pode agregar valor em todas as fases do processo de vendas, desde a prospecção até o fechamento e acompanhamento pós-venda, automatizando processos e gerando *insights* que ajudam a personalizar interações, ao fornecer informações sobre o cliente, e a contribuir para tomadas de decisões, ao providenciar e tratar dados relevantes. Na etapa de pré-abordagem e abordagem [2], por exemplo, pode auxiliar na curadoria de conteúdo e na produção dos textos e documentos que serão utilizados para o primeiro contato com o cliente; na etapa de acompanhamento, pode auxiliar na automação de fluxos de trabalho e serviços de pós-venda, enviando uma sequência de e-mails personalizados ao cliente, por exemplo [4].

Embora essas aplicações aumentem a produtividade, é necessário reconhecer que a integração eficaz da IA nas vendas B2B requer uma colaboração estreita entre a tecnologia e a inteligência humana. Como ressaltado por Paschen, Wilson e Ferreira [4], a inteligência humana permanece essencial para interpretar dados, tomar decisões estratégicas e gerenciar interações complexas com clientes.

E. Representações vetoriais de palavras e LLMs aplicados à avaliação de propostas comerciais

Para proporcionar essas melhorias em propostas comerciais, a IA Generativa utiliza o que na literatura é definido como *Embeddings* e LLMs [28]. Os *Embeddings* são representações vetoriais que são capazes de capturar o significado semântico de palavras e documentos, permitindo que algoritmos processem e comparem textos de forma eficiente [28]. Dessa forma, ao usá-los para analisar apresentações do time de vendas, é possível extrair informações chave, identificar padrões em representações textuais, ou em outros modais de dados, e verificar se os documentos atendem aos requisitos ou padrões pré-definidos pela corporação.

As LLMs, ou *Large Language Models*, como o BERT e o GPT-3, são modelos de linguagem de grande escala que possuem capacidades avançadas para resolver diversas tarefas [29]. As LLMs, utilizam os *embeddings* para gerar linguagem natural de maneira similar à humana através de exemplos, mesmo que estes sejam em pouca quantidade [29], [30]. Na indústria, é possível identificar algumas LLMs com maior uso na área de vendas, como os modelos da OpenAI, incorporados, por exemplo, na Sales Copilot da Microsoft [8] e no Einstein AI da Sales Force [9], além do uso da Cohere e da Anthorpic na Einstein AI [9] e na Clay [11].

Durante o desenvolvimento de uma nova solução, é fundamental identificar e analisar os potenciais competidores do novo produto/serviço que está sendo desenvolvido. Através desta análise de mercado, procura-se referências e inspirações em outras empresas que podem ser utilizadas no projeto [31]. Para conduzir esta análise, utilizou-se o método descrito por Porter [31], segundo ele, é possível classificar os competidores como perfeitos ou imperfeitos, dependendo do grau de diferenciação de seus produtos ou serviços. Em mercados de concorrência perfeita, os produtos são muito parecidos, abordam os mesmos problemas de maneira semelhante e a competição se baseia no preço, ao passo que, em mercados de concorrência imperfeita, as empresas buscam diferenciar-se pela inovação, qualidade e características únicas de seus produtos ou serviços [31].

As Tabelas 1 e 2, apresentam uma comparação entre competidores perfeitos e imperfeitos. Estes dados foram levantados com o intuito de identificar oportunidades e estratégias que podem ser utilizadas na pesquisa [32]. A Tabela 1 apresenta uma comparação entre os competidores perfeitos, e que já operam com o uso de IA Generativa.

TABELA 1
COMPETIDORES PERFEITOS

ATRIBUTOS	COPILOT FOR SALES, MICROSOFT [8]	EINSTEIN AI SALES FORCE [9]
LLM base	OpenAI [8]	OpenAI, preferencialmente. Mas pode ser integrado com Anthropic ou Cohere [9].
Exemplos de clientes	Accenture, Avanade [33]	IBM [9].
Avaliar propostas *Capacidade da ferramenta de revisar e avaliar propostas comerciais existentes*	★★★ Oferece "insights" e pontos pré-combinados entre o cliente e o fornecedor, avaliando as propostas já em desenvolvimento. [8]	★★☆ Na visão do administrador, é possível identificar as propostas com maiores chances de serem fechadas baseado no histórico [9].
Criar propostas *Habilidade da IA de sugerir ideias e recomendações*	★★★ Por meio do chat, pode-se criar uma proposta baseado na reunião anterior e no histórico de propostas passadas. [8]	☆☆☆ Não é possível criar uma proposta comercial [9].
Conexão com CRM *Integração com sistemas de CRM ou outras fontes de dados que permite à ferramenta coletar informações*	★★★ Capaz de integrar as ferramentas da Microsoft (Calendário, Outlook, Teams) e coleta informações de uma ferramenta CRM, como Sales Force. [8]	★★★ Como a ferramenta possui o próprio CRM, a integração com os dados é extremamente

		potencializada, gerando sugestões robustas e completas [9].
Análise comercial em tempo real *Capacidade da ferramenta de revisar e avaliar propostas comerciais existentes*	★★★ Capaz de pesquisar na internet, oferecendo informações públicas disponíveis [8].	★★☆ Há uma percepção de concorrentes possíveis [9].
Preço	US$ 50 por usuário/mês [34]	US$330 por usuário/mês [9]
Idiomas Suportados	24 idiomas [35]	Inglês, francês, alemão, italiano, japonês e espanhol. [34]
Mídias possíveis	PDF, Word, Excel, Power Point, Email, Transcrições de vídeo chamadas, campos de texto do CRM [8].	Email, campos de texto do CRM [9].

Os competidores Sales Copilot da Microsoft [8] e Einstein AI da Sales Force [9] foram classificados como competidores perfeitos segundo o método de avaliação de Poter pois eles abordam os mesmos problemas - buscam melhorar as propostas comerciais através de uma análise de dados e histórico da empresa – e utilizam a mesma tecnologia (LLM base), a OpenAI.

TABELA 2

COMPETIDORES IMPERFEITOS

ATRIBUTOS	DIALPAD AI [11]	**CLAY** [11]	AVOMA [**12**]
LLM base	Proprietária. É um modelo treinado com 6 bilhões de minutos de conversas comerciais [10].	OpenAI, Anthropic e Cohere. Também há outras inteligências artificiais voltadas a coleta de dados na internet, que são proprietárias [11].	Proprietária. Utilizam NLP e vários outros recursos [12].
Exemplo de clientes	Brex [10]	Uber [11].	Athelas
Avaliar propostas	★★☆ Análise de videochamadas, realizando o reconhecimento de fala, análise de sentimento. Classifica as melhores apresentações [10].	☆☆☆ Não possui nenhuma solução nesse aspecto [11].	★★☆ Oferece *insights* sobre todas as propostas já realizadas por conta da gravação e análise, identificando os pontos mais relevantes [12].
Criar propostas	★★☆ Preparação das vendas, oferecendo playbooks de vendas, respostas inteligentes para dúvidas [10].	☆☆☆ Não possui nenhuma solução nesse aspecto [11].	☆☆☆ Não auxilia em nenhuma etapa antes reunião, apenas no agendamento das apresentações [12].
Conexão com CRM	★★☆ Conta com integrações com as principais ferramentas do mercado, como Zendesk, Salesforce, Slack, entre outras [10].	★★☆ Possui várias integrações com múltiplos softwares [11].	★★☆ Possui integração com os principais CRMs do mercado, como Hubspot, Salesforce, Zendesk Sell e Pipedrive [12].
Análise comercial em tempo real	☆☆☆ Não oferece nenhum recurso nesse aspecto [10].	★★★ Dados em tempo real de mercado, obtendo desde informações relevantes das empresas (e.g. setor, funcionários etc.) até nomes de contatos (e.g. CEO, CFO) [11].	☆☆☆ Não oferece nenhum recurso nesse sentido [12].
Preço	US$70 usuário/mês [10].	US$720 mês [11].	US$79 usuário/mês [12].
Idioma	Inglês [10].	Inglês [11].	Inglês [12].
Mídias	Transcrições de vídeo chamadas [10].	Campos de texto do CRM [11].	Transcrições de vídeo chamadas [12].

Legenda

☆☆☆ - Não possui o atributo

★☆☆ - Atributo bem pouco desenvolvido frente aos demais competidores

★★☆ - Atributo parcialmente desenvolvido, mas há competidores mais avançados

★★★ - Atributo bastante desenvolvido

Fig. 2. Classificação dos atributos da matriz de inspiração estratégica da Tabela 1 e 2.

Os competidores Dialpad AI [10], Clay [11] e Avoma [12], foram classificados como imperfeitos segundo a classificação de Poter. Esses competidores se destacam pelas suas características e tecnologias inovadoras, a Avoma e a Dialpad AI, por exemplo, desenvolveram as suas próprias LLMs, o que torna as suas soluções únicas e exclusivas para os seus assinantes.

Com base na análise dos concorrentes, pode-se perceber que o competidor mais desenvolvido nos atributos de forma geral é Sales Copilot Microsoft [8], se destacando principalmente no segundo e terceiro atributos, a saber, na avaliação e na criação de proposta. Além disso, é possível observar uma predominância do uso da OpenAI nas melhores soluções de mercado [8][9], o que contribuiu para a validação do uso deste modelo na pesquisa.

III. METODOLOGIA

A. Materiais

Conforme discutido por Paschen, Wilson e Ferreira [4], para auxiliar o processo de vendas, é preciso realizar o levantamento de dados e identificar oportunidades.

Para coletar dados sobre a empresa parceira e avaliar

o desempenho do projeto desenvolvido, seis testes foram realizados ao longo do desenvolvimento do projeto. Os testes foram separados em dois tipos: (i) testes no formato de reuniões/entrevistas; (ii) testes do modelo (desempenho e experiência do usuário).

A estrutura dos testes no formato de entrevistas pode ser vista a seguir:

Estrutura das entrevistas:

- **Identificador da Reunião:** Nome dado à reunião.
- **Formato e local:** Define se a entrevista foi online ou presencial e o local ou plataforma onde foi realizada.
- **Data:** Data da entrevista.
- **Participantes:** Participantes da entrevista.
- **Instrumentos e materiais:** Instrumentos e materiais utilizados na entrevista.
- **Objetivo:** O que se pretende aprender com essa entrevista.
- **Anotações:** Anotações feitas durante a entrevista.
- **Resultados observados:** Revisão e sintetização das anotações e avaliação dos resultados obtidos.

Com o intuito de avaliar o modelo desenvolvido, e verificar se ele atende aos requisitos e expectativas da empresa, outros dois testes foram realizados, eles seguem uma estrutura muito parecida com a das entrevistas, mas possui algumas diferenças que são relatadas a seguir.

Estrutura dos testes do modelo:

- **Identificador do teste:** Número do teste.
- **Data:** Data, ou período, do teste.
- **Instrumentos e materiais:**
    - **Inputs:** Instrumentos e materiais utilizados para a realização do teste. Exemplos: proposta comercial, modelo desenvolvido e roteiro do teste.
    - **Outputs:** Instrumentos e materiais gerados pelo teste. Exemplos: relatório gerado pela IA, feedback dos participantes.

