

FELIPE FRANÇOLIN JANOWITZER

Aplicação de inteligência artificial generativa nos processos operacionais de um fundo de *venture capital*

São Paulo
2025

FELIPE FRANÇOLIN JANOWITZER

Aplicação de inteligência artificial generativa nos processos operacionais
de um fundo de *venture capital*

Trabalho apresentado à Escola Politécnica
da Universidade de São Paulo para
obtenção do diploma de Engenheiro de
Produção.

Orientador:
Prof. Dr. Renan Favarão da Silva

São Paulo
2025

AGRADECIMENTOS

Gostaria de agradecer ao meu pai, Pedro, à minha mãe, Marta, e à minha irmã, Marina, pelo apoio constante e por todo o suporte ao longo da minha trajetória.

Agradeço também à LEPoli, grupo de extensão que foi fundamental para o meu desenvolvimento durante a graduação, oferecendo aprendizado, desafios e oportunidades que levaria comigo para sempre. Foi lá, inclusive, que tive a felicidade de conhecer pessoas muito especiais — especialmente a Laura, minha namorada.

Por fim, deixo meu sincero agradecimento ao Renan, pelo apoio e pela orientação na construção deste trabalho.

RESUMO

JANOWITZER, Felipe Françolin. **Aplicações de inteligência artificial generativa nos processos operacionais de um fundo venture capital**. 2025. 111 f. Trabalho de conclusão de curso – Departamento de Engenharia de Produção, Escola Politécnica, Universidade de São Paulo, São Paulo, 2025.

A crescente relevância da inteligência artificial (IA) no ambiente de negócios moderno está transformando indústrias, incluindo o setor de *venture capital* (VC). As gestoras de fundos de VC precisam integrar, de forma estruturada e eficiente, as novas ferramentas de IA aos seus processos operacionais e de tomada de decisão, visando a otimização de recursos e tempo. Neste contexto, este trabalho tem como objetivo investigar como ferramentas e plataformas de inteligência artificial generativa podem ser integradas aos processos e rotinas operacionais de uma gestora de fundo de *venture capital*, com foco na melhoria da produtividade e no apoio à tomada de decisão. Para tal, foram estruturadas cinco etapas de pesquisa: Coleta de dados sobre o estado atual; Levantamento de aplicações potenciais; Matriz de priorização; Implementação de IA nas aplicações e mensurações dos resultados; Proposta final de solução. Os principais resultados foram a implementação de sucesso de dois MVPs de IA. A aplicação de IA para qualificação de *startups* resultou na redução do tempo de análise de 15 a 20 minutos para aproximadamente 5 minutos. Já a segunda aplicação de IA para preparação para conversas diminuiu o tempo gasto de 10 a 15 minutos para 3 a 5 minutos por reunião. Assim, as implementações práticas demonstraram o potencial da IA generativa em otimizar significativamente as rotinas de prospecção e análise de um fundo de *venture capital*, elevando o nível de maturidade em IA da gestora deste fundo.

Palavras-chave: Inteligência artificial generativa. IA. *Venture capital*. *Corporate venture capital*. Produtividade. Tomada de decisão.

ABSTRACT

JANOWITZER, Felipe Françolin. **Applications of generative artificial intelligence in the operational processes of a venture capital fund**. 2025. 111 p. Trabalho de conclusão de curso – Departamento de Engenharia de Produção, Escola Politécnica, Universidade de São Paulo, São Paulo, 2025.

The growing relevance of artificial intelligence (AI) in the modern business environment is transforming industries, including the venture capital (VC) sector. VC fund firms need to integrate new AI tools into their operational and decision-making processes in a structured and efficient manner, aiming to optimize resources and time. In this context, this study aims to investigate how generative artificial intelligence tools and platforms can be integrated into the processes and operational routines of a venture capital fund, with a focus on improving productivity and supporting decision-making. To achieve this, five research stages were structured: Data collection on the current state; Survey of potential applications; Prioritization matrix; Implementation of AI in the applications and measurement of results; Final solution proposal. The main results were the successful implementation of two AI MVPs. The application of AI for startup qualification resulted in a reduction of analysis time from 15-20 minutes to approximately 5 minutes. The second AI application for preparing for meetings reduced the time spent from 10-15 minutes to 3-5 minutes per meeting. Thus, the practical implementations demonstrated the potential of generative AI to significantly optimize the prospecting and analysis routines of a venture capital fund, raising the AI maturity level of the fund's management company.

Keywords: Generative artificial intelligence. AI. Venture capital. Corporate venture capital. Productivity. Decision-Making.

LISTA DE ILUSTRAÇÕES

FIGURA 2.1 – Processo de investimento em <i>venture capital</i>	24
FIGURA 2.2 – Estágios de maturidade em IA de Burnham (MIT)	39
FIGURA 2.3 – Estágios de maturidade em IA da Gartner	40
FIGURA 3.1 – Etapas do desenvolvimento da pesquisa	46
FIGURA 4.1 – Etapas do funil de investimento	50
FIGURA 4.2 – Arquitetura da aplicação de IA “Qualificar <i>startups</i> ”	81
FIGURA 4.3 – Arquitetura da aplicação de IA “Preparação para conversas”	87

LISTA DE TABELAS

TABELA 2.1 – Comparação entre as principais LLMs	36
TABELA 4.1 – Resumo das aplicações de IA potenciais	63
TABELA 4.2 – Critérios de avaliação das aplicações potenciais de IA generativa	64
TABELA 4.3 – Comparação da importância dos critérios de impacto estratégico	66
TABELA 4.4 – Tabela normalizada das comparações pareadas	67
TABELA 4.5 – Pesos para os critérios de avaliação	67
TABELA 4.6 – Aplicação núm. 1. “Encontrar startups em listas de empresas”	68
TABELA 4.7 – Aplicação núm. 2. “Qualificar <i>startups</i> ”	69
TABELA 4.8 – Aplicação núm. 3 “Preparação para conversas”	70
TABELA 4.9 – Aplicação núm. 4 “Avaliar <i>pitch decks</i> ”	70
TABELA 4.10 – Aplicação núm. 5 “Decisão em relação ao avanço para <i>deep dive</i> ”	71
TABELA 4.11 – Aplicação núm. 6 “Preparação do memorando de investimento”	72
TABELA 4.12 – Aplicação núm. 7 “Tomada de decisão no comitê de investimento”	72
TABELA 4.13 – Aplicação núm. 8 “Preparação de materiais em gestão de portfólio”	73
TABELA 4.14 – Matriz de priorização multicritério	74

LISTA DE ABREVIATURAS E SIGLAS

Sigla	Significado
-------	-------------

AGI	<i>artificial general intelligence</i> (inteligência artificial geral)
AHP	<i>Analytic Hierarchy Process</i> (Processo de Análise Hierárquica)
API	<i>Application Programming Interface</i> (Interface de Programação de Aplicações)
B2B	<i>business to business</i> (empresa para empresa)
CRM	<i>customer relationship management</i> (gestão de relacionamento com o cliente)
CVC	<i>Corporate venture capital</i> (capital de risco corporativo)
DD	<i>due diligence</i> (diligência)
GPT	<i>Generative Pre-trained Transformers</i> (Transformadores Generativos Pré-treinados)
GP	<i>general partner</i> (sócio gestor)
IA	Inteligência Artificial
IPO	<i>initial public offering</i> (Oferta Pública Inicial)
LLM	<i>large language model</i> (Modelo de Linguagem de Grande Porte)
LP	<i>limited partner</i> (sócio cotista)
MVP	<i>minimum viable product</i> (produto mínimo viável)
PE	<i>private equity</i> (participações privadas)
PLN	Processamento de Linguagem Natural
SaaS	<i>Software as a Service</i> (Software como Serviço)

SUMÁRIO

1 INTRODUÇÃO	11
1.1 OBJETIVOS	13
1.2 JUSTIFICATIVA	13
1.3 ESTRUTURA DO TRABALHO	14
2 FUNDAMENTAÇÃO TEÓRICA	16
2.1 MERCADO DE VENTURE CAPITAL	16
2.1.1 Conceito e características do <i>venture capital</i>	16
2.1.2 Panorama do <i>venture capital</i> no brasil	19
2.1.3 Tipos de fundos de <i>venture capital</i>	20
2.1.4 Processo de investimento em <i>venture capital</i>	23
2.2 FUNDAMENTOS E FERRAMENTAS DE IA GENERATIVA	27
2.2.1 Evolução e marcos históricos da inteligência artificial	27
2.2.2 Fundamentos do funcionamento da inteligência artificial	29
2.2.3 Ferramentas e plataformas de IA no contexto empresarial	35
2.2.4 Obtenção de sucesso com o uso de IA no contexto empresarial	38
2.3 INTELIGÊNCIA ARTIFICIAL APLICADA AO VENTURE CAPITAL	41
3 METODOLOGIA DE PESQUISA	44
3.1 CARACTERIZAÇÃO DA PESQUISA	44
3.2 DESCRIÇÃO DAS ETAPAS E MÉTODOS DA PESQUISA	45
4 ESTUDO DE CASO	48
4.1 CARACTERIZAÇÃO DA ORGANIZAÇÃO	48
4.2 COLETA DE DADOS SOBRE O ESTADO ATUAL	54
4.2.1 Descrição do estado atual	54
4.2.2 Classificação da organização pelos <i>frameworks</i> de maturidade	56
4.3 LEVANTAMENTO DE APLICAÇÕES POTENCIAIS	57
4.3.1 Encontrar <i>startups</i> em listas de empresas	57
4.3.2 Qualificar <i>startups</i>	57
4.3.3 Preparação para conversas	58
4.3.4 Avaliar <i>pitch decks</i>	59

4.3.5 Decisão em relação ao avanço para <i>deep dive</i>	60
4.3.6 Preparação do memorando de investimento	61
4.3.7 Tomada de decisão no comitê de investimento	61
4.3.8 Preparação de materiais em gestão de portfólio	63
4.4 PRIORIZAÇÃO DAS APLICAÇÕES POTENCIAIS	63
4.4.1 Definição dos critérios de avaliação	64
4.4.2 Definição de pesos para os critérios	65
4.4.3 Matriz de priorização	68
4.5 IMPLEMENTAÇÃO DE IA NAS APLICAÇÕES PRIORIZADAS E MENSURAÇÃO DOS RESULTADOS	75
4.5.1 Aplicação potencial de IA núm. 2 “Qualificar <i>startups</i> ”	75
4.5.2 Aplicação potencial de IA núm. 3 “Preparação para conversas”	83
4.6 PROPOSTA FINAL DE SOLUÇÃO	88
4.6.1 Proposta de aplicação de IA na etapa “Qualificar <i>startups</i> ”	89
4.6.2 Proposta de aplicação de IA na etapa “Preparação para conversas”	91
4.6.3 Outras propostas de aplicações de IA e oportunidades futuras	92
5 CONCLUSÕES	93
REFERÊNCIAS	95
APÊNDICE A – Saídas da demonstração da aplicação de IA para “Qualificar <i>startups</i> ”	102
APÊNDICE B – Saídas da demonstração da aplicação de IA para “Preparação para conversas”	107

1 INTRODUÇÃO

A Inteligência Artificial (IA) está transformando o mundo. Entre investidores, empresários e especialistas do setor de tecnologia, cresce o consenso de que vivemos hoje a terceira grande “onda” tecnológica, capaz de alterar profundamente a sociedade. John Werner, empreendedor serial, professor do MIT e sócio do fundo de *venture capital* Link Capital, descreve a evolução tecnológica recente em três grandes ondas. A primeira, marcada pelo avanço dos computadores pessoais, da biotecnologia e das fibras ópticas, consolidou as bases da digitalização. A segunda, no final dos anos 1990 e início dos 2000, foi impulsionada pela internet, pelos telefones celulares e pelo GPS, inaugurando a era das pontocom e da conectividade global. Atualmente, segundo o autor, entramos em uma terceira fase, guiada pela inteligência artificial, que tende a se integrar de forma abrangente em nossas atividades cotidianas e processos produtivos, transformando a maneira como trabalhamos, nos comunicamos e tomamos decisões (WERNER, 2024).

Essa visão é compartilhada por nomes influentes do ecossistema de *venture capital*, como Marc Andreessen, da Andreessen Horowitz e Martin Escobari da General Atlantic, que também reconhecem a IA como a nova infraestrutura sobre a qual serão construídos os modelos de negócio, a produtividade e a inovação das próximas décadas (OFFICECHAI, 2025; FERNANDES; ROCA, 2025). Jensen Huang, CEO da NVIDIA, uma das empresas mais emblemáticas da atual revolução tecnológica, reforçou recentemente essa perspectiva ao afirmar: “Não há dúvidas de que estamos em uma nova era da computação”, referindo-se ao avanço da Inteligência Artificial (REUTERS, 2025).

É quase impossível imaginar a vida contemporânea sem as transformações provocadas pelas duas ondas tecnológicas anteriores. No ambiente profissional e acadêmico, o computador é uma ferramenta essencial para comunicação, produção de conteúdo, elaboração de projetos e pesquisas. O entretenimento e o acesso à informação são dominados por plataformas como Netflix, Spotify, YouTube e Instagram. Até os bancos tornaram-se digitais, permitindo transações com poucos cliques. Setores como varejo, educação, mobilidade, comunicação e saúde foram completamente reconfigurados por essas inovações.

Mais do que conveniência, os avanços tecnológicos contribuíram de maneira concreta para o bem-estar humano, como no desenvolvimento acelerado de vacinas, diagnósticos médicos mais precisos ou sistemas de resposta a emergências mais eficazes. A expectativa, agora, é que a Inteligência Artificial tenha um impacto ainda mais profundo. Segundo Bill Gates, cofundador da Microsoft, “em uma década, a IA poderá realizar a maioria das tarefas humanas, inaugurando uma era de inteligência gratuita” (LERMA, 2025).

Grande parte das empresas que protagonizaram essas transformações tiveram origem como *startups*. Apple, Microsoft, Nvidia, Nubank, Instagram, OpenAI e Netflix são exemplos emblemáticos. Conforme definem Blank e Dorf (2012), “uma *startup* é uma organização temporária em busca de um modelo de negócio escalável, repetível e lucrativo”. Contudo, *startups* frequentemente não encontram instituições para se financiar. Os bancos só financiam um novo negócio na medida em que existam ativos tangíveis para garantir a dívida. Na economia atual, baseada em informação, muitas *startups* possuem poucos ativos tangíveis (ZIDER, 1998).

Neste cenário, os fundos de *venture capital* (VC), em português, fundos de capital de risco, cumprem papel essencial, assumindo riscos elevados em troca de alto potencial de retorno. De acordo com um estudo feito em 2015 pela Universidade de Stanford, empresas apoiadas por fundos de VC representam 57% do valor de mercado das empresas de capital aberto nos Estados Unidos fundadas desde 1979 (STREBULAEV; GOMPERS, 2015).

Neste contexto, este projeto de pesquisa visa responder às seguintes questões de pesquisa:

- Como os fundos de *venture capital* podem integrar a inteligência artificial generativa para otimizar seus processos de investimento e gestão de portfólio?
- Quais tecnologias de IA generativa são mais eficazes para apoiar a análise e seleção de *startups* em fundos de *venture capital*?
- Quais são os impactos práticos da utilização de ferramentas de IA generativa na rotina dos fundos de *venture capital*, especialmente em termos de qualidade das decisões e ganho de produtividade?
- Quais são os desafios e limitações enfrentados pelos fundos de *venture capital* na implementação de soluções baseadas em IA generativa?

Por meio desses questionamentos, elaboram-se os objetivos que conduziram o tratamento da pesquisa.

1.1 OBJETIVOS

O objetivo geral do trabalho é investigar como ferramentas e plataformas de inteligência artificial generativa podem ser integradas aos processos e rotinas operacionais de um fundo de *venture capital*, com foco na melhoria da produtividade e no apoio à tomada de decisão.

Para tanto, definem-se os seguintes objetivos específicos:

- a) Mapear os processos e rotinas operacionais de gestão de um fundo de *venture capital* relacionados à análise e gestão de investimentos;
- b) Identificar oportunidades de aplicação de ferramentas e plataformas de inteligência artificial nas atividades de trabalho da gestão do fundo com base no mapeamento realizado;
- c) Testar e avaliar o uso de diferentes ferramentas e plataformas de IA na operação da gestora do fundo de *venture capital*, considerando aspectos como aplicabilidade, usabilidade e impacto percebido;
- d) Propor uma abordagem para a integração das ferramentas e plataformas de IA selecionadas nos processos e rotinas operacionais da gestão do fundo de *venture capital*.

1.2 JUSTIFICATIVA

A relevância do estudo sobre a aplicação de inteligência artificial em fundos de *venture capital* decorre do impacto crescente que essa tecnologia vem exercendo no ambiente empresarial e financeiro. A IA tem se mostrado capaz de otimizar processos, reduzir vieses e aumentar a eficiência na análise de grandes volumes de dados, características essenciais para a tomada de decisão em fundos que lidam com investimentos de alto risco e elevado potencial de retorno. Assim, compreender como essas ferramentas, especialmente as de inteligência artificial generativa, podem ser integradas às rotinas operacionais de fundos de *venture capital* pode contribuir para

avanços do conhecimento sobre inovação tecnológica nas áreas de finanças e gestão de investimentos.

Ainda, esta temática apresenta forte pertinência prática. A literatura revisada indica que, embora haja um número considerável de estudos focados no investimento de fundos de *venture capital* em *startups* de inteligência artificial, ainda existem lacunas quanto à análise do uso direto da IA dentro das operações dos fundos. Poucos trabalhos estudam casos concretos de aplicação em processos decisórios ou avaliação de *startups*, especialmente em contextos como o brasileiro. Portanto, a pesquisa se justifica pela necessidade de preencher essas lacunas e oferecer *insights* aplicáveis para gestores de fundos e tomadores de decisão.

Outro aspecto que reforça a importância do tema é a divergência de perspectivas observada tanto na literatura quanto no mercado. Enquanto alguns autores e profissionais destacam o potencial da IA em tornar os processos mais objetivos e escaláveis, outros, como Marc Andreessen, enfatizam que determinadas competências humanas, como análise psicológica de empreendedores, dificilmente serão substituídas por tecnologia (NOLAN, 2025). Esta pluralidade evidencia que o debate sobre a integração da IA, em especial da IA generativa, em *venture capital* ainda está em evolução e carece de estudos sistemáticos, capazes de avaliar tanto os benefícios quanto as limitações da tecnologia.

Por fim, a relevância acadêmica e prática do tema também se manifesta na oportunidade de fornecer contribuições para o desenvolvimento de metodologias e *frameworks* de aplicação de IA generativa em fundos de *venture capital*. Ao investigar como plataformas e ferramentas de IA generativa podem ser incorporadas nas rotinas de análise, gestão de portfólio e monitoramento de investimentos, este trabalho pode gerar diretrizes estratégicas que apoiem decisões mais informadas e eficientes. Além disso, resultados obtidos podem servir como referência para futuras pesquisas e estudos comparativos, fortalecendo o corpo de conhecimento sobre inovação tecnológica aplicada ao mercado de *venture capital*.

1.3 ESTRUTURA DO TRABALHO

Para uma melhor organização e apresentação, o trabalho foi estruturado em cinco capítulos: Introdução, Fundamentação Teórica, Metodologia de Pesquisa,

Estudo de Caso e Conclusões. Na sequência, apresenta-se uma seção pós-textual específica para as referências.

Na Introdução, apresenta-se uma breve contextualização do tema de pesquisa acerca da Inteligência Artificial, em especial da IA generativa, e suas aplicações e potencialidades para a indústria de *venture capital*. Em seguida, são expostos os objetivos da pesquisa e a justificativa que motivou sua realização.

O segundo capítulo, Fundamentação Teórica, reúne os referenciais que sustentam o estudo, dividido em duas partes principais. A primeira aborda o mercado de *venture capital* onde inicia-se com sua definição e evolução histórica, seguido das particularidades desse mercado no Brasil, a classificação dos diferentes tipos de fundos e, por fim, a descrição da rotina operacional dessas organizações. A segunda parte dedica-se à inteligência artificial, apresentando seu histórico, o estado atual e as principais ferramentas de IA generativa disponíveis no mercado. Conclui-se com uma revisão de estudos já existentes sobre a aplicações de IA no setor de fundos de *venture capital*.

No capítulo 3, Metodologia de Pesquisa, classifica-se esta pesquisa científica de acordo com seus objetivos, procedimentos técnicos, natureza e abordagem. Em seguida, apresenta-se um fluxograma com todas as etapas previstas para o desenvolvimento do estudo, organizadas de forma sequencial.

Já no quarto capítulo, Estudo de Caso, discute-se o desenvolvimento das etapas de pesquisa na organização selecionada como objeto de estudo: uma gestora de fundo de *venture capital*. O capítulo inicia-se com a caracterização e descrição da instituição e, em seguida, divide-se em seções que acompanham as fases da pesquisa: coleta de dados, identificação de aplicações potenciais, elaboração da matriz de priorização, implementação das aplicações de IA propostas e discussão dos resultados finais.

Por fim, no capítulo 5, Conclusões, traz uma síntese do trabalho desenvolvido, discutindo o alcance dos objetivos propostos, os principais resultados obtidos e os impactos da investigação científica realizada.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, apresenta-se uma fundamentação teórica que sustenta o desenvolvimento deste trabalho, iniciando com uma análise aprofundada do conceito do mercado de *venture capital*, abordando sua origem, evolução e o contexto em que se desenvolveu no Brasil e no mundo. Em seguida, na segunda seção, discute-se o campo da Inteligência Artificial (IA) por meio de suas ferramentas e plataformas para negócios. Por fim, na terceira seção, apresentam-se as aplicações da IA aos fundos de *venture capital*, com base em estudos acadêmicos, análises de mercado e casos reais já reportados.

2.1 MERCADO DE VENTURE CAPITAL

Para melhor organização, a apresentação dos conceitos acerca do mercado de *venture capital* (VC) foi organizada em quatro subseções. Na subseção 2.1.1, discute-se o conceito teórico de *venture capital*, suas características de operação e funcionamento, além do histórico dessa classe de ativos. A subseção 2.1.2 aprofunda o panorama do VC no Brasil, desde seu surgimento até a atualidade. Em seguida, na subseção 2.1.3, são apresentados os diferentes tipos de *venture capital*, classificados de acordo com o perfil dos investidores, o estágio de maturidade das *startups* e o tipo de tese de investimento. Por fim, a subseção 2.1.4 descreve o processo operacional de investimento em fundos de capital de risco.

2.1.1 Conceito e características do *venture capital*

Em poucas palavras, o mercado de *venture capital*, também referenciado como mercado de capital de risco, é entendido como a atividade profissional de gestão de ativos que investe recursos captados de investidores institucionais ou indivíduos de alto patrimônio em novos empreendimentos inovadores, com alto potencial de crescimento (DA RIN; HELLMANN; PURI, 2013). Os fundos de VC não apenas oferecem financiamento às *startups* em troca de participação acionária, mas também disponibilizam serviços de mentoria e suporte estratégico para impulsionar seu desenvolvimento (GREENWOOD; HAN; SÁNCHEZ, 2022).

Os fundos de VC são normalmente considerados um tipo particular de *private equity* (PE) que foca em investir em empresas jovens com alto potencial de crescimento (GREENWOOD; HAN; SÁNCHEZ, 2022), em vez do aporte de capital em grandes empresas já estabelecidas no mercado (LEONEL, 2014), como fazem os fundos convencionais de PE.

O investimento em negócios de alto risco não é uma prática recente. Esse modelo viabilizou, por exemplo, as Grandes Navegações. Contudo, o mercado de capital de risco permaneceu desestruturado durante os séculos XIX e XX (SILVA, 2021). O primeiro fundo de *venture capital* formalmente estruturado foi o American Research and Development Corporation (ARDC), criado em 1946 (GOMPERS; LERNER, 2001). Ao longo dos seus 26 anos de operação como entidade independente, metade dos retornos do ARDC vieram de um único investimento: US\$70 mil aplicados na Digital Equipment Company, em 1957, que se valorizaram para US\$355 milhões (SILVA, 2021). Esse fenômeno, no qual poucos investimentos geram retornos extraordinários capazes de compensar os fracassos, é uma característica intrínseca da indústria de *venture capital*.

Desde então, o setor cresceu exponencialmente. Nos Estados Unidos, os investimentos em *venture capital* totalizaram US\$610 milhões em 1980 (DA RIN; HELLMANN; PURI, 2013). Segundo a KPMG, esse montante atingiu US\$349,4 bilhões em 2024, sendo US\$209 bilhões apenas nos Estados Unidos, refletindo a consolidação e expansão global da indústria (KPMG, 2025).

A grande maioria dos novos empreendimentos não consegue se sustentar e encerra suas atividades em um curto período. Mesmo aquelas que recebem investimento de fundos de *venture capital* continuam expostas a altos riscos de fracasso. Uma pesquisa conduzida por Shikhar Ghosh, com mais de 2.000 empresas que levantaram ao menos US\$ 1 milhão entre 2004 e 2010, revelou que 75% das *startups* financiadas por capital de risco nunca retornam capital aos investidores. Dessas, entre 30% e 40% acabam liquidando seus ativos, resultando em perdas totais para os investidores (GHOSH, 2011). Dado o modelo de portfólio e a estrutura dos acordos utilizados pelos fundos de *venture capital*, apenas de 10% a 20% das empresas investidas precisam ser grandes vencedoras (ou *fund returners*) para que se atinja a taxa de retorno esperada (ZIDER, 1998).

Financiar tecnologias de ponta sempre foi um desafio. É difícil saber se novas ideias são viáveis, se serão comercializáveis e qual é a melhor forma de levá-las ao

mercado. Além disso, é importante garantir que os incentivos de empreendedores e investidores estejam alinhados (DA RIN; HELLMANN; PURI, 2013).

Para enfrentar esses desafios, os fundos de *venture capital* operam com uma estrutura específica. As firmas de VC captam recursos por meio de veículos denominados fundos, organizados na forma jurídica de *limited partnership*. Nesse modelo, a firma de VC, chamada de General Partner (GP), ou sócio gestor, é responsável pela gestão ativa do fundo e assume responsabilidade ilimitada sobre suas decisões e operações. Por outro lado, os investidores, denominados Limited Partners (LPs), os sócios cotistas, possuem responsabilidade limitada, uma vez que não participam da gestão direta do fundo (DA RIN; HELLMANN; PURI, 2013).

O primeiro fundo organizado sob a modalidade de *limited partnership* foi em 1958, e hoje é o modelo predominante (SILVA, 2021). Nesse modelo, os GPs fazem a seleção das empresas que compõem o portfólio, podendo monitorar, orientar e fornecer serviços de valor agregado e, por fim, realizar a saída dessas empresas, distribuindo os retornos aos seus LPs. Os GPs recebem sua remuneração na forma de uma taxa de administração e de pagamentos baseados em desempenho, chamados de *carried interest* (ou simplesmente *carry*) (DA RIN; HELLMANN; PURI, 2013). A taxa de administração é uma porcentagem fixa, em torno de 1% a 2% do total de ativos sob gestão do fundo. Já o *carry* é uma porcentagem de todos os retornos acima de uma taxa de retorno mínima pré-estabelecida, também chamada de *hurdle* (LJUNGQVIST, 2024). Devido ao alto risco, os LPs esperam um retorno entre 25% e 35% ao ano durante todo o período do investimento (ZIDER, 1998).

Dado seu caráter de alto risco, o investimento realizado por fundos de VC é particularmente relevante para o financiamento da inovação (LERNER, TAG, 2013). As empresas, produtos e serviços que o *venture capital* ajudou a desenvolver são onipresentes em nosso dia a dia: o iPhone da Apple, a busca do Google, a Amazon, o Facebook e o Twitter, a Starbucks, a Uber, os veículos elétricos da Tesla, o Airbnb, o Instacart e a vacina contra a COVID-19 da Moderna (GREENWOOD; HAN; SÁNCHEZ, 2022). De acordo com ZIDER (1998), apenas uma pequena parcela dos recursos de VC é direcionada diretamente à pesquisa e desenvolvimento (P&D), enquanto mais de 80% é alocada na construção da infraestrutura necessária para que as empresas cresçam e escalem suas operações. Ainda assim, é inegável que muitas dessas grandes empresas inovadoras dificilmente teriam alcançado o sucesso sem o aporte dos fundos de *venture capital*.

2.1.2 Panorama do *venture capital* no Brasil

A indústria de *venture capital* no Brasil apareceu de forma mais tardia, se formos comparar principalmente com os EUA. A primeira gestora privada de VC/PE do Brasil foi a Brasilpar, criada em 1976 (MEIRELLES; PIMENTA JUNIOR; REBELATTO, 2008). Também neste ano, a Financiadora de Estudos e Projetos (FINEP), iniciou um programa de empréstimos a companhias com objetivo de promover a inovação (SILVA, 2021).

