

FACULDADE FIPECAFI
PROGRAMA DE MESTRADO PROFISSIONAL EM
CONTROLADORIA E FINANÇAS

RAFAEL DOS SANTOS DE ALMEIDA

**Elaboração de um sistema multiagente para previsão de insolvência por meio de
aprendizado de máquina para Micro e Pequenas Empresas (MPEs) brasileiras.**

SÃO PAULO

2024

FACULDADE FIPECAFI

PROGRAMA DE MESTRADO PROFISSIONAL

EM CONTROLADORIA E FINANÇAS

RAFAEL DOS SANTOS DE ALMEIDA

**Elaboração de um sistema multiagente para previsão de insolvência por meio de
aprendizado de máquina para Micro e Pequenas Empresas (MPes) brasileiras.**

Projeto de pesquisa apresentado ao Curso de
Mestrado Profissional em Controladoria e
Finanças da Faculdade FIPECAFI para a
realização do exame de qualificação.

Orientadora: Profa. Dra. Sonia Rosa Arbues
Decoster

SÃO PAULO

2004

FACULDADE FIPECAFI

Prof. Dr. Welington Rocha

Diretor Presidente

Prof. Dr. Fernando Dal-Ri Murcia

Diretor de Pesquisa

Prof. Dr. Welington Rocha

Diretor Geral de Cursos

Prof. Dr. George André Wilrich Sales

Coordenador do Curso de Mestrado Profissional em Controladoria e Finanças

Catologação na publicação

Serviço de Biblioteca da Faculdade FIPECAFI

Fundação Instituto de Pesquisas Contábeis Atuárias e Financeiras (FIPECAFI)

Dados fornecidos pelo (a) autor (a)

A447e Almeida, Rafael dos Santos de.

Elaboração de um sistema multiagente para previsão de insolvência por meio de aprendizado de máquina para micro e pequenas empresas (MPEs) brasileiras. / Rafael dos Santos de Almeida. -- São Paulo, 2024.
123 p. il. col.

Dissertação (Mestrado Profissional) - Programa de Mestrado Profissional em Controladoria e Finanças – Faculdade FIPECAFI Fundação Instituto de Pesquisas Contábeis Atuárias e Financeiras
Orientador: Profa. Dra. Sonia Rosa Arbues Decoster.

1. Inteligência artificial. 2. Aprendizado de máquina. 3. Sistemas Multiagentes (SMA). 4. Micro e pequenas empresas (MPEs). 5. Previsão e modelos de insolvência. I. Profa. Dra. Sônia Rosa Arbues Decoster. II. Título.

657.3

**Elaboração de um sistema multiagente para previsão de insolvência por meio de
aprendizado de máquina para Micro e Pequenas Empresas (MPEs) brasileiras.**

Dissertação de Mestrado apresentada ao Curso de Mestrado Profissional em Controladoria e
Finanças da Faculdade FIPECAFI, para a obtenção do título de Mestre Profissional em
Controladoria e Finanças.

Aprovado em: ____/____/____

Prof. Dra. Sonia Rosa Arbues Decoster

Professor Orientador – Presidente da Banca Examinadora

Prof. Dr. George André Willrich Sales

Membro Interno

Prof. Dr. Gleifer Vaz Alves

Membro Externo

SÃO PAULO

2024

RESUMO

Almeida, R. S. (2024). Elaboração de um sistema multiagente para previsão de insolvência por meio de aprendizado de máquina para Micro e Pequenas Empresas (MPEs) brasileiras. (Dissertação de Mestrado). Faculdade FIPECAFI, São Paulo, SP, Brasil.

Este trabalho apresenta uma solução baseada em um sistema multiagente (*MAS4PI – Multiagent System for Prediction Insolvency*) para prevenção de insolvência das micro e pequenas empresas brasileiras. Os objetivos dos agentes compreendem diagnosticar a saúde financeira das empresas, classificá-las quanto ao estado de insolvência, propor tratamento financeiro e monitorar o desempenho da organização. A solução visa reduzir a alta taxa de mortalidade dos pequenos negócios, automatizar e compartilhar procedimentos, bem como, conhecimentos dos especialistas em finanças, permitindo um tratamento preventivo para essas empresas. O modelo de predição de insolvência é aplicado para prever o estado de insolvência da empresa permitindo que ações corretivas sejam tomadas. As recomendações de tratamentos se baseiam nos mecanismos de inferência dos agentes que atuam em regras definidas conforme o conhecimento de especialistas em finanças voltados para micro e pequenos negócios. Neste estudo, foi utilizada a metodologia *Design Science Research* (DSR), que visa desenvolver uma solução satisfatória para resolução de um problema relevante, gerando dois artefatos: sistema multiagente (MAS4PI) e o modelo preditivo de insolvência. O processo desenvolvimento do SMA foi apresentado por meio da modelagem Tropos, projeto de arquitetura e implementação com o *framework* PADE. Foram realizados dois experimentos para o SMA, demonstrando a capacidade do agente de fornecer um diagnóstico de saúde financeira com uma taxa de acerto de 96% e compartilhar o relatório com outros agentes, além de fornecer recomendações de tratamento com uma precisão de 85% e monitoramento e alertas para as empresas com uma assertividade de 75% comparado a um especialista de finanças. Para o modelo preditivo de insolvência, foram realizados três experimentos para selecionar o melhor modelo de classificação, usando dados de empresas reais. O método de aprendizado de máquina (*machine learning*) floresta aleatória (*random forest*) foi escolhido como o melhor, considerando seu desempenho pelo método de validação cruzada. A solução proposta tem potencial para contribuir para a redução da alta taxa de encerramento de MPEs no Brasil, incluindo uma série de benefícios: diagnóstico preciso da saúde financeira das empresas; recomendações de tratamento financeiro personalizadas; monitoramento contínuo de desempenho; e envio de alerta para antecipação preventiva de problemas financeiros. Os resultados indicam que a solução MAS4PI tem uma boa capacidade de previsão e recomendação usando dados reais de empresas, sendo uma solução viável para auxiliar na gestão e tomada de decisão das micro e pequenas empresas.

Palavras-chave: Previsão de Insolvência, MPEs, Sistema Multiagente; Modelo Preditivo, Aprendizado de Máquina (*machine learning*).

SÃO PAULO

2024

ABSTRACT

This research presents a solution based on intelligent agents to prevent the event of insolvency of Brazilian small enterprises (MAS4PI - Multiagent System for Prediction Insolvency). The objectives of the agents are to diagnose the financial health of companies, classify them according to their insolvency status, propose financial treatment, and monitor the performance of the organization. The solution aims to reduce the high mortality rate of small businesses, automate and share procedures, as well as knowledge from financial experts, allowing preventive treatment for these companies. The insolvency prediction model is applied to predict the insolvency status of the company, allowing corrective actions to be taken. The treatment recommendations are based on the inference mechanisms of the agents that act on rules defined according to the knowledge of financial experts focused on micro and small businesses. The Design Science Research (DSR) methodology was used, which aims to develop a satisfactory solution to solve a relevant problem, generating two artifacts: multi-agent system (MAS4PI) and insolvency predictive model. The SMA development process was presented through Tropos modeling, architectural design, and implementation with the PADE framework. Two experiments were conducted for the SMA, demonstrating the agent's ability to provide a financial health diagnosis with an accuracy rate of 96% and share the report with other agents, as well as provide treatment recommendations with an accuracy of 85% and monitoring and alerts for companies with an accuracy of 75% compared to a financial expert. For the insolvency predictive model, three experiments were conducted to select the best classification model, using data from real companies. The random forest machine learning method was chosen as the best, considering its performance by the cross-validation method. The proposed solution has the potential to contribute to reducing the high closure rate of SMEs in Brazil, including a number of benefits: accurate diagnosis of the financial health of companies; personalized financial treatment recommendations; continuous performance monitoring; and sending alerts to prevent financial problems in advance. The results indicate that the MAS4PI solution has a good forecasting and recommendation capacity using real company data, being a viable solution to assist in the management and decision-making of the small businesses.

Keywords: Insolvency prediction, SMEs, Multi-agent Systems; Prediction models; *Machine learning*