Utilizando as estruturas citadas anteriormente, foram conduzidos quatro reuniões e dois testes do modelo para esta pesquisa, os resultados obtidos nesses testes e como eles agregaram para o projeto são temas discutidos na Seção IV deste documento.

B. Métodos

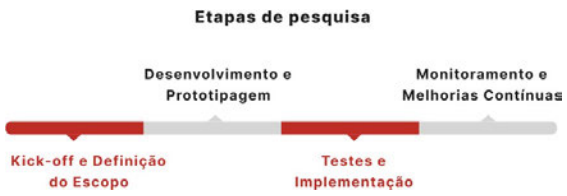

Fig. 3. Fluxograma das etapas de pesquisa

a) *Levantamento de Hipóteses*

Após a etapa inicial de coleta de dados para definição do escopo, foram levantadas hipóteses para direcionar as estratégias do projeto. Para conduzir essa análise, foi utilizada a matriz FOFA (Forças, Oportunidades, Fraquezas e Ameaças) [38], sendo capaz de identificar oportunidades e atenuar fraquezas do projeto. Mediante os resultados da FOFA, discutidos na Seção IV, pode-se formular hipóteses com base em questões internas e externas ao projeto, transformando ameaças em oportunidades, bem como orientar o time para ações concretas e alinhadas aos objetivos gerais [39].

b) Prototipagem

Para apresentar as melhores hipóteses levantadas à empresa parceira, foi elaborado um protótipo de telas interativo. O protótipo foi desenvolvido com o intuito de melhorar a visualização das soluções propostas, materializando as funcionalidades em uma aplicação testável pelo usuário, possibilitando uma devolutiva da empresa com sugestões e oportunidades de melhorias, contribuindo ainda mais para o alinhamento dos stakeholders. [40]

Para o desenvolvimento do protótipo, foi adotada a metodologia Sprint [41]. A Sprint, criada pelo Google para testar ideias em cinco dias [41], tem como subdivisão metodológica as etapas vistas na Figura 4.

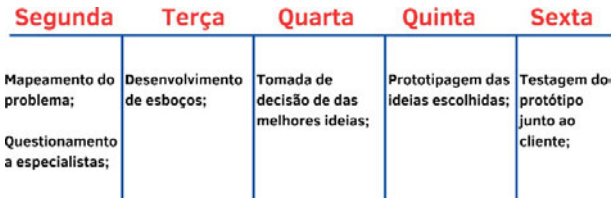

Fig. 4. Processo de prototipagem no modelo Sprint.

Para a etapa de prototipagem das ideias escolhidas (Figura 4), foi utilizado o software Figma [42]. O uso dessa ferramenta permitiu a criação de um protótipo rápido, interativo, e que simula a experiência do usuário. Assim, possibilitando à equipe de usuários (empresa parceira) a fornecer boas devolutivas para alinhar as partes e as expectativas para o restante do projeto.

c) Arquitetura de IA Generativa

Para a avaliação das propostas comerciais automatizadas, foi utilizado o modelo de Inteligência Artificial Generativa baseado em modelos avançados de processamento de linguagem natural (NLP's). Embora modelos como o GPT- 3, DALL-E, BERT etc. sejam bons exemplos dessa tecnologia, a arquitetura proposta não se limita a um modelo específico ou fixo.

Nesse sentido, mediante o uso do framework LangChain [43], é possível integrar diferentes modelos de linguagem e componentes de IA para otimizar as operações. Este framework é projetado para trabalhar com modelos de linguagem de grande escala (LLMs), permitindo a criação de aplicações complexas que envolvem o encadeamento desses modelos com outras ferramentas e bancos de dados externos.

Além disso, o LangChain facilita a integração de fontes de conhecimento externas, gerenciamento de fluxos de conversação e a customização de modelos conforme as necessidades da empresa, resultando em sistemas mais sofisticados e eficientes para aplicações como avaliação de propostas comerciais automatizadas [44].

Consequentemente, a flexibilidade do LangChain permite que a corporação parceira escolha o modelo que melhor se adapta às suas necessidades em termos de desempenho, segurança e custo, o que torna a solução bastante versátil, já que a capacidade de alternar entre modelos ou integrar múltiplos modelos simultaneamente assegura que o sistema possa evoluir e se adaptar às mudanças tecnológicas e estratégicas, sem ficar restrito a uma única tecnologia ou fornecedor.

Contudo, é importante enfatizar que os modelos de Inteligência Artificial utilizados não serão treinados com dados proprietários da empresa. Em vez disso, os modelos serão orientados através de rubricas e outros documentos a avaliar corretamente as propostas comerciais segundo o padrão da empresa parceira, garantindo a integridade e a confidencialidade das informações corporativas.

Além disso, para aprofundar a análise e enriquecer o conteúdo das propostas, é adotada a metodologia de Recuperação de Informações com Modelos de Linguagem (RAG), desenvolvida por Lewis [45], como uma estratégia avançada para otimizar a criação e a precisão das propostas comerciais. O RAG une técnicas de processamento de linguagem natural com algoritmos de recuperação de dados, operando através de um modelo híbrido que integra conhecimento paramétrico e não-paramétrico. Matematicamente, isso é realizado utilizando uma combinação de um modelo *seq2seq* para geração de linguagem e um índice de vetor denso para recuperação de documentos. Na Figura 5, é apresentado um modelo de arquitetura RAG.

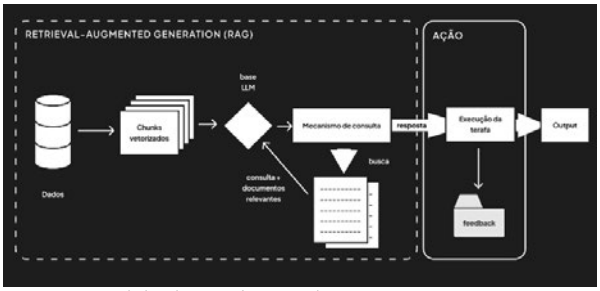

Fig. 5. Modelo de arquitetura de RAG

Para compreender o funcionamento do RAG, pode-se considerar, por exemplo, um documento D que deve ser recuperado pelo modelo e uma consulta Q realizada pelo usuário. Inicialmente, o RAG é utilizado como um "*retriever"* a pontuação de similaridade $s(q, D)$ cada documento D. A pontuação é calculada por meio do produto escalar entre os *embeddings* da consulta e dos documentos [45].

Como resultado dessas operações, obtém-se uma pontuação que varia de -1 a 1, indicando o grau de similaridade semântica entre a consulta e o documento. Documentos com pontuações mais altas são considerados mais semelhantes para a consulta do usuário. Esse mecanismo permite que o conteúdo mais pertinente seja identificado e recuperado pelo RAG a partir da base de dados, auxiliando na geração de propostas comerciais mais precisas e detalhadas.

A fim de organizar e padronizar as respostas originadas pelo RAG, foi desenvolvida uma estrutura de rubricas baseada na escala Likert, conforme delineada por Likert [46]. Esta escala permite quantificar o grau de satisfação em relação a cada item avaliado nas respostas, variando de "Totalmente insatisfeito" a "Totalmente satisfeito", conforme a natureza e objetivo das propostas comerciais. A aplicação da escala Likert facilita a análise qualitativa dos resultados, proporcionando uma abordagem sistemática para medir as nuances das percepções e preferências dos usuários em relação às informações recuperadas pelo RAG. Com isso, as respostas se tornam mais consistentes e alinhadas às expectativas e necessidades dos clientes, contribuindo para a precisão e o impacto das propostas comerciais.

Para aprimorar a capacidade do sistema em realizar raciocínios contextuais e tomar decisões informadas durante a geração das propostas, foi implementado o framework ReACT [47]. Ele permite que o modelo de IA não apenas gere texto, mas também execute ações, como consultar informações adicionais, verificar dados e ajustar a proposta conforme necessário [47].

A integração do ReACT com o sistema ocorre por meio do LangChain, que oferece suporte para a implementação de agentes capazes de combinar raciocínio e ações. Essa combinação proporciona ao sistema uma capacidade avançada de interagir com o ambiente e adaptar-se dinamicamente às necessidades do usuário. A Figura 6 mostra a arquitetura geral desenvolvida.

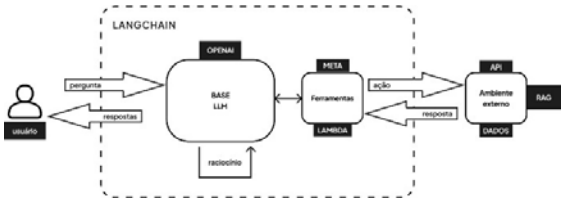

Fig. 6. Arquitetura geral da solução, ilustrando as tecnologias empregadas e suas inter-relações.

Dessa maneira, como visto na Figura 6, a arquitetura geral do sistema foi projetada para integrar harmoniosamente o modelo de IA Generativa, o módulo RAG e o framework ReACT, todos coordenados pelo LangChain como orquestrador central e possui como LLM principal a OpenAI. A arquitetura segue a seguinte divisão de funções:

1. **Modelo de IA Generativa**: Responsável por produzir o texto das propostas comerciais, utilizando capacidades avançadas de compreensão e geração de linguagem natural. Pode ser qualquer modelo compatível com o LangChain, incluindo modelos proprietários ou de terceiros.
    a. A OpenAI foi escolhida como LLM principal pelos seguintes motivos: (i) é uma LLM dominante do mercado e já se provou capaz de realizar as atividades pretendidas por este estudo; (ii) é a LLM utilizada pela

empresa parceira, que providenciou acesso ao modelo e se comprometeu em arcar com os custos dele; (iii) a possibilidade de criar uma LLM própria foi descartada por falta de tempo e de dados disponíveis para treinar um modelo.

2. **Módulo de Recuperação de Informação Multimodal (RAG Multimodal)**: Atua na obtenção de dados específicos da empresa em questão, fornecendo ao modelo de IA informações relevantes para serem incluídas nas propostas. Podendo essas serem textos, tabelas, figuras ou imagens.
3. **Framework LangChain**: Serve como o orquestrador que gerencia a interação entre o modelo de IA, o módulo RAG e o framework ReACT, facilitando o fluxo de dados e a execução das tarefas.
4. **Framework ReACT (Raciocínio e Ação)**: Aprimora a capacidade do sistema de realizar raciocínios contextuais e tomar decisões pautadas em dados durante a geração das propostas [47].

A abordagem de RAG utilizada nesta pesquisa, diferente das estratégias mais simples que permitem apenas a leitura de documentos de texto, emprega o uso de uma estratégia multimodal. O RAG Multimodal, capaz de incorporar textos, tabelas, imagens e figuras, permite uma análise mais completa e diversificada dos documentos enviados pela empresa parceira, ao permitir a extração de informação destes outros artefatos.

Essa estratégia foi adotada para preservar a coerência contextual, unificando diferentes tipos de dados na mesma camada vetorial $\mathbb{R}^d$, onde $\mathbb{R}$ representa o conjunto dos números reais $\mathbb{R}$ e d corresponde ao número de componentes reais de cada vetor.