Entretanto, somente após a estabilização econômica ocorrida por meio do Plano Real em 1994, que realmente iniciaram os investimentos de *private equity* (PE) e VC no Brasil (CARVALHO; RIBEIRO; FURTADO, 2006). Neste mesmo ano, a Comissão de Valores Mobiliários (CVM) editou a primeira Instrução Normativa (209/1994) a lidar diretamente com essa modalidade de investimentos (SILVA, 2021). Em 2000, surgiu a Associação Brasileira de Private Equity e Venture Capital (ABVCAP), com o propósito de desenvolver o ecossistema nacional de investimentos de longo prazo (DISTRITO, 2021).

As mudanças no ambiente regulatório foram particularmente relevantes para os fundos de PE, como o GP Investimentos e o CVC/Opportunity, este último sendo o primeiro fundo brasileiro a atingir a ordem de bilhões de dólares em ativos sob gestão (SILVA, 2021). Já os fundos de *venture capital* começaram a se estruturar de forma mais consistente já no início do século XXI. Um dos primeiros grandes fundos a ser criado foi a DGF Investimentos, em 2001. Posteriormente, surgiu a Monashees, em 2005, que se consolidou como um dos fundos de VC mais relevantes do país, ao lado da Kaszek Ventures, fundada em 2011.

De acordo com Francisco Perez, fundador da Inseed Investimentos e atual diretor executivo no Banco Alfa, o mercado de *venture capital* no Brasil se tornou efetivamente relevante apenas em seu segundo ciclo de desenvolvimento, que abrange o período de 2010 a 2020 (DISTRITO, 2021). O maior marco desse ciclo foi o surgimento do primeiro unicórnio brasileiro, denominação dada a *startups* que atingem um *valuation* superior a 1 bilhão de dólares. Trata-se da 99 Taxi, aplicativo de mobilidade fundado em 2012 por três engenheiros formados pela Escola Politécnica da USP: Ariel Lambrecht, Paulo Veras e Renato Freitas. A 99 alcançou o status de unicórnio em 2018, quando foi adquirida pela gigante chinesa Didi Chuxing.

Atualmente, o Brasil conta com 25 *startups* unicórnios, com destaque para aquelas do setor financeiro, que estão entre as mais desenvolvidas do país, como Nubank, Creditas, Neon, Stone e Ebanx (ALVES, 2022).

Foi justamente nesse período que o mercado de capital de risco experimentou seu maior crescimento no país. Segundo levantamento da ABVCAP e KPMG, o volume investido por fundos de *venture capital* no Brasil passou de R\$800 milhões em 2016 para impressionantes R\$46 bilhões em 2021 (FINSIDERS BRASIL, 2022). No entanto, após esse crescimento exponencial, o setor enfrentou uma crise recente, marcada pela queda nos *valuations* e na captação de recursos, sobretudo devido a fatores macroeconômicos adversos. Esse período, que foi de meados de 2022 até 2023, ficou conhecido como “inverno das *startups*” (MANZONI JR., 2024).

2.1.3 Tipos de fundos de *venture capital*

Os fundos de *venture capital* podem ser classificados de acordo com alguns critérios: o estágio de maturidade das *startups* em que investem (como pré-seed, seed e séries A/B/C) e o perfil dos investidores por trás do capital (como *venture capital* independente, *corporate venture capital* e fundos governamentais), ou o setor ou modelo de negócio no qual o fundo investe. Essa categorização ajuda a entender os diferentes objetivos e estratégias por trás dos aportes.

2.1.3.1 Fundos de *venture capital* por estágio do investimento

Uma das principais características dos investimentos em *venture capital* é o alto risco. Assim, o VC pode reduzir o risco de forma efetiva por meio de *staging* (LI; MAHONEY, 2011). O *staging*, ou financiamento por etapas, é quando fundos investem em *startups* de forma progressiva em diferentes estágios (DAHIA; RAY, 2011). Esse modelo também oferece ao investidor uma oportunidade de aprender sobre o esforço do empreendedor ou a qualidade da empresa do portfólio. Esse aprendizado não ocorrerá sem que haja investimento (LI; MAHONEY, 2011). Investidores abandonam o empreendimento com retornos iniciais baixos, e assim separam os bons projetos dos ruins (DAHIA; RAY, 2011).

Cada aporte realizado é denominado rodada de investimento (ou rodada), cujas características variam de acordo com o estágio de maturidade da empresa. Empresas

em fases iniciais geralmente possuem pouca ou nenhuma trajetória, o que torna sua avaliação mais desafiadora (GOMPERS, 1995). Por outro lado, rodadas realizadas em estágios mais avançados costumam envolver empresas com validação de mercado e indicadores financeiros mais robustos, o que reduz significativamente o risco percebido pelos investidores (SAHLMAN, 1990). Assim, é natural que rodadas mais avançadas envolvam aportes maiores, com empresas avaliadas a *valuations* mais elevados.

A primeira rodada costuma ser chamada de pré-seed, quando a empresa ainda está em estágio muito inicial e busca validar seu produto mínimo viável, do inglês *Minimum Viable Product* (MVP), o modelo de negócio e conquistar os primeiros clientes. Nessa fase, o capital pode vir de fundos especializados em pré-seed, mas também é comum o uso de recursos próprios do fundador, *crowdfunding*, apoio de amigos e familiares, ou ainda de investidores-anjo. Anjos são investidores individuais, pessoas com alto patrimônio líquido que desempenham um papel semelhante ao dos fundos de *venture capital*, mas utilizam recursos próprios (MALHOTRA, 2023).

Na sequência, ocorre a rodada Seed, que tende a ser o primeiro aporte institucional de fundos de *venture capital* (MALHOTRA, 2023). O objetivo principal nesse estágio é financiar o desenvolvimento do produto e estruturar uma estratégia de entrada no mercado (*go to market*), validando o potencial de escalabilidade do negócio. Na sequência, as próximas rodadas são conhecidas como Series A, B, C, e assim por diante. Seed e Series A são conhecidas como investimentos *early-stage* enquanto rodadas posteriores são consideradas de *growth* ou *late-stage* (CARNIEL; GASTAUD; DALLE, 2019). Nesses estágios, os recursos são utilizados para acelerar o crescimento, aprimorar o produto, expandir mercados e até mesmo adquirir outras empresas. É comum que essas *startups* estejam operando com queima de caixa para sustentar a expansão acelerada.

No Brasil, um exemplo emblemático é o Nubank, que chegou a captar uma rodada Series G em 2021 (CRUNCHBASE, 2025), mas globalmente, empresas como a Databricks já captaram rodadas ainda mais avançadas, como uma Series K. No entanto, a maioria das *startups* não alcança tantas rodadas. Elas costumam interromper o ciclo de captação por diferentes motivos: falência, aquisição, abertura de capital (IPO), adoção de alternativas de financiamento como dívida, ou porque atingiram o equilíbrio financeiro (*breakeven*).

2.1.3.2 Fundos de *venture capital* por perfil dos investidores

Outra forma de categorizar os fundos de *venture capital* é a partir do perfil dos investidores que compõem o capital do fundo (LPs). Sob essa ótica, é possível dividir os fundos em três principais categorias: os fundos de *venture capital* independentes (IVC ou simplesmente VC), os fundos de *corporate venture capital* (CVC) e os fundos com participação governamental (GovVC ou GVC).

O modelo de *venture capital* independente (IVC) é o mais comum, amplamente conhecido e difundido no mercado. Os investidores em fundos de *venture capital* são, em geral, grandes instituições como fundos de pensão, instituições financeiras, seguradoras e *endowments* universitários. Essas entidades costumam alocar uma pequena parcela de seus recursos totais em investimentos de alto risco, como o *venture capital*. Em troca, esperam obter um retorno anual entre 25% e 35% ao longo do ciclo de vida do investimento (ZIDER, 1998).

Os fundos de CVC buscam investir o capital de grandes corporações, em empreendimentos inovadores de base tecnológica. Como ferramenta de inovação, estes fundos têm como objetivo desenvolver um ecossistema de testes paralelo às operações corporativas, ao incentivar novos modelos de negócios, produtos e tecnologias, gerando sinergias estratégicas e financeiras para a corporação controladora (ALVES, 2022). Por essa razão, os investimentos costumam ser direcionados a *startups* que atuam em setores com algum grau de afinidade ou complementaridade com o negócio da “empresa-mãe”.

Nos últimos vinte anos, o Brasil recebeu um total de 212 rodadas envolvendo CVC, totalizando US\$1,3 bilhão em investimentos (VALETEC, 2021). Em escala global, segundo ALVES (2022), os fundos de CVC representaram 28% do volume total investido por fundos de *venture capital* em 2021, e responderam por 14% do número total de rodadas realizadas no ano.

A gestão dos fundos de CVC pode ocorrer de duas maneiras. Em alguns casos, os fundos são administrados internamente pela própria corporação, como acontece com o Itaú Ventures e o L4 Ventures, da B3. Em outros casos, a gestão é realizada por empresas especializadas na administração de fundos corporativos, que podem atuar simultaneamente com diferentes corporações. Exemplos dessa abordagem são a MSW Capital e a Valetec Capital.

Por último, o financiamento por meio de Government Venture Capital (GovVC) refere-se ao uso de recursos públicos para investir em empresas voltadas à inovação (BERGER; DECHEZLEPRÊTRE; FADIC, 2024). Ao contrário do que se poderia imaginar, o principal critério de decisão de investimento, segundo ZIDER (1998), não é a qualidade da ideia ou do time empreendedor, mas sim o potencial da indústria ou mercado em que a empresa está inserida. Assim, essa abordagem tem se consolidado como uma ferramenta de política pública para fomentar ecossistemas de inovação e apoiar empresas que não se enquadram no perfil tradicional buscado pelos fundos de *venture capital* privados (BERGER; DECHEZLEPRÊTRE; FADIC, 2024).

No Brasil, esse tipo de fundo ainda é significativamente menos representativo em comparação aos outros modelos. O principal exemplo é o fundo Criatec, criado em 2007, uma iniciativa inovadora por direcionar o apoio via recursos públicos para o estágio mais incipiente da cadeia de valor do capital de risco (MARTINI; MACHADO; NASCIMENTO, 2024).

2.1.3.3 Fundos de *venture capital* por tese de investimento

Por fim, os fundos de VC também podem ser categorizados com base em sua tese de investimento, ou seja, no tipo de empresa, setor ou modelo de negócio em que escolhem investir. Enquanto alguns fundos se especializam em realizar investimentos dentro de um setor específico, outros adotam uma abordagem mais generalista, diversificando seus investimentos entre diferentes setores. (GOMPERS; KOVNER; LERNER, 2009). Embora a especialização reduza o universo de empresas elegíveis, ela permite decisões de investimento mais informadas e maior capacidade de agregar valor às *startups* do portfólio por meio de conhecimento setorial, rede de contatos e experiência acumulada.


Os principais fundos de *venture capital*, tanto globais, como Sequoia Capital, a16z, Accel e SoftBank, quanto brasileiros, como Astella, Kazek e Monashees, geralmente adotam uma abordagem generalista. Entretanto, existe uma crescente diversidade de fundos dedicados a teses de investimento específicas, focando em nichos como *fintech*, cibersegurança, indústria, entre outros. No contexto brasileiro, destacam-se alguns exemplos: a SP Ventures, especializada em *startups* do agronegócio; a Vox Capital, que investe em negócios de impacto social e ambiental;

e a SaaSholic, que investe exclusivamente em empresas com modelo de negócio Software as a Service (SaaS).

2.1.4 Processo de investimento em *venture capital*

O processo de investimento em fundos de *venture capital* pode variar entre gestoras, mas geralmente é longo, com prazo de vigência usualmente de 10 anos, mas com prorrogações permitidas (SILVA, 2021). Esse processo costuma envolver as seguintes etapas: originação de oportunidades (*deal flow*), avaliação das *startups*, tomada de decisão de investimento, realização da *due diligence* (DD), gestão do portfólio e, por fim, o desinvestimento (*exit*), conforme esquematizado na Figura 2.1.

Figura 2.1 - Processo de Investimento em *venture capital*



Fonte: Autoria própria.

Fundos de VC normalmente tem times enxutos, e precisam distribuir seu tempo entre diversas atividades. Eles precisam identificar e atrair novas oportunidades de investimento, monitorar os investimentos existentes, alocar capital adicional para os negócios mais bem-sucedidos e auxiliar nas opções de saída. Os fundos de VC mais experientes conseguem administrar seu tempo de forma eficiente entre as diferentes funções e investimentos (ZIDER, 1998).

O processo de investimento deve ser enxergado como um funil, onde diversas empresas entram no funil e apenas algumas saem. Para cada investimento realizado, um fundo de *venture capital* pode analisar centenas de possibilidades. Dentre essas centenas, talvez algumas dezenas mereçam uma atenção mais detalhada, e menos ainda serão consideradas dignas de uma proposta preliminar (METRICK; YASUDA, 2010).

Uma das etapas mais estratégicas para fundos de VC é a originação de oportunidades, também conhecida como geração de *deal flow*. Trata-se do processo de identificar *startups* que apresentem alinhamento com a tese de investimento do

fundo. Uma forma comum é a busca ativa, realizada por meio de bases de dados públicas ou plataformas especializadas, que permitem mapear as *startups* de determinados setores ou estágios. Outra fonte importante é o inbound, composto por empreendedores que buscam ativamente investimento e se inscrevem para avaliação junto ao fundo.

Segundo Gompers et al. (2020) a maior parte do *deal flow* vem, de alguma forma, das redes de contato dos próprios fundos de VC. A rede de contatos dos sócios e membros da equipe, bem como a participação em eventos setoriais, comunidades de tecnologia e ambientes de inovação, frequentemente resulta em indicações valiosas e conexões com empreendedores promissores.

Além disso, os fundos também se protegem contra riscos coinvestindo com outras firmas. Tipicamente, há um investidor líder e vários *followers* (ZIDER, 1998). Assim, cada VC pode investir em mais projetos e diversificar amplamente o risco específico da empresa. Envolver outras firmas de *venture capital* também oferece uma segunda (e terceira, e quarta) opinião sobre a oportunidade de investimento, o que limita o risco de que negócios ruins sejam financiados (GOMPERS; LERNER, 2001). Por essa razão, outros fundos acabam se tornando uma fonte relevante e frequente de novas oportunidades.

Após a etapa de originação, segue-se a fase de análise, cuja abordagem pode variar conforme o estágio do investimento, a região geográfica ou a tese do fundo. De maneira geral, a análise inclui fatores como que incluem a atratividade do mercado, a estratégia, a tecnologia, o produto ou serviço, a adoção pelos clientes, a concorrência, os termos do negócio e a qualidade e experiência da equipe de gestão (GOMPERS et al., 2020).

Caso o interesse persista, é feita uma proposta preliminar para a *startup*. Ofertas preliminares são feitas por meio de um *term sheet*, que detalha a avaliação proposta, o instrumento financeiro e os direitos de controle sugeridos para os investidores. Se esse *term sheet* for aceito pela empresa *startup*, o fundo de *venture capital* realiza uma *due diligence* aprofundada, analisando todos os aspectos da companhia. Caso o VC fique satisfeito, todas as partes negociam o conjunto final de termos a serem incluídos no contrato formal que será assinado no fechamento definitivo (METRICK; YASUDA, 2010).

Após o investimento, as empresas passam a compor o portfólio dos fundos, o que demanda uma atuação significativa na área conhecida como gestão de portfólio.

O sucesso dos fundos não depende apenas da escolha acertada dos investimentos, mas também da forma como o investidor pode apoiar diretamente a empresa, o que pode se dar por meio de diversas formas. Uma das principais práticas é a ocupação, por parte dos fundos de *venture capital*, de pelo menos uma cadeira no conselho de administração das empresas investidas. Essa presença no conselho possibilita o fornecimento de aconselhamento e suporte estratégico em níveis decisórios elevados. (GOMPERS; LERNER, 2001).

Além da participação no conselho, os fundos podem auxiliar por meio de conexões estratégicas, acesso a especialistas, potenciais clientes, talentos para a empresa e possíveis investidores. Os fundos costumam dedicar uma quantidade significativa de tempo às empresas do portfólio em estágio intermediário (aquelas que estão performando de forma mediana, nem muito bem, nem muito mal), avaliando se e como o investimento pode ser recuperado e se a continuidade da participação é recomendada (ZIDER, 1998).

A etapa final do processo é o *exit*, que corresponde à saída ou evento de liquidez para os investidores e também para os empreendedores. Geralmente, a forma de saída mais lucrativa é o IPO, do inglês *Initial Public Offering*, momento em que a empresa passa a emitir suas ações no mercado aberto (METRICK; YASUDA, 2010). A saída também pode ocorrer por meio da venda da empresa para outro investidor, ou pela venda da empresa para uma empresa maior. Devido à necessidade de realizar o *exit*, os fundos de *venture capital* evitam investir em empresas que podem gerar uma boa renda para os empreendedores, mas que têm pouca chance de serem vendidas ou abrirem capital (METRICK; YASUDA, 2010).

2.2 FUNDAMENTOS E FERRAMENTAS DE IA GENERATIVA

Nesta seção, apresentam-se os fundamentos e as principais ferramentas de IA generativa aplicáveis ao contexto empresarial em três subseções. Na subseção 2.2.1, discute-se a evolução histórica da IA, abordando definições clássicas, bem como os avanços recentes, incluindo a era da IA generativa. Em seguida, a subseção 2.2.2 aprofunda os fundamentos do funcionamento da IA onde explora-se principais e as diferenças entre os tipos de IA e a IA generativa. Por fim, a subseção 2.2.3 apresenta as principais ferramentas e plataformas de IA para negócios, como IA generativa e

automação inteligente, critérios de seleção e adoção dessas ferramentas, bem como aspectos relacionados a custos, segurança da informação e riscos operacionais.

2.2.1 Evolução e marcos históricos da inteligência artificial

Apesar de o tema de IA ter ganhado grande destaque nos últimos anos, seu conceito e origem não são recentes. Ao longo dos séculos, as evoluções tecnológicas trouxeram máquinas e sistemas autônomos capazes de executar tarefas complexas. No entanto, o marco fundador da IA costuma ser atribuído ao matemático Alan Mathison Turing, que, em 1950, publicou o artigo *Computing Machinery and Intelligence*. Nele, Turing levantou a provocativa questão: “Máquinas podem pensar?” (SOBREIRA, 2025). Reconhecido como o “pai da computação”, Turing também foi um dos principais responsáveis por decifrar os códigos nazistas da máquina Enigma durante a Segunda Guerra Mundial.

Poucos anos após sua morte, em 1956, o pesquisador John McCarthy cunhou o termo “Inteligência Artificial” na conferência de Dartmouth College, definindo-a como “fazer a máquina comportar-se de tal forma que seja chamada inteligente caso fosse este o comportamento de um ser humano” (MORAIS; CASTELO BRANCO, 2023). A partir do artigo de Turing e desse encontro histórico, a IA consolidou-se como área de pesquisa e começou a evoluir em diferentes direções (SOBREIRA, 2025). Dessa forma, na sua definição mais estrita, IA significa a imitação, por computadores, da inteligência inerente aos seres humanos (SHEIKH; PRINS; SCHRIJVERS, 2023).

Entre as décadas de 1970 e 1980, surgiram as primeiras aplicações comerciais de IA. Tais sistemas eram desenvolvidos sob demanda para automatizar e acelerar atividades empresariais (SOBREIRA, 2025). Nessa época, predominava a chamada IA simbólica, baseada na manipulação de símbolos, números ou palavras para simular o raciocínio lógico humano (MORAIS; CASTELO BRANCO, 2023). Esse modelo exigia uma vasta quantidade de regras construídas em colaboração com especialistas e se mostrou funcional apenas em contextos muito específicos, além de demandar constante supervisão técnica (SOBREIRA, 2025). Por isso, os resultados dessa onda foram decepcionantes, já que as ambições dos principais projetos nesse período nunca foram alcançadas.

No entanto, como um marco desse período foi o duelo histórico entre o supercomputador Deep Blue, da IBM, e o campeão mundial de xadrez Garry

Kasparov. Em 1996, Kasparov venceu a primeira disputa, mas, em 11 de maio de 1997, o enxadrista foi derrotado em uma série de seis partidas em Nova York um evento que simbolizou a superioridade das máquinas nesse domínio (VEJA, 2017).

Paralelamente ao avanço da IA simbólica, surgiu a chamada IA conexionista, inspirada no funcionamento dos neurônios humanos (SOBREIRA, 2025). Essa abordagem deu origem às redes neurais artificiais, das quais o *deep learning* é um dos principais exemplos, possibilitando que máquinas aprendam de forma mais autônoma e profunda (MORAIS; CASTELO BRANCO, 2023).

No século XXI, o crescimento do poder computacional e a disponibilidade de grandes volumes de dados impulsionaram enormemente o potencial da IA conexionista. Tecnologias de reconhecimento de imagens, processamento de linguagem natural e comunicação avançaram rapidamente (SOBREIRA, 2025), culminando no surgimento de sistemas capazes de interagir com humanos por meio da linguagem natural.

Nesse cenário, diversas organizações passaram a investir em pesquisa e desenvolvimento de IA. Entre elas, destacou-se a OpenAI, fundada em 2015 como organização sem fins lucrativos, cujo propósito é promover o avanço da inteligência artificial de forma segura e acessível (MONTEVIRGEN, 2025). A empresa ganhou notoriedade mundial com o lançamento do ChatGPT, um modelo de linguagem capaz de compreender e gerar textos semelhantes aos produzidos por humanos (MONTEVIRGEN, 2025). A versão ChatGPT 3.5, lançada em 2022, democratizou o uso da IA generativa, tornando-a acessível a qualquer pessoa com conexão à internet (SOBREIRA, 2025).

Esse marco inaugurou a era da IA generativa, que rapidamente evoluiu com novos modelos como Grok (xAI), Gemini (Google) e Claude (Anthropic). A própria OpenAI aprimorou sua tecnologia, lançando versões mais eficientes e precisas, culminando no ChatGPT 5, em agosto de 2025. Apenas essa ferramenta registrou 800 milhões de usuários semanais em abril de 2025, evidenciando a velocidade da adoção global dessa tecnologia (SINGH, 2025).

O futuro da IA, contudo, permanece incerto. A meta declarada da OpenAI é o desenvolvimento da Inteligência Artificial Geral, do inglês, *Artificial General Intelligence* (AGI), uma forma avançada de IA capaz de aprender e atuar em múltiplos domínios de maneira semelhante ou até superior à inteligência humana (MONTEVIRGEN, 2025). Ainda que esse objetivo seja compartilhado por outras

empresas, há um consenso de que a AGI ainda não foi alcançada. O grande debate atual gira em torno do prazo: alguns especialistas acreditam que poderá surgir em poucos anos, outros preveem décadas, e há quem sustente que talvez nunca seja atingida.

2.2.2 Fundamentos do funcionamento da inteligência artificial

Para aplicar a inteligência artificial de forma eficiente em uma organização, é fundamental compreender seu funcionamento, tanto para explorar seu potencial quanto para conhecer suas limitações. Nesta seção, o foco principal será na IA generativa, objeto de estudo desta pesquisa, mas também será abordado o funcionamento da IA simbólica e o aprendizado de máquina (*machine learning*).

Como discutido anteriormente, a IA simbólica baseia-se em regras lógicas pré-definidas. Dessa forma, os computadores aprendem codificando essas regras em fórmulas do tipo “SE X, ENTÃO Y” (SHEIKH; PRINS; SCHRIJVERS, 2023). Essa abordagem é transparente, permitindo que desenvolvedores e usuários compreendam exatamente como o sistema chega às suas conclusões (BELLO, 2024). Apesar de eficaz e confiável em situações mais simples, a IA simbólica apresenta limitações em contextos complexos. Além disso, pequenos erros nas regras podem gerar consequências desastrosas, e o sistema pode falhar quando duas regras se contradizem (SHEIKH; PRINS; SCHRIJVERS, 2023).

Por outro lado, o *machine learning*, ou aprendizado de máquina, representa uma mudança significativa na forma como computadores resolvem problemas. Em vez de seguir instruções rígidas, esses sistemas aprendem a partir de dados, identificando padrões e tomando decisões de forma autônoma (BELLO, 2024). Uma técnica muito difundida de *machine learning* são as redes neurais artificiais (*artificial neural networks*) que simulam o funcionamento dos neurônios no cérebro humano. Para isso, conjuntos de neurônios artificiais são organizados em redes capazes de receber e enviar informações (SHEIKH; PRINS; SCHRIJVERS, 2023). Essas redes são compostas por camadas de nós, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (IBM, 2025). Cada nó, ou neurônio artificial, conecta-se a outros e possui um peso e um limiar associados. Quando a saída de um nó individual excede o limiar definido, ele é ativado, enviando dados para a próxima camada da rede (IBM, 2025).

O *machine learning* pode ser subdividido em três formas diferentes: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (SHEIKH; PRINS; SCHRIJVERS, 2023). No aprendizado supervisionado, um programa recebe dados com rótulos, e é treinado com esses dados de entrada e depois testado para verificar se consegue aplicar corretamente os rótulos a novos dados (SHEIKH; PRINS; SCHRIJVERS, 2023). O aprendizado por reforço é um modelo semelhante ao aprendizado supervisionado, mas onde o modelo aprende à medida que progride, utilizando tentativa e erro (IBM, 2025). Por último, no aprendizado não supervisionado, não há etapa de treinamento, de modo que o algoritmo precisa buscar padrões nos dados por conta própria. Ele recebe grandes quantidades de dados não rotulados, nos quais começa a reconhecer padrões de forma autônoma (SHEIKH; PRINS; SCHRIJVERS, 2023).

Dentro do campo do *machine learning*, uma subárea de destaque é o *deep learning*, cuja difusão tem crescido de forma acelerada nos últimos anos. Já em 2017, modelos baseados nessa técnica alcançavam margens de erro inferiores a 5%, resultados comparáveis ao desempenho humano, e essa evolução segue em curso até hoje (SHEIKH; PRINS; SCHRIJVERS, 2023). Diferentemente do *machine learning* tradicional, o *deep learning* é capaz de processar dados não estruturados em sua forma bruta, como textos e imagens, identificando automaticamente os conjuntos de características que distinguem diferentes categorias de dados (IBM, 2025).

Essa capacidade reduz a necessidade de intervenção humana e viabiliza o aproveitamento de grandes volumes de informação (IBM, 2025). Segundo Lex Fridman, pesquisador do MIT, o *deep learning* pode ser entendido como uma forma de “*machine learning* escalável” (IBM, 2025). Há, entretanto, um problema crucial: o sistema não é capaz de mostrar o caminho trilhado para se chegar àquele resultado (SOBREIRA, 2025) dado que se baseia em redes neurais artificiais profundas.

Impulsionado pelos avanços em *deep learning*, houve um desenvolvimento significativo no Processamento de Linguagem Natural (PLN), uma aplicação da IA que automatiza a leitura, análise e geração da linguagem humana (SHEIKH; PRINS; SCHRIJVERS, 2023). A base desses avanços é o Transformer, introduzido em 2017 no artigo *Attention Is All You Need*, uma arquitetura de modelo que dispensa recorrência e depende inteiramente de um mecanismo de atenção para capturar dependências globais entre entrada e saída (VASWANI et al., 2017).

Dessa forma, os mecanismos de atenção tornaram-se elementos essenciais em modelos avançados de sequenciamento, permitindo a modelagem de dependências independentemente da distância entre elementos nas sequências de entrada ou saída (VASWANI et al., 2017). Os Transformers são amplamente reconhecidos como a força motriz por trás de avanços recentes em IA, incluindo os chamados *foundation models*, como o ChatGPT, desenvolvido pela OpenAI (SCHNEIDER, 2025).

Todos esses avanços permitiram uma escalabilidade em processamento de linguagem natural, o que possibilitou o surgimento de *large language models* (LLM), que são a base de funcionamento da IA Generativa. LLMs são modelos de *deep learning* que identificam e codificam padrões e relações em enormes volumes de dados textuais, utilizando esse conhecimento para compreender solicitações de usuários e gerar novo conteúdo de forma coerente e contextualizada (IBM, 2025).

Um dos tipos mais comuns de LLMs é o GPT (*Generative Pre-trained Transformer*), em português Transformador Generativo Pré-treinado, amplamente utilizado para a geração de textos em linguagem natural. Na prática, funciona como um modelo estatístico a partir de uma enorme base de dados que procura prever qual é a próxima palavra do texto, com o intuito de torná-lo inteligível (SOBREIRA, 2025). É justamente dessa arquitetura que deriva o nome ChatGPT.