LISTA DE FIGURAS

Figura 1: Gráfico total de micro e pequenas empresas ativas	20
Figura 2: Expansão das empresas EPPs e MEIs.	21
Figura 3: Classificador Árvore de Decisão	34
Figura 4: Classificador Floresta Aleatória	35
Figura 5: Técnica de seleção de atributo para o fenômeno de insolvência.....	37
Figura 6: Agentes Reativos Simples.....	41
Figura 7: Agente baseado em Modelo.....	42
Figura 8: Agente baseado em Utilidade	43
Figura 9: Agente com Modelo de Aprendizagem.....	45
Figura 10: Framework Conceitual para entendimento da função de aprendizado de máquina na inteligência Artificial.....	46
Figura 11: Elementos visuais do framework I*	48
Figura 12: Modelo de dependência entre atores	49
Figura 13: Modelo conceitual da pesquisa	51
Figura 14: Quantidade de instâncias (empresas) solvente e insolvente	53
Figura 15: Fluxo de informações para análise de insolvência das MPEs	54
Figura 16: Faixa de Faturamento das Micro e Pequenas Empresas.....	55
Figura 17: Enquadramento das Empresas conforme a disposição do Sebrae.....	55
Figura 18: Setor de atuação das Micro e Pequenas Empresas	56
Figura 19: Regime Tributário das Micro e Pequenas Empresas.....	56
Figura 20: Etapas executadas na revisão sistemática da literatura.....	59
Figura 21: Metodologia utilizada no trabalho para solução de Agentes Inteligentes.....	62
Figura 22: Processo de Criação e Seleção do Modelo Preditivo	63
Figura 23: Diagrama para captura de requisitos iniciais.....	67
Figura 24: Diagrama de requisitos finais	67
Figura 25: Arquitetura do Sistema Multiagente (MAS4PI)	68
Figura 26: Diagrama de sequência referente a fase de projeto detalhado.....	69
Figura 27: Diagrama de atividades referente a fase de projeto detalhado.....	69
Figura 28: Estrutura de documentos gerado no MongoDB.....	70
Figura 29: Modelos de dados conceitual para o sistema MAS4PI	70
Figura 30: Tela inicial para acesso a plataforma solver.ai.....	71
Figura 31: Carregamento dos dados na interface solver.ai	72
Figura 32: Visualização de dados na interface solver.ai	72
Figura 33: Resultado do Diagnóstico de saúde financeira na interface solver.ai	73
Figura 34: Histórico de Empresas com diagnóstico na interface solver.ai	73
Figura 35: Detalhes do tratamento financeiro recomendado.	74
Figura 36: Detalhes do envio de alerta.....	74
Figura 37: Representação do conhecimento do agente PPA.....	75
Figura 38: Representação do conhecimento do agente IMA.....	76
Figura 39: Fluxo de execução do agente EDA para gerar diagnóstico de insolvência	80
Figura 40: Processo de execução do Agente EDA e compartilhamento do relatório de insolvência.	81
Figura 41: Configuração para transformação de dados modelo Floresta Aleatória.....	85
Figura 42: Configuração para transformação de dados para os modelos preditivos.....	86
Figura 43: Conjunto de dados desbalanceado.....	87
Figura 44: Conjunto de dados após o balanceamento	87
Figura 45: Variáveis importantes para o classificador Floresta Aleatória	89
Figura 46: Variáveis importantes para o classificador de Regressão Logística.....	89

Figura 47: Processo de obtenção dos dados da empresa	95
Figura 48: Preenchimento das informações da empresa	96
Figura 49: Avaliação do resultado do diagnóstico financeiro	96
Figura 50: Avaliação do tratamento proposto.	97

LISTA DE TABELAS

Tabela 1: Enquadramento das Micro, Pequenas e Médias Empresas com base na receita anual.	19
Tabela 2: Classificação de empresas por porte conforme seu setor de atuação.	19
Tabela 3: Abertura de Micro e Pequenas empresas	21
Tabela 4: Fechamento de empresas por Porte de 2019 a 2020	21
Tabela 5: Fases da evolução histórica de estudos sobre o tema de insolvência das empresas.	23
Tabela 6: Estudos que abordam a predição da insolvência das MPEs.	24
Tabela 7: Estudos elaborados no Brasil a partir de 2008	26
Tabela 8: Indicadores utilizados pelos modelos de previsão de insolvência para MPEs	29
Tabela 9: Agrupamento de categorias de medição de desempenho das empresas	29
Tabela 10: Estudos recentes abordando inteligência artificial e técnicas de aprendizado de máquina sobre previsão de insolvência foram elaborados de 2017 a 2023.	38
Tabela 11: Funções básicas dos Agentes Inteligentes	39
Tabela 12: Exemplo de Agentes Inteligentes com as características da especificação PEAS	43
Tabela 13: Diretrizes Metodologia para condução de pesquisa DSR	57
Tabela 14: Artefatos selecionados para previsão de insolvência das MPEs	60
Tabela 15: Artefatos selecionados de agentes inteligentes	61
Tabela 16: Métodos e técnicas para avaliação de artefatos	63
Tabela 17: Especificação PEAS - Enterprise Diagnostic Agent - EDA	65
Tabela 18: Especificação PEAS - Propose Procedure Agent - PPA	65
Tabela 19: Especificação PEAS - Insolvency Monitoring Agent - IMA	66
Tabela 20: Variáveis Dependentes do Conjunto de dados	78
Tabela 21: Variável Independente do Conjunto de dados	79
Tabela 22: Tratamentos Recomendados	82
Tabela 23: Monitoramento de indicadores para envio de alertas	83
Tabela 24: Comparação entre especialista em finanças e o MAS4PI	83
Tabela 25: Métricas de Avaliação dos modelos de classificação	87
Tabela 26: Seleção do melhor Modelo Preditivo	90
Tabela 27: Público-alvo de validação da solução projetada	90
Tabela 28: Público Avaliador da Pesquisa	91
Tabela 29: Etapas de Validação da Solução SMA	91

LISTA DE ABREVIATURAS E SIGLAS

Dummy: Variável que assume apenas dois valores, geralmente entre 0 e 1, usadas para codificar variáveis categóricas.

Large Language Model: Modelo de processamento de linguagem natural em larga escala capaz de gerar texto, imagem e vídeo

Iteração: Processo de execução completa de um algoritmo

K-fold Cross Validation: técnica de avaliação de modelos de aprendizado de máquina

Machine Learning: Aprendizado de Máquina

Randon Forest: Classificador Floresta Aleatória

One Hot Encoder: Técnica de codificação usada para transformar variáveis categóricas em variáveis numéricas

Overffiting: Processo de sobreajustar aos dados de treinamento ocorre quando o modelo não capaz de generalizar para dados desconhecidos

Oversampling SMOT: Técnica usada para aumentar o tamanho do conjunto de dados de treinamento da classe minoritária.

Pipeline: Sequência de etapas que são executadas em um conjunto de dados.

Underffiting: Processo de subajustar aos dados ocorre quando o modelo não consegue capturar a relação entre os dados de treinamento

Support Vector Machine - SVM: Máquina de vetor de suporte

SUMÁRIO

1. INTRODUÇÃO	12
1.1 CONTEXTUALIZAÇÃO	12
1.2 PROBLEMA E OBJETIVOS	16
1.2.1 <i>Objetivo geral</i>	17
1.2.2 <i>Objetivos específicos</i>	17
1.3 JUSTIFICATIVAS	17
2. REFERENCIAL TEÓRICO	18
2.1 MICRO E PEQUENAS EMPRESAS	18
2.1.1 <i>Evolução das micro e pequenas empresas</i>	20
2.2 O CONCEITO DE INSOLVÊNCIA	22
2.3 EVOLUÇÃO DOS ESTUDOS INTERNACIONAIS E NACIONAIS DE PREDIÇÃO DE INSOLVÊNCIA	23
2.3.1 <i>Insolvência nas Micro e Pequenas Empresas</i>	24
2.3.2 <i>Fase I – Análise Financeira comparativa de indicadores sem modelos estatísticos para prever falência</i>	24
2.3.3 <i>Fase II – Estudos de modelos univariados baseados em indicadores contábeis tradicionais</i>	25
2.3.4 <i>Fase III – Estudos de modelos multivariados baseados em indicadores contábeis tradicionais</i>	25
2.3.5 <i>Fase IV – Estudos de modelos multivariados baseados em fluxos de caixa</i>	25
2.3.6 <i>Fase V – Modelos multivariados com técnicas estatísticas avançadas e indicadores não financeiros</i>	26
2.3.7 <i>Evolução dos Estudos sobre Insolvência no Brasil</i>	26
2.3.8 <i>Os indicadores financeiros utilizados nos modelos de previsão de insolvência</i>	28
2.4 MÉTODOS E TÉCNICAS PARA PREDIÇÃO DE INSOLVÊNCIA	30
2.4.1 <i>Previsão de Insolvência por meio de Inteligência Artificial e Aprendizado de Máquina</i>	32
2.4.1.1 <i>Aprendizado de Máquina (machine learning)</i>	33
2.4.2 <i>Métodos de classificação</i>	34
2.4.2.1 <i>Métricas de avaliação de modelos de classificação</i>	35
2.4.3 <i>Estudos sobre previsão de insolvência por meio de aprendizado de máquina</i>	37
2.5 AGENTES INTELIGENTES	38
2.5.1 <i>Conceito de agente</i>	38
2.5.2 <i>Agentes racionais</i>	40
2.5.3 <i>Classificação de agentes</i>	41
2.5.4 <i>Arquitetura de um agente de software</i>	43
2.5.4.1 <i>Arquitetura reativa de agente</i>	44
2.5.4.2 <i>Arquitetura avançada para agentes inteligentes</i>	44
2.5.4.3 <i>Arquitetura híbrida de agente</i>	45
2.5.5 <i>Sistema multiagente</i>	47
2.5.6 <i>Metodologia e modelagem dos agentes</i>	47
2.5.6.1 <i>Bibliotecas e linguagem de programação</i>	50
2.6 MODELO CONCEITUAL DA PESQUISA	51
3. METODOLOGIA	52
3.1 ESTRATÉGIA DA PESQUISA	52