No RAG convencional, cada fragmento de texto t_i é mapeado para um vetor de *embeddings* $v_i = \phi_T(t_i)$, onde ϕ_T é a função de *embeddings* textual. Enquanto, no modelo multimodal, diferentes modalidades m (como imagens I, tabelas T e figuras F) são mapeadas por funções específicas ϕm para o mesmo espaço vetorial:

$$v_m = \phi_m(d_m)\ para\ d_m \in m,\ v_m \in R^d$$

Essa unificação permite que todas as representações vetoriais coexistam no mesmo espaço, facilitando operações de similaridade, como a similaridade do cosseno:

$$similaridade(v_a, v_b) = \frac{v_a \cdot v_b}{|v_a|\ |v_b|}$$

Onde v_a e v_b são vetores de diferentes modalidades. Essa abordagem assegura que o contexto seja mantido, permitindo uma integração contextual robusta e operações de recuperação mais eficazes.

Além disso, também foi empregado o uso de OCR e Tesseract para capturar de maneira precisa dados textuais, tabulares, imagens e figuras, assegurando que todas as informações relevantes fossem extraídas sem omissões.

Desta forma, o RAG Multimodal aprimorado não apenas amplia a capacidade de processamento de diversas fontes de informação, mas também garante maior precisão e qualidade na geração de respostas.

C. *Estratégias de Validação*

Para validar a solução proposta, foi realizada uma pesquisa sobre possíveis metodologias de validação. A academia reconhece diversos métodos de pesquisa, incluindo estudos observacionais e experimentais, cada um com suas próprias vantagens e aplicações [48]. Para o presente projeto de avaliação do uso de IA Generativa na análise de propostas comerciais, optou-se por adotar o estudo de caso como instrumento de investigação [49], por ter sido considerada a metodologia mais adequada. Segundo [49], "o estudo de caso como modalidade de pesquisa é entendido como uma metodologia ou como a escolha de um objeto de estudo definido pelo interesse em casos individuais. Visa à investigação de um caso específico, bem delimitado, contextualizado em tempo e lugar para que se possa realizar uma busca circunstanciada de informações". Gil [50] define o estudo de caso em quatro fases: (i) delimitação da unidade- caso; (ii) coleta de dados; (iii) seleção, análise e interpretação dos dados; (iv) elaboração do relatório. No contexto deste estudo, espera-se compreender como o uso de IA Generativa pode contribuir para o processo de criação e avaliação de propostas comerciais da empresa parceira (i). Para isso, priorizou-se a coleta de dados sobre a empresa e seus processos (kick-offs 1 e 2) (ii). As informações coletadas nas entrevistas iniciais e os documentos enviados pela empresa serviram para o levantamento de hipóteses (iii) e desenho das soluções propostas (Tabela 5) (iv).

As soluções propostas foram apresentadas à empresa (entrevista com o time técnico) e decidiu-se que a proposta de desenvolver um analisador de propostas comerciais seria a prioridade do projeto. Para validar a solução desenvolvida, foram realizados uma série de testes seguidos por iterações no modelo, de acordo com a metodologia descrita na Seção A. Materiais. As características e resultados observados nos testes são discutidos na Seção IV.

IV. Resultados

A. *Resultados da Entrevista*

As reuniões Kick-off 1 e 2 marcaram o início do projeto. Nesta etapa, foram realizadas interações para alinhar as expectativas e definir o escopo do estudo de caso. Para esta etapa foram utilizados os questionários produzidos e indicados no Questionários Kick-off 1 e 2, vistos no Apêndice 1.

I. Kick-off 1

Através do Kick-off 1 (Figura 1), compreendeu-se o modelo de negócio da empresa parceira, seus setores de atuação, produtos ofertados, motivações e expectativas para este projeto. A empresa, de atuação nacional/multinacional (escolha conforme o caso), está posicionada em vários setores, com foco em atender grandes indústrias multinacionais, oferecendo mais de 90 serviços de tecnologia, incluindo soluções de nuvem e cibersegurança. A cultura organizacional da empresa é caracterizada por um ambiente inovador e com foco no cliente.

Com uma infraestrutura robusta, equipes técnicas especializadas e ferramentas avançadas, a empresa busca, ao

final deste projeto, implementar uma solução de IA que potencialize seus resultados comerciais e otimize o processo de vendas. Para avaliar o impacto e o progresso da solução desenvolvida, foram definidos indicadores específicos de sucesso. Esses indicadores incluem uma análise estruturada em um sistema de rubricas, aplicadas a cada proposta comercial e definidas e validadas na fase de entrevistas com o time comercial (Entrevista IV). Esse sistema foi utilizado em conjunto com a LLM para orientar o processo de avaliação dos documentos.

Os stakeholders do projeto foram identificados durante essa reunião (Apêndice 3).

II. Kick-off 2

Durante o Kick-off 2, foram identificados dois fluxos comerciais: (i) voltado para a base de clientes, onde os vendedores trabalham no modelo de vendas recorrentes, oferecendo produtos adicionais ou melhorias do produto original (*cross-sell* e *upsell,* respectivamente); (ii) focado na prospecção de novos clientes, que se dá principalmente por meio de recomendações dos clientes atuais. No contexto da empresa parceira, a maior parte dos vendedores está alocada no primeiro fluxo, e seguem a estratégia comercial da empresa que é estruturada em cima do seu relacionamento com os clientes. Além disso, foram identificados pontos de melhoria no processo de vendas onde soluções envolvendo tecnologias IA poderiam agregar valor. No Kick-off 2, observou-se uma carência na estruturação e padronização das propostas comerciais produzidas, que divergiam em identidade e formato. Apesar dos vendedores possuírem "decks" (estruturas base de apresentação dos produtos) para orientar e estruturar suas apresentações, a empresa reportou que esses materiais não são utilizados com frequência pelos funcionários da empresa. Os vendedores, utilizando esses decks, poderiam customizar a proposta para o contexto do cliente e fortalecer a sua oferta, o que é fundamental de acordo com Nguyen, Paswan e Dubinsky [6]. Por fim, segundo a própria equipe de inteligência de mercado da companhia, acredita-se que uma solução que aprimora a qualidade geral das propostas de vendas produzidas pela empresa, é a melhor forma pela qual uma IA poderia melhorar e contribuir para o processo de vendas.

Com base nas evidências e dados coletados, e nas necessidades levantadas com a empresa, de implementar uma solução que utiliza IA para fornecer suporte ao processo de vendas durante a etapa de apresentação [2], decidiu-se desenvolver uma solução para auxiliar no desenvolvimento das comerciais produzidas pelos vendedores, excluindo soluções voltadas para a etapa de prospecção e focando na etapa de apresentação [2], presente nos dois fluxos comerciais. Para isso, o modelo irá avaliar propostas comerciais, oferecer sugestões de melhorias para auxiliar os usuários durante o processo de criação de propostas, utilizando os decks elaborados por especialistas como referência para sugerir os melhores produtos para cada cliente, criando assim uma solução de inteligência colaborativa, conforme discutido por Paschen, Wilson e Ferreira [4].

III. Entrevista com o time técnico

Com o intuito de validar o primeiro protótipo, o escopo definido para o projeto e de aprender mais sobre IA e suas possíveis aplicações no mercado, o teste 3 (Reunião com o Time Técnico), Figura 3, foi realizado. Para este teste, foram produzidos um questionário e um protótipo de telas. O questionário foi desenhado para identificar quais são as principais ferramentas de Inteligência Artificial adotadas pelo setor de vendas e como as tecnologias atuais da empresa funcionam. Nesta etapa foi possível perceber que as tecnologias adotadas pela empresa também utilizam LangChain, possibilitando o uso e a integração de diferentes ferramentas e LLMs. Além disso, a empresa utiliza o modelo GPT-4o como orquestrador. Nesta plataforma disponível aos funcionários da empresa, os usuários podem acessar uma variedade de ferramentas que possuem objetivos específicos, como, por exemplo, traduzir um contrato com termos jurídicos para uma linguagem mais acessível.

Para validar o escopo do projeto e a solução proposta, um protótipo de telas foi criado para simular o fluxo de trabalho que o usuário iria percorrer para avaliar a sua proposta comercial com uma IA, além disso, o protótipo fornece um exemplo de como seria o modelo de resposta gerado pela IA para o usuário, Figura 7. A estrutura da solução, também foi apresentada e discutida com o técnico entrevistado.

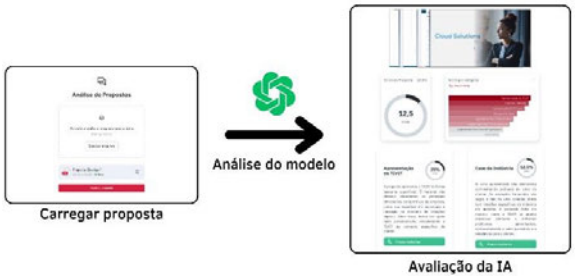

Fig. 7. Protótipo de telas

Após compreender o funcionamento da plataforma de inteligência artificial da empresa e apresentar a solução proposta, percebeu-se que os dois projetos tinham sinergia em termos de tecnologia e objetivo, e, portanto, poderiam ser integrados. Diante dos dados coletados nessa entrevista, o escopo do projeto foi alterado, com o objetivo final sendo redefinido para integrar o modelo proposto neste artigo à plataforma a plataforma da empresa parceira, como mais uma de suas ferramentas. Por fim, devido ao alinhamento dos projetos, a empresa parceira disponibilizou uma chave API privada para os modelos GPT-4o, GPT-4o mini e text-embedding-ada-002, contribuindo para a segurança e privacidade dos dados analisados pelo analisador de propostas comerciais.

IV. Entrevista com o time comercial

Para entender melhor a persona principal desta solução e identificar as dificuldades enfrentadas durante o processo de criação de propostas comerciais, foi realizada uma entrevista com um Key Account Sales Executive do setor de Seguros e Saúde, com mais de 10 anos de experiência na

empresa ("Reunião c/ Time Comercial", Figura 3). Este profissional, com alta expertise no relacionamento com o cliente e profundo conhecimento das necessidades estratégicas do setor, contribuiu com insights detalhados sobre o processo comercial e os desafios de venda no setor. A entrevista ocorreu nas dependências da empresa, em um ambiente propício à coleta de informações específicas e observação das práticas de trabalho. A abordagem incluiu uma entrevista estruturada, com um questionário orientador, que buscou explorar as metas e os desafios enfrentados ao longo do projeto. A seleção desse participante visou alinhar a análise às necessidades reais da empresa, proporcionando uma compreensão aprofundada dos desafios organizacionais específicos deste setor.

Os principais resultados observados no quarto teste foram:

- Os vendedores já utilizam IA para realizar pesquisas e aprender mais sobre os seus clientes e os mercados em que se encontram, mas não utilizam nenhum modelo para avaliar e corrigir as suas propostas, isso se dá, principalmente, por motivos de confidencialidade e segurança. Os vendedores e consultores temem em subir arquivos da empresa em modelos abertos ao público geral.
- Os vendedores perdem bastante tempo avaliando e corrigindo a redação das propostas, procurando por erros de ortografia e coesão.
- O vendedor acompanha todo o processo de venda com a empresa, desde a primeira abordagem, onde ele escuta as necessidades do cliente e repassa essas impressões ao time de consultoria que irá sugerir os melhores produtos a serem ofertados, até a apresentação da oferta, fechamento e acompanhamento do cliente no pós-venda.