Por último, um último conceito teórico que deve ser mencionado são os agentes de IA. Um agente de IA refere-se a um sistema capaz de executar tarefas de forma autônoma em nome de um usuário ou de outro sistema, projetando seu próprio fluxo de trabalho e utilizando as ferramentas disponíveis (KRISHNAN, 2025). Apesar do conceito e nomenclatura existir desde os anos 1990, o avanço causado pelas LLMs permitiu um avanço muito grande nesse campo. Hoje, agentes de IA conseguem compreender instruções complexas, raciocinar a partir de diversas fontes de informação e executar planos sofisticados em múltiplas etapas (KRISHNAN, 2025).

Os agentes de IA podem ser classificados em diferentes tipos, segundo sua complexidade e autonomia. Os reflexos simples atuam com base em regras condicionais são adequados para tarefas simples em ambientes estáveis, enquanto os baseados em modelo incorporam uma representação interna do mundo, permitindo decisões mais elaboradas. Já os agentes baseados em objetivos direcionam suas ações para metas específicas, e os baseados em utilidade avaliam alternativas em busca da decisão mais vantajosa. Complementarmente, os agentes de aprendizado

aperfeiçoam continuamente seu desempenho a partir da experiência, e os hierárquicos organizam tarefas em diferentes níveis, coordenando ações entre agentes especializados para lidar com problemas complexos (KRISHNAN, 2025).

Por fim, é fundamental destacar as principais limitações dos modelos de IA generativa. A mais relevante refere-se à própria arquitetura e ao funcionamento dos LLMs. Ou seja, embora sejam projetados para produzir sentenças gramaticalmente consistentes, isso não garante que o conteúdo gerado seja verdadeiro. Quando tais sistemas produzem informações incorretas ou inventadas, esse fenômeno é denominado “alucinação” (SOBREIRA, 2025). Esses problemas de confiabilidade exigem uma supervisão humana cuidadosa e limitam a autonomia que pode ser concedida com segurança aos sistemas de agentes (KRISHNAN, 2025).

Como mencionado anteriormente, algoritmos complexos de *machine learning* frequentemente não revelam o caminho seguido para chegar a uma resposta, o que limita a transparência e a explicabilidade do modelo. Modelos de linguagem de grande porte (LLMs) muitas vezes funcionam como “caixas-pretas”, cujas operações internas e processos de tomada de decisão resistem a explicações diretas. Essa opacidade pode comprometer a autonomia do usuário e dificultar a identificação e a correção de erros (KRISHNAN, 2025).

Além disso, modelos treinados com dados que contêm vieses históricos podem perpetuar ou até mesmo intensificar padrões discriminatórios em suas recomendações, decisões ou interações (KRISHNAN, 2025). Há também a constatação de que textos produzidos por GPT podem ser xenófobos e racistas, resultado das bases textuais utilizadas em seu treinamento (SOBREIRA, 2025). Tais comportamentos podem impactar significativamente processos que utilizam IA, como recrutamento, reconhecimento facial e algoritmos em plataformas de mídia social (IBM, 2025).

Por fim, a privacidade constitui uma questão relevante. Os sistemas de agentes coletam e processam grandes volumes de dados para operar de maneira eficaz, incluindo informações pessoais sensíveis, registros de comunicação e padrões de comportamento. Esses dados podem ser usados de forma inadequada ou sofrer acesso não autorizado, representando riscos especialmente elevados para agentes que atuam de forma contínua em contextos pessoais ou profissionais (KRISHNAN, 2025).

2.2.3 Ferramentas e plataformas de IA no contexto empresarial

Nesta subseção, apresenta-se uma breve contextualização de ferramentas e plataformas de IA que podem ser utilizadas no contexto empresarial, abordando tanto os modelos e ferramentas de IA generativas, plataformas de automação inteligente e outras ferramentas mais específicas, que usam IA para automatizar e otimizar tarefas específicas.

Destacam-se, nesse cenário, os modelos pré-treinados de grande escala, conhecidos como modelos fundacionais (*foundation models*) ou modelos de IA de propósito geral, que são treinados com vastos conjuntos de dados e podem ser aplicados a uma ampla variedade de tarefas (BURKHARDT; REIDER, 2024). Esses modelos servem de base para sistemas como o ChatGPT, da OpenAI, voltado à geração de texto, e para geradores de imagens, como o Midjourney (BURKHARDT; REIDER, 2024).

Essas ferramentas podem ser utilizadas gratuitamente por qualquer pessoa, embora também ofereçam planos pagos que dão acesso a modelos mais avançados e com funcionalidades adicionais. Seu funcionamento baseia-se, em grande parte, no uso de *prompts*, que consistem em instruções descritivas utilizadas para orientar os sistemas na execução de tarefas específicas (BURKHARDT; REIDER, 2024). Esse modelo apresenta bons resultados em atividades como resumir textos, realizar pesquisas e executar outras operações. No entanto, no contexto deste trabalho, cujo foco é a aplicações de IA generativas nos processos operacionais e o apoio à tomada de decisão empresarial, um modelo de prateleira, geralmente falha em cumprir os requisitos de organizações, cujas necessidades estão intrinsecamente ligadas ao seu contexto operacional único (CUI et al., 2024). Por esse motivo, é fundamental que os modelos incorporem conhecimento ou contexto relacionado à organização em que serão aplicados.

Assim, tornou-se tendência que grandes empresas explorem as tecnologias de *foundation models* para incorporar inteligência artificial em seus processos internos. Um exemplo emblemático é o Morgan Stanley, banco norte-americano que, em parceria com a OpenAI, vem desenvolvendo aplicações próprias, como o AI @ Morgan Stanley Debrief, capaz de resumir reuniões realizadas por vídeo e gerar automaticamente e-mails de acompanhamento integrados a ferramentas como Outlook, Zoom e Salesforce (BOUSQUETTE, 2024). A grande vantagem desses

produtos é que podem ser desenhados sob medida para se encaixar nos fluxos de trabalho da organização e aproveitar seus dados proprietários, garantindo maior precisão e segurança (BOUSQUETTE, 2024). A abordagem do Morgan Stanley de trabalhar diretamente com desenvolvedores de modelos, em vez de simplesmente adotar tecnologias prontas, está se tornando cada vez mais comum em todo o setor de serviços financeiros (BOUSQUETTE, 2024).

Dessa forma, as desenvolvedoras dos grandes modelos permitem que usuários personalizem seus modelos, adicionando dados. Esse processo pode ocorrer por meio de instruções customizadas, integração com bases proprietárias ou até pelo re-treinamento parcial (*fine-tuning*). Nesse contexto, a OpenAI lançou os chamados GPTs Personalizados, que permitem a qualquer usuário criar uma versão adaptada do ChatGPT, tornando-o mais eficiente para tarefas específicas e possibilitando seu compartilhamento com outras pessoas (OPENAI, 2023). Esses produtos podem ser configurados sem necessidade de programação, sendo alimentados tanto por bases de conhecimento enviadas via *upload* de documentos quanto por meio de Interface de Programação de Aplicações (API), o que amplia a relevância e a precisão das respostas geradas (OPENAI, 2023).

Outras empresas também oferecem alternativas nesse campo. A Anthropic, por exemplo, lançou o Claude Projects, recurso que possibilita aos usuários organizar suas interações em Projetos, reunindo conjuntos de conhecimento e atividades de chat em um único espaço (ANTHROPIC, 2024). Cada projeto pode receber até 20 arquivos, fornecendo maior contexto ao modelo (ANTHROPIC, 2024). Já a Google, com o modelo Gemini, disponibiliza a criação de Gems, que funcionam como instruções detalhadas para atividades recorrentes, além de permitir o envio de arquivos (GOOGLE GEMINI, 2025). Paralelamente, a empresa oferece soluções mais avançadas voltadas a desenvolvedores, como o Vertex AI, que integra ferramentas externas, APIs e um construtor de agentes. Esse recurso proporciona capacidades robustas de orquestração e personalização, permitindo que desenvolvedores criem uma variedade de agentes e aplicações de IA generativa fundamentados nos dados de suas organizações (GOOGLE CLOUD, 2025).

Por outro lado, modelos como o LLaMA, desenvolvido pela Meta, e o DeepSeek seguem uma abordagem distinta em relação à personalização. A principal diferença é que esses modelos são disponibilizados em código aberto (*open source*). Um *software* de código aberto é aquele cujo código-fonte está livremente acessível para inspeção,

modificação e distribuição (PARTHASARATHY, 2024). No caso desses modelos, isso significa que desenvolvedores podem baixar, copiar e utilizar gratuitamente, inclusive realizando *fine-tuning* e outras formas de customização (PARTHASARATHY, 2024).

Com o lançamento contínuo de novos modelos, multiplicam-se também os estudos e análises comparativas de desempenho. Essas avaliações geralmente consideram múltiplas dimensões, como raciocínio lógico e matemático, compreensão e geração de linguagem natural, capacidade de codificação, além de aspectos de eficiência computacional e segurança. É importante destacar que esses resultados são altamente dinâmicos, uma vez que cada nova versão de modelo tende a alterar o estado da arte. A seguir, apresenta-se uma tabela comparativa com os modelos mais recentes das cinco LLMs mencionadas anteriormente: ChatGPT, Claude, Gemini, LLaMA e DeepSeek.

Tabela 2.1 – Comparação entre as principais LLMs

Modelo	Inteligência (1-100)	Preço (\$/1M de Tokens)	Tokens por segundo
ChatGPT 5.1	70	3,4	151
Claude Sonnet 4.5	63	6	72
Gemini 3 Pro	73	4,5	46*
Llama 4 Maverick	36	0,4	132
DeepSeek V3.2	57	0,3	30

Nota: *considerando o modelo Gemini 2.5 Pro.
Fonte: Artificial Analysis (2025).

Na Tabela 2.1, compara-se as principais LLMs em três dimensões centrais: inteligência, custo e velocidade. A dimensão de inteligência agrega dez *benchmarks* distintos, incluindo avaliações de raciocínio, capacidade de escrita de código e outras tarefas (ARTIFICIAL ANALYSIS, 2025). O custo é medido em dólares por milhão de tokens, enquanto a velocidade corresponde ao número de *tokens* gerados por segundo. No contexto de modelos de IA generativa, *tokens* são as unidades fundamentais de processamento: podem corresponder a um único caractere ou a uma palavra inteira, dependendo do idioma e do contexto (OPENAI HELP CENTER, 2025). A partir dos dados apresentados, observa-se que os modelos da OpenAI e do Google apresentam o melhor desempenho, enquanto Llama e DeepSeek oferecem preços substancialmente mais baixos, porém com níveis de performance inferiores.

A evolução dos modelos de inteligência artificial possibilitou o surgimento de ferramentas especializadas, que aproveitam a infraestrutura e a escala dos grandes modelos, mas são treinadas para atender demandas específicas, executando ações e aprofundando o conhecimento em determinados domínios. À medida que os modelos de IA avançam, sua principal promessa reside justamente na especialização por área de atuação. Setores que dependem de precisão, conformidade regulatória e dados em tempo real já começam a experimentar o impacto transformador dessa abordagem (SHUKLA, 2025).

Paralelamente, observa-se uma transição dos modelos para o papel de executores. Os agentes de IA funcionam em um ciclo cognitivo, percebendo entradas, elaborando planos e executando ações, o que lhes confere autonomia em fluxos de trabalho especializados (SHUKLA, 2025). Essa estrutura em camadas amplia a função da IA: de uma ferramenta de perguntas e respostas para um especialista autônomo em determinado domínio, capaz de realizar tarefas complexas em áreas como direito, medicina, finanças e educação, sem a necessidade de supervisão constante (SHUKLA, 2025).

Nesse cenário, multiplicam-se as ferramentas voltadas ao uso empresarial, que não desenvolvem modelos proprietários, mas sim organizam conhecimentos e estruturam fluxos adaptados às necessidades de setores específicos. Entre elas, alguns exemplos são: o Cursor (CURSOR, 2025), que auxilia na escrita de código; o Lovable, que automatiza a criação de aplicativos e sites; a Enter (ENTER, 2025), que agiliza tarefas do trabalho jurídico; o Clay (CLAY, 2025), que otimiza rotinas de equipes de vendas; a Abridge (ABRIDGE, 2025), que facilita o registro de conversas clínicas; e a Fireflies (FIREFLIES, 2025), que anota e resume reuniões virtuais. Além disso, há a Perplexity (PERPLEXITY, 2025), que opera como outras LLMs, mas se diferencia por acessar a internet em tempo real.

No cenário de *venture capital*, diversas ferramentas utilizam LLMs para automatizar análises e otimizar decisões. O CB Insights fornece dados sobre empresas privadas e tendências de mercado, permitindo prever desempenho e realizar due diligence de forma mais eficiente (CB INSIGHTS, 2025). A Alkymi processa documentos financeiros não estruturados, transformando-os em dados padronizados para acelerar a análise de investimentos (ALKYMI, 2025). No Brasil, a VeeCee automatiza a avaliação de pitch decks de *startups*, destacando apenas as mais promissoras para análise humana (VEECE, 2025).

Por último, em termos de ferramentas de IA, vale destacar as soluções dedicadas à automação e orquestração inteligente, como n8n e Zapier. Essas plataformas permitem conectar diferentes aplicações e sistemas sem intervenção manual e sem necessidade de programação (XCLOUD, 2025). No contexto da IA, elas possibilitam integrar o uso de LLMs a outras ferramentas ou bases de dados, permitindo automatizar fluxos completos. Por exemplo, um e-mail recebido pode ser enviado a uma LLM para redigir uma resposta, que em seguida é registrada automaticamente no sistema de CRM.

A principal diferença entre essas duas ferramentas é que o n8n é uma ferramenta open-source, focada em flexibilidade para usuários técnicos, e ideal para automações complexas e de grande volume. Já o Zapier prioriza a simplicidade e rapidez, sendo perfeito para usuários sem conhecimento técnico que precisam de automações mais diretas (XCLOUD, 2025).

2.2.4 Obtenção de sucesso com o uso de IA no contexto empresarial

Com a popularização da inteligência artificial generativa, empresas de diversos setores vêm buscando incorporar essa tecnologia em seus processos. Segundo estudo da McKinsey (2025), muitas organizações estão redesenhando fluxos de trabalho à medida que implantam a IA generativa e atribuindo a líderes seniores papéis críticos, como a supervisão da governança de IA. O estudo também aponta que as companhias têm atuado para mitigar um conjunto crescente de riscos relacionados à tecnologia, ao mesmo tempo em que criam novos cargos voltados à área e promovem a requalificação de colaboradores para participar de sua implementação (MCKINSEY, 2025).

Além disso, mais de 75% dos entrevistados afirmam que suas organizações já utilizam IA em pelo menos uma função de negócios. No entanto, companhias com receita anual acima de 500 milhões de dólares estão avançando de forma mais acelerada do que empresas menores. Apesar disso, mais de 80% dos respondentes relatam que suas organizações ainda não observam impacto tangível nos resultados financeiros em nível corporativo. Entre aquelas que já utilizam IA generativa, 21% afirmam ter redesenhado de forma fundamental ao menos alguns fluxos de trabalho, uma prática que se destaca como um dos fatores mais relevantes para gerar impacto financeiro positivo (MCKINSEY, 2025).

Segundo a consultoria BCG (2024), as empresas que mais se destacam no uso da IA compartilham três características centrais: demonstram maior ambição, estabelecendo metas ousadas e destinando investimentos significativos ao desenvolvimento de capacidades digitais e de IA; adotam um foco estratégico, priorizando poucos casos de uso de alto impacto e concentrando neles recursos para maximizar o retorno; e direcionam esforços para transformar o *core business*, aplicando a IA não apenas em funções de suporte, mas também em áreas essenciais, onde residem as maiores oportunidades de vantagem competitiva (BCG, 2024).

Sendo assim, pode-se concluir que a inteligência artificial generativa é uma ferramenta com grande potencial para apoiar empresas, mas que, na maioria dos casos, ainda demanda altos investimentos, cujos retornos permanecem pouco evidentes. Diante desse cenário, o presente trabalho tem como objetivo explorar as aplicações de IA generativa nos processos operacionais de um fundo de *venture capital*, buscando identificar potencialidades concretas. Para apoiar essa jornada, destacam-se os *frameworks* desenvolvidos por instituições acadêmicas renomadas e consultorias, que orientam as organizações a diagnosticar seu estágio atual e a estruturar a adoção da IA de forma a gerar valor estratégico relevante.

O primeiro *framework* foi desenvolvido pelo Centro de Pesquisa em Sistemas de Informação do MIT e tem como objetivo categorizar as organizações segundo sua maturidade em inteligência artificial. Os pesquisadores defendem que, em vez de focar em casos extremos, as empresas devem identificar qual dos quatro estágios representa a maior parte de suas atividades em IA. Dessa forma, é possível que as organizações desenvolvam capacidades e aprendizados cumulativos em IA avançando gradualmente rumo a um estado de uso da tecnologia preparado para o futuro (BURNHAM, 2025), conforme Figura 2.2.

Como ilustrado na Figura 2.2, Burnham (2025) propõe quatro estágios de maturidade em Inteligência Artificial: (i) experimentar e preparar, (ii) construir pilotos e capacidades, (iii) desenvolver novas formas de trabalhar com IA e (iv) tornar-se preparada para o futuro impulsionado pela IA. Observa-se, ainda, que a grande maioria das empresas se encontra nos três primeiros estágios, indicando que o ecossistema corporativo ainda está em processo de consolidação dessas capacidades.

Figura 2.2 – Estágios de maturidade em IA de Burnham (MIT)

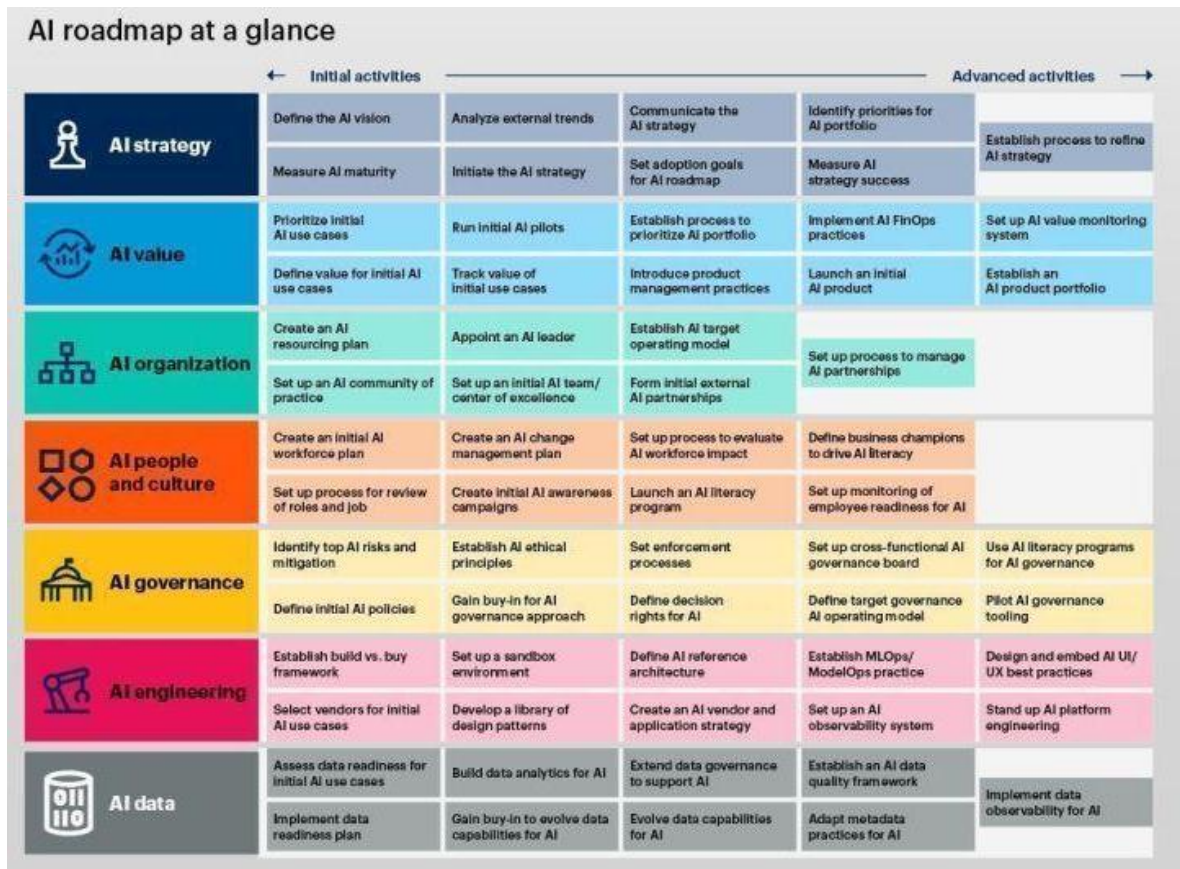
Four Stages of Enterprise AI Maturity				
AI STAGE	Experiment and prepare	Build pilots and capabilities	Develop AI ways of working	Become AI future-ready
PERCENTAGE OF FIRMS	28%	34%	31%	7%
ATTRIBUTES	<ul style="list-style-type: none"> • Educating the workforce on AI • Setting up acceptable-use policies • Working on making data accessible • Ensuring that decision-making uses data • Identifying where humans need to be in the loop 	<ul style="list-style-type: none"> • Beginning to simplify and automate processes • Creating use cases • Sharing data via APIs • Leveraging a coach-and-communicate management style • Using LLMs – both out-of-the-box traditional and generative AI models – to augment work 	<ul style="list-style-type: none"> • Expanding process automation efforts • Changing to a more test-and-learn way of working • Architecting for reuse • Incorporating pretrained models into work and investigating the use of proprietary AI models • Exploring autonomous agents 	<ul style="list-style-type: none"> • Embedding AI into decision-making and processes • Creating and selling AI-augmented business services • Combining traditional, generative, agentic, and robotic AI
FOCUS	Exploration and education	Business cases and pilots	Scaling AI platforms and dashboards	Continuous innovation and new revenue streams

Fonte: Burnham (2025).

Outra referência útil para avaliar a maturidade em IA é o modelo desenvolvido pela Gartner, uma das principais consultorias globais em tecnologia. Esse modelo organiza a maturidade em IA a partir de sete dimensões empresariais: Estratégia, Geração de Valor, Organização, Pessoas e Cultura, Governança, Engenharia e Dados. Para cada uma dessas dimensões, a Gartner propõe um *roadmap* de evolução, composto por atividades que vão desde ações iniciais até práticas mais avançadas (GARTNER, 2025). Dessa forma, a empresa pode identificar em que estágio se encontra em cada dimensão e, a partir disso, estabelecer prioridades e orientar os próximos passos para avançar em sua jornada de adoção de IA, conforme Figura 2.3.

Como pode-se observar pela Figura 2.3, a Gartner organiza as sete dimensões mencionadas anteriormente e, para cada uma delas, estabelece um conjunto de atividades. As atividades posicionadas mais à esquerda representam iniciativas iniciais no processo de maturidade em IA, enquanto aquelas à direita indicam estágios mais avançados.

Figura 2.3 – Estágios de maturidade em IA da Gartner



Fonte: Gartner (2025).

2.3 INTELIGÊNCIA ARTIFICIAL APLICADA AO VENTURE CAPITAL

Como etapa final da fundamentação teórica, realiza-se uma revisão da literatura existente sobre o tema do trabalho, com o objetivo de identificar e analisar os principais avanços já produzidos pela pesquisa acadêmica e por outros especialistas. Essa revisão concentra-se no uso da inteligência artificial no setor de *venture capital*, de modo a apontar as contribuições mais relevantes e destacar as lacunas que ainda se apresentam.

A pesquisa em repositórios acadêmicos, como Scopus, Google Scholar e SSRN evidencia a existência de um volume considerável de estudos que abordam a relação entre inteligência artificial generativa e o setor de *venture capital*. No entanto, observa-se que grande parte dessas publicações se concentra no investimento de fundos de *venture capital* em *startups* de inteligência artificial, com foco na análise do crescimento do volume de aportes nesse tipo de empresa e na interpretação de dados sobre tais investimentos. Exemplos de trabalhos com essa abordagem incluem

Cogliati (2025) e Siddik (2024). Embora essa discussão seja relevante, ela não se alinha ao escopo deste trabalho.

No entanto, também há literatura acadêmica dedicada à aplicação de inteligência artificial na rotina de fundos de *venture capital*, sobretudo como ferramenta de apoio à tomada de decisão. Ainda na década de 2010, surgiram estudos que exploraram o uso de IA nesse contexto, com foco em algoritmos e técnicas de *machine learning*. Bhat e Zelit (2011) utilizaram *random forests* para prever *exits* de empresas privadas e identificar os fatores mais relevantes em decisões de investimento *late-stage*. Dixon e Chong (2014), propuseram uma abordagem Bayesiana combinada a algoritmos de aprendizado supervisionado para ranquear empresas de acordo com sua probabilidade de sucesso.

No entanto, recentemente, foram publicados mais artigos sobre o tema, desta vez com foco nos avanços recentes da IA Generativa. Um estudo de Reale (2025) analisa possíveis oportunidades de aplicação de IA em *venture capital*, destacando as etapas em que a tecnologia pode ser utilizada: priorização automatizada de *deal flow*, CRM inteligente, automação da DD, monitoramento em tempo real do portfólio, gestão de risco e detecção de anomalias, previsão de *exits* e estimativa de retornos, e *benchmarking* automatizado entre *startups* similares. Além disso, o estudo apresenta de forma superficial alguns casos práticos, mostrando como fundos já incorporam IA em suas rotinas. Um exemplo notável é o da EQT Ventures, fundo europeu de VC, que criou sua própria plataforma de IA, chamada "Motherbrain", capaz de monitorar e avaliar continuamente milhares de *startups* globalmente (REALE, 2025).

Um outro estudo publicado recentemente estuda como LLMs podem ser utilizadas para ajudar gestores de fundos de VC em acelerar as etapas iniciais de análise de alto volume de *deal flow* (VISMARA, 2025). A pesquisa utilizou um agente baseado em LLM em um banco de dados contendo 61.814 *startups* em estágio inicial, com o objetivo de avaliar a eficiência e a qualidade da categorização no processo de triagem (VISMARA, 2025). Os resultados indicam que agentes baseados em LLM superam analistas humanos, operando 537 vezes mais rápido do que um analista de VC, e com desempenho comparável ao de um humano (VISMARA, 2025).

No estudo de Rossi (2023), foi realizada uma pesquisa com 25 especialistas, sendo 9 especialistas em IA e 16 investidores de VC. Os dados foram analisados por meio de um *software* que identificou temas e padrões relevantes. Os resultados indicaram que a IA pode aprimorar a tomada de decisão em *venture capital*, tornando-

a mais rápida, eficiente e objetiva, ao reduzir vieses humanos e possibilitar a análise de grandes volumes de dados. Apesar desses benefícios, o estudo também apontou desafios importantes, como a falta de transparência dos sistemas de IA, possíveis vieses nos dados de treinamento e a resistência de tomadores de decisão humanos à adoção dessa tecnologia (ROSSI, 2023).

No entanto, ainda são escassos os estudos de caso dentro de organizações que analisam aplicações concretas de IA e seu impacto nos processos de tomada de decisão. Um exemplo relevante foi publicado por Klerk (2025). O estudo de caso investigou a avaliação de *pitch decks* de *startups* em estágio inicial com o suporte de IA, realizado na InnovationQuarter, uma aceleradora na Holanda, utilizando a plataforma Deckmatch, capaz de extrair informações relevantes dos *pitch decks*.

Os resultados indicaram que os modelos híbridos (combinação de julgamento humano e IA) podem melhorar tanto a eficácia quanto a eficiência das avaliações, dependendo do tipo de modelo utilizado. Modelos de busca sequencial e interativa aumentaram a eficácia da análise, ainda que com uma leve redução na eficiência de tempo, enquanto o modelo autônomo melhorou a eficiência de tempo, mas com menor eficácia. Além disso, a pesquisa destacou a importância da confiança e da transparência nos resultados gerados pela IA, fatores determinantes para a percepção de utilidade pelos avaliadores. No geral, os participantes apresentaram uma percepção positiva da utilidade dos modelos híbridos, reforçando seu potencial como ferramenta de apoio à tomada de decisão em venture capital (KLERK, 2025).