3.1.1	POPULAÇÃO E AMOSTRA	52
3.1.2	COLETA DE DADOS.....	53
3.1.2.1	<i>Análise exploratória dos dados</i>	54
3.2	ABORDAGEM METODOLÓGICA (DSR).....	56
3.2.1	<i>Identificação dos artefatos e configuração das classes de problemas</i>	60
3.2.2	<i>Proposta de artefatos para resolução do problema específico</i>	61
3.2.3	<i>Projeto e desenvolvimento dos artefatos</i>	62
3.2.3.1	<i>Elaboração do Sistema Multiagente</i>	64
4.	APRESENTAÇÃO DA PROPOSTA DE SOLUÇÃO	66
4.1	<i>Fases da proposta de solução</i>	66
4.1.1	<i>Fase de requisitos iniciais</i>	66
4.1.2	<i>Fase de requisitos finais</i>	67
4.1.3	<i>Fase de projeto arquitetural</i>	67
4.1.4	<i>Projeto detalhado</i>	68
4.2	<i>Implementação da proposta</i>	69
4.2.1	<i>A interface solver.ai</i>	70
4.2.2	<i>O Sistema multiagente MAS4PI</i>	74
4.2.3	<i>Elaboração do modelo preditivo</i>	76
4.2.4	<i>Avaliação dos Artefatos</i>	79
5.	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	79
5.1	<i>Avaliação dos artefatos por experimentos</i>	79
5.1.1	<i>Validação do artefato – sistema multiagente</i>	79
5.1.2	<i>Experimento 1</i>	79
5.1.3	<i>Experimento 2</i>	82
5.2	<i>Validação do Artefato – Modelo Preditivo</i>	83
5.2.1	<i>Experimento 1</i>	84
5.2.2	<i>Experimento 2</i>	85
5.2.3	<i>Experimento 3</i>	86
5.4	<i>Avaliação de desempenho e seleção do melhor modelo preditivo</i>	89
5.5	<i>Validação por público-alvo da pesquisa</i>	90
5.5.1	<i>Feedback 1: Validação dos artefatos por especialistas Sebrae</i>	92
5.5.2	<i>Feedback 2: Validação dos Artefatos por Micro e Pequenos Empresários</i>	93
5.5.3	<i>Feedback 3: Validação dos Artefatos por Contadores</i>	94
5.5.4	<i>Feedback geral sobre o preenchimento do formulário</i>	95
5.6	<i>Explicitação das aprendizagens</i>	100
5.	PRINCIPAIS CONCLUSÕES E POTENCIAIS CONTRIBUIÇÕES	101
6.1	<i>Limitações da pesquisa</i>	103
6.2	<i>Recomendações para trabalhos futuros</i>	103
6.	GENERALIZAÇÃO PARA UMA CLASSE DE PROBLEMA.....	104
7.	REFERÊNCIAS	104
8.	APÊNDICES.....	109
8.1	<i>Apêndice A – Instrumento de Validação da Pesquisa</i>	110
8.2	<i>Apêndice B – Formulário de Feedback após Validação da Pesquisa</i>	110
9.	ANEXOS	112

1. INTRODUÇÃO

1.1 Contextualização

A história do empreendedorismo está associada à própria evolução dos grandes ciclos econômicos vividos pela humanidade. Segundo Dornelas, (2008) empreendedor é aquele que detecta uma oportunidade e cria um negócio para capitalizar sobre ela, assumindo riscos calculados. No âmbito da teoria econômica, a análise do ato de "empreender" ganhou força, quando, ao lado da criação de uma oportunidade, passou a ser relevante a introdução de inovação, por meio de novos métodos, novos mercados e/ou novos modos de comercialização.

Assim, para muitos, o empreendedorismo surgiu a partir da 1ª revolução Industrial, na Grã-Bretanha do século XVII, quando os empreendedores passaram a se distinguir dos fornecedores de capital, os capitalistas. Seguida posteriormente por outras revoluções, tais com 2ª e 3ª revolução industrial e o advento da computação e da robótica, que no século XXI, tende a levar o mundo a um nível de digitalização nunca visto antes, onde podemos citar convergências de novas tecnologias de informação e comunicação, Inteligência Artificial (IA), *Big Data*, Indústria 4.0 entre outras (Sebrae, 2023; Schwab, 2018).

A palavra "revolução" denota mudança abrupta e radical. Em nossa história, as revoluções têm ocorrido quando novas tecnologias e novas formas de perceber o mundo desencadeiam uma alteração profunda nas estruturas sociais e nos sistemas econômicos. A terceira revolução iniciou-se na década de 1960, ela costuma ser chamada de revolução digital ou informática, pois foi impulsionada pelo desenvolvimento dos semicondutores, da computação e *mainframe* (1960), da computação pessoal (1970) e da Internet (1990) (Schwab, 2018; Brynjolfsson & McAfee, 2014).

Face a isso, Schwab (2018), acredita que estamos no início da quarta revolução industrial (indústria 4.0). Ela teve seu início na virada do século XX e baseia-se na revolução digital no século XXI. É caracterizada por uma internet mais ubíqua e móvel, por sensores menores e mais poderosos que se tornaram baratos e pela inteligência artificial (IA) e aprendizado de máquina automática, ou seja, aprendizado de máquina (*machine learning*).

Diante do contexto atual de avanços tecnológicos e empreendedorismo, é fundamental que as micro e pequenas empresas (MPEs) se adaptem às novas formas de gestão e sejam capazes de competir no cenário global (Souza & Correa, 2014). Nesse sentido, existem agentes capacitadores que desempenham um papel crucial no desenvolvimento das MPEs, como o Serviço Brasileiro de Apoio às Micro e Pequenas Empresa (SEBRAE), uma entidade privada sem fins lucrativos atuante desde 1972. O SEBRAE contribui por meio de programas de capacitação, facilitação de acesso ao crédito e estímulo à inovação, além de promover o associativismo, feiras e rodadas de negócios, impulsionando a competitividade e o desenvolvimento sustentável desse setor (Sebrae, 2021).

Conforme o Sebrae (2018), as micro e pequenas empresas são categorizadas em diferentes tipos, incluindo o Microempreendedor Individual (MEI), Microempresa (ME) e Empresa de Pequeno Porte (EPP). A classificação das MPEs pode ser feita com base no porte do empreendimento, que varia de micro, pequena, média e grande empresa, levando em consideração o número de funcionários. É importante ressaltar que esse número pode variar de acordo com o setor de atividade, como indústria, construção, comércio e serviços.

A relevância das MPEs no contexto econômico-financeiro e na geração de emprego é perceptível quando analisamos seus números. Entretanto, necessitam se adaptar, por uma questão do mercado altamente competitivo e inovador, pois são importantes para economia nacional e mundial em função de sua quantidade, abrangência, capilaridade e capacidade de adaptação aos novos desafios (Sebrae, 2023; Santos et al. 2018; Souza & Correa, 2014). Estima-se que as MPEs compõem 95% das empresas no mundo, e no Brasil, esse fato não é diferente. De acordo com a Agência Sebrae (2023) o Brasil registrou a abertura de 3,6 milhões de novos pequenos negócios, isso demonstra um crescimento de quase 20% em relação à pré-pandemia da COVID-19. Observa-se que as MPEs são diferentes das grandes multinacionais em relação à economia e aspectos de

gestão (Santos et al., 2018; Souza & Correa, 2014; Ferreira et al., 2011), todavia os autores exaltam seu destaque na estrutura de um país e a necessidade de estudá-las.

Santos et al. (2018) destaca que, no entanto, o nascimento e a morte destas empresas têm ocorrido em grande escala, inclusive no cenário internacional. Ainda conforme o Sebrae (2021) há evidências que a mortalidade das MPEs no Brasil está acima da média mundial. Segundo pesquisa realizada pelo Sebrae (2021) muitas das empresas fecham mesmo antes de completar cinco anos de existência. São apontados diversos fatores condicionantes para este fato, tais como, o ambiente de negócios desfavorável, a crise econômica, a alta carga tributária, problemas particulares de sócios, a ausência ou pouco tempo destinado a planejamento da empresa antes do início da atividade, inexistência da assessoria de um contador, ausência do uso de informações contábeis para tomada de decisão, além da falta de acesso a crédito (Sebrae, 2021; Ferreira et al., 2012).

Conforme destacado por Aoki et al. (2014), a Constituição Federal de 1988 no Brasil estabelece um tratamento diferenciado para as MPEs, com o objetivo de incentivá-las e fortalecer sua participação no desenvolvimento econômico e social. No entanto, as políticas públicas direcionadas às MPEs muitas vezes impõem restrições que limitam o acesso a crédito. Ressalta-se que o acesso ao crédito é uma ferramenta crucial para o desenvolvimento econômico do país. Uma vez que as empresas não tenham acesso a recursos financeiros, isto reduz sua capacidade produtiva e de investimento, por sua vez diminui seu faturamento, a geração de emprego e renda, e eleva a mortalidade das MPEs (Sebrae, 2021; Aoki et al., 2014; Camargos et al., 2010).

Por outro lado, o fornecimento de crédito tanto pela iniciativa pública (BNDES/Finame) ou pela iniciativa privada (bancos e outras instituições financeiras) para MPEs é um desafio constante, uma vez que para se obter crédito, é necessário fornecer uma série de garantias para estas instituições. Para liberação de recursos financeiros, as instituições necessitam não só de garantias, mas também obter informações confiáveis sobre o negócio a respeito da saúde financeira, liquidez e solvência da empresa (Aoki et al., 2014). Para Camargos et al. (2010), qualquer instituição financeira mantém uma política de crédito e cobrança bem delimitada, o qual são exigidas várias informações socioeconômicas sobre a empresa e sobre os empresários solicitantes do crédito, visando minimizar a inadimplência e o risco de *default*.