Os resultados observados corroboram para a constatação de que um analisador de propostas, que garante a privacidade dos dados analisados, pode contribuir para otimização das tarefas do time de vendas e de consultores da empresa parceira. Além das perguntas presentes no questionário, também foram apresentadas as rubricas utilizadas pelo modelo para avaliar as propostas. A primeira rubrica busca avaliar a qualidade gramatical e textual da proposta segundo os seguintes aspectos:

I. Coesão e concisão:

Avalia a clareza e concisão do texto, verificando se está livre de ambiguidades [51].

II. Argumentação:

Verifica a solidez dos argumentos apresentados para persuadir o cliente [52].

III. Gramática:

Assegura que o texto está livre de erros gramaticais e ortográficos [53].

IV. Clareza e coerência:

Garante que todas as partes do texto estão alinhadas em termos de argumentos e informações, formando um todo coeso [54].

O vendedor entrevistado aprovou a primeira rubrica e reforçou o valor que uma ferramenta capaz de corrigir esses erros automaticamente traria para o fluxo de vendas, principalmente para o trabalho de produção e correção de propostas comerciais. Por fim, foi apresentada a rubrica de conteúdos utilizada pelo modelo para avaliar as propostas. Esta rubrica avalia os seguintes atributos:

I. Apresentação da Empresa:

Mede a capacidade da apresentação fornecer uma visão geral da organização, destacando seus principais resultados e realizações [55].

II. Case da Indústria:

Avalia a relevância do caso de sucesso contido na apresentação, se este é do mesmo setor do cliente-alvo, e é capaz de demonstrar o histórico da empresa em alcançar resultados positivos naquela indústria [56].

III. Apresentação do Produto:

Descreve de forma clara e objetiva o produto ou serviço oferecido, garantindo que o cliente compreenda exatamente o que está sendo proposto [57].

IV. Proposta de Valor:

Avalia a capacidade da proposta comercial de comunicar de maneira clara o valor agregado do serviço, destacando os benefícios específicos para o cliente [58].

V. Legibilidade pelo Time de Tecnologia:

Avalia o quão clara a oferta comercial é para o CTO ou líder técnico do cliente, garantindo que as informações técnicas estejam bem apresentadas [59].

VI. Legibilidade pelo Time Financeiro:

Mede a eficácia da apresentação em evidenciar os pontos relevantes para o CFO ou líder financeiro, especialmente no que diz respeito ao valor e ao retorno sobre o investimento para o cliente [60].

VII. Legibilidade pelo Time de Operações:

Avalia o quão bem a proposta comunica-se com o COO ou líder de operações, explicando de forma clara as mudanças que o produto ou serviço trará para a operação do cliente [61].

VIII. "Storytelling":

Mede a qualidade da narrativa da oferta comercial, analisando se a informação é transmitida de forma envolvente e em uma sequência lógica que conta uma história convincente [62].

Segundo o vendedor, os aspectos considerados na rubrica são relevantes e importantes em uma proposta comercial, mas ele apontou que, segundo sua experiência, a legibilidade pelo time de tecnologia é, geralmente, o ponto mais relevante para os clientes. Além disso, ele revelou que, para propostas direcionadas aos clientes da base já existente da empresa, a seção de apresentação da empresa pode ser mais curta, uma vez que esses clientes já passaram por essa apresentação pelo menos uma vez e frequentemente pedem para pular essa parte quando ela é muito longa ou repetitiva.

Por conta disso, optou-se por focar o escopo desta

pesquisa em desenvolver uma rubrica específica para a seção de apresentação da empresa para clientes recorrentes. Dessa forma, a pesquisa prioriza as necessidades identificadas como mais relevantes para o público-alvo, garantindo que a solução desenvolvida esteja alinhada às expectativas e práticas observadas no setor.

B. Resultados da Matriz FOFA

Com base nos resultados das entrevistas, foi possível formular hipóteses para a construção do protótipo utilizando a Análise FOFA, conforme discutido na seção 3.B, apresentada a seguir:

1) **Forças**
   a. Hipótese: A aplicação de tecnologias de IA permite: uma análise mais sistemática, rápida e automatizada das propostas; análise de um grande volume de dados e melhoria do modelo ao longo do tempo.
   b. Hipótese: A padronização do processo de criação de propostas comerciais permite identificar elementos chave e realizar testes.
   c. Hipótese: Personalização do conteúdo das propostas com base nos dados do cliente; propostas personalizadas de acordo com o setor e perfil do cliente.
2) **Fraquezas**
   a. Hipótese: A IA pode fornecer respostas errôneas ou alucinações, os modelos LLM não são determinísticos.
   b. Hipótese: Poucas propostas comerciais disponíveis para iniciar o projeto.
3) **Oportunidades**
   a. Hipótese: Aproveitar os dados do CRM do cliente para aumentar a performance da IA e gerar respostas mais personalizadas e direcionadas ao cliente.
   b. Hipótese: Conversar com vendedores experientes para entender o processo de criação de suas propostas comerciais.
   c. Hipótese: A OpenAI é amplamente utilizada pelos principais players do mercado e se mostra uma solução mais viável em comparação ao desenvolvimento de uma tecnologia proprietária.
4) **Ameaças**
   a. Hipótese: Dependência em modelos externos (IA); dependência em dados externos.
   b. Hipótese: Pouca ou nenhuma interação com os vendedores (usuários) da ferramenta.
   c. Hipótese: Pouco tempo para implementar e refinar a solução.
   d. Hipótese: Integração com CRM é viável, mas pode haver limitações e complexidades.
   e. Hipótese: Uma interface similar ao ChatGPT para gerar apresentações é extremamente útil; no entanto, a criação de PDFs com um estilo visual adequado pode ser um desafio.

C. Soluções propostas

Com a conclusão dos Kick-offs 1 e 2, e o levantamento das hipóteses levantadas na análise FOFA, conclui-se a etapa de mapeamento do problema, definida pelo método Sprint [41] como "Segunda". A partir desse estudo, foi possível esboçar duas ideias de soluções. A tabela 5 representa essa etapa ("Terça").

TABELA 5
SOLUÇÕES PROPOSTAS

SOLUÇÃO	OBJETIVO	PONTOS POSITIVOS	PONTOS NEGATIVOS
1 - Análise de propostas	A ferramenta analisa propostas comerciais com o objetivo de fornecer sugestões e insights valiosos ao vendedor, auxiliando na criação de soluções mais eficazes e alinhadas às necessidades do cliente.	O modelo não requer uma base de dados extensa para operar de maneira eficaz; basta utilizar uma 'Proposta Ideal' como referência. Essa abordagem simplificada facilita a implementação das sugestões, sendo responsabilidade do vendedor aplicá-las conforme necessário.	Baixa interação com o vendedor; trabalho manual do vendedor para inserir as sugestões propostas
2 - Assistente de propostas	A ferramenta auxilia o vendedor na criação de uma proposta comercial desde o início, facilitando o desenvolvimento de uma solução completa e personalizada para o cliente.	O processo de criação de propostas torna-se mais rápido e eficiente, permitindo a geração de uma versão inicial em pouco tempo, com uma identidade clara e conteúdo personalizado. O vendedor tem a possibilidade de direcionar e fornecer sugestões à IA ao longo do processo, garantindo uma maior adequação às necessidades específicas do cliente.	Implementação mais complexa, tempo de implementação maior do que o disponível para o projeto; exige alterações no processo de trabalho dos vendedores;

Após a avaliação das duas soluções da Tabela 5, a Solução 1 foi selecionada para validação com a empresa, pelos seguintes motivos:

- A Solução 2 demanda mudanças mais significativas no processo de vendas, já a Solução 1 possibilita uma integração mais gradual da inteligência artificial na área de negócios. Esta abordagem é recomendada por Paschen, Wilson e Ferreira (2020) [4], conforme discutido em 2.B.
- O projeto exige uma implementação rápida, com pouco tempo disponível.
- A Solução 2 demandaria ciclos de desenvolvimento ("sprints") muito longos, o que comprometeria o progresso do projeto.

Essa decisão marcou a terceira etapa do método Sprint [41]. Em seguida, a Solução 1 foi prototipada e validada na entrevista com o time técnico, cujos resultados já foram explorados na subseção "A. Resultados das Entrevistas". Assim, finalizando as últimas duas etapas do modelo, prototipagem ("Quinta") e testagem ("Sexta").

D. Versionamento das soluções

Abaixo, tem-se o versionamento desenvolvido da solução proposta:

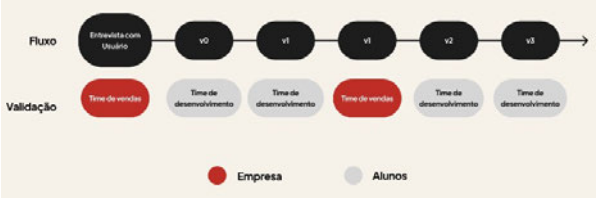

Fig. 8. Fluxo do versionamento e time responsável pela validação.

Como é possível analisar na figura 8, após a realização da entrevista com usuário (mencionados no subitem IV do item A), foram desenvolvidos os seguintes versionamentos:

- **Versão 0 (v0):** Versão base, apenas com modelos da OpenAI (gpt-4o, gpt-4o-mini), validada com o time desenvolvimento;
- **Versão 1 (v1):** adição do recurso RAG (documentos relevantes com diretrizes), com escala *Likert*, validada com o time desenvolvimento e com o time de vendas;
- **Versão 2 (v2):** tratamento de dados e nova funcionalidade de gerador de propostas comerciais, validada com o time desenvolvimento;
- **Versão 3 (v3):** análise *multi-modal,* analisando imagens e tabelas, bem como avaliação de múltiplas rubricas simultaneamente, validada com o time desenvolvimento;

E. Arquitetura da Versão 0 (v0)

Abaixo, tem-se a arquitetura base para o desenvolvimento da Versão 0.

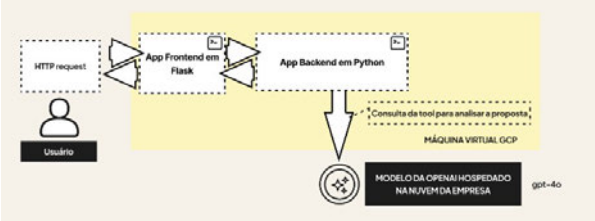

Fig. 9. Arquitetura da versão 0.

Como é possível observar na figura 9, a versão 0 possui os seguintes componentes:

- Máquina virtual na nuvem *Google Cloud Plataform* (GCP), para hospedagem do *Frontend* e *Backend*;
- Aplicação *Backend* em Python, que realiza uma chamada via *API* para o modelo hospedado na nuvem da empresa (*gpt-4o*);
- Aplicação *Frontend* em Python com *Flask*, que se comunica com o Backend via chamada API e que renderiza a interface usada pelo usuário para submeter as propostas comerciais;
- Usuário, via requisição HTTP, acessa o IP da máquina virtual e interage com o *Frontend* desenvolvido;

F. Arquitetura da Versão 1 (v1)

Abaixo, tem-se a arquitetura base para o desenvolvimento da Versão 1.