No contexto brasileiro, a produção acadêmica sobre o tema ainda é bastante limitada, e não foram encontrados estudos que pudessem ser aplicados diretamente ao *venture capital*. Entretanto, ao ampliar a análise para áreas correlatas do mercado financeiro, já existem pesquisas que exploram a aplicação de inteligência artificial em processos decisórios. Um estudo de MANGABEIRA (2025), feito a partir da comparação entre recomendações geradas por IA e aquelas fornecidas por especialistas e investidores experientes, concluiu que em boa parte das situações, a IA apresenta estratégias coerentes. Contudo, ficou evidente que ainda há limitações na aplicação prática dessas tecnologias, tal como à interpretação de variáveis subjetivas humanas (MANGABEIRA, 2025).

Por fim, fora do âmbito estritamente acadêmico, o tema também vem sendo discutido por profissionais do mercado de *venture capital*, incluindo investidores de fundos de destaque no Brasil e no mundo. Um exemplo é Martín Escobari, cofundador

do Submarino, importante varejista brasileiro, e atualmente co-presidente e membro do comitê da General Atlantic, um dos maiores fundos globais de VC. Escobari é um entusiasta do uso de IA no setor e destaca que a tecnologia já vem sendo aplicada de forma ampla nas operações internas do fundo, em diversas etapas do processo de análise (MARKET MAKERS, 2025).

Segundo ele, o comitê de investimentos da General Atlantic, responsável pela decisão final, é composto por cinco membros humanos e um agente de IA. Esse agente analisa dados da empresa e do mercado para formular uma recomendação de investimento. Embora seu “voto” ainda não tenha caráter oficial, a General Atlantic já testou retroativamente suas análises em todos os investimentos realizados. Os resultados indicaram que, em vários casos, as recomendações da IA teriam proporcionado retornos superiores aos obtidos pelas decisões efetivamente tomadas pelo fundo (MARKET MAKERS, 2025).

Por outro lado, Marc Andreessen, uma das principais referências globais em *venture capital*, cofundador da a16z, fundo que investiu em empresas como Facebook e Airbnb, apresenta uma visão oposta. Em entrevista recente, ele afirmou que o trabalho de um investidor de VC dificilmente será automatizado pela inteligência artificial. Para ele, essa atividade envolve um conjunto de habilidades intangíveis, mais próximas de uma arte do que de uma ciência. Andreessen explica que grande parte do processo está ligada à análise psicológica dos fundadores: entender quem são essas pessoas e como reagem sob pressão (NOLAN, 2025).

Isso ajuda a corroborar com a importância da temática e deste trabalho, já que evidencia não apenas o interesse crescente da academia e do mercado em torno da aplicação de inteligência artificial no *venture capital*, mas também a pluralidade de visões existentes sobre seus impactos. Ainda, observa-se a limitada disponibilidade de estudos de caso que avaliem concretamente os efeitos da tecnologia no interior das organizações, com destaque para a escassez de pesquisas no contexto brasileiro.

3 METODOLOGIA DE PESQUISA

Este capítulo tem como objetivo apresentar a metodologia utilizada para a realização do trabalho. Inicialmente, será feita a caracterização da pesquisa, com a discussão do seu objetivo, procedimentos técnicos, natureza e abordagem. Em seguida, serão detalhadas as etapas do estudo, bem como os procedimentos técnicos adotados para a coleta e análise dos dados.

3.1 CARACTERIZAÇÃO DA PESQUISA

A caracterização da pesquisa tem como propósito tornar mais claro o seu planejamento e facilitar sua compreensão. De acordo com GERHARDT e SILVEIRA (2009) e GIL (2002), uma investigação científica pode ser classificada com base nos aspectos: objetivos, procedimentos técnicos, natureza e abordagem.

No que se refere aos objetivos, esta pesquisa é classificada como exploratória, uma vez que busca proporcionar maior familiaridade com o tema investigado, com vista a torná-lo mais explícito ou a construir hipóteses (GIL, 2002). Esse tipo de pesquisa é especialmente adequado quando o fenômeno estudado ainda é pouco conhecido ou pouco sistematizado na literatura, como é o caso do uso de ferramentas de IA no contexto de fundos de *venture capital*.

Em relação aos procedimentos técnicos, ou seja, às estratégias adotadas para a coleta e análise dos dados, trata-se de um estudo de caso. Conforme definido por GIL (2002), um estudo de caso consiste no estudo profundo e exaustivo de um ou poucos objetos, de maneira que permita seu amplo e detalhado conhecimento. No trabalho, a empresa objeto de estudo será analisada de forma minuciosa, com o intuito de compreender seu contexto atual, identificar oportunidades para aplicação da inteligência artificial e propor uma solução estruturada para apoiar sua operação.

Quanto à natureza da pesquisa, trata-se de uma pesquisa aplicada, pois tem como objetivo gerar conhecimento voltado para a aplicação prática, visando à solução de problemas específicos (GERHARDT; SILVEIRA, 2009). Por isso, a pesquisa tem caráter contextual, voltado à compreensão e solução de problemas específicos observados na realidade da organização estudada.

Por último, a abordagem da pesquisa é predominantemente qualitativa, já que o principal objetivo é aprofundar o conhecimento em uma organização, para explicar os porquês das coisas (GERHARDT; SILVEIRA, 2009). No caso deste estudo, isso se traduz na análise das aplicações práticas, percepções e rotinas, permitindo identificar oportunidades e analisar o seu impacto, que é mais do que geração de dados quantitativos.

3.2 DESCRIÇÃO DAS ETAPAS E MÉTODOS DA PESQUISA

De acordo com FONTELLES et al., (2009), a elaboração de uma pesquisa científica é constituída por etapas ordenadas de maneira lógica e racional, abrangendo desde a escolha do tema, o planejamento do processo de investigação, o desenvolvimento do método escolhido, a coleta e a tabulação de dados, a análise de resultados, a elaboração das conclusões, até a divulgação de seus resultados.

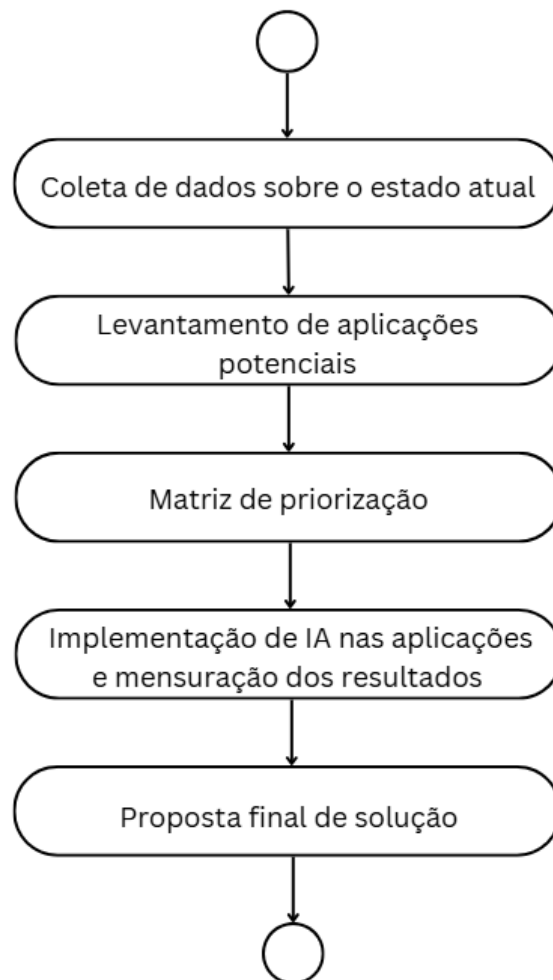
O fluxograma da Figura 3.1 apresenta todas as etapas previstas para o desenvolvimento desta pesquisa, organizadas de forma sequencial para garantir clareza e estrutura ao processo investigativo.

A primeira etapa, de coleta de dados sobre o estado atual, tem como objetivo mapear em detalhes o funcionamento atual do fundo de *venture capital* de modo a compreender todas as fases do processo de investimento, desde a originação até a formalização do aporte. Para isso, serão utilizadas entrevistas não estruturadas com os sócios, análise de documentos internos, observações diretas e revisão de processos já formalizados na organização. Busca-se compreender, tanto de forma quantitativa quanto qualitativa, o esforço demandado em cada etapa (em termos de tempo, recursos e nível de decisão) e os respectivos resultados esperados, com o intuito de identificar gargalos, ineficiências e oportunidades de melhoria que possam ser endereçadas com o uso de ferramentas de inteligência artificial.

A segunda etapa consistirá na aplicação do *brainstorming*, uma técnica de criatividade que visa gerar o maior número possível de ideias para a solução de um problema, sem julgamentos iniciais (OSBORN, 1953). A partir do mapeamento realizado na etapa anterior, serão identificadas etapas, atividades ou rotinas nas quais o uso de ferramentas de IA generativa possam agregar valor às operações da gestora do fundo. Pretende-se, nessa fase, levantar um portfólio amplo e diversificado de

hipóteses de aplicação da IA considerando diferentes tecnologias, ferramentas e abordagens. Logo, o resultado esperado é a construção de uma base robusta de possibilidades a serem avaliadas e priorizadas na etapa seguinte.

Figura 3.1 – Etapas do desenvolvimento da pesquisa



Fonte: Autoria própria

Na terceira fase, será utilizada uma matriz de priorização para priorizar as aplicações potenciais identificadas na etapa anterior. Serão considerados critérios como impacto esperado, viabilidade técnica, disponibilidade de dados e complexidade de implementação. Com a matriz, será possível comparar as aplicações de forma sistemática e objetiva, atribuindo pesos e notas conforme os critérios definidos. O objetivo é selecionar, de forma estruturada, as hipóteses mais relevantes a serem aprofundadas nas próximas etapas do estudo.

Na sequência, na quarta etapa, após a definição dos focos de atuação, serão testadas soluções baseadas em ferramentas de inteligência artificial para aprimorar os processos selecionados. Os testes serão realizados com base em dados reais e, sempre que possível, os resultados serão mensurados por meio de indicadores quantitativos, como tempo poupado, qualidade das decisões e redução de erros.

Por fim, a partir dos aprendizados obtidos ao longo da pesquisa, será desenvolvida uma proposta estruturada para a incorporação contínua da inteligência artificial na rotina da empresa. Essa proposta irá contemplar recomendações práticas, modelos experimentados, requisitos de dados e sugestões para a expansão futura da aplicação de ferramentas de IA em outras etapas do processo de investimento.

4 ESTUDO DE CASO

Este capítulo está organizado de forma a apresentar, de maneira estruturada, o desenvolvimento do estudo de caso, conforme as etapas metodológicas descritas no capítulo anterior. Inicialmente, na seção 4.1, é realizada a caracterização do contexto em que o estudo foi conduzido, oferecendo uma visão geral da organização e de suas principais particularidades. Em seguida, o capítulo se divide em outras cinco seções correspondentes a cada fase da pesquisa: (4.2) coleta de dados sobre o estado atual; (4.3) levantamento de aplicações potenciais; (4.4) aplicação de uma matriz de priorização; (4.5) implementação de soluções baseadas em inteligência artificial nas aplicações potenciais selecionadas, acompanhada da mensuração dos resultados obtidos; e, por fim, (4.6) apresentação da proposta final de solução.

4.1 CARACTERIZAÇÃO DA ORGANIZAÇÃO

A organização objeto deste estudo é um fundo de *venture capital* com sede na cidade de São Paulo, fundado em 2022. O fundo é especializado em investimentos *early stage*, com foco principal em rodadas Seed e Series A. Apesar desse foco, o portfólio do fundo já inclui um investimento em estágio mais avançado (Series B). Um dos critérios fundamentais para investimento é que a empresa investida já possua um produto em operação, ainda que em estágio inicial, como um MVP (*Minimum Viable Product*). Além disso, é exigido que a *startup* demonstre alguma validação de mercado, ou seja, tenha clientes pagantes.

A atuação do fundo é predominantemente em coinvestimentos com outros fundos de *venture capital*, podendo tanto liderar quanto acompanhar as rodadas. Seu foco geográfico está centrado no Brasil, com prioridade para empresas brasileiras com atuação no mercado nacional. No entanto, o fundo também está aberto a investir em *startups* estrangeiras que operem no Brasil.

Trata-se de um *corporate venture capital* (CVC), ou seja, um fundo que possui como cotista uma corporação. No momento, o fundo é responsável pela gestão de um veículo de investimento, mas está em negociação para a estruturação de novos fundos com outras corporações. A atual corporação cotista é uma grande empresa brasileira do setor de tecnologia, especializada em soluções B2B (*Business to*

Business) no modelo SaaS. Seu portfólio inclui desde sistemas de gestão empresarial até plataformas voltadas para automação de processos, serviços financeiros e outras ferramentas digitais voltadas à produtividade e eficiência de negócios em diversos setores da economia. Dessa forma, os objetivos do fundo extrapolam o retorno financeiro: busca-se também um retorno estratégico, com foco em gerar sinergias entre as *startups* investidas e a corporação cotista. Um dos principais mecanismos para viabilizar essa sinergia é o apoio à distribuição dos produtos das *startups* para a base de clientes da corporação. Por isso, a tese de investimento do fundo está centrada em empresas SaaS B2B, que podem ter sinergias com a corporação.

Até o momento, o fundo realizou 16 investimentos, dos quais um já resultou em uma saída (*exit*). A meta é realizar aproximadamente cinco novos aportes por ano, além de seguir investindo em rodadas subsequentes (*follow-ons*) nas *startups* já investidas, o que é prática comum no setor de *venture capital*.

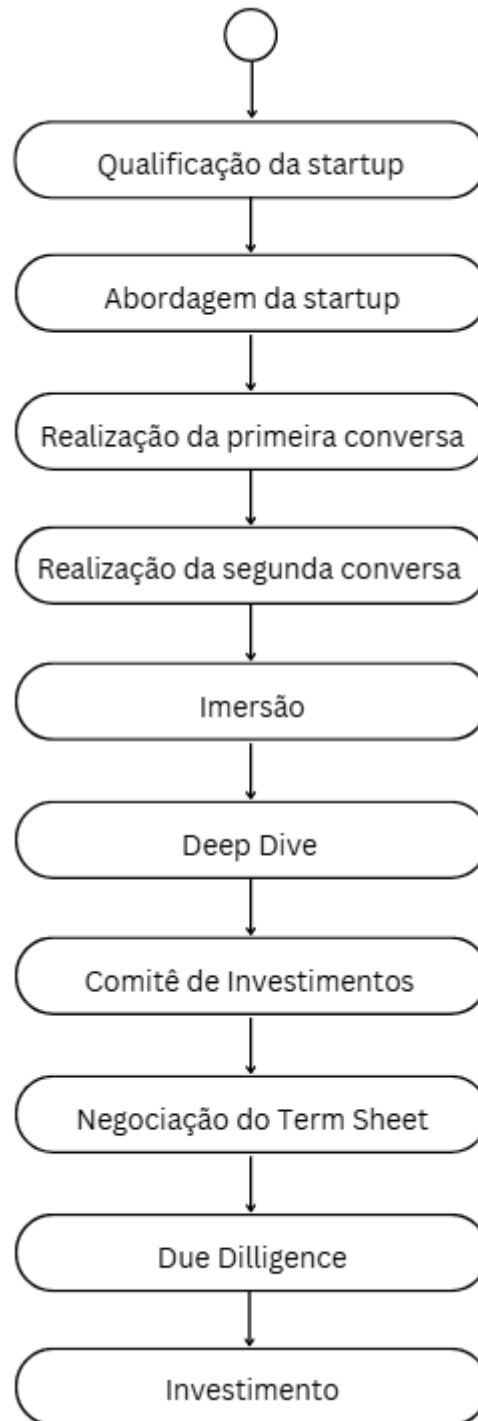
Operacionalmente, o fundo está estruturado em três áreas principais: Investimentos, Gestão de Portfólio e Pesquisa. A área de Pesquisa é responsável pela produção de materiais analíticos e geração de conhecimento, tanto para subsidiar as decisões internas de investimento quanto para compartilhar tendências tecnológicas com a corporação cotista. A área de Investimentos abrange todo o processo de análise e execução dos aportes, conforme descrito anteriormente na Seção 2.1.4. Esse processo segue um funil estruturado em dez etapas, conforme Figura 4.1.

O funil de investimentos é gerido por meio de um sistema de CRM, do inglês *Customer Relationship Management*, que permite organizar as *startups* de acordo com a etapa em que se encontram no processo de análise. Essa ferramenta centraliza todos os registros e anotações relacionados a cada empresa, garantindo histórico completo e padronizado das interações. Ainda, o CRM possibilita o acompanhamento de métricas de conversão entre etapas, o que é fundamental para a identificação de gargalos e a implementação de melhorias contínuas na operação do fundo.

A equipe de investimentos é responsável por conduzir todas as etapas do processo de análise e seleção de *startups*. Esse processo é estruturado em formato de funil, no qual, anualmente, milhares de empresas são avaliadas na etapa inicial, resultando em apenas algumas investidas no final. Cada etapa tem como objetivo filtrar as oportunidades com maior potencial, otimizando o tempo da equipe ao evitar a análise aprofundada de *startups* que não atendem aos critérios fundamentais do fundo, mas sem comprometer a identificação de boas oportunidades. Para melhor

compreensão, a Figura 4.1 apresenta uma sequência das atividades realizadas do funil de investimento, que são discutidas brevemente.

Figura 4.1 – Etapas do funil de investimento



Fonte: Autoria própria.

Na primeira etapa do funil, qualificação da *startup*, realiza-se uma análise inicial baseada em informações públicas. O time avalia o site da empresa para compreender seu produto, mercado de atuação, modelo de negócio e possíveis clientes, complementando essa investigação com buscas em notícias, histórico de captações, avaliações e dados setoriais disponíveis na internet. Um ponto central dessa etapa é a análise do time fundado, frequentemente realizada por meio dos perfis no LinkedIn, considerando que a qualidade dos empreendedores é um dos fatores mais determinantes para o sucesso de uma *startup*.

As empresas que se mostram promissoras avançam para a abordagem inicial, quando o fundo busca estabelecer o primeiro contato com algum dos fundadores da *startup*, geralmente via LinkedIn, rede de relacionamentos ou indicações de parceiros. Esse contato tem como objetivo agendar uma primeira conversa, que normalmente consiste em uma reunião de aproximadamente 45 minutos. Nesse encontro, os fundadores apresentam um *pitch* abordando os principais pontos do negócio, como produto, diferenciais competitivos e tração. Após a reunião, o time de investimento realiza uma avaliação interna para determinar se a empresa atende aos critérios mínimos para avançar.

Quando isso ocorre, segue-se para uma segunda conversa, mais aprofundada e direcionada. Esta quarta etapa exige preparação prévia, com a identificação dos principais pontos críticos a serem explorados, como dúvidas estratégicas, riscos ou elementos ainda pouco claros na tese da *startup*. Após essa conversa adicional, ocorre uma nova discussão interna para decidir se a empresa possui características suficientemente promissoras para seguir adiante.

A quinta etapa, denominada Imersão, concentra uma análise abrangente da *startup* em um curto período de tempo. Normalmente envolve uma visita presencial, uma demonstração aprofundada do produto e uma avaliação detalhada dos pontos críticos identificados anteriormente. Nessa fase, os fundadores também são apresentados ao comitê de investimentos, que decide se a análise deve avançar.

Caso decidam seguir, inicia-se o *deep dive*, a etapa mais longa e minuciosa de todo o funil de investimento. Nela, a *startup* compartilha informações financeiras completas, como balanço patrimonial, demonstração de resultados (DRE) e fluxo de caixa, enquanto o fundo realiza uma pesquisa externa detalhada, incluindo avaliação de concorrentes, análise de mercado (nacional e internacional) e entrevistas com clientes e investidores atuais. Em alguns casos, executivos da corporação cotista

também participam da análise. Ao longo dessa etapa, o time elabora o memorando de investimento, documento que consolida todas as informações levantadas e fundamenta a tese de investimento, além de propor, preliminarmente, o valor a ser investido, a participação societária e o *valuation*. Com o memorando concluído, o processo segue para o comitê de Investimentos, etapa decisiva em que os sócios deliberam sobre a aprovação ou rejeição do investimento. O documento é lido antecipadamente e serve de base para a discussão. A aprovação ocorre apenas em caso de unanimidade dos membros.

Aprovada a operação, inicia-se a negociação do *term sheet*, na oitava etapa do funil de investimento, que formaliza os principais termos da transação, incluindo *valuation*, instrumento financeiro e direitos de governança, conforme descrito previamente na seção 2.1.4. Em seguida, realiza-se a *due diligence*, conduzida por uma empresa especializada, com foco na verificação legal, tributária, trabalhista e regulatória, buscando identificar riscos, passivos ocultos ou eventuais inconsistências antes da formalização do investimento. Por fim, ocorre a etapa de Investimento, que envolve a chamada de capital e a oficialização da entrada da *startup* no portfólio do fundo.

Vale destacar que esse processo nem sempre segue uma sequência estritamente linear. Por exemplo, é comum haver uma primeira conversa com o empreendedor, mesmo que a empresa, apesar de promissora, não tenha interesse imediato em captar recursos ou ainda esteja em um estágio inicial de desenvolvimento. Logo, o time de investimento também assume a responsabilidade de acompanhar essas empresas ao longo do tempo, seja por meio de reuniões periódicas ou oferecendo formas de agregar valor antes do investimento, com o objetivo de incentivar que, no momento oportuno, o fundo seja prioridade para elas.

Por último, a gestão de portfólio cuida de toda a operação pós-investimento, dessa forma, consiste em monitorar e apoiar as empresas investidas. Essa atividade envolve monitoramento de indicadores financeiros e operacionais, avaliação do desempenho estratégico, apoio na tomada de decisões críticas e suporte em áreas como governança, captação de recursos, vendas e desenvolvimento de produtos.

Ademais, inclui a identificação e análise de oportunidades de investimentos *follow-on*, a preparação para rodadas futuras de financiamento e a mitigação de riscos por meio de intervenções estratégicas quando necessário. A gestão de portfólio também contempla o processo de desinvestimento (*exit*), que envolve a avaliação do

estágio de maturidade da empresa, a identificação de potenciais compradores e a estimativa do retorno financeiro esperado para o fundo.

Em termos de atividades, a gestão de portfólio em fundos de *venture capital* apresenta grande diversidade. Inclui tanto projetos específicos voltados para uma empresa do portfólio, como análises financeiras, suporte a uma dor operacional específica ou a conexão da empresa com potenciais investidores ou clientes, quanto iniciativas de caráter mais amplo que beneficiam todas as empresas do fundo, como produção de conteúdo, mapeamento de talentos ou organização de eventos e encontros de *networking*.

Além desses projetos, a área realiza atividades rotineiras fundamentais, como a participação mensal em reuniões de conselho das empresas investidas e a elaboração de relatórios periódicos que consolidam informações financeiras e operacionais. Esses relatórios são preparados em diferentes níveis de detalhamento, incluindo materiais mensais para acompanhamento contínuo e relatórios semestrais mais completos. Em síntese, a gestão de portfólio é essencial para assegurar que as *startups* recebam suporte estratégico e operacional adequado, que seus objetivos estejam alinhados à estratégia do fundo e que os investimentos conduzam à valorização consistente do portfólio ao longo do tempo.

4.2 COLETA DE DADOS SOBRE O ESTADO ATUAL

Nesta etapa, busca-se compreender a situação atual do fundo de *venture capital*, objeto deste estudo de caso, mapeando seus processos e identificando de que forma a inteligência artificial é utilizada no momento. Em seguida, a organização será classificada de acordo com os *frameworks* de maturidade apresentados na seção 2.2.4 deste trabalho.

4.2.1 Descrição do estado atual

O uso de IA generativa no fundo de *venture capital* analisado encontra-se em estágio inicial e pouco estruturado. Apesar da adoção de algumas ferramentas, a aplicação prática permanece fragmentada e não integrada aos processos estratégicos da organização. Um exemplo é o uso do Fireflies, restrito ao registro de reuniões, sem que os dados coletados sejam posteriormente explorados para gerar inteligência. Da

mesma forma, modelos de IA generativa como GPT e Gemini são utilizados apenas de forma pontual, sem inserção consistente no fluxo de trabalho. Há ainda a utilização do Zapier, empregado na criação de relatórios sobre o funil de investimentos e conversões. Essa ferramenta, no entanto, opera de forma determinística, sem a incorporação de elementos de IA generativa, funcionando mais como mecanismo de automação de tarefas do que como recurso analítico.

Os gargalos mais evidentes encontram-se na fase de origem e qualificação de *startups*. A construção de listas extensas de potenciais investidas constitui um desafio recorrente, uma vez que essas bases frequentemente incluem empresas que não se enquadram minimamente no perfil de um fundo de *venture capital*, como consultorias, *software houses*, agências, empresas de produtos físicos ou negócios voltados para o consumidor final. Essa ausência de filtragem inicial faz com que até decisões rápidas, como descartar modelos de negócio incompatíveis, demandem tempo desproporcional, atrasando o processo de triagem. Como consequência, é comum que se leve de 20 a 30 minutos até identificar uma empresa que minimamente atenda aos critérios buscados.

Além disso, mesmo após a identificação de *startups* potencialmente relevantes, o trabalho de qualificação permanece custoso, exigindo análise detalhada caso a caso. Nesse ponto, a aplicação de IA generativa já demonstra utilidade ao auxiliar na compreensão e explicação dos modelos de negócio, bem como na pesquisa de informações públicas, como notícias e avaliações em mídias abertas. Contudo, ainda se nota a ausência de contexto específico sobre variáveis críticas como qualidade do time fundador, sinergia com a estratégia do fundo, ou entendimento aprofundado da lógica de *venture capital*, o que limita o alcance dessas ferramentas.

As etapas subsequentes, ligadas à preparação para reuniões, elaboração de memorandos e gestão do portfólio, também se caracterizam pela informalidade e pela baixa sistematização do uso de IA generativa. A preparação para *calls* exige pesquisas destinadas a compreender o setor de atuação da empresa e a formular perguntas relevantes, mesmo que algumas delas sejam recorrentes e de caráter padronizado. A redação dos memorandos de investimento envolve coleta e análise de informações sobre mercado, concorrência e dados financeiros, mas ainda depende fortemente de processos manuais. No entanto, nessa etapa, é preciso ter um entendimento e compreensão profunda da empresa, então o processo não pode ser simplesmente delegado para uma inteligência artificial. No caso da gestão de portfólio,

a maior organização ocorre apenas na consolidação de materiais a partir de dados enviados pelas próprias empresas, enquanto as demais atividades são conduzidas de forma dispersa.

O relacionamento com empreendedores e outros fundos segue lógica semelhante. No caso das empresas, os contatos ocorrem em ciclos trimestrais, sem grande personalização. Já a interação com fundos parceiros é igualmente periódica e pouco adaptada ao contexto específico de cada relação. No envio de mensagens para empreendedores, que ocorre em média cinco ou seis vezes por semana, o padrão é manter comunicações uniformes, sem aplicação de IA para personalização ou automação, por não se considerar que tal recurso agregaria valor nesse ponto.

Cabe destacar também que o fundo objeto deste estudo de caso realiza atividades de pesquisa com caráter principalmente exploratório. Essas iniciativas têm como objetivo principal o aprendizado interno e a ampliação da base de conhecimento para apoiar a tomada de decisão. Nesse caso, a automação não se mostra adequada, pois se trata de processos cuja natureza está mais relacionada à formação de repertório do que à eficiência operacional.

Comparando com o estudo de caso realizado em uma aceleradora (KLERK, 2025), é importante ressaltar que o modelo de atuação do fundo de VC difere substancialmente daquele adotado pelo modelo da aceleradora. Enquanto estas recebem grande volume de *pitch decks* e precisam selecionar alguns para avaliação mais detalhada, o fundo parte de listas extensas de empresas potenciais, como algumas listas públicas, e outras obtidas por meio do Apollo e Cruchbase, e deve decidir quais justificam a realização de uma primeira conversa. A análise preliminar, portanto, concentra-se em critérios como qualidade do time e aderência à tese de investimento, o que reforça a relevância de ferramentas que possam apoiar o processo de triagem inicial.

4.2.2 Classificação da organização pelos *frameworks* de maturidade

Quando posicionado o fundo deste estudo de caso diante da Matriz de Maturidade de IA desenvolvida pelo MIT (Figura 2.2), o fundo pode ser classificado na fase inicial, de experimentação e preparação. Essa fase é caracterizada pela adoção experimental e não integrada de ferramentas, onde avalia-se quais processos podem ser automatizados, e onde a decisão humana ainda precisa ser considerada. Essa

matriz descreve uma progressão que vai da simples experimentação até a incorporação estratégica e transformacional da IA. O objetivo central deste trabalho, portanto, é compreender quais mudanças estruturais são necessárias para que o fundo avance para a fase seguinte, marcada pela sistematização e pelo uso mais direcionado da tecnologia em processos críticos (BURNHAM, 2025).