Do exposto, para mitigar o risco de *default* e que a empresa entre no estado de insolvência faz-se necessário prever este fato o quanto antes. Nesse sentido, entende-se por previsão de insolvência, equações matemáticas capazes de identificar empresas na iminência de serem liquidadas ou tornarem-se insolventes (Pereira & Martins, 2015). De acordo com Costenaro (2021), ao longo do tempo, a predição de insolvência tem sido amplamente utilizada por empresas fornecedoras de crédito, especialmente bancos e instituições financeiras. Atualmente, os modelos de predição de insolvência têm como principal objetivo mensurar a probabilidade de uma empresa enfrentar um evento de *default* ao longo do tempo. Esses modelos são construídos com base em uma amostra de casos históricos de empresas de crédito, divididas em dois grupos: um grupo de empresas que enfrentaram eventos de *default*, chamado de insolventes, e outro grupo de empresas que não enfrentaram tal evento, chamado de solventes (Brito et al., 2009).

A análise de crédito tem sido historicamente o ponto de partida para a avaliação da insolvência das empresas. Seu objetivo é identificar os riscos nas situações de empréstimos, como argumentado por Silva (2017), a fim de obter conclusões sobre a capacidade de pagamento do tomador de empréstimo. Portanto, a verificação da insolvência é fundamental para subsidiar a decisão de conceder ou não crédito.

Sales e Nunes (2020) afirmam que muitas organizações enfrentam dificuldades de compreender o desempenho financeiro devido à falta de conhecimento das ferramentas e métodos necessários para detectar problemas nessa área. Diante disso, existe a probabilidade de insolvência, que indica que o devedor pode não ter os meios necessários para cumprir a maioria de suas obrigações.

Portanto, é necessário realizar uma classificação do risco de insolvência apresentado por cada empresa. Brito et al. (2009) explicam que os agentes de mercado classificam esse risco como

"rating" ou pontuação, "score", a fim de avaliar a probabilidade de as empresas cumprirem seus contratos. No entanto, é importante considerar também o aspecto interno da própria empresa, buscando diluir o risco de falência e realizar a predição de insolvência.

Assim, torna-se necessário o uso de modelos de previsão de insolvência no momento de tomar a decisão de concessão de crédito, pois os créditos são considerados "perdidos" no momento da concessão. Essa é a abordagem adotada pela Resolução do Conselho Monetário Nacional (número 2.682, de 21 de dezembro de 1999), que estabelece critérios para classificação de operadoras de crédito. Além disso, é essencial contar com modelos que avaliem a capacidade das empresas em situação financeira desconhecida, como é o caso das MPEs, a fim de determinar se elas serão capazes de se recuperar de uma situação financeira ruim ou de insolvência e ter sucesso. De acordo com Abreu (2023), as fronteiras entre uma situação econômica difícil e a insolvência são incertas e imprecisas. No entanto, em ambas as situações, seja uma situação financeira desfavorável ou uma insolvência iminente, há uma possibilidade, maior ou menor, de que a empresa enfrente dificuldades financeiras e entre em estado de insolvência. Essa realidade afeta empresas de todos os portes, sejam elas micro, pequenas, médias ou grandes.

Desde 1930, os avanços na área de Contabilidade/Finanças e tecnologia têm influenciado as pesquisas de previsão de insolvência. As pesquisas nesse campo tiveram início na década de 1930 com o estudo seminal de Fitzpatrick (1932) e, posteriormente, incluíram estudos conhecidos de Beaver (1966, 1968), Altman (1968), Ohlson (1980) e estudos realizados no Brasil por Kanitz (1976, 1978), Altman et al. (1979), Elizabetsky (1976) e Matias (1978). A evolução dos modelos preditivos passa por diversas fases, tais como, estudos de modelos univariados e multivariados, por meio de indicadores de fluxos de caixa, e recentemente os estudos vêm incorporando técnicas estatísticas avançadas e modelagem por meio de aprendizado de máquina (Lee & Shin, 2020; Costenaro, 2021; Pereira & Martins, 2015).

Nesse contexto, após o advento da crise financeira de 2008, que teve seu início nos Estados Unidos e se espalhou pelo mundo (Callado & Melo, 2018), adicionalmente percebe-se a intensificação de estudos de predição de insolvência nos últimos anos (Ciampi, 2015). Pode-se citar trabalhos como os de Scarpel, (2008), Brito et al. (2009), Guimarães e Moreira (2008), Guimarães e Alves (2009), Gevert et al. (2010), Horta et al. (2014), Soares e Rebouças (2015), Prado et al. (2020), Soares et al. (2021) e Almeida et al. (2023) em que constata-se que estes estudos são voltados a grandes empresas. Nos últimos anos as pesquisas de predição de insolvência têm avançado na direção das MPEs, Lemos e Oliveira (2012), Hirsch (2013), Andreeva et al. (2016), Crosato et al. (2021), entretanto ainda são poucos os trabalhos. Estes estudos utilizam tanto técnicas estatísticas, quanto modelagem por meio de algoritmos de aprendizado de máquina e inteligência artificial, utilizando redes neurais artificiais.

As tendências tecnológicas têm impulsionado o uso de aprendizagem de máquina em várias indústrias. A adoção de aprendizado de máquina tem alcançado um ponto de inflexão tecnológica e social à medida que a competição tem pressionado as empresas por mais inovação (Lee & Shin, 2020; Schwab, 2021). Brynjolfsson e McAfee (2014) afirmaram que os computadores estavam tão hábeis que era praticamente impossível prever suas novas utilidades em alguns poucos anos no futuro. A inteligência artificial (IA) está em nosso entorno, em carros que pilotam sozinhos, *drones*, assistentes virtuais, em forma de *chatbots* ou *softbots*, *softwares* de tradução e *agentes inteligentes*. Isso está transformando a sociedade como um todo. A IA fez progressos impressionantes, impulsionada pelo aumento exponencial da capacidade de processamento (Lee & Shin, 2020) e pela disponibilidade de grandes quantidades de dados (*big data*), desde *softwares* usados para descobrir medicamentos até algoritmos que preveem nossos interesses culturais, recomendem quais os melhores ativos a serem comprados no mercado financeiro, ou agentes inteligentes que nos auxiliam nas atividades do dia a dia (Schwab, 2018).

A capacidade de subáreas da IA já foi vislumbrada, de acordo com Schwab (2018), atualmente, o reconhecimento de voz e inteligência artificial progredem em uma velocidade tão rápida, que falar com computadores se tornará em breve algo da vida do cotidiano. Por outro lado,

a ideia de agentes inteligentes não é nova, o conceito de agente originou-se na inteligência artificial, que teve seu início em Dartmouth College em 1956, com a ideia de conjecturar sobre cada aspecto do aprendizado, e fazer com que as máquinas usem a linguagem, a partir de abstrações e conceitos, resolvam os tipos de problemas antes restritos aos seres humanos e se aperfeiçoem (Russell & Norvig, 2022; Weiss et al., 2010).

Pode-se definir um agente como um programa de computador capaz de executar tarefas de forma autônoma para o qual foram projetados sem serem explicitamente programados. Um agente pode ser capaz de perceber seu ambiente por meio de sensores e de agir sobre esse ambiente por intermédio de atuadores (Russell & Norvig, 2022; Weiss et al. 2010). Desta forma, pode-se ter sistemas multiagentes, isto é, vários agentes se comunicando por meios de trocas de mensagens em uma rede. Pode-se delegar para um agente a execução de tarefas em favor de seus usuários, pode-se citar o exemplo de um agente que atua no mercado financeiro comprando e vendendo ações, com base em seu conhecimento do histórico de preço dos ativos, ou ainda, o agente motorista de táxi onde sua função é levar passageiro com segurança para um determinado destino (Russell & Norvig, 2022; Boissier et al., 2020; Bordini & Dastani, 2010; Wooldridge, 2009).

Os sistemas multiagentes (SMA) representam uma abordagem inovadora na concepção de sistemas inteligentes, integrando a atuação de múltiplos agentes autônomos capazes de perceber, raciocinar e interagir de maneira cooperativa ou competitiva. Este paradigma, conforme discutido por Russell & Norvig (2022) e Wooldridge (2009), proporciona a flexibilidade necessária para adaptação a ambientes dinâmicos, enfatizando a importância da inteligência dos agentes na tomada de decisões autônomas. Nesse contexto, a aplicação de um agente inteligente pode permitir que ele adquira habilidades de um especialista em finanças, com o objetivo de prever a insolvência de uma empresa. O agente atuará de forma independente, reagindo às percepções recebidas (mudança nas informações financeiras) e se adaptando à evolução do ambiente organizacional para auxílio dos profissionais responsáveis pela tomada de decisão.

Neste contexto, os agentes são considerados inteligentes quando demonstram autonomia, reatividade, pró-atividade e habilidades sociais, conforme destacado por Wooldridge (2009). Essas características fundamentais capacitam os agentes a desempenharem uma variedade de papéis em sistemas multiagentes, respondendo a estímulos do ambiente, tomando iniciativas e interagindo de maneira socialmente competente.

A modelagem desses agentes, crucial para o desenvolvimento de sistemas baseados em aprendizagem, encontra respaldo em metodologias específicas, como a Tropos. Este trabalho explora a complexidade e a importância da modelagem em sistemas multiagentes, apresentando o seu desenvolvimento por meio das fases da metodologia Tropos, a qual se destaca pela modelagem orientada a objetivos, discutindo a relevância do raciocínio autônomo dos agentes. Além disso, destaca a aplicação de agentes baseados em técnicas de aprendizado de máquina, utilizando o classificador Floresta Aleatória (*Random Forest*) e na previsão de eventos de insolvência, particularmente no contexto financeiro das micro e pequenas empresas. Ao delinear esses tópicos, busca-se fornecer uma solução funcional que auxilie os pequenos negócios em sua gestão e tomada de decisão.