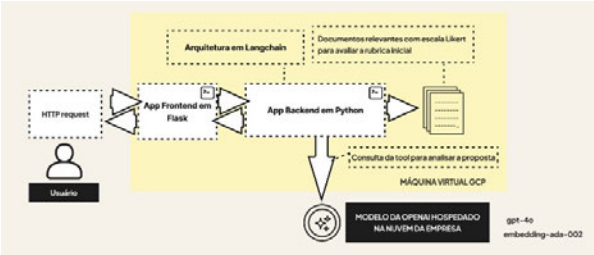

Fig. 10. Arquitetura da versão 1.

Como é possível observar na figura 10, a Versão 1 possui todos os elementos mencionados na Versão 0, com as seguintes melhorias:

- Na aplicação *Backend*, foi implementada a arquitetura *Langchain*, bem como a adição de documentos relevantes com a escala *Likert* para avaliar a rubrica mencionada no subitem IV do item A;
- Foi adicionado uma nova consulta para um novo modelo hospedado na nuvem da empresa (*embedding-ada-002*), para a realização dos *embeddings* dos documentos relevantes;
- Para melhorar a tomada de decisão do agente, foi adicionado aos documentos de referências checagens que definem os casos de uso nas avaliações, divididos entre pontos fortes, alertas e erros. Abaixo, na Figura 11, tem-se exemplo dessas checagens.

Fig. 11. Exemplo das checagens para rubrica Argumentação.

Como é possível observar, os pontos fortes, alertas e erros são atributos característicos das propostas comerciais, que auxiliam a inteligência artificial a sempre avaliar os mesmos aspectos da proposta comercial, reduzindo o não- determinismo da IA.

Testes com a Versão 1

Para avaliar a capacidade do modelo em identificar erros nas propostas comerciais analisadas, foi realizado um primeiro teste, com foco em identificar falhas argumentativas, que é um dos parâmetros relevantes levantados pela entrevista com o time comercial. Os detalhes e resultados dessa avaliação são descritos a seguir:

- Nome: Teste 1 (Avaliação da Capacidade do Modelo)
- Formato e Local: Local
- Data: 12/11
- Participantes: Time de Desenvolvedores

Contexto e Estrutura do Teste:

Para garantir uma avaliação precisa, o teste utilizou duas versões de uma mesma proposta comercial fictícia para uma consultoria de tecnologia, especializada em serviços de nuvem e cibersegurança. A proposta foi desenvolvida em duas versões:

1. Versão Original: Estruturada para atender aos critérios mais elevados de qualidade da rubrica de avaliação, apresentando uma proposta de valor clara, evidências robustas, personalização detalhada e um fluxo argumentativo lógico e progressivo [63].
2. Versão com Erros Pré-Definidos: Uma segunda versão da proposta foi alterada intencionalmente para incluir falhas específicas, principalmente na área de argumentação, com o objetivo de testar a precisão do modelo em identificar esses erros [64].

Nas Figuras 8 e 9, é possível observar os resultados da análise realizada pelo modelo para a Versão Original [63] e para a Versão com Erros Pré-Definidos [64].

Fig. 12. Versão Original

Fig. 13. Versão com Erros Programados

Erros Programados na Proposta com Falhas:

Na versão alterada da proposta [64], foram introduzidos erros específicos para simular uma argumentação de baixa qualidade:

1. **Falta de Compreensão das Necessidades do Cliente:** A proposta possuía informações genéricas, sem foco nas necessidades específicas do cliente.
   a. Texto original: *"Mais de 15 anos no setor de tecnologia, com uma equipe altamente qualificada e certificada em segurança cibernética"*
   b. Erro programado: *"Nossa empresa oferece serviços em TI"*
2. **Proposta de Valor Vaga:** A proposta de valor foi deixada imprecisa e não apresentava benefícios claros para o cliente.
   a. Texto original: *"Infraestrutura Escalável: Implementação de infraestrutura em nuvem que cresce conforme as suas necessidades"*
   b. Erro programado: *" O cliente pode usar a nuvem para escalar suas operações"*
3. **Ausência de Evidências:** A proposta foi desprovida de dados, estudos de caso ou qualquer tipo de evidência que sustentasse as alegações.
   a. Texto original: *" Desafio: O cliente enfrentava problemas com segurança e escalabilidade devido ao aumento das transações digitais. Solução: Implementamos uma infraestrutura híbrida em nuvem e camadas de segurança aprimoradas, reduzindo vulnerabilidades em 70%. "*
   b. Erro programado: *" A empresa é mais segura com nossos serviços de cibersegurança."*
4. **Estrutura Argumentativa Fragmentada:** Os argumentos foram organizados sem uma estrutura lógica ou progressiva, prejudicando a coerência.
   a. Texto original:
      i. "Soluções de Nuvem Personalizadas:
      - *Infraestrutura Escalável: Implementação de infraestrutura em nuvem que cresce conforme as suas necessidades.*
      - *Redução de Custos: Modelos de pagamento por uso que reduzem despesas de capital e otimizam a alocação de recursos.*
      - *Alta Disponibilidade: Garantia de uptime de 99,99% com redundância automatizada e recuperação de desastres."*
   b. Erro programado:
      i. "O cliente pode usar a nuvem para escalar suas operações;
      ii. A segurança dos dados é mantida, e nós monitoramos o ambiente do cliente;

iii. *A empresa não precisa investir em infraestrutura física. "*

5. **Chamadas à Ação Genéricas e Fracas:** As chamadas à ação não ofereciam incentivo concreto ou direcionamento claro para o cliente.
    a. Texto original: *"Programe uma demonstração personalizada para visualizar nossas soluções em ação"*
    b. Erro programado: *"Entre em contato para saber mais. "*

Instrumentos e Materiais Utilizados:

- Inputs:
    - Proposta comercial com erros intencionais;
    - Plataforma de avaliação de propostas com o modelo em teste;
    - Roteiro estruturado para guiar o teste;
- Outputs:
    - Relatório gerado pelo modelo de avaliação, detalhando os pontos fortes, alertas e erros identificados na proposta;
- *Objetivo do Teste:* Avaliar a capacidade do modelo em identificar e reportar os erros na proposta. O foco da avaliação foi determinar qual porcentagem dos erros programados o modelo conseguiria identificar corretamente no relatório gerado.

Resultados Observados:

As análises feitas pela IA da Versão Original se encontram em [65] e a Versão com Erros Programados em [66].

O modelo foi capaz de identificar 80% dos erros introduzidos:

- **Erros Identificados:**
    - Falta de compreensão das necessidades do cliente
    - Ausência de uma proposta de valor clara;
    - Falta de estrutura argumentativa e ausência de evidências;
    - Ausência de diferenciais competitivos e chamadas à ação;
- **Erros Não Identificados:**
    - Em alguns casos, o modelo não identificou a ausência de personalização específica e tratou algumas chamadas à ação fracas como adequadas, sugerindo uma necessidade de ajuste na avaliação de personalização e clareza das chamadas à ação.

Pontos de Melhoria do Modelo:

- Ao analisar os *logs,* observou-se que os dados recebidos pela IA estavam com uma série de espaçamentos entre as letras das palavras, o que pode estar dificultando a análise da IA*;*
- Embora os pontos fortes, alertas e erros estão sendo úteis para avaliação da proposta comercial, a inteligência artificial não indicou a página aonde o ponto forte, alerta ou erro foi identificado, o que dificulta a usabilidade da ferramenta.

G. Resultados do Teste 2 da Versão 1

Para validar o modelo desenvolvido, o Teste 2, conduzido com a equipe comercial da empresa parceira foi no mês três desta pesquisa. Neste teste, avaliou-se o protótipo desenvolvido quanto a sua capabilidade em detectar erros gramaticais e de coesão nas propostas, além disso, pediu-se para que os participantes do teste também realizassem uma avaliação das propostas, para que fosse possível realizar uma comparação entre a análise do modelo, e de um ser humano. As características do Teste 2 são as seguintes:

- **Nome:** Teste 2 (Teste com o usuário)
- **Formato e local:** Síncrono, Videochamada.
- **Data:** Realizado entre 11/11/2024 e 15/11/2024.
- **Participantes:** Equipe de inteligência de mercado e um vendedor do time comercial da empresa parceira
- **Instrumentos e materiais:**
    - **Inputs:**
        - Uma proposta comercial para ser avaliada;
        - Plataforma de avaliação de propostas com o modelo desenvolvido;
        - Rubrica utilizada para avaliar propostas comerciais;
        - Roteiro do teste;
    - **Outputs:**
        - Relatório gerado pelo avaliador de propostas;
        - Avaliação do vendedor;
        - Feedback do vendedor;
- **Objetivo:** Validar o modelo desenvolvido ao responder as seguintes questões:
    - O modelo agrega valor para o vendedor/empresa?
    - O modelo ataca uma dor real do usuário?
    - O modelo é capaz de produzir sugestões relevantes?
- **Anotações:** O protótipo do modelo a ser testado, junto com um roteiro e todos os materiais necessários para a realização do teste foram disponibilizados à empresa parceira.

Resultados Observados:

- O modelo baseado em rubricas se mostrou bastante útil, e a aplicação dos testes ajudou a materializar melhor o significado de cada rubrica.
- A abordagem de categorização em Pontos Fortes, Médios e Erros demonstrou ser funcional.
- Foi identificado que o analisador poderia sugerir melhorias na proposta comercial para agregar mais valor ao processo.

H. Arquitetura da Versão 2 (v2)

Na figura 11, tem-se a arquitetura base da Versão 2.

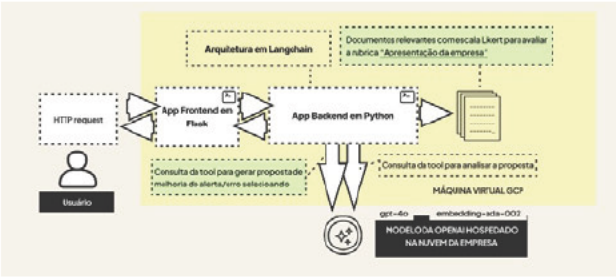

Fig. 14. Arquitetura da Versão 2.

Conforme observado na Figura 14, a Versão 2 contempla todos os elementos presentes na Versão 1, apresentando, contudo, as seguintes melhorias:

- Foi desenvolvida a seção intitulada "Apresentação da Empresa", identificada como uma das mais relevantes para o time comercial, conforme destacado em entrevistas conduzidas durante o estudo;
- Para mitigar os problemas detectados na versão anterior, realizou-se a remoção dos espaçamentos entre letras e a inclusão de um separador no slide, conforme ilustrado na Figura 15.

Fig. 15. Remoção dos espaços e separador do slide.

- Para incorporar o feedback do time de vendas obtido no Teste 2, foram implementadas melhorias nos alertas e mensagens de erro. Especificamente, foi adicionado um novo documento de referência para que a Inteligência Artificial possa gerar uma versão corrigida dos slides contendo o erro identificado. Os detalhes dessa implementação estão descritos na Figura 16.

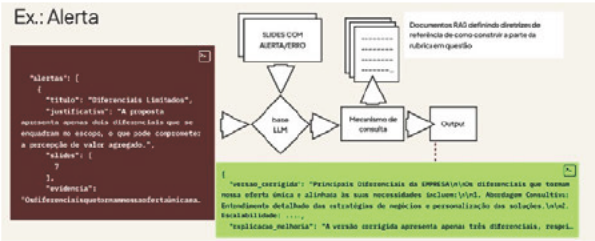

Fig. 16. Propostas de Melhoria dos Alertas/Erros

- Para facilitar a visualização, foi adicionado um gráfico indicando a quantidade pontos fortes, alertas e erros identificados na proposta, como é possível verificar na Figura 17.