Já com base na matriz de maturidade da Gartner (Figura 2.3), observa-se igualmente que a organização se encontra em um estágio inicial. Esse modelo contempla uma série de atividades introdutórias em diferentes dimensões, que podem orientar a condução das ações do trabalho. No eixo de Estratégia, por exemplo, já foram abordados neste estudo a definição da visão de IA (objetivos do trabalho), a maturidade em IA (delimitado nesta seção) e a análise de tendências externas em IA, conforme discussões da fundamentação teórica, com maior ênfase na seção 2.3.

4.3 LEVANTAMENTO DE APLICAÇÕES POTENCIAIS

Nesta etapa, serão identificadas as aplicações potenciais nas quais a IA generativa pode ser implementada de forma sistemática, com os principais objetivos de aprimorar a tomada de decisão, aumentar a eficiência e acelerar a execução dos processos em um fundo de *venture capital*. Uma vez mapeadas essas oportunidades, a etapa seguinte deste estudo de caso consiste em estabelecer prioridades, de modo a definir quais iniciativas demandam implementação mais imediata. As demais, embora não priorizadas, manterão sua relevância, uma vez que comporão um *backlog* de ações que poderão ser desenvolvidas progressivamente, conforme o nível de maturidade no uso de IA evoluir dentro da organização.

4.3.1 Encontrar *startups* em listas de empresas

A etapa inicial de prospecção de *startups* parte, em grande medida, de listas amplas obtidas em bases públicas ou em plataformas especializadas, como Apollo e Crunchbase. Esse processo resulta em um volume expressivo de empresas potenciais, mas uma parcela significativa delas não apresenta características mínimas de compatibilidade com a lógica de *venture capital*, por exemplo, consultorias, agências, *software houses* ou negócios de produtos físicos. A ausência de

mecanismos de filtragem adequados faz com que até decisões elementares, como descartar modelos de negócio evidentemente incompatíveis, consumam tempo desproporcional da equipe, retardando etapas posteriores de análise.

A aplicação de ferramentas ou plataformas de IA generativa de forma sistemática tem potencial de transformar essa etapa do funil de investimento por meio da criação de mecanismos de classificação e ranqueamento automáticos, baseados em critérios de elegibilidade previamente definidos pelo fundo. Modelos treinados para reconhecer padrões característicos de *startups* escaláveis, com potencial de atração de capital de risco, teriam capacidade de reduzir substancialmente o esforço de triagem inicial, direcionando a atenção da equipe apenas para casos de maior relevância.

Na maioria dos casos, esse processo exige o uso de técnicas avançadas de processamento de linguagem natural, capazes de interpretar e sintetizar as informações disponíveis em sites e outras fontes públicas sobre a empresa. Essa competência constitui um dos principais diferenciais dos modelos de IA generativa. Adicionalmente, a integração desses modelos ao sistema de relacionamento já utilizado pelo fundo permitiria identificar automaticamente se determinada empresa já se encontra cadastrada ou acompanhada. Dessa forma, se evitaria a duplicidade de registros e a dispersão de esforços em análises redundantes, conferindo maior eficiência e consistência ao processo de prospecção.

4.3.2 Qualificar *startups*

Após a etapa inicial de prospecção, o fundo de VC utiliza um *framework* estruturado para a qualificação das *startups*, que contempla diferentes dimensões críticas. Entre elas, destacam-se: o histórico e a formação acadêmica e profissional do time fundador, geralmente obtidos em plataformas como o LinkedIn; a clareza e a consistência da solução proposta, com a verificação de sua lógica de negócio e adequação a um modelo escalável; o potencial de mercado, incluindo a atratividade do setor, o grau de competição (mercados saturados ou “vermelhos”) e o alinhamento com a tese de investimento, especialmente no que se refere à relação com a corporação cotista do fundo; e o perfil de clientes atendidos pela empresa. Além disso, são analisados o histórico de captação, por meio de informações em bases como Crunchbase, notícias de mercado ou indícios de participação de investidores-anjo, e

outras fontes públicas complementares, como avaliações em lojas de aplicativos, menções no ReclameAqui ou cobertura jornalística, quando disponíveis.

Nesse ponto, a IA generativa poderia desempenhar um papel central ao automatizar a coleta e a análise dessas informações, sintetizando dados provenientes de múltiplas fontes e reduzindo significativamente o esforço manual exigido da equipe. Modelos avançados de linguagem seriam capazes de interpretar conteúdos heterogêneos desde descrições de sites corporativos até perfis individuais de fundadores e notícias de mercado. A partir desse processamento, a IA poderia produzir um relatório de qualificação preliminar, atribuindo uma nota ou recomendação final, do tipo “vale ou não abordar”, de acordo com os critérios estabelecidos no *framework*. Essa sistematização teria o potencial de acelerar a triagem, aumentar a consistência das avaliações e liberar tempo da equipe para análises mais estratégicas e de maior complexidade.

4.3.3 Preparação para conversas

Na etapa do funil de investimento de interação direta com fundadores, a preparação adequada para as conversas é determinante para a qualidade das informações coletadas e para a profundidade da análise subsequente. Atualmente, o fundo dispõe de um roteiro padrão composto por nove perguntas centrais, que serve como guia inicial para as entrevistas. Entretanto, a efetividade dessa etapa ainda depende fortemente do preparo individual e da capacidade de adaptação dos analistas, o que em alguns casos resulta em lacunas. É relativamente comum que, ao final de uma conversa de 45 minutos a 1 hora, determinados pontos críticos não tenham sido explorados, seja por falta de tempo, seja pela ausência de gatilhos que direcionam a discussão para aspectos mais relevantes do negócio.

Nesse contexto, a IA generativa poderia atuar como um recurso estratégico para enriquecer a preparação das entrevistas. Ao analisar previamente dados públicos e privados da *startup*, como informações do site institucional, perfis dos fundadores, rodadas de captação registradas e até mesmo menções em notícias ou redes sociais, a ferramenta de IA teria condições de identificar áreas de risco ou de potencial interesse e, a partir delas, sugerir perguntas adicionais ou personalizar o roteiro padrão. Essa abordagem sistematizada garantiria que os principais temas fossem

abordados de maneira consistente em todas as interações, ao mesmo tempo em que permitiria adaptar a conversa às especificidades de cada caso.

Esse potencial se torna ainda mais evidente em casos de conversas subsequentes entre o fundo e a *startup*, que vão além do primeiro contato. Nessas situações, a ferramenta de IA generativa poderia se apoiar nos registros já disponíveis em sistemas de CRM ou em ferramentas de transcrição de reuniões, como o Fireflies, para analisar o histórico das interações anteriores. A partir desse material, seria possível identificar de forma estruturada quais pontos já foram explorados, quais pontos permanecem pouco claros e quais lacunas ainda precisam ser endereçadas. Com isso, o roteiro de perguntas seria continuamente refinado, evitando repetições desnecessárias e garantindo uma progressão lógica na profundidade da análise. Com isso, o processo de entrevistas se tornaria mais robusto, menos sujeito a omissões e mais alinhado aos objetivos do fundo.

4.3.4 Avaliar *pitch decks*

O estudo de Klerk (2025) oferece uma evidência relevante sobre o potencial de aplicação da inteligência artificial na análise de *pitch decks*. Conduzido na InnovationQuarter, uma aceleradora na Holanda, o caso investigou o uso da plataforma Deckmatch para extrair informações relevantes de apresentações de *startups* em estágio inicial. Os resultados mostraram que modelos híbridos, que combinam julgamento humano e suporte de IA, podem elevar tanto a eficácia quanto a eficiência das avaliações.

Transpondo essa experiência para o contexto do fundo de *venture capital*, a análise de *pitch decks* poderia ser significativamente enriquecida por ferramentas semelhantes. Tradicionalmente, essa etapa exige uma leitura, extração de informação e análise manual, o que demanda tempo e está sujeito a vieses individuais. A aplicação da ferramenta de IA generativa nesse processo teria o potencial de automatizar a triagem preliminar, gerar benchmarks comparativos entre diferentes *startups* e sinalizar lacunas ou inconsistências relevantes, permitindo que a equipe concentre seus esforços na interpretação estratégica das informações. Dessa forma, a IA funcionaria como um recurso complementar, capaz de aumentar a consistência e a escalabilidade do processo sem substituir o discernimento crítico humano.

4.3.5 Decisão em relação ao avanço para *deep dive*

A decisão sobre avançar ou não para a fase de *deep dive* é uma das mais relevantes dentro do processo de avaliação, pois implica uma alocação significativa de tempo tanto por parte do fundo quanto dos fundadores da *startup*. Por essa razão, é necessário atingir um nível de convicção minimamente alto antes de seguir adiante, ao mesmo tempo em que se deve evitar falsos negativos, ou seja, deixar de explorar oportunidades promissoras. As principais fontes de informação para essa etapa incluem não apenas os dados públicos e o *pitch deck*, mas também o conteúdo das interações prévias, normalmente compostas por pelo menos duas conversas estruturadas com a equipe empreendedora, nas quais perguntas críticas são exploradas em maior profundidade.

Nesse ponto, a ferramenta de IA generativa poderia desempenhar um papel central ao apoiar a consolidação e a análise integrada de todas essas informações. A partir de dados coletados em documentos, registros de CRM e transcrições de reuniões, a IA seria capaz de organizar os pontos já esclarecidos, destacar questões ainda em aberto e até sugerir hipóteses que merecem investigação adicional antes do *deep dive*. Além disso, modelos de linguagem poderiam gerar relatórios comparativos, identificando padrões entre *startups* avaliadas anteriormente e destacando riscos ou sinais de alerta recorrentes. Essa sistematização aumentaria a consistência e a robustez das decisões, funcionando como um mecanismo de suporte à tomada de decisão que complementa o julgamento humano.

4.3.6 Preparação do memorando de investimento

O memorando de investimento constitui o principal material de análise profunda elaborado pelo fundo, servindo como base para a deliberação do comitê. Trata-se de um documento detalhado que consolida todas as informações relevantes sobre a *startup*, abrangendo aspectos como a trajetória e o perfil da equipe fundadora, a estrutura financeira e operacional, as métricas de desempenho, o tamanho e a atratividade do mercado, o cenário competitivo e o histórico de captação. Além da descrição objetiva desses elementos, o memorando apresenta a argumentação central que sustenta a recomendação de investimento, explicitando os motivos pelos

quais a oportunidade se mostra alinhada à tese do fundo e quais são os principais riscos a serem monitorados.

Nesse processo, uma ferramenta de IA generativa poderia assumir um papel significativo ao automatizar parte da coleta, organização e sistematização das informações, reduzindo o esforço manual da equipe. Modelos de linguagem poderiam gerar versões preliminares do documento a partir de dados já armazenados em sistemas internos, relatórios de reuniões, *pitch decks* e fontes externas, estruturando o conteúdo de acordo com um padrão definido. Além disso, a IA poderia apoiar na elaboração de análises comparativas, trazendo *benchmarks* de mercado, indicadores financeiros de referência ou exemplos de casos semelhantes. Com isso, o trabalho da equipe se concentraria na validação das informações, no refinamento das análises estratégicas e na construção da argumentação final, aumentando a consistência e velocidade na produção dos memorandos apresentados ao comitê.

4.3.7 Tomada de decisão no comitê de investimento

O caso da General Atlantic (MARKET MAKERS, 2025) ilustra como uma solução de IA generativa pode ser integrada à tomada de decisão em comitês de investimento. Lá, um agente de IA analisa todos os dados coletados para fornecer recomendações aos membros humanos, servindo como suporte estratégico. Embora seu “voto” ainda não seja oficial, testes retroativos mostraram que suas análises poderiam ter gerado retornos superiores aos obtidos pelas decisões humanas. Esse exemplo evidencia o potencial da IA generativa como ferramenta complementar, capaz de aumentar a consistência das decisões, reduzir vieses e fornecer insights adicionais que reforçam a avaliação do comitê.

No caso do fundo analisado, seria possível implementar um modelo semelhante, em que a inteligência artificial forneceria recomendações, mas sem que seu “voto” tivesse caráter oficial. Além disso, a ferramenta poderia ser utilizada para análises retroativas, comparando decisões passadas com aquelas geradas pela aplicação de IA generativa e permitindo avaliar seu impacto potencial sobre a qualidade das decisões e a identificação de oportunidades ou riscos previamente não detectados.

4.3.8 Preparação de materiais em gestão de portfólio

Como última aplicação, podemos incluir a preparação de materiais de gestão de portfólio. Esse processo envolve a elaboração de *slides*, relatórios e dashboards sobre as empresas já investidas. Os materiais têm como objetivo consolidar informações sobre desempenho financeiro, métricas operacionais, progresso estratégico, evolução do mercado e indicadores de risco, permitindo ao fundo monitorar a saúde e o valor das participações. Tradicionalmente, a produção desses relatórios demanda tempo considerável da equipe, que precisa coletar dados de múltiplas fontes internas e externas, organizar informações heterogêneas e apresentar análises de forma clara e comparável.

Nesse contexto, a aplicação de inteligência artificial poderia automatizar grande parte desse trabalho operacional, reunindo dados de sistemas internos, planilhas financeiras, CRMs e fontes externas, e estruturando relatórios ou apresentações padronizadas. Modelos de linguagem poderiam gerar resumos executivos, destacar variações significativas em métricas-chave ou sinalizar tendências relevantes no portfólio. Com isso, a equipe teria mais tempo para interpretar os resultados, propor ações estratégicas e embasar decisões de *follow-on investments*, aumentando a consistência e a eficiência do monitoramento do portfólio.

4.4 PRIORIZAÇÃO DAS APLICAÇÕES POTENCIAIS

Na etapa anterior, foram identificadas oito aplicações potenciais de IA no contexto de um fundo de *venture capital*, as quais foram discutidas na seção precedente. A Tabela 4.1 apresenta um resumo dessas aplicações, indicando seu nome, numeração e a etapa correspondente do funil de investimento, apresentado anteriormente na Figura 4.1.

Desta forma, nesta terceira etapa, realizou-se a priorização das aplicações potenciais a serem contempladas no escopo deste estudo de caso. Essa priorização está alinhada ao *roadmap* de IA proposto pela Gartner (2025), que estabelece como uma das etapas iniciais a definição e priorização dos casos de uso. O estudo da BCG (2024) reforça essa perspectiva, ao destacar que concentrar esforços em um número

reduzido de iniciativas, mas de alta prioridade, tende a maximizar o retorno dos investimentos em IA.

Tabela 4.1 - Resumo das aplicações de IA potenciais

Num.	Aplicação potencial de IA	Etapa do funil
1	Encontrar <i>startups</i> em listas de empresas	Qualificação da <i>startup</i>
2	Qualificar <i>startups</i>	Qualificação da <i>startup</i>
3	Preparação para conversas	Realização da 1a e 2a Conversas
4	Avaliar <i>Pitch Decks</i>	Realização da 1a Conversa
5	Decisão em relação ao avanço para <i>deep dive</i>	Imersão
6	Preparação do Memorando de Investimento	<i>Deep dive</i>
7	Tomada de decisão no comitê de investimento	Comitê de Investimentos
8	Preparação de materiais em gestão de portfólio	Investimento

Fonte: Autoria própria.

Para isso, será adotada uma abordagem de priorização multicritério baseada em um método de tomada de decisão multicritério, do inglês, *Multicriteria Decision-Making* (MCDM), que permite selecionar de forma sistemática quais etapas merecem atenção prioritária. O primeiro passo desse processo consiste em definir critérios de priorização, que servirão de guia para a escolha das aplicações potenciais a serem atacadas, garantindo que a seleção seja fundamentada, objetiva e alinhada aos objetivos estratégicos do estudo.

4.4.1 Definição dos critérios de avaliação

A seleção das aplicações a serem priorizadas demanda um processo estruturado de avaliação, capaz de equilibrar tanto o impacto potencial de cada iniciativa quanto sua viabilidade prática de implementação. A partir de conversas realizadas com as lideranças da gestora do fundo de VC e da revisão dos principais desafios operacionais identificados, estabeleceu-se um conjunto de critérios que orientaram a priorização. Logo, a Tabela 4.2 apresenta esses critérios, acompanhados

de um identificador (ID), de sua denominação e de uma breve descrição do propósito de cada um.

Tabela 4.2 - Critérios de avaliação das aplicações potenciais de IA generativa

ID	Critério	Explicação
C1	Relevância para a decisão de investimento	Grau em que a aplicação influencia diretamente a qualidade das escolhas do fundo, afetando o acerto ou erro nas decisões de investimento.
C2	Potencial de ganho de eficiência	Redução estimada de tempo ou esforço manual que poderia ser obtida com a automação da etapa.
C3	Frequência de uso da aplicação	Número de vezes que a etapa ocorre no fluxo operacional (quanto maior a recorrência, maior o impacto acumulado).
C4	Potencial de replicabilidade	Capacidade da solução desenvolvida ser aplicada em outras etapas internas ou reutilizada em diferentes contextos.
C5	Redução de risco / mitigação de vieses	Grau em que a aplicação de IA pode trazer maior consistência, neutralidade e padronização às análises.
C6	Disponibilidade e qualidade dos dados	Existência e acessibilidade das informações necessárias para alimentar ou treinar os modelos de IA generativa.
C7	Complexidade técnica da solução	Nível de sofisticação necessário (ex.: regras simples vs. modelos avançados), afetando tempo e esforço de desenvolvimento.
C8	Custo de Implementação	Recursos financeiros requeridos, incluindo licenças, infraestrutura ou serviços externos.

Fonte: Autoria própria.

Em uma análise de priorização, é necessário que os tomadores de decisão determinem os pesos relativos entre esses critérios de modo que possam agregar em uma única pontuação (*score*) ponderada o desempenho de cada aplicação potencial de IA da Tabela 4.1, diante de cada um dos oito critérios.

4.4.2 Definição de pesos para os critérios

Com os critérios já estabelecidos, a etapa seguinte consiste em atribuir pesos a cada um deles, de forma a refletir sua importância relativa no processo de

priorização. A ponderação é necessária porque, embora todos os critérios contribuam para a avaliação final, eles não têm o mesmo impacto na tomada de decisão. Desde sua definição, os critérios foram organizados em duas dimensões distintas: impacto estratégico, associado ao valor gerado pela aplicação de IA generativa em cada etapa do processo (C1–C5), e viabilidade técnica e operacional, relacionada às condições práticas para implementação das soluções no estágio atual de maturidade da organização (C6–C8).

O primeiro passo consiste em definir a proporção entre as duas dimensões de avaliação: impacto estratégico e viabilidade técnica. Neste estudo, o impacto estratégico recebeu peso de 70%, enquanto a viabilidade técnica ficou com 30%. Essa escolha se baseia no estudo do BCG (2024), que aponta que projetos de IA com maior retorno estão concentrados em atividades centrais ao negócio, ainda que exijam maior complexidade técnica. No entanto, considerando que a organização analisada é de pequeno porte, a viabilidade técnica também assume papel relevante, garantindo que as iniciativas propostas sejam exequíveis com os recursos disponíveis.

A partir dessa definição, é possível detalhar os pesos de cada critério individual. Na dimensão de viabilidade técnica, optou-se por atribuir pesos iguais aos três critérios: disponibilidade de dados (2.1), complexidade técnica (2.2) e custo de implementação (2.3). Cada um deles representa um fator essencial para garantir que as iniciativas possam ser implementadas de forma eficiente e sustentável. Logo, cada um desses critérios foi considerado com um peso relativo geral de 0,1 (10%).

Já para a primeira dimensão de impacto estratégico, a comparação dos cinco critérios dessa dimensão (1.1 a 1.5), foi adotada uma abordagem mais estruturada, utilizando o método de comparação por pares proposto por Thomas Saaty, baseado no *Analytic Hierarchy Process* (AHP). Este método consiste em comparar cada critério com os demais dois a dois, avaliando qual deles é mais importante e em que grau de importância. As comparações são realizadas com base em uma escala fundamental de nove pontos, em que o valor 1 indica igual importância entre os critérios, enquanto os valores 3, 5, 7 e 9 representam níveis crescentes de importância de um critério sobre o outro, sendo possível utilizar valores intermediários (2, 4, 6 e 8) para expressar julgamentos intermediários (SAATY, 1980).

Na escala, o valor 1 representa igual importância entre os critérios, 3 indica importância moderada superior, 5 corresponde a importância forte, 7 a importância muito forte e 9 a importância extrema em relação ao outro critério (SAATY, 1980).

Dessa forma, com apoio das lideranças da gestora do fundo de VC realizou-se a comparação par a par dos cinco critérios do domínio de impacto estratégico para estabelecer os pesos relativos, conforme Tabela 4.3.

Tabela 4.3 – Comparação da importância dos critérios de impacto estratégico

Critérios	Relevância	Eficiência	Frequência	Replicabilidade	Risco
Relevância (2.1)	1	3	4	6	5
Eficiência (2.2)	1/3	1	2	4	3
Frequência (2.3)	1/4	1/2	1	3	1
Replicabilidade (2.4)	1/6	1/4	1/3	1	1/3
Redução Risco (2.5)	1/5	1/3	1	3	1
Soma	1,95	5,08	8,33	17,00	10,33

Fonte: Autoria própria.

O método original do AHP utiliza o autovetor principal da matriz de comparação para extrair os pesos dos critérios. No entanto, Saaty (1980) também descreve uma forma aproximada de obtenção das prioridades, na qual os pesos podem ser estimados pela normalização das colunas da matriz de julgamentos, seguida do cálculo da média de cada linha. A partir das somas apresentadas na matriz de comparação, o passo seguinte consiste, portanto, em construir a matriz normalizada, na qual cada elemento é dividido pela soma total da coluna correspondente. O resultado dessa normalização é apresentado na Tabela 4.4.

Tabela 4.4 - Tabela normalizada das comparações pareadas

Critério	Relevância	Eficiência	Frequência	Replicabilidade	Risco	Média
C1	0,513	0,59	0,48	0,353	0,484	0,484
C2	0,171	0,197	0,24	0,235	0,29	0,227
C3	0,128	0,098	0,12	0,176	0,097	0,124
C4	0,086	0,049	0,4	0,059	0,032	0,053
C5	0,103	0,066	0,12	0,176	0,097	0,112

Fonte: Autoria própria.

Dessa forma, a média dos valores de cada linha da tabela normalizada corresponde ao peso relativo de cada critério dentro da dimensão de impacto estratégico, conforme o procedimento do método AHP. No entanto, como os critérios C1–C5 compõem apenas 70% do peso total do modelo de avaliação, seus valores devem ser ajustados multiplicando-se cada média por 0,7. A Tabela 4.5 apresenta os pesos finais resultantes deste cálculo, já incorporando também os pesos dos critérios técnicos (C6–C8), que receberam valores fixos e iguais por comporem os 30% restantes da ponderação geral.

Tabela 4.5 - Pesos para os critérios de avaliação

Critérios	Peso na Dimensão	Método de cálculo
Relevância (C1)	0,33	AHP
Eficiência (C2)	0,16	AHP
Frequência (C3)	0,09	AHP
Replicabilidade (C4)	0,04	AHP
Redução do Risco (C5)	0,08	AHP
Disponibilidade de dados (C6)	0,10	Peso fixo
Complexidade técnica (C7)	0,10	Peso fixo
Custo de implementação (C8)	0,10	Peso fixo

Fonte: Autoria própria.

Uma vez concluída a definição dos pesos relativos entre os critérios, pode-se avaliar o desempenho de cada aplicação potencial de IA no contexto do fundo de *venture capital* diante de cada um dos oito critérios. Na sequência, agrega-se um score para cada uma das aplicações na matriz de priorização considerando os pesos determinados nesta subseção.

4.4.3 Matriz de priorização

Com base nos pesos definidos para cada critério na subetapa anterior, o próximo passo consiste em atribuir uma nota a cada potencial aplicação de IA em

relação a cada critério, com o objetivo de selecionar aquelas que serão priorizadas no trabalho. Para tal, definiram-se notas que variam de 1 a 5, sendo que valores mais altos indicam maior impacto estratégico ou maior viabilidade da solução. A seguir, cada tabela apresenta uma aplicação potencial de IA, a nota atribuída a cada critério e a justificativa correspondente para a escolha dessa nota.

Tabela 4.6 – Aplicação núm. 1. “Encontrar *startups* em listas de empresas”

Critério	Nota	Justificativa
C1	3	A etapa é de triagem inicial e não a decisão final de investimento. No entanto, um bom filtro é relevante, pois garante que a equipe concentre seus esforços nas oportunidades mais promissoras.
C2	3	O ganho de eficiência é moderado, pois a IA automatiza o filtro de empresas que não se enquadram no perfil, mas o trabalho de qualificação das empresas que passam pelo filtro ainda é manual
C3	5	A prospecção em listas amplas de empresas são atividades contínuas. O processo envolve muitas empresas na etapa inicial do funil, o que torna a recorrência máxima.
C4	3	A solução pode ser adaptada para diferentes listas e bases de dados (Apollo, Crunchbase, listas públicas). A lógica de classificação pode ser parcialmente reutilizada na qualificação.
C5	2	O objetivo principal é a eficiência, não a mitigação de vieses na decisão de investimento, que é o foco de etapas posteriores
C6	5	A etapa depende de dados públicos e externos, como sites de <i>startups</i> , plataformas e informações públicas na internet
C7	4	O modelo depende de uma classificação relativamente objetiva e critérios claros, algo que pode ser viabilizado com IA generativa
C8	3	Os custos envolvem APIs de LLM e ferramentas de integração, mas com consumo maior do que em outras etapas.

Fonte: Autoria própria.

Tabela 4.7 – Aplicação núm. 2. “Qualificar *startups*”

Critério	Nota	Justificativa
C1	4	A qualificação é uma etapa crucial de filtro. A IA consolida informações sobre o time fundador, produto, mercado, e sinergia com o fundo, gerando um relatório que influencia diretamente o "vale ou não abordar" e, consequentemente, a qualidade das empresas que avançam no funil.

C2	4	Há um alto potencial, pois a IA automatiza a coleta, interpretação e síntese de informações de múltiplas fontes (LinkedIn, sites, Crunchbase, notícias). Isso reduz significativamente o esforço manual de análise caso a caso
C3	5	Esta é uma das atividades de maior volume, pois ocorre logo após a triagem inicial (prospecção). A equipe precisa qualificar um grande número de empresas semanalmente.
C4	4	O framework de qualificação é estruturado e utiliza critérios padronizados (Time, Produto, Mercado). O modelo pode ser reutilizado em etapas como a avaliação de pitch decks.
C5	2	O objetivo primário é a eficiência e consistência, mas o julgamento de variáveis críticas ainda exige intervenção humana
C6	3	A solução depende de dados públicos (sites, perfis, notícias) que são acessíveis, mas também de informações como a opinião do fundo em relação a determinada solução/categoria de software.
C7	4	O modelo depende de uma classificação relativamente objetiva e critérios claros, algo que pode ser viabilizado com IA generativa
C8	4	Os custos envolvem APIs de LLM e ferramentas de integração

Fonte: Autoria própria.

Tabela 4.8 – Aplicação núm. 3 “Preparação para conversas”

Critério	Nota	Justificativa
C1	3	A qualidade da conversa influencia a coleta de informações e, portanto, o avanço da <i>startup</i> no funil. No entanto, esta etapa de preparação não chega a ser crucial para o processo.
C2	4	O ganho é significativo porque a IA pode analisar dados públicos e privados para identificar áreas de risco e sugerir perguntas adicionais, acelerando o processo de análise.
C3	4	A preparação ocorre para a primeira conversa e, de forma mais aprofundada, para a segunda conversa e subsequentes, envolvendo uma frequência alta na rotina do fundo.
C4	4	A lógica de análise e sugestão de perguntas é altamente replicável para diversas conversas com diferentes <i>startups</i> e pode ajudar a construir soluções para etapas subsequentes.
C5	3	A aplicação de IA ajuda a garantir que pontos críticos não sejam negligenciados, o que aumenta a consistência, mas não elimina o viés do julgamento humano.

C6	4	Grande parte dos dados são disponíveis, incluindo informações do site, perfis de fundadores, histórico do CRM e transcrições de reuniões (Fireflies).
C7	4	O modelo depende de LLMs para analisar histórico de interações, identificar lacunas, e personalizar o roteiro de perguntas.
C8	4	Os custos envolvem APIs de LLM e ferramentas de integração

Fonte: Autoria própria.