Com relação à abordagem metodológica, este estudo utiliza a *Design Science Research* (DSR), sendo que a sua principal característica é a ênfase na evolução de uma “ciência de projeto”. A DSR busca contribuir para o avanço do conhecimento, promovendo uma abordagem multidisciplinar para resolver problemas complexos contextualizados, resultando em soluções funcionais e aplicáveis a diferentes contextos (Dresh et al., 2015; Gregor & Havner, 2013; Hevner & Chatterjee, 2010).

Nesse contexto, a adoção da metodologia DSR no emprego da solução visa auxiliar a gestão das MPEs, contribuindo para prevenção de insolvência antes que empresa tenha sua falência decretada. A metodologia é empregada para construção de artefatos eficazes voltados para o problema de insolvência das empresas. Por fim, este estudo propõe uma solução abrangente para o fenômeno de insolvência das MPEs no Brasil, visando reduzir sua taxa de mortalidade. Para

tanto, são desenvolvidos dois artefatos: um modelo de aprendizado de máquina para prever a insolvência e um sistema multiagente autônomo com capacidade de aprendizado que utiliza o modelo preditivo gerado para atuar como ferramenta para tomada de decisão no ambiente empresarial. O desenvolvimento da pesquisa segue as diretrizes proposta por Dresch et. al (2015), com base nos trabalhos seminais (Gregor & Havner, 2013; Peffers et al. 2007; Hevner et al. 2004).

1.2 Problema e Objetivos

Durante pesquisa bibliográfica empreendida neste estudo, verificou-se que a predição de insolvência e mitigação do risco de falência tem se tornado cada vez mais complexa. Verificou-se que a análise das demonstrações contábeis exerce muita relevância, entretanto há evidências de descrédito a elas como fonte principal de informação, uma por inconsistência imposta pela legislação e outra pela não conformidade ou ausência de informações pelas empresas. (Barboza et al, 2017; Altman et al., 2010; Pereira & Martins, 2015; Ciampi, 2015).

O uso de modelo estáticos, baseados em análise discriminante nos primórdios da predição de insolvência, teve um papel fundamental (Altman, 1968; Ohlson, 1966), seguindo-se de modelos univariados e multivariados, sendo que ao longo dos últimos anos tem-se empregado novas abordagens, com técnicas mais avançadas de aprendizado de máquina e redes neurais, as quais são chamadas de modelos de terceira geração e técnicas avançadas (Ciampi, 2015; Pereira & Martins, 2015).

Nota-se que estudos atuais estão dando ênfase em atributos não mensurados via demonstrativos contábeis ou indicadores não financeiros (e.x: tamanho do *board* executivo, quantidades de diretores etc.) (Lee & Shin, 2020). Durante esta pesquisa, foi realizada uma análise da modelagem de modelos preditivos no contexto das micro e pequenas empresas (MPEs). Foi constatado que existem lacunas na literatura em relação ao uso de modelos estatísticos, como análise discriminante e regressão logística, especificamente voltados para as MPEs. Observou-se a tentativa de replicar os modelos tradicionais às MPEs (Hirsch, 2013), em que vários desafios são encontrados devido à natureza dessas empresas (Santos et. al. 2018) e os modelos não terem sido concebidos levando este fator em consideração.

Adicionalmente, há poucos estudos de predição de insolvência para micro e pequenas empresas que utilizam a abordagem de aprendizado de máquina juntamente com inteligência artificial. Ainda mais, não foi encontrada nenhuma evidência de estudo que procure abordar agentes inteligentes como uma proposta de solução que busque trazer a eficiência aos modelos preditivos de insolvência aplicados ao contexto da MPEs.

Nesse sentido, esta pesquisa, além de assumir a premissa de que há possibilidade de se identificar, por meio das demonstrações contábeis das micro e pequenas empresas entre outras informações não mensuradas em demonstrativos, a sua situação financeira, também pretende mensurar a capacidade de solvência dessas organizações, através da elaboração de um agente inteligente com capacidade de prever a insolvência que irá utilizar as técnicas de aprendizado de máquina e agindo de forma inteligente para aprender os padrões dos dados de acordo com a particularidade dessas empresas.

A interpretação, precisão, confiança e usabilidade, são elementos contundentes, quando se trata de IA e seus algoritmos (Schwab, 2018; Lee & Shin, 2020). Conforme se materializa as tendências de inteligência artificial, cada vez mais veremos o uso de agentes inteligentes para resolver problemas em favor de seus usuários, e facilitar o uso de ferramentas avançadas no estado da arte da IA.

À luz do exposto acima, surgiu como problema desta pesquisa a seguinte questão: **Como a elaboração de um sistema multiagente baseado em aprendizado de máquina pode auxiliar na predição de insolvência das micro e pequenas empresas no Brasil?**

1.2.1 Objetivo geral

Agora que a questão deste estudo já foi apresentada, é possível partir para a formulação dos objetivos da pesquisa. Segundo Gil (2008), a determinação de objetivos da pesquisa é uma tarefa importante porque indica o ponto de partida e a direção a seguir.

Portanto, diante do exposto e considerando a questão proposta, esta pesquisa tem como objetivo elaborar um sistema multiagente de predição de insolvência no Brasil sobre o prisma da estruturação de um modelo de aprendizado de máquina sendo a base de conhecimento do agente com capacidade de medir e prever o estado de insolvência de micro e pequenas empresas. Busca-se, em específico, desenvolver, a partir da vasta literatura, um modelo que contemple os indicadores previamente citados na literatura sobre o tema, e elaborar um sistema com três agentes, sendo um agente que faça a predição de insolvência por meio de aprendizado de máquina, um agente capaz de recomendar tratamentos para que empresa deixe a situação de insolvência e um agente que irá monitorar o desempenho do negócio enviando notificações de alerta, para melhorar da interpretabilidade, precisão, bem como, auxílio na gestão estratégica das micro e pequenas empresas.

O presente trabalho pretende contribuir no entendimento dos modelos preditivos de insolvência, não somente aplicados para uso pelos fornecedores de recursos financeiros (bancos e instituições financeiras), mas também do ponto de vista das empresas que precisam se antecipar aos cenários financeiros para tomada de decisão. Adicionalmente trazer uma visão geral da aplicação de agentes inteligentes, especialmente, sistemas multiagente que se comunicam entre si aplicados no contexto de insolvência para melhor interpretabilidade e usabilidade dos modelos preditivos, em virtude de que até o momento, não foram encontradas evidências de terem sido explorados na literatura atual.

Em outras palavras, pode-se dizer que, nesta dissertação, toda a análise da literatura e toda a construção do desenho da pesquisa empírica seguem a direção comum de propor uma solução que seja satisfatória para auxiliar as micro e pequenas empresas a mitigar o risco de insolvência e auxiliar a gestão das organizações ter capacidade de tomar melhores decisões para continuidade do negócio.

1.2.2 Objetivos específicos

Para que o seguimento desta direção comum seja viabilizado, especificamente, este trabalho irá explorar o fenômeno de predição de insolvência por meio de agente inteligentes e aprendizado de máquina, colocaram-se os seguintes objetivos específicos:

- a) Pesquisar a literatura existente sobre tema de insolvência, no que tange, as abordagens propostas para estudo deste fenômeno.
- b) Investigar a abordagem de previsão de insolvência para micro e pequenas empresas.
- c) Analisar a representatividade das micro e pequenas empresas, bem como, sua taxa de mortalidade.
- d) Analisar as técnicas de inteligência artificial e aprendizado de máquina utilizadas no campo da predição de insolvência
- e) Averiguar as variáveis que são utilizadas nos modelos que predizem o estado de insolvência das empresas
- f) Analisar os tipos de agentes inteligentes e suas aplicações em diversos setores da economia
- g) Pesquisar a modelagem de agentes inteligentes no que tange sistemas multiagente para resolver problemas nas organizações

1.3 Justificativas

De acordo com Santos et al. (2017) a maioria das pesquisas são conduzidas voltadas às grandes empresas. Principalmente empresas de capital aberto onde há disponibilidade maior de dados. Assim, os estudos de previsão de insolvência que têm suas origens na década de 1930, têm

sido feitos para empresas de grande porte, como constatado pela revisão sistemática feita por Pereira e Martins (2015).

A relevância desta pesquisa reside no fato da força inquestionável e representatividade das MPEs, sendo mais de 95% dos negócios, no Brasil e em outros países (Sebrae, 2022; Ferreira et al. 2011). Nesse sentido, as Micro e Pequenas Empresas (MPEs) desempenham um papel fundamental no desenvolvimento econômico de um país, contribuindo significativamente para a geração de empregos, inovação e dinamismo nos mercados. No entanto, essas empresas enfrentam desafios únicos, como acesso limitado a recursos financeiros, menor capacidade de investimento em tecnologias e sistemas avançados de gestão. Há evidências de que a taxa de mortalidade dessas empresas está acima da média mundial. Muitas fecham as portas nos seus primeiros anos de vida (Santos et al. 2018; Souza & Correa, 2014; Ferreira et al. 2012).

Dado este contexto, mitigar o alto índice de mortalidades das MPEs tem se tornado cada vez mais relevante, e a temática de previsão de insolvência se tornado essencial na concretização deste objetivo. Entender os fatores que levam uma empresa a enfrentar dificuldades financeiras e ser capaz de prever tais situações de forma antecipada é um desafio constante ainda mais no cenário das micro e pequenas empresas brasileiras (Costenaro, 2021; Hirsch, 2013; Lemes & Oliveira, 2012). A busca pela sobrevivência das MPEs passa por se adaptar ao novo mundo, dominado por novas tecnologias, sendo estas emergentes (*big data*, inteligência artificial, *IoT* dentre outras) (Schwab, 2018; Santos et al. 2017; Brynjolfsson & McAfee, 2016).