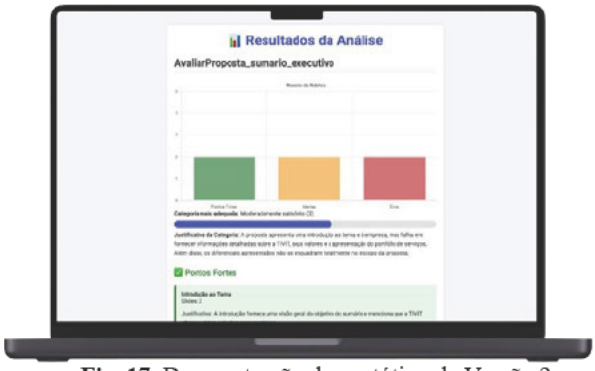

Fig. 17. Demonstração do protótipo da Versão 2.

Desempenho do Modelo:

- Na proposta classificada como "Boa", o modelo apresentou uma melhoria de 50% na identificação de alertas e 100% na identificação de erros;
- A implementação da remoção de espaços indesejados e a inserção de separadores entre slides foram fundamentais para essa melhoria, indicando que o protótipo v2 oferece maior compatibilidade com o processamento textual da IA em comparação com a Versão 1;

Geração de Propostas de Melhoria:

As propostas de melhoria foram geradas com sucesso, alinhadas às diretrizes estabelecidas pela empresa, comprovando a eficácia das atualizações implementadas.

I. Análise de Determinismo entre as Versões 0,1 e 2

Para avaliar o grau de determinismo entre os modelos desenvolvidos, foi conduzido o seguinte experimento:

1. Foi elaborada uma proposta denominada Proposta 1, seguindo todas as diretrizes especificadas nos documentos de referência, com foco na rubrica "Apresentação da Empresa".
2. Uma segunda proposta, denominada Proposta 2, foi criada de forma similar à Proposta 1, mas com a introdução de erros programados.

Cada modelo foi executado 100 vezes para cada uma das propostas, totalizando 600 execuções no experimento. A análise subsequente investigou as classificações atribuídas pelos modelos às propostas com base na escala Likert.

Os resultados dessa análise estão apresentados na Figura 18.

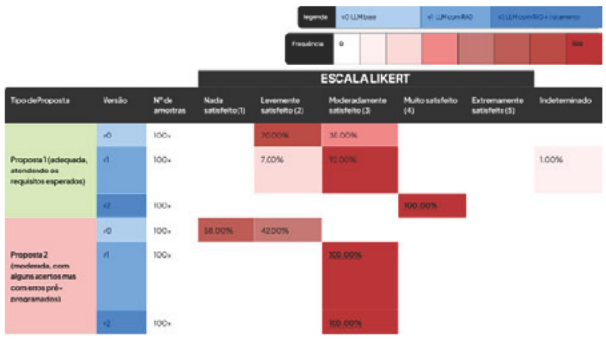

Fig. 18. Análise de determinismo entre as Versões 0,1 e 2.

Com base nos resultados ilustrados na Figura 15:

- **Versão 0:** Apresentou o maior índice de não determinismo entre as versões analisadas. Além disso, classificou incorretamente ambas as propostas (Proposta 1 e Proposta 2).
- **Versão 1:** Atingiu o índice de determinismo desejado (100%) para a Proposta 2. Contudo, classificou tanto a Proposta 1 quanto a Proposta 2 como "Moderadamente Satisfeito", indicando dificuldade em diferenciar os cenários.
- **Versão 2:** Alcançou o índice de determinismo desejado (100%) para ambas as propostas. Além disso, diferenciou corretamente as propostas, classificando a Proposta 1 como superior à Proposta 2.

Conclusão

A análise de determinismo entre as Versões 0, 1 e 2 demonstrou uma evolução significativa na capacidade dos modelos em alcançar classificações consistentes e alinhadas aos critérios esperados. Enquanto a Versão 0 apresentou limitações evidentes, tanto em determinismo quanto na precisão das classificações, a Versão 1 conseguiu atingir o determinismo ideal em situações específicas, embora ainda demonstrasse dificuldades em diferenciar propostas com níveis distintos de qualidade. Por outro lado, a Versão 2 não apenas alcançou 100% de determinismo em ambos os cenários, como também foi capaz de classificar adequadamente a Proposta 1 como superior à Proposta 2, evidenciando sua maior robustez e confiabilidade. Esses resultados reforçam o progresso obtido nas iterações e validam a eficácia das melhorias implementadas no modelo.

I. Discussão

Através das entrevistas Kick-offs e da conversa com o vendedor, foi possível identificar as características e motivações da empresa, o perfil do cliente ideal, o processo de vendas, as principais dificuldades enfrentadas nesse processo, o principal ponto de falha e como funciona o processo de criação de uma proposta comercial. Com isso, foram levantadas hipóteses analisadas segundo uma matriz FOFA. Essas hipóteses originaram duas possíveis soluções, que foram comparadas e ajudaram a direcionar o restante do projeto. Em seguida, através da entrevista com o time técnico da empresa, foi possível validar a estrutura tecnológica proposta, receber acesso aos modelos necessários para o desenvolvimento da solução e definir o escopo final para o projeto (integração à plataforma de inteligência artificial da empresa).

Com o objetivo definido, iniciou-se o desenvolvimento gradual da solução. Inicialmente, priorizou- se a criação de uma aplicação capaz de receber arquivos no formato PDF, processar e interpretar os dados desse documento através dos *embeddings*. Em seguida, iniciou-se o processo de aprimoramento para tornar o modelo capaz de apontar os erros textuais da proposta, avaliando o PDF segundo a rubrica semântica, apresentada no tópico *IV. Entrevista com o time comercial*, dentro da seção *IV.*

Resultados.

Os progressos feitos no modelo foram testados e validados através dos Testes 1 e 2. Durante o Teste 1, verificou-se que o modelo é capaz de identificar a maior parte dos erros programados, entretanto, ainda existem erros e pontos a serem melhorados. Já, através do Teste 2, verificou- se que a ferramenta proposta ataca uma dor real dos usuários e possui grande potencial para contribuir para o ambiente e fluxo de trabalho deles, além de auxiliar na correção textual dos documentos produzidos, o modelo promete oferecer sugestões relevantes para implementar o conteúdo apresentados nas propostas, contribuindo para o processo de vendas da empresa.

Atualmente, a solução desenvolvida é capaz de receber arquivos no formato de PDF, vetorizar essas informações, analisar, raciocinar e gerar um relatório segundo as suas impressões. O modelo se provou capaz de classificar uma proposta comercial com determinismo através de rubricas seguindo a escala Likert.

Com isso, é possível afirmar que a ferramenta desenvolvida ao longo desse estudo pode ser aplicada em diferentes casos de uso que envolvem a avaliação de documentos.

Embora os resultados desta pesquisa permitam conduzir o processo de avaliação das propostas, é importante destacar que a solução implementada foi estruturada considerando as seguintes limitações: (i) o acesso a uma base de dados restrita a apenas oito propostas comerciais e (ii) comunicação pouco frequente com os usuários finais da ferramenta, os vendedores. Estas limitações podem afetar a capacidade de generalização do modelo, sendo necessário levar em consideração que algumas adaptações podem ser necessárias para avaliação de propostas que empreguem trechos, ou partes de documentos, que não foram utilizados neste estudo. Além disso, a limitação
(ii) gera impacto direto na avaliação de usabilidade e experiência do usuário.

Para o futuro, pretende-se continuar o desenvolvimento desta solução que utiliza Inteligência Artificial para gerar avaliações de propostas comerciais. Os próximos passos serão a integração do modelo analisador de propostas comerciais ao ambiente da empresa parceira, o aprimoramento deste modelo através do treinamento dele com
o uso de mais documentos e propostas anteriores da empresa,
o refinamento das rubricas utilizadas por ele para avaliar as propostas, e, posteriormente, o desenvolvimento do assistente de propostas, solução que promete auxiliar o vendedor durante
o processo de criação da proposta comercial, entregando uma versão inicial da proposta com base nos dados coletados sobre a empresa prospectada em poucos minutos.

APÊNDICES

APÊNDICE 1

PERGUNTAS REALIZADAS NAS ENTREVISTAS COM CLIENTE.

Índice	Entrevista	Tópico	Perguntas
1	Kick-off 1	Seleção e Identificação de Clientes Ideais	Como a sua empresa seleciona os clientes? Poderia descrever o perfil do Cliente Ideal (ICP)? Existem diferentes perfis de