Tabela 4.9 – Aplicação núm. 4 “Avaliar *pitch decks*”

Critério	Nota	Justificativa
C1	4	O pitch deck é uma fonte fundamental para a análise e serve como base para o avanço no funil.
C2	3	O ganho de eficiência é moderado, pois a IA automatiza a extração e a triagem de informações, mas a análise do conteúdo ainda depende do discernimento crítico humano.
C3	3	A avaliação de pitch decks é um passo importante, mas acontece apenas para as <i>startups</i> que estão em processo de <i>fundraising</i> e tem um <i>pitch deck</i> atualizado.
C4	3	A solução de extração de dados e benchmarks é aplicável a todos os pitch decks (documentos com estrutura relativamente padronizada).
C5	4	A IA pode gerar benchmarks comparativos e sinalizar lacunas ou inconsistências, o que reduz os vieses individuais na triagem.
C6	2	Não são todas as empresas que estão em processo de <i>fundraising</i> e tem um <i>pitch deck</i> atualizado.
C7	3	O modelo depende de LLMs para analisar informações não estruturadas em um documento, o que tem uma complexidade maior do que as etapas anteriores.
C8	3	O custo envolve o uso de APIs de LLMs para processar documentos e a possível necessidade de plataformas especializadas

Fonte: Autoria própria.

Tabela 4.10 – Aplicação núm. 5 “Decisão em relação ao avanço para *deep dive*”

Critério	Nota	Justificativa
C1	4	É uma decisão crucial no funil, pois implica uma alocação

		significativa de tempo e recursos tanto do fundo quanto dos fundadores da <i>startup</i> . Exige alto nível de convicção.
C2	3	O ganho de eficiência é moderado, pois é um processo que não demanda muito tempo nem trabalho manual.
C3	3	A frequência é baixa em comparação com as etapas iniciais, pois ocorre após algumas interações com a empresa, em um funil bem mais estreito.
C4	3	A lógica de consolidação de dados de múltiplas fontes e a geração de relatórios comparativos poderia ser adaptado e reutilizado para outras decisões de "go/no-go"
C5	4	A IA pode aumentar a consistência e a robustez da decisão ao identificar padrões, riscos e sinais de alerta, funcionando como um mecanismo de suporte à tomada de decisão.
C6	3	Alguns dos dados são bem disponíveis, mas a decisão também depende de algumas percepções sobre a qualidade da equipe e da solução.
C7	3	É uma decisão mais complexa que etapas anteriores, e por isso tem uma complexidade relativamente maior de ser construída.
C8	4	Os custos envolvem APIs de LLM e ferramentas de integração

Fonte: Autoria própria.

Tabela 4.11 – Aplicação núm. 6 “Preparação do memorando de investimento”

Critério	Nota	Justificativa
C1	3	O memorando é o principal material de análise profunda e serve como base para a deliberação do comitê de investimento. Embora seja fundamental, a preparação do documento em si é mais uma tarefa de consolidação do que a própria decisão
C2	4	O potencial de eficiência é alto, pois a aplicação de IA pode automatizar a coleta, organização e sistematização de informações de diferentes fontes
C3	1	A frequência é muito baixa, pois este documento só é elaborado para as poucas <i>startups</i> que chegam à fase final.
C4	2	A solução de geração de memorandos segue um padrão definido, mas o conteúdo é altamente específico para cada empresa, reduzindo a replicabilidade da análise em si, em comparação com etapas de triagem inicial
C5	2	A IA apoia a consistência do formato e estrutura do memorando,

		mas a argumentação central e a análise que sustentam a tese de investimento dependem do julgamento humano.
C6	4	Há alta disponibilidade, pois a aplicação de IA pode utilizar dados já armazenados em sistemas internos, relatórios de reuniões, pitch decks e outras fontes externas.
C7	4	O modelo depende de LLMs para analisar histórico de interações, e compor o documento.
C8	3	O custo é significativo devido ao uso de LLMs para geração de texto e consolidação de dados.

Fonte: Autoria própria.

Tabela 4.12 – Aplicação núm. 7 “Tomada de decisão no comitê de investimento”

Critério	Nota	Justificativa
C1	5	Esta é a etapa decisiva do processo de investimento. O comitê delibera sobre a aprovação ou rejeição do investimento, sendo o ponto de maior relevância para as escolhas do fundo
C2	2	O potencial de eficiência é baixo, pois a IA não substitui o voto final, nem a discussão. A função da aplicação de IA é servir como suporte estratégico e não para acelerar o processo.
C3	1	A frequência é muito baixa, pois este é o último filtro antes do investimento, ocorrendo apenas para as poucas <i>startups</i> que chegam ao final do funil.
C4	1	A solução é altamente específica para o contexto da decisão final e para os critérios de votação do comitê, reduzindo sua replicabilidade para outras etapas.
C5	4	O uso da IA pode aumentar a consistência das decisões, reduzir vieses e fornecer insights adicionais que complementam o julgamento humano.
C6	2	A aplicação de IA depende da análise de todos os dados coletados nas etapas anteriores, que são heterogêneos. Além disso, depende de alguns dados relacionados ao julgamento humano, que não estão disponíveis.
C7	2	A solução envolve a integração de dados e a geração de uma recomendação com base em critérios complexos.
C8	4	Os custos envolvem APIs de LLM e ferramentas de integração

Fonte: Autoria própria.

Tabela 4.13 – Aplicação núm. 8 “Preparação de materiais em gestão de portfólio”

Critério	Nota	Justificativa
C1	3	Essa aplicação consolida informações para monitorar a saúde do portfólio e embasar decisões de follow-on, o que é relevante, mas menos central do que decisões de investimento
C2	4	O potencial de eficiência é alto, pois a IA pode automatizar a coleta, a organização e a estruturação de relatórios
C3	3	A área realiza relatórios mensais para acompanhamento contínuo e semestrais mais completos. A frequência é alta, mas não tão volumosa quanto etapas de triagem inicial
C4	1	A solução é altamente específica para o processo de monitoramento e apoio das empresas investidas, tendo pouca relação com as demais etapas aqui citadas.
C5	1	O foco principal é a eficiência e a consolidação de dados. Não há um papel significativo para mitigar vieses na tomada de decisão.
C6	3	A IA se baseia em dados enviados pelas próprias empresas, planilhas financeiras, CRMs, mas também depende de interações mais informais e outras percepções.
C7	5	A complexidade técnica não é muito alta, pois não depende de uma “tomada de decisão”
C8	4	Os custos envolvem APIs de LLM e ferramentas de integração

Fonte: Autoria própria.

Com base nas notas atribuídas para cada uma das 8 aplicações potenciais de IA nos oito critérios de priorização, conforme Tabelas 5 a 12, e nos pesos definidos na Subseção 4.4.2, é possível utilizar a matriz de priorização para ranquear as oito aplicações potenciais por meio de um score agregado, conforme Tabela 14.

Com base nos resultados da Tabela 4.14, as aplicações “Qualificar *startups*” e “Preparar para conversas” foram as escolhidas para implementação inicial devido ao seu score agregado que indica maior prioridade. Essas duas atividades se concentram na ponta inicial do funil de investimentos, onde a frequência de uso é alta. Embora as análises iniciais possam ser mais simples e objetivas do que as fases posteriores, elas são fundamentais para a assertividade e o sucesso das etapas subsequentes.

Tabela 4.14 - Matriz de priorização multicritério

Aplicações potenciais de IA no contexto do fundo de <i>venture capital</i>	Critérios								Score
	C1	C2	C3	C4	C5	C6	C7	C8	
	Pesos relativos								
	0,33	0,16	0,09	0,04	0,08	0,1	0,1	0,1	
1. Encontrar <i>startups</i>	3	3	5	3	2	5	4	3	3,40
2. Qualificar <i>startups</i>	4	4	5	4	2	3	4	4	3,83
3. Preparar para conversas	3	4	4	4	3	4	4	4	3,59
4. Avaliar <i>pitch decks</i>	4	3	3	3	4	2	3	3	3,31
5. Avanço para <i>deep dive</i>	4	3	3	3	4	3	3	4	3,51
6. Preparar Memorando	3	4	1	2	2	4	4	3	3,06
7. Decisão no comitê	5	2	1	1	4	2	2	4	3,22
8. Gestão de portfólio	3	4	3	1	1	3	5	4	3,22

Fonte: Autoria própria.

Ao focar nestas aplicações, o fundo pode aprimorar rapidamente a curva de aprendizado e a maturidade no uso de IA. O sucesso nesta fase de sistematização do uso da tecnologia permitirá que a organização avance de forma mais estruturada para a aplicação de IA em processos mais complexos e decisivos, como o *deep dive* e o comitê de investimento.

4.5 IMPLEMENTAÇÃO DE IA NAS APLICAÇÕES PRIORIZADAS E MENSURAÇÃO DOS RESULTADOS

Com base nas aplicações potenciais priorizadas no capítulo anterior (Qualificar *startups* e Preparar para conversas), será realizada a implementação da IA generativa nas etapas selecionadas. Esta fase incluirá a definição detalhada dos requisitos específicos para cada solução, as ferramentas e metodologias a serem empregadas,

o produto final esperado da implementação da IA, e, por fim, a mensuração dos resultados obtidos após a adoção das soluções.

4.5.1 Aplicação potencial de IA núm. 2 “Qualificar *startups*”

Para melhor compreensão da discussão da implementação dessa aplicação potencial de IA “Qualificar *startups*” no contexto do fundo de VC, apresentam-se as discussões em quatro subseções.

4.5.1.1 Definição de requisitos da aplicação de IA

O objetivo fundamental desta aplicação consiste em converter o processo manual de qualificação de *startups* em uma rotina automatizada por meio da aplicação de Inteligência Artificial. De forma abrangente, a solução de IA deverá atuar como um agente de pesquisa e análise, recebendo como *input* primário o endereço eletrônico do site da *startup* e, a partir dele, extraindo, processando e consolidando um conjunto de informações críticas para a decisão de avanço no funil de investimentos. Para tal, foram definidos os seguintes requisitos de extração e análise detalhados:

I. Análise da equipe fundadora da *startup*:

- **Formação acadêmica:** A aplicação de IA deve identificar o histórico educacional dos fundadores da empresa, avaliando se possuem graduação e/ou pós-graduação em instituições de ensino reconhecidas pela sua qualidade e reputação.
- **Experiências profissionais prévias:** O agente deve extrair e analisar o histórico profissional da equipe fundadora, destacando aspectos como cargos de liderança, passagem por empresas de referência no mercado, experiências empreendedoras anteriores e atuação em setores de tecnologia ou áreas correlatas ao negócio da *startup*.
- **Complementaridade e dedicação:** A solução deve avaliar a complementaridade entre as habilidades e funções dos fundadores (por exemplo, CEO, CTO, etc.), bem como verificar o nível de dedicação de cada um, identificando se atuam em tempo integral na *startup* ou se mantêm outros vínculos profissionais.

- Eficiência operacional: O sistema deve correlacionar o número de colaboradores com o tempo de existência da empresa, de modo a identificar possíveis desvios que indiquem baixo crescimento (por exemplo, uma *startup* com 5 anos de fundação e apenas 3 funcionários).

II. Avaliação do produto e tese de investimento:

- Proposta de valor: O agente de IA deve sintetizar o produto ou serviço oferecido em uma descrição concisa.
- Sinergia estratégica: É crucial determinar se a solução da *startup* apresenta *fit* e sinergia com a tese de investimento estabelecida pelo fundo.
- Risco de *overlap* no portfólio: A ferramenta deve cruzar o produto com o portfólio atual do fundo para identificar qualquer potencial de concorrência (*overlap*).

III. Análise de mercado e concorrência:

- Posicionamento Competitivo: A IA deve realizar uma avaliação preliminar do cenário competitivo para classificar o mercado como "mar vermelho" (saturado) ou "mar azul" (pouca concorrência).
- Diferenciação: O sistema precisa identificar os concorrentes existentes e as propostas de valor únicas que a *startup* oferece para o mercado.
- Potencial de Crescimento: O requisito exige a confirmação de que o mercado endereçável é substancial, que poderia sustentar um alto crescimento.

IV. Histórico de *fundraising* e *timing*:

- Capitalização: A ferramenta deve pesquisar o histórico de captação de recursos (*fundraising*), identificando investidores anteriores (anjos, fundos) e o montante captado.
- *Timing* do Fundo: Deve-se avaliar se o montante e o estágio de captação são compatíveis com o *timing* de investimento do fundo, evitando *startups* que já ultrapassaram a fase de investimento alvo.

V. Consolidação de informações públicas e recomendação:

- Dados Complementares: O sistema deve buscar outras informações de relevância pública, como avaliações de clientes, menções na mídia e notícias, se existirem.
- Geração de Recomendação: Com base na consolidação e análise de todas as descobertas, o agente de IA deve emitir uma recomendação formal sobre a pertinência de avançar ou não com a *startup* no funil de investimentos.

Além dos requisitos funcionais, a aplicação possui um requisito não funcional essencial: centralizar o desenvolvimento do agente em um número reduzido de ferramentas, priorizando soluções que minimizem custos operacionais, complexidade técnica e curva de aprendizado para a equipe.

4.5.1.2 Processo de implementação da aplicação de IA

Revisitando as aplicações apresentadas na fundamentação teórica, conforme Capítulo 2, concluiu-se que não há justificativa para a adoção de uma ferramenta de prateleira, uma vez que esse tipo de solução tende a limitar o grau de personalização necessário para o caso em estudo. O caminho mais adequado foi, portanto, o uso de uma solução personalizável sem exigir o desenvolvimento em código, conciliando flexibilidade e simplicidade operacional.

Nesse sentido, optou-se por adotar uma ferramenta baseada em modelos de linguagem generativa, como os GPTs personalizados, Gems ou Claude Projects, que permitem um elevado nível de customização a partir de configurações em linguagem natural, sem a necessidade de programação. Entre essas alternativas, o ChatGPT foi escolhido por ser o modelo mais consolidado no mercado, pelo maior nível de familiaridade da equipe com a ferramenta e pela relação custo-benefício favorável.

O custo de implementação está restrito a duas licenças da versão ChatGPT Plus, ao valor de US\$20 por usuário/mês, além de eventuais consumos via API da OpenAI, caso seja necessária a integração com fluxos externos. O custo marginal de uso da API é baixo, uma vez que o volume de requisições previsto é limitado. As tarifas da OpenAI variam conforme o modelo utilizado, sendo, no caso do GPT-4, da ordem de centavos de dólar por mil tokens processados, ou seja, muito baixo para o volume de uso pretendido.

O núcleo de funcionamento do agente está baseado no *system prompt*, um texto em linguagem natural que atua como a “configuração central” do agente, definindo sua identidade, objetivos e forma de interação. O *system prompt* funciona como uma espécie de instrução permanente, que orienta o modelo a responder sempre de acordo com determinados critérios, regras ou estilos predefinidos. Por exemplo, é possível instruir o agente a adotar um papel específico (como analista de investimentos, avaliador de *startups* ou pesquisador), seguir uma estrutura de resposta padronizada, priorizar certos tipos de informação e até aplicar critérios de julgamento.

Embora haja limitação no tamanho do *prompt* (em número de caracteres), ele permite um alto grau de detalhamento. Além disso, o GPT personalizado permite adicionar arquivos de referência que compõem sua base de conhecimento, oferecendo ao modelo acesso contextual a informações relevantes, sem necessidade de treinamento adicional. Essa base foi construída de forma padronizada, utilizando planilhas de Excel com tabelas para facilitar a compreensão e o processamento das informações pelo modelo. Os primeiros arquivos adicionados à base de conhecimento contemplaram:

1. Parâmetros de análise: alinhados aos requisitos definidos anteriormente (equipe, histórico de *fundraising*, entre outros), classificando cada item segundo os níveis *Ideal*, *Aceitável* e *Preocupante*;
2. Lista dos principais fundos de *venture capital* do Brasil: utilizada como indicador positivo quando identificada uma relação com a *startup* analisada;
3. Portfólio de empresas investidas: com breve descrição de suas atividades;
4. Histórico de decisões de qualificação: contendo exemplos de *startups* analisadas, resultados (aceitas ou recusadas) e justificativas que fundamentaram as decisões.

Com essa estrutura, foi possível desenvolver um MVP do agente de IA. Durante sua execução, observou-se a necessidade de aprimoramentos, os quais foram realizados de forma iterativa, ajustando-se gradualmente o *system prompt* e o conteúdo da base de conhecimento. Uma das principais limitações identificadas nessa

primeira versão estava relacionada à análise da equipe fundadora da *startup*. Embora informações sobre os fundadores estejam disponíveis em plataformas como o LinkedIn, os modelos de linguagem, por restrições de acesso, não conseguem consultar diretamente esses dados.

Para contornar esse desafio, foi integrada a ferramenta Apollo, utilizada em processos de prospecção. Por meio de uma chamada de API, o sistema passou a obter informações sobre as empresas, como número de funcionários, data de fundação, identificação de cofundadores (a partir de palavras-chave como CEO, CTO, Fundador, Sócio) e seus respectivos históricos profissionais, incluindo cargos e períodos de atuação. A única limitação observada foi a ausência de dados acadêmicos, já que o Apollo não tem acesso a esses dados, apesar de estarem no LinkedIn.

A introdução dessa camada adicional de dados tornou o fluxo do agente mais complexo, levando a perdas de coerência e consistência nas respostas. O modelo frequentemente omitia partes da análise ou apresentava alucinações em algumas respostas. Para mitigar esse problema, adotou-se uma abordagem de sistemas multiagente, amplamente utilizada em projetos de Inteligência Artificial. Essa estratégia consiste em dividir o processo analítico em múltiplos agentes especializados, cada um responsável por uma etapa específica da análise, com contexto suficiente para executar sua função de forma eficaz. Os dados gerados por cada agente são, então, organizados e integrados posteriormente.

Essa divisão em dois fluxos principais (ou “*chunks*”) resultou em um ganho significativo de precisão e concisão nos resultados. Para operacionalizar essa arquitetura, utilizou-se a ferramenta n8n, que atuou como orquestradora dos fluxos de agentes, permitindo automatizar a sequência de interações entre os módulos e assegurar a coesão do processo de análise.

4.5.1.3 Aplicação de IA final para qualificação da *startup*

O produto final desenvolvido para esta primeira oportunidade de aplicação de IA no fundo de VC consistiu em um agente conversacional de IA, implementado na plataforma ChatGPT, com foco na qualificação automatizada de *startups*. A aplicação foi estruturada para operar de maneira simples e interativa, possibilitando que o

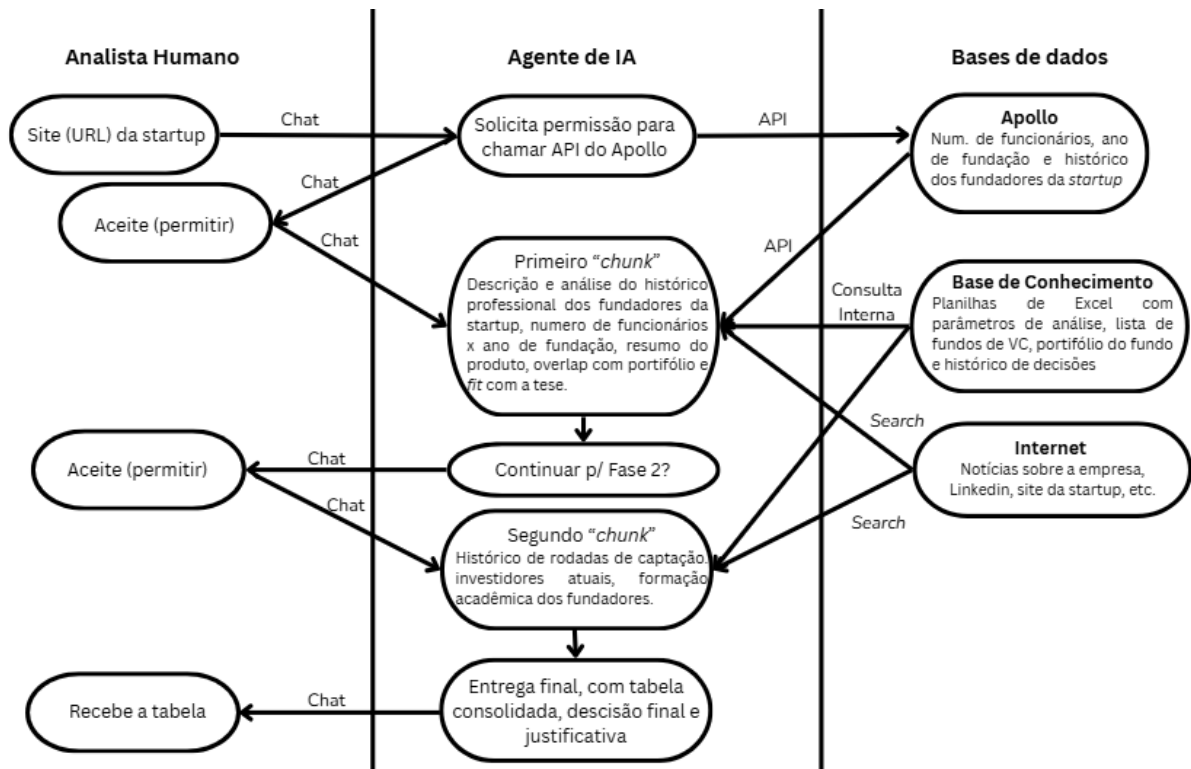
usuário inicie a análise apenas informando o endereço eletrônico do site da empresa a ser avaliada.

Após o acionamento, o agente de IA solicita autorização para acessar a API da ferramenta Apollo, a qual é responsável por coletar dados estruturados da empresa, como número de funcionários, data de fundação, identificação dos fundadores e seus históricos profissionais. No primeiro *chunk*, o agente combina os dados da Apollo com informações da base de conhecimento interna (parâmetros de avaliação, portfólio, teses de investimento) e dados públicos da internet para entregar uma análise inicial abrangendo: análise da equipe fundadora, características do produto, se concorre com empresas do portfólio e avaliação de *fit* com a tese de investimento. Concluída essa fase, o agente solicita uma segunda autorização para executar o segundo *chunk*, que complementa a análise com informações sobre o histórico de *fundraising* da empresa e o background acadêmico dos fundadores. Essa etapa integra dados da base de conhecimento interna e de fontes públicas disponíveis na internet.

O resultado final é apresentado em uma tabela-síntese, que reúne as principais dimensões avaliadas: equipe fundadora, produto e tese de investimento, mercado e concorrência, histórico de captação, além de outras informações complementares relevantes. Essa tabela organiza os dados de forma clara e objetiva, permitindo uma visualização rápida, padronizada e comparativa entre diferentes *startups* analisadas. A avaliação é realizada em nove dimensões distintas, cada uma classificada segundo três níveis de desempenho: Ideal, Aceitável ou Preocupante. Essa categorização possibilita uma leitura imediata da aderência da *startup* aos parâmetros definidos, destacando pontos fortes e fragilidades de forma visual e estruturada. Com base nessa matriz de avaliação, o agente de IA gera automaticamente uma recomendação de avanço ou não nas próximas etapas do funil de investimentos, fundamentada nos critérios pré-estabelecidos e na ponderação dos resultados obtidos em cada dimensão.

A Figura 4.2 apresenta a arquitetura da aplicação de IA, ilustrando o fluxo completo: os *inputs* fornecidos pelo analista humano, os dados processados pelo agente de IA e as saídas geradas pelo sistema, explicitando a dinâmica de funcionamento da solução.

Figura 4.2 - Arquitetura da aplicação de IA “Qualificar *startups*”



Fonte: Autoria própria.

Com essa configuração, o produto final entrega um processo completo, automatizado e interpretável de qualificação de *startups*, reduzindo o tempo de análise, padronizando critérios e apoiando a tomada de decisão de forma transparente e rastreável. A arquitetura modular adotada (com múltiplos agentes e integração via n8n) permite, ainda, a evolução incremental da solução, viabilizando a adição de novas fontes de dados, dimensões de análise e aprimoramentos futuros sem comprometer a estrutura existente.

4.5.1.4 Resultados quantificáveis e limitações

A aplicação de IA vem sendo testada e utilizada na organização como parte da rotina de qualificação de *startups*. No Apêndice A, apresenta-se os resultados detalhados obtido a partir da demonstração da aplicação de IA em um cenário real realizado com a *startup* WeHandle, um software de gestão de serviços terceirizados voltado a grandes corporações, que passou pelo processo de análise do fundo de *venture capital* deste estudo de caso.

A implementação do agente de IA para a qualificação de *startups* gerou ganhos tangíveis de eficiência e qualidade para a gestora do fundo de VC do estudo de caso.

O principal impacto observado foi a redução significativa do tempo de qualificação, uma vez que a extração e a análise de informações passaram a ocorrer de forma automatizada, eliminando etapas manuais que antes demandavam elevado esforço operacional. Uma análise que durava entre 15-20 minutos por empresa passou a ser feita em 5 minutos, aproximadamente.

Além da economia de tempo, a ferramenta demonstrou capacidade de identificar e consolidar dados que, em alguns casos, não seriam facilmente encontrados por meio de pesquisa manual, ampliando a profundidade da análise e a base informacional disponível para os analistas. O produto final, ao gerar um “relatório” padronizado e auditável, permitiu também aumentar a transparência e a rastreabilidade das decisões, oferecendo evidências claras que sustentam o racional por trás de cada recomendação. Outro resultado relevante foi o apoio à tomada de decisão com menor viés subjetivo. Ao adotar parâmetros objetivos e uma estrutura de avaliação replicável, o agente contribuiu para maior consistência nas decisões de investimento, reduzindo a influência de percepções individuais.

Do ponto de vista organizacional, o desenvolvimento do MVP proporcionou uma base metodológica e técnica sólida para a expansão do uso da IA generativa em outras etapas do funil de investimento. A arquitetura criada, combinando agentes especializados e base de conhecimento serve agora como framework para o desenvolvimento de novos agentes, aplicáveis em fases como análise de *pitch decks*, priorização de *startups* para *deep dive* e até na avaliação de desempenho pós-investimento.

Apesar dos resultados positivos, algumas limitações foram identificadas durante o uso do sistema. A principal delas está relacionada à inconsistência na obtenção de informações acadêmicas dos fundadores, uma vez que esses dados nem sempre estão disponíveis nas fontes acessadas pela API da Apollo. Outra limitação diz respeito à identificação de *overlaps* com o portfólio existente, que, em alguns casos, apresentou erros de interpretação ou “alucinações”. Esse fenômeno decorre da ausência de vetorização da base de dados sobre as empresas do portfólio, que restringe a capacidade do modelo de linguagem em reconhecer similaridades conceituais entre empresas.

Adicionalmente, a solução ainda não incorpora o histórico subjetivo de decisões e percepções estratégicas da equipe de investimentos, o que limita a personalização das análises. Essa lacuna está sendo endereçada por meio da construção de um

repositório estruturado de teses e experiências anteriores, que servirá como insumo para versões futuras do agente. Por fim, observou-se que a busca por informações de captação (*fundraising*) ainda depende, em grande parte, de notícias públicas, o que pode gerar lacunas nos casos de rodadas menores ou de investidores-anjo não divulgados. Uma evolução prevista é o treinamento do agente para identificar investidores individuais via LinkedIn, ampliando a precisão das análises.

4.5.2 Aplicação potencial de IA núm. 3 “Preparação para conversas”

Para melhor compreensão da discussão da implementação dessa aplicação potencial de IA “Preparação para conversas” no contexto do fundo de VC, apresentam-se as discussões em quatro subseções.

4.5.2.1 Definição de requisitos da aplicação de IA

O objetivo final desta aplicação é aprimorar a qualidade das interações com os fundadores da *startup*, qualificada em etapa anterior do funil de investimento, de modo a transformar a preparação de reuniões em um processo sistemático e personalizado, suportado por IA generativa. A aplicação de IA deve atuar como um recurso estratégico para enriquecer o preparo das entrevistas, garantindo que os analistas abordem os temas mais relevantes e evitem lacunas de informação. De forma análoga à aplicação anterior, o agente de pesquisa e análise receberá como input primário o endereço eletrônico do site da *startup* e, a partir dele, entregará um “roteiro” estruturado com os principais pontos a serem abordados durante a chamada. Os requisitos de informação para a composição do roteiro são detalhados a seguir:

I. Resumo executivo da *startup*:

- A IA deve gerar um Resumo Breve para “relembrar” o analista sobre o core business da empresa. Este resumo deve incluir: definição concisa do que a empresa faz; o mercado de atuação e o modelo de negócio adotado; sinais de tração e o histórico de *fundraising* da *startup*

II. Análise detalhada do produto/serviço:

- O sistema deve realizar uma análise aprofundada do produto(s) ou serviço(s) oferecido(s), incluindo uma descrição breve de cada um e a proposta de valor central entregue ao cliente.