Nesse sentido, a utilização de técnicas de inteligência artificial, mais especificamente a elaboração de um sistema multiagente para previsão de insolvência, baseado no aprendizado máquina, apresenta-se como uma solução promissora. A inteligência artificial possui a capacidade de analisar grandes volumes de dados e identificar padrões e tendências ocultas que podem ser indicadores de problemas financeiros iminentes. Enquanto os agentes podem operar de forma autônoma em prol da empresa auxiliando nesta complexa tarefa de prever o estado de insolvência em dada as condições de seu ambiente. Além disso, a aplicação da inteligência artificial e agentes inteligentes na previsão de insolvência contribuirá para o avanço do conhecimento científico nessa área, uma vez que o contexto brasileiro das MPEs apresenta características específicas que precisam ser consideradas no desenvolvimento de soluções inovadoras (Russel & Norvig, 2022; Kirrane, 2021; Santos et al., 2018; Souza & Correa, 2014; Girardi & Leite, 2013; Weiss et al. 2010).

Portanto, a elaboração de um sistema multiagente para previsão de insolvência adaptado às particularidades das micro e pequenas empresas brasileiras se torna essencial. Essa pesquisa contribuirá para a melhoria da gestão financeira dessas organizações, permitindo uma tomada de decisão mais embasadas e auxiliando na identificação precoce de problemas financeiros, o que possibilitará a adoção de medidas corretivas e oportunas.

Espera-se que os resultados deste estudo possam subsidiar tanto a academia quanto as empresas brasileiras, fornecendo informações valiosas para aprimorar os modelos de previsão de insolvência existentes e desenvolver estratégias eficientes de gestão financeira. Ademais, essa pesquisa poderá servir como base para futuros estudos e aplicações práticas que visem melhorar a saúde financeira das micro e pequenas empresas no Brasil.

2. REFERENCIAL TEÓRICO

2.1 Micro e Pequenas Empresas

A Lei Geral de Micro e Pequenas Empresas, também conhecida como Estatuto Nacional da Microempresa e da Empresa de Pequeno Porte, foi criada pela Lei Complementar n 123/2006 para regulamentar um tratamento favorecido, simplificado e diferenciado a esse setor, conforme disposto na Constituição Federal. Por outro lado, segundo o Sebrae (2020) que realizou uma pesquisa Sobrevivência de Empresas, identificou que a taxa de mortalidade das microempresas, após cinco anos, é de 21,6% e a das entidades de pequeno porte, de 17%. Ainda conforme esse levantamento, cerca de 34% dos entrevistados disseram acreditar que ter acesso a crédito poderia ter evitado o fechamento da empresa, sendo que apenas 7% do grupo de empresas que fecharam

havia solicitado crédito bancário e não obtiveram êxito. O objetivo principal do Sebrae é fomentar o desenvolvimento e competitividade de Micro e Pequenas Empresas e de Microempreendedores Individuais como estratégia de geração de emprego, distribuição de renda, inclusão social, redução da informalidade e fortalecimento da economia.

Conforme dados do Sebrae (2022) e a Lei Geral Simplificada, as micro e pequenas empresas são divididas, tais como, Microempreendedor Individual (MEI), Microempresa (ME) e Empresa de Pequeno Porte (EPP). A tabela 1 - Demonstra que a classificação do porte das empresas está baseada na receita bruta anual.

Tabela 1: Enquadramento das Micro, Pequenas e Médias Empresas com base na receita anual.

Classificação	Critério de Enquadramento
MEI	Receita bruta anual de até R\$ 81 mil
ME	Receita bruta anual de até R \$360 mil.
EPP	Receita bruta anual superior a R\$ 360 é igual ou inferior a R\$ 4,8 milhões

Nota. Adaptado de Sebrae (2022).

Dada a importância das MPEs, a lei garante que toda nova obrigação que atingir os pequenos negócios deve especificar, no instrumento que a instituiu, o tratamento diferenciado, sob pena de não se aplicar às micro e pequenas empresas. Ainda há a existência de outros enquadramentos para MPEs, tais como, receita federal e Banco Nacional de Desenvolvimento (BNDES) que podem utilizar critérios tanto de faturamento, bem como, número de pessoas ocupadas. Alguns fatores são aplicados para categorizar as empresas nos setores da indústria, comércio e serviços, esses são os critérios utilizados pelo Sebrae (2018), como demonstra a tabela 2. Assim, uma empresa de comércio que possui de dez (10) a quarenta e nove (49) funcionários, pode ser classificada como de pequeno porte, caso as empresas tenham entre cinquenta (50) e noventa e nove (99) empregados é classificada como uma empresa de médio porte. Entretanto, há diferenças entre a classificação das empresas feita pelo Sebrae e o BNDES.

Tabela 2: Classificação de empresas por porte conforme seu setor de atuação.

Porte	Setores	
	Indústria e Construção	Agropecuária, Comércio e Serviços
Microempresa	até 19 pessoas ocupadas	até 9 pessoas ocupadas
Pequena empresa	De 20 a 99 pessoas ocupadas	De 10 a 49 pessoas ocupadas
Média empresa	De 100 a 499 pessoas ocupadas	De 50 a 99 pessoas ocupadas
Grande Empresa	500 pessoas ocupadas ou mais	100 pessoas ocupadas ou mais

Nota. Adaptado de Sebrae (2018).

Pela pesquisa de Monitoramento Global do Empreendedorismo (GEM), que é a principal pesquisa de empreendedorismo no mundo. Realizada há 22 anos, onde já participaram mais de 115 países, que respondem por mais de 95% da população e do PIB mundial. GEM (2021), demonstra que o empreendedorismo, medido pela proporção da população adulta (18 a 64 anos) está envolvida com um empreendimento, é um fenômeno muito diferente em todo o mundo. Nesse caso, não é incomum que pequenos negócios, em especial, os de caráter familiar, respondam por uma parcela elevada da população em atividade.

O Brasil é considerado um país com alto índice de empreendedorismo. Isto está associado, ao fato de que "ter um negócio próprio" é considerado um dos principais sonhos a serem atingidos pelo brasileiro. Segundo a pesquisa GEM (2021) onde participaram 50 países, o Brasil chegou a 30,4% da população adulta (18 a 64 anos) envolvida em empreendedorismo. Em termos

quantitativos, os pequenos negócios representam em torno de 99% das empresas brasileiras e, mesmo em condições adversas, como ocorreu em 2020, com o esfriamento da economia provocado pela pandemia de covid-19, houve uma queda de apenas 0,5% no número de registros de abertura das Micro e Pequenas Empresas. O ano de 2020 apresentou 626.883 MPEs abertas, enquanto, em 2019, foram 629.738. Isso é uma pequena amostra do universo dessas empresas; há uma infinidade de outros números que comprovam a força das MPEs.

Desta forma, no Brasil, a taxa total de empreendedorismo passou de 20,9% para 39,3% da população adulta, entre 2002 e 2015, quase dobrando a taxa, em pouco mais de uma década. Isto se dá por conta de que, em parte, ocorreu uma melhora no ambiente para empreender e pela regulamentação na área, por meio da Lei Geral das MPE, Simples Nacional, pela criação do MEI entre outros.

Adotou-se nesse estudo o enquadramento utilizado pelo Sebrae, respaldado na Lei Geral de Micro e Pequenas Empresas, ou seja, empresas que obtiveram o faturamento anual de até R \$4,8 milhões.

2.1.1 Evolução das micro e pequenas empresas

Considerando um horizonte de 11 anos, segundo o Panorama geral das Micro e Pequenas Empresas feito pelo Sebrae (2022), nota-se que o total de MPEs apresentou crescimento de cerca de 28% entre 2010 e 2017. No entanto, desde então, observou-se um movimento de redução no total de MPE, sendo que em 2021 o total chegou a 7,2 milhões, figura 1.




Figura 1: Gráfico total de micro e pequenas empresas ativas

Nota. Pesquisa Sebrae (2022).

Quando se analisa isoladamente microempresas e empresas de pequeno porte, figura 2, nota-se que entre as empresas de pequeno porte (EPP) o movimento foi de expansão, e que, portanto, a contração das empresas se dá nas esferas da Microempresas (ME).




Figura 2: Expansão das empresas EPPs e MEIs.

Nota. Pesquisa Sebrae (2022).

Os dados da tabela 3 demonstram os registros de abertura de Empresas de Pequenos Porte (EPP), Microempresas (ME) e de Microempreendedores Individuais (MEI) para os anos de 2019 a 2021, segundo os dados coletados pelo Sebrae (2022) e Receita federal do Brasil.

Tabela 3: Abertura de Micro e Pequenas empresas

Porte	2019	2020	2021
EPP	87.713	95.135	122.538
ME	584.382	585.792	690.977
MEI	3.413.219	2.603.470	3.120.530
Total	3.085.314	3.284.397	3.934.045

Nota. Adaptado de pesquisa Sebrae (2022).

Contudo, temos que considerar as empresas baixadas no período. Em 2021, foram 938 mil MEI baixados e 425 mil MPEs. A tabela 4 demonstra o fechamento das empresas de porte nos anos de 2019 a 2020.

Tabela 4: Fechamento de empresas por Porte de 2019 a 2020

Porte	2019	2020	2021
EPP	35.631	35.766	40.049
ME	3364.730	347.348	385.863
MEI	714.815	624.761	938.552
Total	1.115.176	1.007.875	1.364.464

Nota. Adaptado de Pesquisa Sebrae (2022).