			clientes ideais para a empresa?
2	Kick-off 1	Estratégia de Prospecção	Como vocês prospectam os clientes de vocês? Se existe vários canais quais são os principais?
3	Kick-off 1	Estratégia de Primeiro Contato	Quais são os principais objetivos dos vendedores ao realizar o primeiro contato com um potencial cliente? Quais informações eles buscam obter e qual é a importância dessas informações para o processo de vendas?
4	Kick-off 1	Abordagem e Contato	Qual é o nível de personalização dos conteúdos (mensagens e-mails propostas) na fase de abordagem e pré-abordagem?
5	Kick-off 1	Apresentação e Demonstração	Durante a apresentação das soluções para os clientes quais ferramentas ou abordagens a empresa utiliza para garantir que os benefícios do produto sejam claramente comunicados? Existe o uso de prototipagem?
6	Kick-off 1	Desenvolvimento de Propostas Comerciais	Como os vendedores estruturam as propostas comerciais? Quais são os critérios utilizados para a escolha do pacote ou solução a ser oferecida ao cliente?
7	Kick-off 1	Impacto de Ofertas de Amostras Grátis	Vocês oferecem demonstrações ou amostras dos produtos de vocês? Se sim vocês já identificaram se existe alguma correlação com o sucesso ou insucesso nas vendas? Como a empresa avalia o impacto dessa estratégia?
8	Kick-off 1	Ciclo de Fechamento de Vendas	Qual é o tempo médio necessário para fechar uma venda com um cliente? Existem variações significativas nesse prazo dependendo do tipo de cliente ou serviço?
9	Kick-off 1	Desafios no Processo de Vendas	Em qual etapa do processo de vendas a empresa perde mais clientes? Existem ações específicas adotadas para tentar mitigar essa perda?
10	Kick-off 1	Desafios no Processo de Vendas	Quais são as principais objeções enfrentadas pelos vendedores ao tentar fechar uma venda? Vocês utilizam alguma ferramenta que ajuda nas estratégias de precificação?
11	Kick-off 1	Padrões e Características de Clientes de Sucesso	A empresa identificou algum padrão ou característica comum entre os clientes mais bem-sucedidos? Se sim poderia descrever esses padrões?
12	Kick-off 2	Abordagem Comercial e Crescimento	Houve alguma mudança na abordagem comercial da empresa em resposta ao crescimento da base de clientes? Se sim, quais foram as principais adaptações? Vocês já identificaram se uma dessas mudanças prejudicou/ajudou o desempenho nas vendas?
13	Kick-off 2	Gestão e Disponibilidade de Dados	Como vocês acompanham o progresso das vendas? Qual plataforma vocês utilizam para cadastrar os dados sobre as propostas comerciais? Essa plataforma oferece algum recurso que ajuda vocês a melhorarem o desempenho das vendas além da própria gestão?
14	Kick-off 2	Métricas e Indicadores Financeiros	A empresa acompanha métricas como Lifetime Value (LTV), Custo de Aquisição de Clientes (CAC) e Custo por Aquisição (CPA)? Se sim como essas métricas influenciam as estratégias de vendas e marketing?
15	Kick-off 2	Métricas e Indicadores Financeiros	Quais são as métricas do processo de vendas que vocês julgam ser importantes e acompanham? Como elas influenciam a estratégia de vendas e marketing de vocês hoje?
16	Kick-off 2	Acompanhamento Pós-Venda	Como a empresa gerencia o acompanhamento após a venda ser concluída? Existe o uso de alguma ferramenta para automatizar fluxos de trabalho atendimento pós-venda ou identificar novas oportunidades de upsell e cross-sell?
17	Kick-off 2	Cultura Corporativa e Relacionamento com Clientes	Existe uma correlação entre a cultura corporativa da TIVIT e o relacionamento com seus clientes? Como essa correlação impacta o sucesso das parcerias?
18	Kick-off 2	Identificação de Gargalos e Impacto da Inteligência Artificial	Em qual etapa do processo de vendas a empresa acredita que a inteligência artificial pode trazer o maior impacto? Onde estão os maiores gargalos ou desafios que poderiam ser solucionados com o uso de IA?
19	Kick-off 2	Uso de IA no Processo de Vendas	Vocês já utilizam IA em alguma das etapas das vendas? Se sim em qual? Qual é o valor que ela gera?
20	Kick-off 2	Iniciativas de Análise Técnica	A TIVIT já possui profissionais de tecnologia envolvidos na análise e observação do escopo proposto do projeto? Se sim qual é o papel deles no processo?
21	Kick-off 2	Iniciativas de Análise Técnica	Vocês já estão tentando usar IA para melhorar vendas? Se sim qual?
22	Kick-off 2	Características dos Vendedores	O que representa um bom e um mal vendedor?
23	Kick-off 2	Características dos Vendedores	Vocês já identificaram se existe uma relação (matching) entre os vendedores e os produtos/propostas que eles vendem?
24	Kick-off 2	Setores	Qual(is) é o setor mais relevante para vocês? Por que ele é o mais relevante?
25	Kick-off 2	Setores	Qual(is) os setores de maior sucesso (maior taxa de vendas)? E o(s) de maior insucesso?
26	Kick-off 2	Setores	Na opinião de vocês, qual o setor precisa melhorar mais em vendas?
27	Kick-off 2	Produtos	Qual é o carro chefe da companhia?
28	Kick-off 2	Produtos	Existe algum produto que serve como porta de entrada para os outros?
29	Kick-off 2	Tecnologia	Existe alguma restrição para o uso de dados para o treinamento de um modelo de inteligência artificial mesmo que ela seja de uso exclusivo da TIVIT?
30	Kick-off 2	Tecnologia	Existe alguma restrição de uso de tecnologia? Podemos definir a linguagem de programação e os modelos de LLM?
31	Kick-off 2	Tecnologia	Vocês têm alguma preferência por tecnologia e modelo de LLM?

APÊNDICE 2

RESPOSTAS DAS PERGUNTAS PELOS STAKEHOLDERS

Índice	Perguntas	Respostas
1	Como a sua empresa seleciona os clientes? Poderia descrever o perfil do Cliente Ideal (ICP)? Existem diferentes perfis de clientes ideais para a empresa?	[redacted]

2	Como vocês prospectam os clientes de vocês? Se existe vários canais quais são os principais?	[redacted]
3	Quais são os principais objetivos dos vendedores ao realizar o primeiro contato com um potencial cliente? Quais informações eles buscam obter e qual é a importância dessas informações para o processo de vendas?	[redacted]
4	Qual é o nível de personalização dos conteúdos (mensagens emails propostas) na fase de abordagem e pré-abordagem?	[redacted]
5	Durante a apresentação das soluções para os clientes quais ferramentas ou abordagens a empresa utiliza para garantir que os benefícios do produto sejam claramente comunicados? Existe o uso de prototipagem?	[redacted]
6	Como os vendedores estruturam as propostas comerciais? Quais são os critérios utilizados para a escolha do pacote ou solução a ser oferecida ao cliente?	[redacted]
7	Vocês oferecem demo/amostras dos produtos de vocês? Se sim vocês já identificaram se existe alguma correlação com o sucesso ou insucesso nas vendas? Como a empresa avalia o impacto dessa estratégia?	[redacted]
8	Qual é o tempo médio necessário para fechar uma venda com um cliente? Existem variações significativas nesse prazo dependendo do tipo de cliente ou serviço?	[redacted]
9	Em qual etapa do processo de vendas a empresa perde mais clientes? Existem ações específicas adotadas para tentar mitigar essa perda?	[redacted]
10	Quais são as principais objeções enfrentadas pelos vendedores ao tentar fechar uma venda? Vocês utilizam alguma ferramenta que ajuda nas estratégias de precificação?	[redacted]
11	A empresa identificou algum padrão ou característica comum entre os clientes mais bem-sucedidos? Se sim poderia descrever esses padrões?	[redacted]
12	Houve alguma mudança na abordagem comercial da empresa em resposta ao crescimento da base de clientes? Se sim quais foram as principais adaptações? Vocês já identificaram se uma dessas mudanças prejudicou/ajudou o desempenho nas vendas?	[redacted]
13	Como vocês acompanham o progresso das vendas? Qual plataforma vocês utilizam para cadastrar os dados sobre as propostas comerciais? Essa plataforma oferece algum recurso que ajuda vocês a melhorarem o desempenho das vendas além da própria gestão?	[redacted]
14	A empresa acompanha métricas como Lifetime Value (LTV) Custo de Aquisição de Clientes (CAC) e Custo por Aquisição (CPA)? Se sim como essas métricas influenciam as estratégias de vendas e marketing?	[redacted]
15	Quais são as métricas do processo de vendas que vocês julgam ser importantes e acompanham? Como elas influenciam a estratégia de vendas e marketing de vocês hoje?	[redacted]
16	Como a empresa gerencia o acompanhamento após a venda ser concluída? Existe o uso de alguma ferramenta para automatizar fluxos de trabalho atendimento pós-venda ou identificar novas oportunidades de upsell e	[redacted]

	cross-sell?	[redacted]
17	Existe uma correlação entre a cultura corporativa da TIVIT e o relacionamento com seus clientes? Como essa correlação impacta o sucesso das parcerias?	[redacted]
18	Em qual etapa do processo de vendas a empresa acredita que a inteligência artificial pode trazer o maior impacto? Onde estão os maiores gargalos ou desafios que poderiam ser solucionados com o uso de IA?	[redacted]
19	Vocês já utilizam IA em alguma das etapas das vendas? Se sim em qual? Qual é o valor que ela gera?	[redacted]
20	A TIVIT já possui profissionais de tecnologia envolvidos na análise e observação do escopo proposto do projeto? Se sim qual é o papel deles no processo?	[redacted]
21	Vocês já estão tentando usar IA para melhorar vendas? Se sim qual?	[redacted]
22	O que representa um bom e um mal vendedor?	[redacted]
23	Vocês já identificaram se existe uma relação (matching) entre os vendedores e os produtos/propostas que eles vendem?	[redacted]
24	Qual(is) é o setor mais relevante para vocês? Por que ele é o mais relevante?	[redacted]
25	Qual(is) os setores de maior sucesso (maior taxa de vendas)? E o(s) de maior insucesso?	[redacted]
26	Na opinião de vocês qual o setor precisa melhorar mais em vendas?	[redacted]
27	Qual é o carro chefe da companhia?	[redacted]
		nuvem.
28	Existe algum produto que serve como porta de entrada para os outros?	[redacted]
29	Existe alguma restrição para o uso de dados para o treinamento de um modelo de inteligência artificial mesmo que ela seja de uso exclusivo da TIVIT?	[redacted]
30	Existe alguma restrição de uso de tecnologia? Podemos definir a linguagem de programação e os modelos de LLM?	[redacted]
31	Vocês têm alguma preferência por tecnologia e modelo de LLM?	

APÊNDICE 3

STAKEHOLDERS DO PROJETO

Stakeholder	Posição	Papel no projeto
Enzo Francisco Klann Fonteyne	Estudante do INSPER	Planejamento e desenvolvimento
Luiz Felipe Lazzaron	Estudante do INSPER	Planejamento e desenvolvimento
Livia Tanaka	Estudante do INSPER	Planejamento e desenvolvimento
Lucca Hiratsuca Costa	Estudante do INSPER	Planejamento e desenvolvimento
André Luiz Maciel Santana	Professor do INSPER	Orientador do Projeto (INSPER)
Funcionário 1	Empresa parceira - RH	Gestão dos encontros entre a empresa e os alunos.
Funcionário 2	Empresa parceira - inteligência de mercado	Ponto de contato com a empresa
Funcionário 3	Empresa parceira - inteligência de mercado	Ponto de contato com a empresa
Funcionário 4	Empresa parceira - inteligência de mercado	Ponto de contato com a empresa
Diretor 1	Empresa parceira – Diretor da área de inteligência de mercado	Coordenador do projeto (Empresa parceira)

REFERÊNCIAS

[1] IDC, "The Global Impact of Artificial Intelligence on the Economy and Jobs", Sep. 17, 2024. [Online]. Available: https://www.idc.com/getdoc.jsp?containerId=prUS52600524. [Accessed: Sep. 19, 2024].

[2] A. J. Dubinsky, "A factor analytic study of the personal selling process," Journal of Personal Selling & Sales Management, vol. 1, no. 1, pp. 26-33, 1980/1981.

[3] N. Syam and A. Sharma, "Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice," Industrial Marketing Management, vol. 69, pp. 135-146, 2018.

[4] J. Paschen, M. Wilson, and J. J. Ferreira, "Collaborative intelligence: How human and artificial intelligence create value along the B2B sales funnel," Business Horizons, vol. 63, no. 3, pp. 403-414, 2020.

[5] M. Bohanec, M. Kljajić Borštnar, and M. Robnik-Šikonja, "Explaining machine learning models in sales predictions," Expert Systems With Applications, vol. 71, pp. 416-428, 2017.

[6] T. D. Nguyen, A. Paswan, and A. J. Dubinsky, "Allocation of Salespeople's resources for generating new sales opportunities across four types of customers," Industrial Marketing Management, vol. 68, pp. 114-131, 2018.

[7] P. Sinha, A. Shastri, and S. E. Lorimer, "How generative AI will change sales," Harvard Business Review, 2023. [Online]. Available: https://hbr.org/2023/03/how-generative-ai-will-change-sales. [Accessed: Aug. 19, 2024].