III. Recomendação para a conversa (identificação de pontos críticos):

- Esta é a parte de maior valor agregado da ferramenta. O sistema deve ser capaz de identificar de quatro a cinco pontos críticos, riscos ou dúvidas que a IA recomendaria investigar durante a chamada.
- Tais pontos devem variar por empresa, mas tipicamente envolvem: potencial de escalabilidade; análise da concorrência (incumbentes, competidores, saturação de mercado, "mar azul" ou "mar vermelho"); maturidade e tamanho do mercado; barreiras de entrada e riscos regulatórios.

IV. Uso inteligente do histórico de interações (para conversas subsequentes):

- Análise de Transcrições: Em casos de conversas subsequentes, a IA deverá apoiar-se em registros já disponíveis, como sistemas de CRM ou ferramentas de transcrição de reuniões (ex: Fireflies).
- Identificação de lacunas e progressão lógica: A partir desse material, o sistema deve identificar de forma estruturada quais pontos já foram explorados e quais permanecem pouco claros ou precisam ser endereçados.

4.5.2.2 Processo de implementação da aplicação de IA

O processo de implementação seguiu uma lógica bastante semelhante à do primeiro agente de IA discutido na Seção 4.5.1.2. O objetivo era centralizar as ferramentas em uma única interface, e para isso foi utilizado o ChatGPT, com GPTs personalizados. Esse agente baseia-se quase integralmente no *system prompt*, sem necessidade de uma base de conhecimento externa extensa. Ainda assim, foi utilizado o mesmo arquivo de portfólio como fonte complementar de dados.

O *prompt* foi estruturado para guiar o agente por etapas de análise bem definidas. Primeiro, ele realiza uma avaliação interna da empresa, identificando e organizando informações sobre produtos e soluções. Em seguida, passa à análise de riscos estratégicos, na qual é instruído a investigar fatores críticos como diferenciais

competitivos, principais concorrentes (nacionais e internacionais), barreiras de entrada e potencial de escalabilidade.

Com essa abordagem, foi possível desenvolver um MVP funcional do agente, capaz de gerar roteiros consistentes e estruturados que apoiam de forma eficaz a preparação de conversas exploratórias. A principal limitação identificada, contudo, está na falta de integração com ferramentas externas como CRM ou Fireflies, o que impede o acesso ao histórico de interações. Por esse motivo, o agente apresenta ótimo desempenho em primeiras conversas, quando há pouca informação prévia sobre a *startup*, mas torna-se limitado em etapas posteriores, nas quais o contexto acumulado passa a ser fundamental. Essa limitação decorre da complexidade técnica envolvida em integrar múltiplas fontes de dados e analisar informações não estruturadas. Apesar disso, o uso do agente em estágios iniciais é altamente relevante, considerando que a maioria das *startups* não avança para fases subsequentes de análise.

Por se tratar de um agente de suporte analítico, ele recebeu menor prioridade em relação ao primeiro agente, voltado à tomada de decisão, que ainda apresentava lacunas significativas em seu MVP. Ainda assim, este segundo agente mostrou-se mais consistente e estável, entregando resultados práticos e de real valor para a rotina do fundo.

4.5.2.3 Aplicação de IA final para preparação para conversas

O produto final desenvolvido consiste em um agente conversacional de Inteligência Artificial, implementado na plataforma ChatGPT, voltado à preparação estruturada de conversas com fundadores de *startups*. A aplicação foi concebida para operar de forma simples e intuitiva, a partir de um único *input*: o endereço eletrônico do site da empresa a ser analisada. A partir desse ponto, o agente realiza automaticamente a coleta, síntese e organização das informações necessárias para apoiar o analista antes de uma reunião.

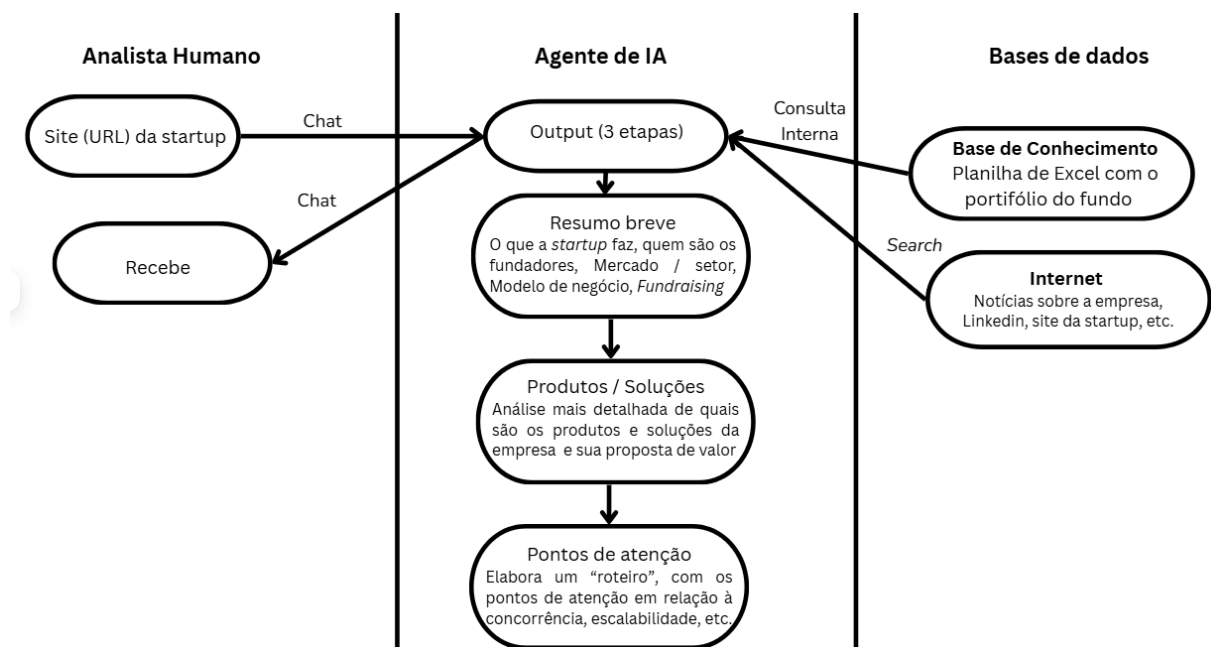
O agente segue uma sequência analítica estruturada em três etapas principais. Na primeira, gera um resumo executivo da *startup*, sintetizando o *core business*, o mercado de atuação, o modelo de negócio e eventuais sinais de tração ou histórico de captação. Em seguida, realiza uma análise detalhada do produto ou serviço, identificando sua proposta de valor central, diferenciais competitivos e características

de posicionamento no mercado. Por fim, o sistema apresenta uma recomendação de pauta para a conversa, composta por quatro a cinco pontos críticos ou dúvidas estratégicas que devem ser explorados durante a reunião, como potenciais riscos de escalabilidade, barreiras de entrada, saturação de mercado ou *gaps* na proposta de valor.

O resultado final é entregue em formato de roteiro estruturado, dividido em seções claras e objetivas, que permitem ao analista compreender rapidamente os aspectos essenciais da *startup* e conduzir a conversa de forma mais estratégica. A estrutura padronizada do roteiro facilita a comparação entre diferentes empresas e garante consistência na preparação, reduzindo a dependência de memória ou de anotações dispersas.

De maneira semelhante ao que foi feito no item anterior, a Figura 4.3 resume a arquitetura da aplicação de IA, com os inputs, dados processados e as saídas. Cabe destacar que esta representação contribui para o entendimento da aplicação assim como replicação em outros contextos.

Figura 4.3 - Arquitetura da aplicação de IA “Preparação para conversas”



Fonte: Autoria Própria.

4.5.2.4 Resultados quantificáveis e limitações

Igualmente à anterior, esta aplicação de IA também vem sendo usada na organização para empresas que passam para a etapa de realização da 1ª conversa. Ou seja, avançam da etapa de qualificação da *startup*. No Apêndice B, apresenta-se a demonstração de um cenário real de funcionamento desta aplicação de IA, realizado com a mesma *startup* WeHandle, após ter concluída a etapa de qualificação da *startup*. A ideia que os resultados apresentados no apêndice contribuam para ilustrar quais são as saídas desta aplicação de IA, seguindo a arquitetura da Figura 4.3.

A implementação do agente de IA de preparação para conversas resultou em ganhos significativos de eficiência, qualidade e consistência nas interações com fundadores de *startups*. O principal impacto observado foi a redução do tempo de preparação de reuniões, que anteriormente demandava de 10 a 15 minutos por empresa e passou a ser realizada em cerca de 3 a 5 minutos, com maior padronização e profundidade analítica. Esse ganho operacional permitiu que os analistas concentrassem esforços nas etapas de maior valor agregado do processo de investimento.

Além da economia de tempo, o agente demonstrou capacidade de ampliar a qualidade do preparo, reunindo em um único roteiro informações que, antes, estavam dispersas entre anotações, pesquisas manuais e trocas informais. O formato padronizado de saída também contribuiu para aumentar a comparabilidade entre *startups*, facilitando a priorização de oportunidades e a identificação de padrões relevantes. Outro benefício percebido foi o aumento da confiança e da fluidez nas conversas com fundadores, uma vez que os analistas passaram a chegar às reuniões com maior preparo sobre o negócio, o mercado e os potenciais pontos de atenção.

Apesar dos resultados positivos, algumas limitações foram identificadas. A principal delas está relacionada à ausência de integração com sistemas externos, como CRMs ou ferramentas de transcrição, o que restringe o uso do agente em interações subsequentes com a mesma empresa. Sem esse histórico, a ferramenta não é capaz de identificar automaticamente lacunas de informação ou acompanhar a progressão das conversas ao longo do processo de análise.

Outra limitação observada refere-se à dependência de informações públicas disponíveis nos sites das *startups* ou em fontes acessíveis via busca. Em casos de empresas em estágio muito inicial ou com pouca presença digital, o agente tende a

gerar roteiros mais genéricos, com menor densidade informacional. Ainda assim, nessas situações, o modelo manteve a capacidade de estruturar perguntas relevantes, preservando sua utilidade prática. Por fim, o agente não incorpora, nesta versão, a base de conhecimento da organização, com percepções subjetivas, hipóteses estratégicas ou aprendizados de interações anteriores. Esses fatores, se devidamente capturados, poderiam enriquecer a personalização dos roteiros.

4.6 PROPOSTA FINAL DE SOLUÇÃO

Com base no framework do MIT (BRUNHAM, 2025), Figura 2.2., é possível identificar que a organização evoluiu da fase inicial de maturidade para a segunda etapa: *Build Pilots and Capabilities*. Isso se deve ao fato de que, a partir das soluções já implementadas, observou-se o início de um processo consistente de simplificação e automação de atividades, bem como a criação de casos de uso com Inteligência Artificial.

Entretanto, os MVPs desenvolvidos representam apenas o ponto de partida. Há oportunidades claras para aprofundar o nível de maturidade, expandindo o escopo dos processos automatizados e aumentando o grau de integração da IA generativa nas operações, para alcançar o próximo patamar de maturidade. Dessa forma, esta seção apresenta as propostas de evolução tanto das duas soluções selecionadas quanto da ampliação do uso da IA em outras áreas da organização, visando consolidar uma jornada contínua de transformação digital e de ganho de eficiência operacional.

4.6.1 Proposta de aplicação de IA na etapa “Qualificar *startups*”

A partir do MVP desenvolvido e discutido na Seção 4.5.1, a proposta final de solução tem como objetivo elevar o agente de qualificação de *startups* a um nível superior de maturidade, precisão e escalabilidade, consolidando-o como uma ferramenta estratégica e central no processo de triagem e decisão do fundo. Essa evolução envolve aprimoramentos técnicos e estruturais, com foco na modularização do sistema, na ampliação das fontes de dados e na incorporação do conhecimento organizacional acumulado pela equipe.

O primeiro eixo de desenvolvimento concentra-se na melhoria do fluxo de orquestração implementado no n8n. A proposta consiste em torná-lo mais granular e flexível, substituindo a atual divisão em dois “*chunks*” principais por uma arquitetura multiagente especializada, na qual cada módulo seja responsável por uma dimensão específica da análise. Essa abordagem permitirá a criação de agentes dedicados à avaliação da equipe fundadora, à análise de mercado e concorrência e à verificação de *fit* com a tese de investimento, entre outras dimensões. Com isso, o sistema se tornará mais preciso, rastreável e adaptável, possibilitando ajustes incrementais sem comprometer o fluxo geral de funcionamento.

Outro aprimoramento relevante está na ampliação das fontes de dados utilizadas. Uma das limitações observadas na versão inicial do agente foi a dificuldade em acessar informações acadêmicas dos fundadores, dado que a API atualmente integrada (Apollo) não fornece esses dados. Para superar essa restrição, propõe-se a integração com a API do Perplexity, uma tecnologia baseada em IA generativa que realiza buscas em tempo real na internet e é capaz de extrair o histórico acadêmico a partir da busca do perfil do LinkedIn. Paralelamente, a própria API do Apollo poderá ser explorada de forma mais abrangente, permitindo a identificação não apenas de fundadores, mas também de investidores-anjo e membros de conselhos, com base em cargos e palavras-chave específicas. Essa expansão aumentará a completude das análises de *fundraising* das *startups*.

No âmbito da arquitetura de dados, propõe-se a substituição dos arquivos em formato texto e planilhas atualmente utilizados por uma estrutura vetorizada, que permita ao agente reconhecer similaridades semânticas entre *startups*, portfólios e teses de investimento. O uso de tecnologias de vetorização em ambiente *low-code*, em rápida evolução, representa um avanço significativo para reduzir erros de interpretação e aprimorar a capacidade do modelo de linguagem, além de evitar as alucinações que ocorrem hoje. Além disso, prevê-se a adoção do Model Context Protocol (MCP Server), uma tecnologia recente que expande o contexto de trabalho dos agentes de IA e possibilita a integração de múltiplas fontes de informação, tanto estruturadas (como planilhas, CRMs e APIs) quanto não estruturadas (como textos e notícias). Essa camada adicional ampliará o contexto analítico disponível ao modelo, tornando as análises mais completas e contextualizadas.

Outro eixo central da proposta refere-se à formalização do conhecimento tácito acumulado pela equipe de investimentos. Atualmente, boa parte das heurísticas,

percepções estratégicas e teses de análise encontra-se dispersa na experiência individual dos analistas. O objetivo, portanto, é sistematizar esse conhecimento e convertê-lo em uma base estruturada de aprendizados e parâmetros qualitativos, que possa ser incorporada à base de conhecimento do agente. Embora seja um processo trabalhoso, essa iniciativa permitirá capturar a “intuição institucional” do fundo, garantindo maior consistência nas avaliações e reduzindo a dependência de julgamentos individuais.

Com a implementação desses aprimoramentos, espera-se alcançar ganhos significativos em precisão analítica, consistência e escalabilidade do sistema. O agente passará a gerar análises mais completas e contextualizadas, com menor incidência de erros e alucinações, maior integração de dados e capacidade de evolução contínua. Em síntese, a proposta final consolida o agente de qualificação de *startups* como uma plataforma inteligente, modular e autoevolutiva, capaz de combinar múltiplas fontes de informação e aprendizado institucional para apoiar, de forma confiável e escalável, o processo de decisão de investimento.

4.6.2 Proposta de aplicação de IA na etapa “Preparação para conversas”

O desenvolvimento de um agente de IA de preparação para conversas tem como objetivo torná-lo um sistema cada vez mais inteligente e estratégico, capaz de apoiar o time de investimento não apenas na organização das informações sobre uma *startup*, mas também na geração de insights que orientem diálogos mais profundos, críticos e direcionados. A proposta busca transformar o agente em um copiloto analítico, que aprenda com interações passadas e contribua ativamente para a qualidade das discussões com os fundadores.

Um dos principais aprimoramentos propostos consiste em treinar o agente com base nas perguntas que já foram feitas em reuniões anteriores. A partir dessa base histórica, o modelo poderia identificar padrões e lacunas, sugerindo novas perguntas mais relevantes, provocativas e específicas, indo além do nível superficial e explorando dimensões que testem a visão, a capacidade analítica e o pensamento estratégico do fundador. Com o tempo, o agente se tornaria capaz de reconhecer o estilo de questionamento da equipe e propor abordagens complementares.

Outro avanço importante diz respeito à ampliação da profundidade das análises concorrenciais. Atualmente, o agente é capaz de identificar concorrentes diretos e

indiretos de uma *startup*, mas de forma ainda descritiva. A proposta é que ele passe a contextualizar esses concorrentes dentro do mercado, explorando elementos como histórico de saídas, rodadas de investimento, diferenciais tecnológicos e posicionamento competitivo. Essa camada adicional permitiria à equipe entender não apenas quem compete com a *startup* analisada, mas também como esses concorrentes evoluíram e quais aprendizados podem ser extraídos de seus movimentos estratégicos.

Em termos de contexto informacional, propõe-se a integração do agente com bases internas como o Fireflies e o CRM utilizado pelo fundo. Essa integração permitirá ao agente compreender o histórico completo de interações com cada empresa (o que já foi perguntado, o que foi respondido e o que ainda não foi explorado), tornando as próximas conversas mais objetivas e bem direcionadas. Essa camada de memória operacional complementa a base de conhecimento institucional mencionada na aplicação anterior, criando um ecossistema de dados que combina informações factuais, contextuais e relacionais.

Por fim, a proposta de longo prazo é incorporar ao agente a capacidade de ajustar seu comportamento conforme o tipo de reunião. Ao receber como input o estágio da interação, por exemplo, uma primeira conversa, uma segunda *call* ou uma imersão, o agente poderá adaptar o nível de detalhamento e o tipo de perguntas sugeridas de acordo com os objetivos específicos de cada etapa. Em reuniões iniciais, por exemplo, o foco poderia estar em explorar o problema e o mercado; em fases mais avançadas, o agente poderia sugerir perguntas sobre métricas, diferenciais de produto e visão de longo prazo.

Com esses aprimoramentos, o agente de preparação para conversas evolui de uma ferramenta de suporte informacional para uma plataforma capaz de combinar aprendizado histórico, análise de mercado e adaptação contextual. Espera-se que, a partir dessa evolução, as interações entre o fundo e as *startups* se tornem mais produtivas, profundas e estratégicas, reforçando o papel do agente como um parceiro cognitivo no processo de decisão e relacionamento com empreendedores.

4.6.3 Outras propostas de aplicações de IA e oportunidades futuras

As aplicações de IA generativa desenvolvidas neste trabalho possui potencial de aplicação em diversas outras etapas do processo de investimento, ampliando de

forma significativa o impacto e a utilidade da solução no médio e longo prazo. Embora o foco inicial tenha sido direcionado para as etapas de qualificação de *startups* e preparação para conversas, as arquiteturas propostas e os aprendizados obtidos podem ser estendidos para outras etapas do funil de investimento.

Um exemplo claro dessa expansão está na etapa de encontrar *startups*. Toda a estrutura analítica construída no agente de qualificação pode ser aplicada à identificação de *startups* em listas públicas, bancos de dados de inovação e portfólios de aceleradoras e fundos. A mesma lógica de classificação e ranqueamento pode ser utilizada para automatizar parte do processo de descoberta, sugerindo oportunidades alinhadas à tese do fundo e reduzindo o tempo gasto em análises preliminares. De forma análoga, a inteligência desenvolvida para análise contextual e de concorrência pode ser aproveitada para avaliação de *pitch decks*, auxiliando na identificação de inconsistências, riscos e diferenciais competitivos ainda na fase inicial de contato.

Outras possibilidades incluem o aprimoramento das etapas de *deep dive* e preparação de memorandos de investimento, em que os agentes poderiam apoiar a estruturação de análises mais completas e consistentes, agregando dados históricos e informações extraídas automaticamente de múltiplas fontes. Essa integração entre diferentes aplicações permitiria uma continuidade natural entre as fases do processo, em que cada agente contribui com uma camada específica de inteligência, mas dentro de um mesmo ecossistema.

Além disso, a própria experiência acumulada na criação e operação desses agentes, como integrações, uso de ferramentas e bases de conhecimento, tende a evoluir continuamente. Com o tempo, espera-se que o time de investimento desenvolva não apenas novas ferramentas, mas também uma cultura interna de experimentação e aprendizado em IA generativa, incorporando progressivamente essas soluções na rotina analítica e decisória do fundo.

O objetivo final desse movimento não é substituir o analista humano, mas potencializar sua capacidade de análise, interpretação e tomada de decisão. Ainda que as tecnologias avancem em velocidade notável, a autonomia total dos agentes de IA permanece limitada por fatores como contexto, julgamento qualitativo e nuances subjetivas das interações humanas. Assim, o papel desses sistemas deve ser entendido como o de copilotos inteligentes, com potencial para aumentar a eficiência, reduzir o esforço operacional e oferecer suporte estruturado à análise, sem comprometer o protagonismo do discernimento humano no processo de investimento.

5 CONCLUSÕES

O presente Trabalho de Formatura dedicou-se a investigar a intersecção entre a tecnologia de IA generativa e a indústria de fundo de *venture capital*. Reconhecendo os avanços tecnológicos provocados pela popularização da IA generativa, o estudo partiu da premissa de que a IA generativa representa uma alavanca estratégica para a otimização das atividades-chave das gestoras. Dessa forma, o objetivo geral estabelecido para a pesquisa foi investigar como ferramentas e plataformas de Inteligência Artificial podem ser integradas aos processos e rotinas operacionais de uma gestora de fundo de *venture capital*, com foco na melhoria da produtividade e no apoio à tomada de decisão.

Para atingir o objetivo proposto, a pesquisa adotou uma metodologia de natureza aplicada, com abordagem qualitativa e caracterizada como um estudo de caso em um fundo de CVC focado em investimentos *early stage*. O caminho metodológico foi estruturado em etapas sequenciais: 1) Coleta de dados e definição de escopo, que inclui o mapeamento das rotinas e gargalos do time; 2) Levantamento de aplicações potenciais de IA generativa que pudessem atender às necessidades identificadas; 3) Matriz de priorização, usando critérios de impacto e viabilidade, resultando na escolha de duas aplicações; 4) Implementação e desenvolvimento das soluções como MVP; e 5) Mensuração de resultados, avaliando a eficácia das novas ferramentas e a evolução da maturidade em IA da gestora do fundo de VC.

Os resultados alcançados demonstraram o potencial transformador das aplicações de IA generativa nas rotinas de prospecção e análise de *startups*. O primeiro MVP, focado na Qualificação de *startups*, permitiu a automação da extração e análise de informações críticas (time, produto, mercado), culminando na redução do tempo de qualificação de 15 a 20 minutos para, aproximadamente, 5 minutos por empresa. Paralelamente, o segundo MVP, destinado à Preparação para Conversas, forneceu roteiros estruturados e resumos executivos, diminuindo o tempo de preparo de reuniões de 10 a 15 minutos para uma média de 3 a 5 minutos.

Essas melhorias quantificáveis liberaram tempo valioso da equipe de investimento, permitindo que os profissionais alocassem seus esforços em atividades de maior valor estratégico, como o relacionamento com empreendedores e a análise aprofundada de *deal flow* promissor. Em termos de maturidade organizacional, a

gestora, que antes estava na fase de "Experimentar e preparar", avançou para a fase de "Construir pilotos e capacidades" no Framework de Maturidade em IA do MIT.

Como oportunidades futuras de pesquisa e desenvolvimento, sugere-se a expansão e integração dos MVPs implementados com o CRM e demais sistemas internos do fundo de *venture capital*. Além disso, as aplicações baseadas em IA generativa desenvolvidas neste trabalho podem ser ampliadas para diversas outras etapas do funil de investimento, reaproveitando a arquitetura criada para qualificação de *startups* e preparação para conversas. As mesmas capacidades e bases de conhecimento podem apoiar atividades como encontrar *startups*, avaliar *pitch decks*, conduzir *deep dives* e preparar memorandos.

Por fim, cabe destacar que a integração progressiva destas aplicações de IA generativas baseadas em agentes tende a criar um ecossistema contínuo de suporte analítico, fortalecendo a cultura interna de uso de IA. Ainda, recomenda-se também a realização de um estudo ao longo do tempo para mensurar o impacto das aplicações de IA na performance de longo prazo dos investimentos e na taxa de sucesso das *startups* selecionadas.

REFERÊNCIAS

ABRIDGE. Disponível em: <https://www.abridge.com>. Acesso em: 21 nov. 2025.

ALVES, V. H. **Panorama da prática de corporate venture capital no Brasil: como as corporações brasileiras estão investindo no ecossistema de inovação**. 2022. Trabalho de Conclusão de Curso (Administração) – Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade, São Paulo, 2022.

ALKYMI. Disponível em: <https://www.alkymi.io>. Acesso em: 13 set. 2025.

ANTHROPIC. Collaborate with Claude on Projects. Anthropic News, 25 jun. 2024. Disponível em: <https://www.anthropic.com/news/projects>. Acesso em: 9 set. 2025.

ARTIFICIAL ANALYSIS. Comparison of Models: Intelligence, Performance & Price Analysis. nov. 2025. Disponível em: <https://artificialanalysis.ai/models#intelligence>. Acesso em: 23 nov. 2025.

BCG. The leader's guide to transforming with AI. BCG, 12 dez. 2024. Disponível em: <https://www.bcg.com/featured-insights/the-leaders-guide-to-transforming-with-ai>. Acesso em: 02 out. 2025.

BELLO, S. Symbolic AI vs. Machine Learning: A Comprehensive Guide. SmythOS – Developers. 2024. Disponível em: <https://smythos.com/developers/agent-development/symbolic-ai-vs-machine-learning/>. Acesso em: 19 ago. 2025.

BERGER, M.; DECHEZLEPRÊTRE, A.; FADIC, M. What is the role of Government Venture Capital for innovation-driven entrepreneurship? **OECD Science, Technology and Industry Working Papers**, No. 2024/10. OECD Publishing, Paris, 2024.

BHAT, H. S.; ZAELIT, D. Predicting private company exits using qualitative data. In: PACIFIC-ASIA CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 2011, Berlin. Anais [...]. Berlin: Springer, 2011. p. 399-410.

BLANK, S.; DORF, B. **The Startup Owner's Manual: The Step-By-Step Guide for Building a Great Company**. 1. ed. Pescadero: K&S Ranch, 2012.

BOUSQUETTE, I. Morgan Stanley Moves Forward on Homegrown AI. The Wall Street Journal, New York, NY, 26 de julho de 2024. Disponível em: <https://www.wsj.com/articles/morgan-stanley-moves-forward-on-homegrown-ai-120c59ab>. Acesso em: 9 set. 2025.

BRUNHAM, K. What's your company's AI maturity level?. MIT Sloan School of Management, 25 fev. 2025. Disponível em: <https://mitsloan.mit.edu/ideas-made-to-matter/whats-your-companys-ai-maturity-level>. Acesso em: 22 set. 2025.

BURKHARDT, S.; REIDER, B. Foundation models are platform models: Prompting and the political economy of AI. **Big Data & Society**, 11(2). abr, 2024.

CARVALHO, A. G.; FURTADO, C. V.; RIBEIRO L. L. **1º Censo brasileiro da indústria de Private Equity e Venture Capital**. São Paulo: Editora Nonono, 2006.

DISTRITO. Histórico do venture capital no Brasil: do surgimento até hoje. Distrito, São Paulo, 17 out. 2021. Disponível em: <https://distrito.me/blog/historico-do-venture-capital-no-brasil/>. Acesso em: 12 ago. 2025.

CB INSIGHTS. Disponível em: <https://www.cbinsights.com>. Acesso em: 13 set. 2025.

CLAY. Disponível em: <https://www.clay.com>. Acesso em: 21 nov. 2025.

CRUNCHBASE. Crunchbase Company Database. 2025. Disponível em: <https://www.crunchbase.com/>. Acesso em: 14 ago. 2025.

CUI, J.; ZHANG, W.; TANG, J.; TONG, X.; ZHANG, Z.; AMIE; WEN, J.; WANG, R.; WU, P. AnyTaskTune: Advanced Domain-Specific Solutions through Task-Fine-Tuning. *arXiv preprint*, v. 2407.07094, Jul. 2024.

CLAY. Disponível em: <https://cursor.com/>. Acesso em: 21 nov. 2025.

COGLIATI, D. AI as a Signal: Funding Effects of Key Generative AI Milestones on Startups. 2025. Dissertação (Mestrado em International Management) - Universidade de Utrecht, Utrecht, 2025.

DA RIN, M.; HELLMANN, T.; PURI, M. A survey of venture capital research. In: CONSTANTINIDES, G.; HARRIS, M.; STULZ, R. (Ed.). **Handbook of the economics of finance: corporate finance**. v. 2A. Amsterdam: Elsevier, 2013. p. 573–648.