São apontados diversos fatores condicionantes para este fato (fechamento dos negócios), tais como, o ambiente de negócios desfavorável, a crise econômica, a alta carga tributária, problemas particulares de sócios, a ausência ou pouco tempo destinado a planejamento da empresa antes do início da atividade, inexistência da assessoria de um contador, ausência do uso de informações contábeis para tomada de decisão, além da falta de acesso a crédito. Entretanto, esses dados confirmam a importância de se gerar ferramentas úteis para MPEs terem a capacidade de dar continuidade ao negócio (Sebrae, 2021; Ferreira et al., 2012).

2.2 O conceito de Insolvência

Etimologicamente, insolvência consiste na falta de solvência, de solvo (*solvi, solutum*). *Solvere* é um verbo latino que significa desatar, livrar, pagar, resolver: *in Dicionário Latino-português*, menciona Rosário (2012), no que tange, o Direito da Insolvência na esfera jurídica.

Lemos (2012) diz que insolvência é um termo oriundo do latim *solvere*, regido pela negativa *in*, significa "o estado em que se encontra a pessoa de não poder solver ou não poder pagar suas dívidas" ou "não poder cumprir com suas obrigações". Entretanto, em termos jurídicos, a insolvência é concedida toda vez que as dívidas excederem à importância dos bens do devedor. (art. 748 do Código de Processo Civil, Lei n 5.869 de 11.01.1973). Verifica-se que este conceito abrange especificamente o devedor pessoa física. A respeito de pessoas jurídicas, o artigo 94º da Lei n 11.101, de 09.02.2005, prevê a falência do devedor que:

- i) - sem relevante razão de direito, não paga, no vencimento, obrigação líquida materializada em título ou títulos executivos protestados, cuja soma ultrapasse o equivalente a 40 (quarenta) salários-mínimos na data do pedido de falência;
- II) - executado por qualquer quantia líquida, não paga, não deposita e não nomeia à penhora bens suficientes dentro do prazo legal;
- III – pratica qualquer dos seguintes atos, exceto se fizer parte do plano de recuperação judicial:
 - a) procede à liquidação precipitada de seus ativos ou lança mão de meio ruinoso ou fraudulento para realizar pagamentos;
 - b) realiza ou, por atos inequívocos, tenta realizar, com o objetivo de retardar pagamentos ou fraudar credores, negócio simulado ou alienação de parte ou da totalidade de seu ativo a terceiro, credor ou não;
 - c) transfere estabelecimento a terceiro credor ou não sem o consentimento dos demais credores e sem ficar com bens suficientes para solver seu passivo;
 - d) simula a transferência de seu principal estabelecimento com o objetivo de burlar a legislação ou a fiscalização ou para prejudicar credor;
 - e) dá ou reforça garantia a credor por dívida contraída anteriormente sem ficar com bens livres e desembaraçados suficientes para saldar seu passivo;

Duarte e Barbosa (2020) definem a dificuldade financeira das empresas como sendo a incapacidade de uma determinada empresa de pagar suas obrigações financeiras com seus credores, sejam eles fornecedores, instituições financeiras e acionistas. Classicamente em finanças, uma empresa no estado de insolvência significa que ela não possui capacidade de cumprir suas obrigações de pagamentos, nesse sentido a situação de insolvência pode ser caracterizada como ausência de dinheiro, ou seja, sem liquidez, argumenta (Nunes & Sales, 2020; Duarte et al., 2020; Rezende et al., 2017).

Nunes e Sales (2020) entendem que a insolvência é a incapacidade de pagar dívidas, é uma premissa básica do conceito. A situação de insolvência ou não vai mais além da simples definição de concordatas e/ou falências para empresas. Nota-se que essas definições compreendem os aspectos gerais sobre conceito de insolvência. Tanto para uma pessoa física ou jurídica, que pode estar em estado de insolvência. Portanto, delimita-se o termo insolvência, nesse estudo, como a incapacidade de a empresa não arcar seus débitos junto a seus fornecedores e credores, por estar passando por dificuldades financeiras em determinado período.

Na avaliação de Rezende et al. (2017), o conceito de dificuldade financeira ou insolvência, não é definido de forma precisa se comparado às legislações que definem os processos, como falência, recuperação judicial, liquidação e concordata. Evita-se, dessa maneira, qualquer

incoerência metodológica, pois a definição não é tão simples, conforme se verificou em estudos e bibliografias sobre administração, economia e finanças.

2.2.1 Instituições legais e Lei de Recuperação Judicial e Falência

A Lei nº 11.101/2005, conhecida como a nova Lei de Falência e Recuperação de Empresas, trouxe uma nova abordagem para lidar com a falência e reorganização de empresas em dificuldades no Brasil. Essa legislação introduziu importantes inovações nos processos falimentares e de recuperação, tornando-os mais conhecidos e eficientes.

Os dispositivos da Lei foram redigidos com base nos seguintes princípios, conforme descrito no parecer da Comissão de Assuntos Econômicos do Senado Federal: preservação da empresa, distinção entre os conceitos de empresa e empresário, busca pela recuperação das sociedades e empresários que podem ser recuperados, retirada do mercado das sociedades ou empresários que podem ser recuperados e redução do custo do crédito no Brasil.

A Recuperação Judicial tem como objetivo principal promover a reestruturação da gestão empresarial, buscando alcançar um "lucro autossustentável" que permita superar a crise econômico-financeira enfrentada pela empresa. Seu foco está na preservação da atividade econômica, na manutenção dos empregos e na garantia dos interesses dos credores (da Silva, 2018).

2.3 Evolução dos Estudos Internacionais e Nacionais de Predição de Insolvência

Previsão de insolvência, segundo Pereira & Martins (2015), são equações matemáticas capazes de identificar empresas na iminência de serem liquidadas ou tornarem-se insolventes. Previsão insolvência tem um histórico de longa data na literatura, tanto nacional, como na internacional, a sua discussão remonta à década de 1930, com o estudo de Fitzpatrick (1932) e Smith (1935), tomando ímpeto nos anos de 1970 no Brasil, com estudo de Kanitz (1978) e Elizabetsky (1976) entre tantos outros, onde foram espelhados nos trabalhos de Altman (1968) e Ohlson (1966). Os autores procuravam entender o insucesso de empresas com base nos indicadores obtidos a partir dos demonstrativos contábeis (Horta et al. 2014; Ciampi, 2015).

Pereira e Martins (2015) e Gissel et al. (2007) realizaram um levantamento sistemático, sobre estudos preditivos de insolvência, trazendo à tona a cronologia dos estudos nesse campo com maior relevância, e podem ser agrupados em dois aspectos. O primeiro aspecto envolve quais indicadores financeiros são utilizados nos testes empíricos; o segundo trata o tipo de método estatístico utilizado na previsão. Tendo como base os dois aspectos citados, pode-se agrupar a previsão de falência em cinco fases distintas de seus desenvolvimentos conforme (Tabela 5).

Tabela 5: Fases da evolução histórica de estudos sobre o tema de insolvência das empresas.

-	Descrição
Fase I	Análise financeira comparativa de indicadores sem modelos estatísticos para prever falência
Fase II	Estudos de modelos univariados baseados em indicadores contábeis tradicionais
Fase III	Estudos de modelos multivariados baseados em indicadores contábeis tradicionais
Fase IV	Estudos de modelos multivariados baseados em fluxo de caixa
Fase V	Estudos de modelos multivariados baseadas em técnicas estatísticas de terceira geração (Machine Learning, Redes Neurais, Análise por Envoltória de Dados, dentre outras) e o uso de indicadores financeiro-contábeis e não contábeis

Nota. Adaptado de Pereira & Martins (2015)

2.3.1 Insolvência nas Micro e Pequenas Empresas

Conforme a pesquisa de Muñoz-Izquierdo et al. (2018), 94% dos negócios no mundo são pequenos, 5% são médios e apenas 1% é de grande porte. No Brasil, de acordo com o Sebrae (2022) 95% das empresas são micro e pequenas (MPEs).

Por outro lado, as MPEs, têm mais dificuldades em seus estágios iniciais, principalmente devido à alta competição de mercado e falta de crédito (Crosato et al., 2021; Santos et al., 2018). Dada a alta taxa de mortalidade dessas empresas, a predição de insolvência, se faz altamente necessária, atualmente e no futuro que se apresenta, pois as MPEs são força motriz em nosso país (Sebrae, 2023; Santos et al., 2018; Souza & Correa, 2014).

Durante a pesquisa bibliográfica, foram encontrados alguns trabalhos que focaram especificamente na predição de insolvência para pequenas e médias empresas. Estes trabalhos, consultados tanto no Brasil e internacionalmente, seguem relacionados na tabela 6, com o intuito de apresentar o estado atual das pesquisas acadêmicas como foco em MPEs.