[8] Microsoft, "Introdução ao Sales Copilot." [Online]. Available: https://learn.microsoft.com/pt-br/microsoft-sales-

copilot/introduction. [Accessed: Sep. 7, 2024].
[9] Salesforce, "Inteligência artificial no Salesforce." [Online]. Available: https://www.salesforce.com/br/artificial-intelligence/. [Accessed: Sep. 7, 2024].
[10] Dialpad, "AI Sales: Inteligência Artificial para Vendas." [Online]. Available: https://www.dialpad.com/ai-sales/. [Accessed: Sep. 7, 2024].
[11] Clay, "Clay: Plataforma de Prospecção Inteligente." [Online]. Available: https://www.clay.com/. [Accessed: Sep. 7, 2024].
[12] Avoma, "Avoma: Assistente de IA para Reuniões e Transcrições." [Online]. Available: https://www.avoma.com/. [Accessed: Sep. 7, 2024].
[13] D. Henriksen, C. Richardson, and R. Mehta, "Design thinking: A creative approach to educational problems of practice," Thinking Skills and Creativity, vol. 26, pp. 140-153, Dec. 2017, doi: 10.1016/j.tsc.2017.10.001. [Accessed: Nov. 11, 2024].
[14] L. Banh e G. Strobel, "Generative artificial intelligence," Electronic Markets, vol. 33, no. 63, pp. 1–17, 2023.
[15] D. Castelvecchi, "Can we open the black box of AI?," Nature, vol. 538, no. 7623, pp. 20–23, 2016.
[16] P. H. Winston, Artificial Intelligence, 3rd ed., Addison-Wesley, 1993.
[17] E. Brynjolfsson and T. Mitchell, "What can machine learning do? Workforce implications," Science, vol. 358, no. 6370, pp. 1530–1534, 2017.
[18] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," Electronic Markets, vol. 31, no. 3, pp. 685–695, 2021.
[19] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning, MIT Press, 2016.
[20] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444, 2015.
[21] T. Jebara, "Generative versus discriminative learning," in Machine Learning, Springer, 2004, pp. 17–60.
[22] F. Lehmann and D. Buschek, "Examining autocompletion as a basic concept for interaction with generative AI," I-Com, vol. 19, no. 3, pp. 251–264, 2020.
[23] J. M. Tomczak, Deep Generative Modeling, Springer International Publishing, 2022.
[24] T. H. Davenport and R. Ronanki, "Artificial Intelligence for the Real World," Harvard Business Review, vol. 96, no. 1, pp. 108- 116, 2018.
[25] V. Shankar, "How Artificial Intelligence (AI) is Reshaping Retailing," Journal of Retailing, vol. 94, no. 4, pp. 6-11, 2018.
[26] P. Gentsch, AI in Marketing, Sales and Service: How Marketers Without a Data Science Degree Can Use AI, Big Data and Bots. Springer, 2018.
[27] Y. K. Dwivedi et al., "'So what if ChatGPT wrote it?': Multidisciplinary perspectives on opportunities, challenges, and implications of generative conversational AI for research, practice, and policy," International Journal of Information Management, vol. 71, 102642, 2023.
[28] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space," in Proc. Int. Conf. Learning Representations (ICLR), 2013.
[29] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding," in 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), 2019, pp. 4171–4186.
[30] T. B. Brown et al., "Language Models are Few-Shot Learners," in Advances in Neural Information Processing Systems, vol. 33, 2020, pp. 1877–1901.
[31] M. E. Porter, Estratégia Competitiva: Técnicas para Análise de Indústrias e da Concorrência. Rio de Janeiro: Elsevier, 1999.
[32] R. M. McDonald and K. M. Eisenhardt, "Parallel Play: Startups, Nascent Markets, and Effective Business-model Design," Administrative Science Quarterly, vol. 65, no. 2, 2020.
[33] Microsoft, "Copilot for Sales," Microsoft. [Online]. Available: https://www.microsoft.com/en-us/microsoft-365/copilot/copilot- for-sales. [Accessed: Sep. 18, 2024].
[34] Microsoft, "Microsoft Sales Copilot - FAQ," Microsoft Learn. [Online]. Available: https://learn.microsoft.com/pt-br/microsoft-sales-copilot/sales-copilot-faq. [Accessed: Sep. 17, 2024].
[35] Microsoft, "Supported languages for Microsoft Sales Copilot," Microsoft Learn. [Online]. Available: https://learn.microsoft.com/pt-br/microsoft-sales-copilot/supported-languages. [Accessed: Sep. 17, 2024].
[36] Salesforce, "Generative AI Platform Supported Languages," Salesforce Help. [Online]. Available: https://help.salesforce.com/s/articleView?id=sf.generative_ai_platform_languages.htm&type=5. [Accessed: Sep. 17, 2024].
[37] EBSCO, "EBSCO Discovery Service," EBSCO. [Online]. Available: https://www.ebsco.com/pt/produtos/ebsco-discovery- service. [Accessed: Sep. 18, 2024].
[38] M. A. Benzaghta, A. Elwalda, M. M. Mousa, I. Erkan, and M. Rahman, "SWOT analysis applications: An integrative literature review," Journal of Global Business Insights, vol. 6, no. 1, pp. 55- 73, 2021. [Online]. Available: https://www.doi.org/10.5038/2640-6489.6.1.1148. [Accessed: Sep. 18, 2024].
[39] E. Gurel and M. Tat, "SWOT Analysis: A Theoretical Review," The Journal of International Social Research, vol. 10, pp. 994- 1006, 2017.
[40] C. Dell'Era, S. Magistretti, C. Cautela, R. Verganti, and F. Zurlo, "Four kinds of design thinking: From ideating to making, engaging, and criticizing," Creativity and Innovation Management, vol. 29, no. 2, pp. 324–344, Jan. 2020, doi: 10.1111/caim.12353.
[41] J. Knapp, J. Zeratsky, and B. Kowitz, Sprint: How to solve big problems and test new ideas in just five days. 2016. [Online]. Available: https://dlibrary.ittelkom-pwt.ac.id/index.php?p=show_detail&id=10808. [Accessed: Sep. 18, 2024].
[42] Figma, "Figma," Figma. [Online]. Available: www.figma.com. [Accessed: Sep. 18, 2024].
[43] LangChain, "LangChain," LangChain. [Online]. Available: www.langchain.com. [Accessed: Sep. 18, 2024].
[44] M. Fauscette, "Using the LangChain Framework with Generative AI," Arion Research, 2023. [Online]. Available: https://www.arionresearch.com/blog/using-the-langchain- framework-with-generative-ai. [Accessed: Sep. 18, 2024].
[45] P. Lewis et al., "Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks," arXiv preprint arXiv:2005.11401, 2020. [Online]. Available: https://arxiv.org/pdf/2005.11401. [Accessed: Sep. 18, 2024].
[46] R. Likert, "A technique for the measurement of attitudes," Archives of Psychology, vol. 22, no. 140, pp. 1-55, 1932.
[47] S. Yao et al., "ReAct: Synergizing Reasoning and Acting in Language Models," arXiv preprint arXiv:2210.03629, 2022. [Online]. Available: https://arxiv.org/abs/2210.03629. [Accessed: Sep. 18, 2024].
[48] R. Hamlin, "The Relative Merits of Observational and Experimental Research: Four Key Principles for Optimising Observational Research Designs," Nutrients, vol. 14, no. 21, p. 4649, 2022.
[49] M. M. Ventura, "O estudo de caso como modalidade de pesquisa," Revista SoCERJ, vol. 20, no. 5, pp. 383-386, 2007.
[50] A. C. Gil, Como elaborar projetos e pesquisa, 3rd ed. São Paulo: Atlas, 1995, p. 58.
[51] Self-Published,. "Clareza e concisão." [Online]. Available: https://drive.google.com/drive/folders/1xIgjg0PRmL-YoyVT2noPn_f58zAdXpnh?usp=sharing. [Accessed: Nov. 12, 2024].
[52] Self-Published, "Argumentação." [Online]. Available: https://drive.google.com/drive/folders/1pPWCjhTMdI2hmt80dm0Ycb9tXg9odsnI?usp=sharing. [Accessed: Nov. 12, 2024].
[53] Self-Published, "Gramática." [Online]. Available: https://drive.google.com/drive/folders/19l2C4rbITDufU6bpPsGQCyEmsaH_tHRI?usp=sharing. [Accessed: Nov. 12, 2024].
[54] Self-Published, "Coesão e coerência." [Online]. Available: https://drive.google.com/drive/folders/1xamlJhUFv4oRXPUYiUQrgbTcBHaN8jqh?usp=sharing. [Accessed: Nov. 12, 2024].
[55] Self-Published, "Apresentação da empresa." [Online]. Available: https://drive.google.com/drive/folders/17hwxv94ZebuVbLKEkbF_Xn9nfUrBSZ3a?usp=sharing. [Accessed: Nov. 12, 2024].
[56] Self-Published, "Case da indústria." [Online]. Available: https://drive.google.com/drive/folders/1kuq8- 74c9Kuc6FlSS2tLfo1dE-VNe_mC?usp=sharing. [Accessed: Nov. 12, 2024].
[57] Self-Published, "Apresentação do Produto." [Online]. Available: https://drive.google.com/drive/folders/19VTl-nawcyEdHSR0jDRn2UN1OjuWLY0S?usp=sharing. [Accessed: Nov. 12, 2024].
[58] Self-Published, "Proposta de valor." [Online]. Available: https://drive.google.com/drive/folders/1B-74y1DnCFmsuYbBy_MfFmwKYFYaMqrf?usp=sharing.

[Accessed: Nov. 12, 2024].
[59] Self-Published, "Legibilidade pelo Time de Tecnologia." [Online]. Available: https://drive.google.com/drive/folders/1qazhMTCjq6zAb0GvvSm RXIQJc-7eARbS?usp=sharing. [Accessed: Nov. 12, 2024].
[60] Self-Published, "Legibilidade pelo Time Financeiro." [Online]. Available: https://drive.google.com/drive/folders/1jS0zV605icBX6dZqu9oW 7wllb870MYQw?usp=sharing. [Accessed: Nov. 12, 2024].
[61] Self-Published, "Legibilidade pelo Time de Operações." [Online]. Available: https://drive.google.com/drive/folders/1YjTAXTkoWRP22u2xZgjt DGNcsQcn3Lm0?usp=sharing. [Accessed: Nov. 12, 2024].
[62] Self-Published, "Storytelling." [Online]. Available: https://drive.google.com/drive/folders/1ur_gxW4dxc6DgnuXSAfO zQaWgUjoW3_E?usp=sharing. [Accessed: Nov. 12, 2024].
[63] Self-Published, "Versão Original." [Online]. Available: [https://drive.google.com/file/d/11SX_hG736LtlarxMPf3ErGBBP QZBUzFp/view?usp=sharing] [Accessed: Nov. 12, 2024].
[64] Self-Published, "Versão com erros programados." [Online]. Available: [https://drive.google.com/file/d/1fe9fstuaXaQvpzn9zinyicQiA2Pw 8A0r/view?usp=sharing] [Accessed: Nov. 12, 2024].
[65] Self-Published, " Resultados da Análise - versão original" [Online]. Available: [https://drive.google.com/file/d/1n-xD6874lgBpAvrc3AKO_9QBekEKC3jd/view?usp=sharing] [Accessed: Nov. 12, 2024].
[66] Self-Published, "V Resultados da Análise - versão com erros programados" [Online]. Available: [hhttps://drive.google.com/file/d/1lz8k7aqAgN8PbaULhcdwU4W RQd9pTsw5/view?usp=sharing] [Accessed: Nov. 12, 2024