DAHIYA, S.; RAY, K.. Staged Investments in Entrepreneurial Financing. **Journal of Corporate Finance**, v. 18, n. 5, p. 1193–1216, 2012.

DE KLERK, J.N. **Artificial Intelligence in Venture Capital**. 2025. Dissertação (Mestrado em Tecnologia, Política e Gestão) – Universidade Técnica de Delft, Delft, 2025.

DIXON, M.; CHONG, J. A Bayesian approach to ranking private companies based on predictive indicators. **AI Communications**, [S.I.], v. 27, n. 2, p. 173–188, 2014.

ENTER. Disponível em: <https://www.getenter.ai>. Acesso em: 21 nov. 2025.

FERNANDES, A.; ROCA, G. Brasil não pode perder a oportunidade da revolução da inteligência artificial, diz copresidente da General Atlantic. O Globo, 14 maio 2025. Disponível em: <https://oglobo.globo.com/economia/summit-brazil-eua-2025/noticia/2025/05/14/summit-brazil-usa-brasil-nao-pode-perder-a-oportunidade-da-revolucao-da-inteligencia-artificial-diz-copresidente-da-general-atlantic.ghtml>. Acesso em: 11 ago. 2025.

FINSIDERS BRASIL. Investimentos de venture capital somam R\$ 46,5 bilhões em 2021. Finsiders Brasil, São Paulo, 2022. Disponível em: <https://finsidersbrasil.com.br/tecnologia-para-fintechs/investimentos-de-venture-capital-somam-r-465-bilhoes-em-2021-diz-pesquisa-da-abvcap-e-kpmg/> . Acesso em: 12 ago. 2025.

FIREFLIES. Disponível em: <https://fireflies.ai/>. Acesso em: 21 nov. 2025.

FONTELLES, M. J.; SIMÕES, M. G.; FARIAS, S. H.; FONTELLES, R. G. S. Metodologia da pesquisa científica: diretrizes para a elaboração de um protocolo de pesquisa. **Revista Paraense de Medicina**, v. 23, n. 3, p. 1–8, jul./set. 2009.

GARTNER, 2025. Disponível em: https://www.linkedin.com/posts/gartner_ai-innovation-leadership-activity-7376592246495748096-W_Ya/. Acesso em: 30 set. 2025.

GASTAUD, C.; CARNIEL, T.; DALLE, J.-M. The emerging sectoral diversity of startup ecosystems. Paris, 2019. Disponível em: <https://arxiv.org/abs/1906.02455>. Acesso em: 14 ago. 2025.

GERHARDT, E.; SILVEIRA, M. **Métodos de pesquisa: classificados quanto a objetivos, procedimentos técnicos, natureza e abordagem**. 1. ed. Porto Alegre: Editora da UFRGS, 2009.

GHOSH, S. The venture capital secret: 3 out of 4 start-ups fail. The Wall Street Journal, 20 set. 2012. Disponível em: <https://www.wsj.com/articles/SB10000872396390443720204578004980476429190v> Acesso em: 12 ago. 2025.

GIL, A. C.. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Editora Atlas, 2002.

GOMPERS, P. A. Optimal Investment, Monitoring, and the Staging of Venture Capital. **The Journal of Finance**, v. 50, n. 5, p. 1461–1489, dez., 1995.

GOMPERS, P.; LERNER, J. The venture capital revolution. **Journal of Economic Perspectives**, v. 15, n. 2, p. 145–168, abr. 2001.

GOMPERS, P.; KOVNER, A.; LERNER, J. Specialization and success: evidence from venture capital. **Journal of Economics & Management Strategy**, v. 18, n. 3, p. 817–844, set., 2009.

GOMPERS, P. A.; GORNALL, W.; KAPLAN, S.N.; STREBULAEV, I. A. How do venture capitalists make decisions? **Journal of Financial Economics**, v. 135, n. 1, p. 169–190, jan., 2020.

GOOGLE CLOUD. Vertex AI. Disponível em: <https://cloud.google.com/vertex-ai#features>. Acesso em: 11 set. 2025.

GOOGLE GEMINI. Gems. Disponível em: <https://gemini.google/overview/gems/>. Acesso em: 11 set. 2025.

GREENWOOD, J.; HAN, P.; SÁNCHEZ, J. M. Venture capital: a catalyst for innovation and growth. **SSRN Electronic Journal**, abr. 2022. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4077464. Acesso em: 12 ago. 2025.

KPMG. 2024 global VC investment rises to \$368 billion as investor interest in AI soars. KPMG, 2025. Disponível em: <https://kpmg.com/xx/en/media/press-releases/2025/01/2024-global-vc-investment-rises-to-368-billion-dollars.html>. Acesso em: 12 ago. 2025.

KRISHNAN, N. **AI Agents: Evolution, Architecture, and Real-World Applications**. 2025. arXiv:2503.12687 [cs.AI]. Disponível em: <https://arxiv.org/abs/2503.12687>. Acesso em: 25 ago. 2025

IBM. Machine Learning. IBM, 2025 Disponível em: <https://www.ibm.com/think/topics/machine-learning>. Acesso em: 19 ago. 2025.

LER-NER, J.; TÁG, J. Institutions and venture capital. **Industrial and Corporate Change**, v. 22, n. 1, p. 153–182, fev. 201

LEONEL, S. G. **Mitos e verdades sobre a indústria de venture capital**. 2014. Tese (Doutorado em Economia) – Universidade Federal de Minas Gerais, Belo Horizonte, 2014.

LERMA, A. Z. La previsión de Bill Gates con el futuro de la humanidad y la inteligencia artificial: augura una era de “inteligencia gratuita”. MeriStation, 7 abr. 2025. Disponível em: <https://as.com/meristation/betech/la-prevision-de-bill-gates-con-el-futuro-de-la-humanidad-y-la-inteligencia-artifical-augura-una-era-de-inteligencia-gratuita-n/>. Acesso em: 11 ago. 2025.

LJUNGQVIST, A. The economics of private equity: a critical review. Preliminary draft. **Stockholm: Stockholm School of Economics**, 12 fev. 2024.

LI, Y.; MAHONEY, J. T. When are venture capital projects initiated?. **Journal of Business Venturing**, v. 26, n. 3, p. 239-254, 2011.

MALHOTRA, V. **Managing Risks at Early-Stage Investment – An Information Asymmetry and Signaling Perspective**. 2023. Dissertação (Doutorado em Administração) – Florida Institute of Technology, Melbourne, Florida, 2023.

MANGABEIRA, I.U.S. **Uso de Inteligência artificial na tomada de decisão no mercado Financeiro: As “IA’s” são apenas uma ferramenta ou poderão substituir um profissional da área?**. 2025. Trabalho de Conclusão de Curso (Graduação em Ciências Contábeis) – UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE, Natal, 2025.

MANZONI JR., R. O que mudou nos contratos de aportes no Brasil com o inverno das startups. NeoFeed, 7 mar. 2024. Disponível em: <https://neofeed.com.br/startups/o-que-mudou-nos-contratos-de-aportes-no-brasil-com-o-inverno-das-startups/>. Acesso em: 14 ago. 2025.

MARKET MAKERS. *Market Makers #199 – episódio com Martin Escobari*. [S. l.]: YouTube, 27 mar. 2025. 1 vídeo (1 h 20 min). Disponível em: <https://www.youtube.com/watch?v=glggMFhsnC4>. Acesso em: 28 ago. 2025.

MARTINI, R. A.; MACHADO, L.; NASCIMENTO, L. O. O impacto dos fundos Criatec no crescimento e inovação de startups: uma análise baseada em estudo de eventos. **Estudos Econômicos**, São Paulo, v. 54, n. 4, p. 1-36, 2024.

MEIRELLES, J. L. F.; PIMENTA JÚNIOR, T.; REBELATTO, D. A. N. Venture capital e private equity no Brasil: alternativa de financiamento para empresas de base tecnológica. **Gestão e Produção**, v. 15, n. 1, p. 11-21, 2008.

METRICK, A.; YASUDA, A. **Venture Capital and the Finance of Innovation**. 3. ed. Hoboken: John Wiley & Sons, 2021.

MORAIS, F. D. B.; CASTELO BRANCO, V. R. A Inteligência Artificial: conceitos, aplicações e controvérsias. In: SIMPÓSIO INTERNACIONAL DE CIÊNCIAS INTEGRADAS DA UNAERP - CAMPUS GUARUJÁ, 20. Anais... Guarujá: 2023.

MONTEVIRGEN, Karl. OpenAI. Encyclopaedia Britannica, 2025. Disponível em: <https://www.britannica.com/money/OpenAI>. Acesso em: 18 ago. 2025.

NOLAN, B. Marc Andreessen prevê que o venture capital pode ser um dos poucos empregos a sobreviver à automação pela IA. Fortune, 1 mai. 2025. Disponível em: <https://fortune.com/article/mark-andreessen-venture-capitalism-ai-automation-a16z/>. Acesso em: 28 ago. 2025.

OFFICECHAI. We're Investing On The Thesis That Everything Will Be Rebuilt Because Of AI: Marc Andreessen. 12 jun. 2025. Disponível em: <https://officechai.com/ai/were-investing-on-the-thesis-that-everything-will-be-rebuilt-because-of-ai-marc-andreessen/>. Acesso em: 11 ago. 2025.

OSBORN, A. F. **Applied Imagination: Principles and Procedures of Creative Problem Solving**. New York: Charles Scribner's Sons, 1953.

OPENAI. Introducing GPTs. OpenAI Blog, São Francisco, 6 nov. 2023. Disponível em: <https://openai.com/index/introducing-gpts/>. Acesso em: 9 set. 2025.

OPEN AI HELP CENTER. What are tokens and how to count them? 2025. Disponível em: <https://help.openai.com/en/articles/4936856-what-are-tokens-and-how-to-count-them>
Acesso em: 23 nov. 2025.

PARTHASARATHY, S. Is Llama 3.1 Really Open Source? Medium, 23 jul. 2024. Disponível em: <https://medium.com/gptalk/is-llama-3-1-really-open-source>. Acesso em: 11 set. 2025

PERPLEXITY. Disponível em: <https://www.perplexity.ai/>. Acesso em: 21 nov. 2025.

REALE, A. **AI on venture Capital**. 2025. Dissertação (Mestrado em Management Engineering) – POLITECNICO DI TORINO, Turim, 2025.

REUTERS. AI means everyone can now be a programmer: Nvidia chief Jensen Huang. The Economic Times, 29 mai. 2023. Disponível em: <https://economictimes.indiatimes.com/tech/technology/ai-means-everyone-can-now-be-a-programmer-nvidia-chief-jensen-huang/articleshow/100587919.cms>. Acesso em: 11 ago. 2025.

ROSSI, I. The Role of AI in Accelerating Venture Capital Decision-Making. **Digital Transformation and Administration Innovation**, 1(1), 46.

SAATY, T. L. **The analytic hierarchy process**: planning, priority setting, resource allocation. 1. ed. New York: McGraw-Hill, 1980.

SAHLMAN, W. A. The structure and governance of venture-capital organizations. **Journal of Financial Economics**, v. 27, n. 2, p. 473–521, out., 1990.

SCHNEIDER, J. **What Comes After Transformers?** A Selective Survey Connecting Ideas in Deep LearningGPT. In: ROCHA, A. P.; STEELS, L.; VAN DEN HERIK, J. (eds.). Agents and Artificial Intelligence. ICAART 2024. Lecture Notes in Computer Science, v. 15592. Cham: Springer, 2025.

SHEIKH, H.; PRINS, C.; SCHRIJVERS, E. **Mission AI**: The New System Technology. 1. ed. Cham: Springer International Publishing, 2023.

SHUKLA, A. K. The Future of AI: How Domain-Specific LLMs, RAG & Agentic AI Are Redefining Intelligence. Preprint, maio 2025.

SIDDIK, A. B.; LI, Y.; DU, A. M. Unlocking funding success for generative AI startups: The crucial role of investor influence. Finance Research Letters, v. 69, parte B, p. 106203, nov., 2024

SILVA, R. A. **Fundos de investimento em venture capital e private equity no Brasil: estrutura, função e exercício do poder de controle**. 2021. Tese (Doutorado em Direito) – Universidade de São Paulo, Faculdade de Direito, São Paulo, 2021.

SINGH, Shubham. ChatGPT Statistics (2025) – Daily & Monthly Active Users. DemandSage, 14 ago. 2025. Disponível em: <https://www.demandsage.com/chatgpt-statistics/>. Acesso em: 18 ago. 2025.

SINGLA, A.; SUKHAREVSKY, A.; YEE, L.; CHUI, M.; HALL, B.; The State of AI: How organizations are rewiring to capture value. McKinsey & Company, 12 mar. 2025. Disponível em: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>. Acesso em: 30 set. 2025.

STREBULAEV, I. A.; GOMPERS, P. A. How Much Does Venture Capital Drive the U.S. Economy? **Stanford Graduate School of Business**, 21 out. 2015. Disponível em: <https://www.gsb.stanford.edu/insights/how-much-does-venture-capital-drive-us-economy>. Acesso em: 11 ago. 2025.

SOBREIRA, V. Um panorama da História da Inteligência Artificial e suas aplicações na pesquisa histórica. **Varia Historia**, Belo Horizonte, v. 41, e25035, 2025.

WERNER, J. Three Waves Of Innovation And Three Harbingers Of AI. Forbes, 26 set. 2024. Disponível em: <https://www.forbes.com/sites/johnwerner/2024/09/26/three-waves-of-innovation-and-three-harbingers-of-ai/>. Acesso em: 11 ago. 2025.

VALETEC. CVC se destaca como meio de investimento em startups no Brasil. Valetec. São Paulo, 2021. Disponível em: <https://valetec.com.br/site/cvc-se-destaca-como-meio-de-investimento-em-startups-no-brasil/>. Acesso em: 14 ago. 2025.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, Ł.; POLOSUKHIN, I.. **Attention Is All You Need**. In: Advances in Neural Information Processing Systems, v. 30, 2017.

VEECEEE. Disponível em: <https://www.veecee.ai>. Acesso em: 13 set. 2025.

VEJA. Demasiado humano: há 20 anos, Kasparov era esmagado por Deep Blue. VEJA, São Paulo, 11 maio 2017. Disponível em: <https://veja.abril.com.br/coluna/reveja/demasiado-humano-ha-20-anos-kasparov-era-esmagado-por-deep-blue/>. Acesso em: 18 ago. 2025.

VISMARA, S.; LATIFI, G.; MEINZINGER, L.; PASS, A. Generative AI-powered venture screening: Can large language models help venture capitalists? **International Review of Financial Analysis**, v. 109, p. 104748, 2025.

XCLOUD. n8n vs Zapier: Which One Should You Choose? xCloud, 7 jul. 2025. Disponível em: <https://xcloud.host/n8n-vs-zapier-which-one-should-you-choose/>. Acesso em: 13 set. 2025.

ZIDER, B. How venture capital works. **Havard Business Review**. Nov-Dez, p. 131-139, 1998.

APÊNDICE A – SAÍDA DA APLICAÇÃO DE IA PARA “QUALIFICAR STARTUPS”

Apresenta-se, neste apêndice, o resultado de uma interação com o agente de IA com a aplicação de “Qualificar *startups*” para a *startup* WeHandle, conforme citado no item 4.5.1.4 deste trabalho. À esquerda, encontram-se os *inputs* do usuário e, à direita, o resultado devolvido pelo agente no ChatGPT.

<https://wehandle.com.br/>

Você permitiu esta ação
Falou com api.apollo.io
Empresa: Wehandle | URL: wehandle.com.br

Founders (Apollo)

Nome	Cargo	LinkedIn	Prof. (Apollo)	Fonte
Rodrigo Faustini	Founder & CEO	linkedin.com/in/rodrigo-faustini-14660114	• Founder & CEO — Wehandle (2020–atual) • Owner — SS Soluções (2006–2020) • Owner — UP SAFER (2013–2020) • University Teacher — Universidade São Marcos (2010–2012)	[Apollo]
Augusto Macedo	Founder & COO	linkedin.com/in/augusto-macedo-759939123	• Founder & COO — Wehandle (2025–atual) • CPO — Wehandle (2024–2025) • CTO — Wehandle (2020–2024) • Engineer — SS Soluções (2016–2020) • Intern — Procter & Gamble (2016)	[Apollo]
Pedro Santos	Founder & CTO	linkedin.com/in/pedro-luis-capelato-dos-santos-5952b47b	• Founder & Head of Software Development — Wehandle (2020–atual) • Programmer Analyst — SS Soluções (2017–2021)	[Apollo]

Fonte: Autoria Própria.

IDs (Apollo)

ID	Valor	Classe	Fonte
ID1	06/2020 — data mais antiga de início de founder (Rodrigo Faustini)	Ideal	[Apollo/LinkedIn]
ID6	Fundadores com histórico técnico-operacional (engenharia, TI, automação, docência). Experiência sólida em gestão e tecnologia.	Ideal	[Apollo]
ID7	≈160 funcionários (Apollo)	Ideal	[Apollo]
ID8	Categoria: Information Technology & Services — (classificação: Aceitável)	Aceitável	[Apollo]

Fonte: Autoria Própria.

Produto & Sinergia (prévia)

- **Produto:** Plataforma SaaS de gestão de terceiros baseada em IA, automatizando ciclo completo de controle de prestadores de serviço (documentos, compliance, treinamento, operação).
- **Overlap Portfólio:** Não há sobreposição direta relevante com empresas do portfólio atual.
- **Fit Tese:** Alinhado com tese de *automação B2B e eficiência operacional via IA*; foco SaaS enterprise, modelo escalável, fundadores complementares.
-

Deseja que eu execute a FASE 2 para buscar ID2–ID5 (captação, último round, investidores e formação acadêmica)?

Sim

Ótimo. A seguir a FASE 2 para a Wehandle — preenchendo ID2–ID5.

Captação & Rodadas (ID2 / ID3 / ID4)

- Em setembro de 2025, a Wehandle captou R\$ 36 milhões em uma nova rodada. A rodada foi liderada pela Canary, com participação de ONEVC, Valutia, Blustone e Quartzo.
- Segundo a própria Wehandle, esse é seu segundo grande aporte desde a rodada anjo/seed inicial.
- Embora o site da Crunchbase mostre duas rodadas, com última seed data em “Sep 13, 2024” e rodada anterior em “Oct 30, 2023”
- A reportagem de 2025 refere à rodada como “Seed”, mesmo sendo o segundo grande investimento.

ID2 (Histórico de Rodadas):

- Seed / anjo (~2021) — aporte inicial (valor não divulgado publicamente nas fontes recentes)
- Seed (set/2025) — R\$ 36 milhões, liderada pela Canary, com participação de ONEVC, Valutia, Blustone e Quartzo.

ID3 (Último Round):

- Setembro de 2025 — Seed, R\$36 milhões. Classe: — (ver classificação abaixo)

ID4 (Investidores):

- Canary (lead)
- ONEVC, Valutia, Blustone, Quartzo

Formação Acadêmica dos Fundadores (ID5)

Não consegui localizar dados confiáveis públicos sobre a formação acadêmica dos fundadores da Wehandle (Rodrigo Faustini; Augusto Macedo; Pedro Santos) em fontes jornalísticas ou via LinkedIn público (blocked ou não listam cursos).

- LinkedIn da empresa indica apenas número de funcionários e setor, não detalha formação.
- Perfis individuais não são acessíveis publicamente para confirmar curso superior.

Conclusão ID5: — (sem dados públicos) → classificar como Preocupante.

Tabela Consolidada (IDs 1–8 com fase 2) para Wehandle

ID	Valor / Descrição	Classe	Fonte
ID1	06/2020 (data mais antiga de início de fundador)	Ideal	[Apollo/LinkedIn]
ID2	Rodadas: Anjo/Seed (~2021); Seed — 09/2025, R\$ 36M, lead Canary + ONEVC, Valutia, Blustone, Quartzo	Aceitável	[site notícias, Crunchbase]
ID3	Último round: 09/2025	Aceitável	[notícias 2025]
ID4	Investidores: Canary; ONEVC; Valutia; Blustone; Quartzo	Ideal	[notícias 2025, Funil cruzamento]
ID5	Formação acadêmica fundadores = —	Preocupante	[LinkedIn / web — não encontrado]
ID6	Histórico profissional dos fundadores: técnico-operacional, engenharia/ti/compliance	Ideal	[Apollo]
ID7	≈ 160 funcionários (conforme Apollo)	Ideal	[Apollo]
ID8	Categoria: <i>Information Technology & Services</i> — Categoria não encontrada na base de categorias	Aceitável	[Apollo / tblCategorias]

Fonte: Autoria Própria.

Produto & Sinergia (revisado)

- **Produto:** Plataforma SaaS de gestão de terceiros com IA e automação para homologação, compliance e monitoramento documental e de fornecedores.
- **Overlap Portfólio:** sem sobreposição clara com atuais empresas no portfólio.

- **Fit de Tese:** Forte — automação B2B, eficiência operacional, SaaS *enterprise*, compliance, dados / IA.

Decisão (SIM / NÃO)

SIM — a Wehandle apresenta um perfil muito atrativo para investimento adicional (growth / próxima rodada), pelos seguintes motivos:

1. **Momento de crescimento claro** — a rodada recente de R\$ 36 mi demonstra validação do mercado e tração (clientes grandes, expansão internacional).
2. **Produto com fit de tese e sinergia** — oferece tecnologia estratégica para compliance e gestão de terceiros, vertical que se complementa com corporação cotista.
3. **Time fundador experiente e equilibrado** — histórico técnico-operacional, experiência prévia em serviço/automação, o que dá credibilidade para entrega contínua e execução.

APÊNDICE B – SAÍDA DA APLICAÇÃO DE IA PARA “PREPARAÇÃO PARA CONVERSAS”

Apresenta-se, neste apêndice, o *output* do agente de IA com a demonstração da aplicação desenvolvida “Preparação para conversa” para a *startup* WeHandle, conforme citado no item 4.5.2.4 deste trabalho.

Resumo breve (para levar à *call*)

- O que fazem:** wehandle oferece uma plataforma SaaS com IA para gestão de terceiros e serviços — desde homologação e qualificação de fornecedores até controle documental, compliance, treinamento e monitoramento contínuo.
- CEO:** Rodrigo Faustini — cofundador e CEO.
- Setor / mercado:** gestão de terceiros / fornecedores, compliance, *supply-chain*, recursos humanos terceirizados, segurança do trabalho.
- Modelo de negócio:** SaaS + serviços de compliance/documental + automação — licenciamento de software e uso da plataforma para gestão e monitoramento de terceiros.
- Fundraising & tração:** captou US\$ 1,2 mi em rodada *seed* em 2024 (liderada pela ONEVC). Em 2025 levantou R\$ 36 milhões numa rodada liderada por Canary (com ONEVC, Valutia, Blustone e Quartz) para expansão agressiva. A empresa afirma já ter 350+ clientes corporativos, e ampliou atuação para o Chile, mirando outros países da América Latina.

Produtos / Soluções

Com base no site, os módulos/soluções da wehandle incluem:

Módulo / Solução	O que entrega / funcionalidades principais
Homologação e Qualificação de Fornecedores	Consulta automática de CNPJ, verificação de idoneidade, score financeiro, comparativo de fornecedores, monitoramento de CNPJ.

Gestão de Serviços e Terceiros	Validação documental automática (mais de 1000 tipos de documentos), matriz de risco personalizada, notificações de vencimento, portal para fornecedores, integração com portaria/catracas, app para checagem em campo.
Capacitação de Colaboradores (EAD / <i>Onboarding</i>)	Plataforma EAD para integração de colaboradores e prestadores, com provas, rastreamento de progresso, controle de homologação de pessoas/fornecedores.
BI & Dashboards / Relatórios e Monitoramento	Visão em tempo real da operação de terceiros, dashboards com filtros por unidade de negócio ou CNPJ, dados de conformidade, status documental, auditoria e risco.
Soluções para equipes específicas – Compras & Suprimentos / Segurança do Trabalho / RH / <i>Supply Chain</i>	Adaptações da plataforma conforme necessidade do departamento: homologação e governança para compras; controle de acesso, conformidade e segurança para segurança do trabalho; compliance, passivos trabalhistas e gestão de terceiros para RH; visibilidade e compliance para <i>supply chain</i> .

Fonte: Autoria Própria.

Em síntese: a wehandle não é uma simples ferramenta de checklist — busca cobrir todo o ciclo de gestão de terceiros: da homologação e *due diligence* até *onboarding*, compliance contínuo, documentação, treinamento e visibilidade operacional.

Pontos de atenção estratégicos (riscos / dúvidas a investigar na *call*)

1. Escalabilidade de receita vs. custo operacional e suporte

- Embora o software seja SaaS, clientes maiores provavelmente demandam *onboarding*, suporte, customizações e gestão de documentos — o custo de atendimento pode crescer com a base.

- Pergunta para a call: *Qual % da receita vem de licenciamento puro vs. serviços de onboarding/consultoria? Vocês conseguem dimensionar custo incremental por cliente grande?*

2. Diferenciação real frente à concorrência local e externa

- Há players de compliance, gestão de fornecedores, software de ERP com módulos de *vendor management*, consultorias especializadas. Não está claro o quão “proprietária” é a vantagem de IA + automação da wehandle no longo prazo.
- Pergunta para a call: *Quais são seus principais concorrentes no Brasil e América Latina — e o que diferencia wehandle deles? Vocês possuem patentes ou tecnologia proprietária numa “caixa preta” de validação/documentos?*

3. Dependência da legislação, regras de compliance e sensibilidade de dados

- Empresas clientes podem exigir altos níveis de compliance, governança, auditoria, privacidade — e se a wehandle falhar em auditorias ou houver erro documental, risco de passivos é grande. Isso exige maturidade de processos internos, monitoramento contínuo e suporte robusto.
- Pergunta: *Como vocês garantem confiabilidade e consistência das validações documentais/risco, especialmente diante de mudanças regulatórias em diferentes países da América Latina?*

4. Mercado pode ser fragmentado e verticalizado — dificuldade de padronização internacional

- Diferentes indústrias (construção, logística, indústria, serviços, saúde, energia, etc.) têm requisitos regulatórios distintos — adaptar a plataforma para todos pode ser custoso. A expansão internacional (já iniciada no Chile) pode exigir customizações específicas por país/região.
- Pergunta: *Quais adaptações a plataforma exige para operar em diferentes países ou indústrias reguladas? Há planos de padronização?*

5. Concorrência com internalização do *vendor management* por empresas grandes

- Empresas grandes podem decidir internalizar a gestão de fornecedores e terceirizados, investindo em times próprios ou ERPs corporativos customizados — reduzindo o mercado endereçável da wehandle.
- Pergunta: *Vocês perceberam churn quando empresas optam por internalizar vendor management? Qual o perfil de clientes mais aderentes ao modelo?*

6. Tamanho do mercado endereçável (TAM) e penetração futura

- O mercado de terceirização e gestão de fornecedores é grande, dado o tamanho da economia terceirizada no Brasil, mas é difícil estimar quantas empresas valorizam automação/compliance. Há risco de mercado fragmentado, com muitas PME que não pagariam pelo serviço completo.
- Pergunta: *Qual é a estimativa de TAM que vocês utilizam para Brasil e América Latina? Quantas empresas potenciais seriam clientes escaláveis para wehandle?*

Sugestões de perguntas estratégicas para a call

Para cada um dos riscos acima:

- Escalabilidade / custo: “Como vocês modelam o custo incremental de atendimento a novos clientes corporativos de grande porte? A margem bruta diminui à medida que a base cresce?”
- Concorrência / diferenciação: “Quais empresas (concorrentes) vocês veem como ameaças diretas hoje e por que a wehandle se diferencia delas?” — “Vocês têm tecnologia proprietária ou qualquer propriedade intelectual (patentes, algoritmos únicos) que dificulte a replicação?”
- Compliance / risco regulatório: “Como garantem a consistência e atualização das validações documentais e de compliance, especialmente com variações regulatórias entre estados e países?”
- Fragmentação de mercado / internacionalização: “Quais adaptações foram necessárias para lançar no Chile? Vocês planejam expandir para outros países da América Latina? Como vai funcionar a padronização da plataforma?”

- Concorrência de internalização: “Vocês observam que grandes empresas internalizam a gestão de terceiros? Em que casos fazem isso, e por que a wehandle continua sendo escolhida por quem terceiriza *vendor management*?”
- Tamanho de mercado (TAM): “Qual é a estimativa de tamanho de mercado (TAM) que vocês usam para mapear o potencial da wehandle no Brasil e América Latina? Quantas empresas e de que porte seriam o alvo ideal?”