Tabela 6: Estudos que abordam a predição da insolvência das MPEs

Autor	Ano	Estudo
Crosato, L., Domenech, J., & Liberati, C.	2021	<i>Predicting SME's default: Are their websites informative?</i>
Sacramone, M. B., Waisberg, I., Nunes, M. G., & Scardoa, R.	2020	O processo de insolvência e o tratamento das microempresas e empresas de pequeno porte em crise no Brasil. <i>Pensar—Revista de Ciências Jurídicas</i> , 25(3), 2317-2150.
Beatriz Galeano Lima Cardoso, M	2018	Causas da Insolvência das Pequenas e Médias Empresas: a percepção dos empresários dos conselhos de Castelo Branco e da Covilhã
Tobback, E., Bellotti, T., Moeyersoms, J., Stankova, M., & Martens, D	2017	<i>Bankruptcy prediction for SMEs using relational data</i>
Andreeva, G., Calabrese, R., & Osmetti, S. A	2016	<i>A comparative analysis of the UK and Italian small businesses using Generalized Extreme Value models</i>
Hirsch G.	2013	Aplicabilidade dos modelos de previsão de insolvência nas micro e pequenas empresas
Lemos, L. F., & Oliveira, R. S	2012	Previsão de Insolvência em Micro e Pequenas Empresas Utilizando Indicadores Contábeis.
Lemos, L. F. B.	2009	Elaboração de um Modelo de Insolvência para Micro e Pequenas Empresas utilizando Indicadores Contábeis

A literatura sobre predição de insolvência de MPEs, abrange uma variedade de estudos de caso e metodologias, partindo desde regressão logística (LR) até inteligência artificial (IA) e *support vector machine* (SVM). A maioria dos métodos são aplicados em dados financeiros e contábeis (Crosato et al., 2021; Andreeva et al. 2016). Para Tobback et al. (2017), e são poucos os trabalhos que contêm informações sobre o contexto de gestão, sendo dados qualitativos do gerenciamento das empresas.

Nesse contexto, Lemos e Soares (2012) procuraram gerar um modelo de previsão de insolvência para as MPEs, dada a relevância dos micros e pequenos negócios no Brasil referente ao período de 1995 a 2007, utilizando indicadores contábeis, e aplicando análise discriminante, juntamente com análise fatorial. Como resultado, diminui-se de 25 indicadores para 5 fatores, onde o modelo alcançou a precisão de 96,15%. Posteriormente se gerou uma régua de insolvência, com uma escala ilustrativa, com análise de conglomerados com a amostra da pesquisa.

2.3.2 Fase I – Análise Financeira comparativa de indicadores sem modelos estatísticos para prever falência

Os primeiros estudos de previsão de falência incluíram indicadores financeiros com o objetivo de investigar a utilidade dessas análises comparativas para distinguir empresas falidas de empresas bem-sucedidas. Esses estudos foram univariados e tiveram implicações importantes no

desenvolvimento de modelos futuros, servindo como base para modelos multivariados de previsão de falência (Pereira & Martins, 2015; Tinoco, 2013; Mateos-Ronco, 2011; Gissel et al., 2007).

Pode-se citar alguns estudos pioneiros de previsão de falência com caráter descritivo, tais como: *Bureau of Business Research* (1930), Ramser e Foster (1931), Fitzpatrick (1932) entre outros, sendo este último o mais relevante dessa época (Lee & Shin, 2020; Duarte et al., 2020; Pereira & Martins 2015).

2.3.3 Fase II – Estudos de modelos univariados baseados em indicadores contábeis tradicionais

Tinoco (2013) destaca o estudo fundamental de Beaver (1966), que utilizou uma abordagem univariada com indicadores contábeis importantes para distinguir empresas solventes das insolventes. Gissel et al. (2007) e Pereira & Martins (2015) reconhecem a relevância do estudo de Beaver (1966), que comparou os valores médios de 30 indicadores de 79 empresas falidas e 79 empresas não falidas em 38 indústrias durante o período de 1954 a 1964. Os resultados do autor demonstraram capacidade preditiva (92% de precisão, um ano antes da quebra). Posteriormente em seu segundo estudo Beaver (1968) examinou a capacidade de predição de 14 outros indicadores utilizando a mesma amostra e metodologia do estudo de 1966. Nesse estudo o indicador de Fluxo de Caixa/Passivo Total obteve a melhor capacidade de falência (93%).

Esses estudos evidenciaram que nem todos os indicadores têm o mesmo grau de capacidade preditiva das quebras e que as previsões de empresas solventes são mais exatas que a predição de empresa insolvente. Assim, Beaver (1968) estabeleceu dois tipos de erros que eram a taxa de erro tipo I, que significa classificar erroneamente uma empresa quebrada como saída, e taxa de erro tipo II que consiste em classificar erroneamente uma empresa saída como empresa quebrada (Pereira & Martins, 2015; Gissel et al. 2007).

2.3.4 Fase III – Estudos de modelos multivariados baseados em indicadores contábeis tradicionais

De acordo com Gissel et al. (2007), um dos mais conhecidos modelos de predição de insolvência conhecido foi desenvolvido por Altman (1968), o qual utilizou ferramentas estatísticas mais evoluídas, como análise discriminante, para tentar superar as deficiências das análises baseadas em um único índice. Evidencia-se pela literatura (Tinoco, 2013; Volk, 2013) que o estudo de Altman (1968), teve uma ótima relevância, onde selecionou uma subamostra de 33 empresas que faliram e outra subamostra de 33 empresas que não faliram, de tamanho médio e do setor industrial e que tinham ações em bolsa no período de 1946 a 1965. Considerou 22 indicadores dentre aqueles mais populares na literatura e utilizando a análise discriminante múltipla chegou-se a um modelo preditivo composto por cinco indicadores: o *Z-score* previu a falência por meio da pontuação calculada para empresa e verificando essa pontuação estava dentro de um intervalo (Costenaro, 2021; Giannopoulos & Sigbjornsen, 2019).

2.3.5 Fase IV – Estudos de modelos multivariados baseados em fluxos de caixa

Na sequência dos estudos foi observado que o uso exclusivo de indicadores contábeis históricos possui limitações na previsão da falência. Estudos realizados antes dos anos 1980 foram criticados por se basearem apenas em dados contábeis registrados a custo histórico. A partir dos anos 1980, pesquisadores começaram a investigar a capacidade preditiva de indicadores que levam em consideração o fluxo de caixa (Pereira & Martins, 2016; Gissel et al., 2007). Pode-se citar o estudo de Azevedo (2012), que argumenta que a demonstração do fluxo de caixa vem cada vez mais sendo usada como ferramenta de gestão para saber a posição financeira das empresas. O fluxo de caixa operacional sobre o ativo total (FCOPT) pode ajudar a prever a insolvência de empresas, uma vez que o indicador mede a capacidade da empresa de pagar suas dívidas. Problemas na geração de novos fluxos de caixa e restrições na concessão de crédito são fatores que contribuem para a insolvência e falência das empresas, conforme mostram pesquisas recentes sobre a

importância da utilização do fluxo de caixa não somente no Brasil, mas em outros países (Melo et al., 2022).

2.3.6 Fase V – Modelos multivariados com técnicas estatísticas avançadas e indicadores não financeiros

A partir dos anos 1990, houve avanços significativos na capacidade computacional, resultando no surgimento de novas técnicas estatísticas de análise de dados. Essas técnicas incluem algoritmos, programação computacional, aprendizado de máquina e inteligência artificial, sendo as redes neurais a técnica mais utilizada (Kasgari et al., 2013). Além disso, a Análise por Envoltória de Dados (DEA) é outra técnica comum na análise estatística, de acordo com Pereira e Martins (2015).

Estudos mais recentes têm incorporado em seus modelos indicadores não contábeis como retornos das ações no mercado financeiro, o tamanho *board* executivo da empresa entre outros fatores (Lee & Shin, 2020; Duarte et al, 2020; Tinoco & Wilson, 2013). Pode-se citar alguns estudos como os de Mantas e Abellán (2014) que utilizaram a Modelagem por Árvore de Decisão (MAD) em empresas japonesas, alemãs e australianas, obtendo uma eficiência de 93,64%. Lu et al. (2015) aplicaram métodos de Redes Neurais (RN) e *Support Vector Machine* (SVM) em uma amostra genérica, alcançando uma precisão de 98,6% no modelo. No contexto brasileiro, Almeida et al. (2023) exploram o aprendizado de máquina aplicando o algoritmo de *Naive Bayes* em empresas brasileiras listadas na Bovespa onde foi selecionado o período de 2014 e 2017, alcançando uma taxa de acerto de 88% de acerto na previsão de insolvência. Prado et al. (2020) aplicaram a técnica de Redes Neurais Artificiais em empresas financeiras, utilizando um modelo dinâmico de análise financeira para mitigar o risco de custo de crédito e prever a insolvência com 91% de precisão.

2.3.7 Evolução dos Estudos sobre Insolvência no Brasil

No Brasil, os estudos de previsão de falência começaram na década de 1970. O estudo pioneiro de Kanitz (1974) e posteriormente Elizabetsky (1976) são considerados estudos tradicionais nessa área. Esses autores, juntamente com o trabalho de Altman (1966), utilizaram a análise discriminante como metodologia estatística. Ao longo do tempo, outros autores contribuíram para o conhecimento do assunto, explorando a análise de risco de crédito e a previsão de insolvência por meio de diferentes abordagens estatísticas (Gomes et al. 2021; Costenaro, 2021; Gevert et al., 2010; Brito et al., 2009).

Desse modo, nos últimos anos, foram realizados diversos estudos sobre insolvência classificados como modernos. Esses estudos se destacam por atenderem às características das empresas no cenário atual, diferenciando-se dos estudos tradicionais (Gomes et al. 2021; Costenaro, 2021). A tabela 7 apresenta alguns estudos sobre o fenômeno de insolvência mapeados a partir de 2008.

Tabela 7: Estudos elaborados no Brasil a partir de 2008

Autor	Ano	Estudo
Scarpel	2008	Previsão de insolvência de empresas utilizando <i>support vector machine</i> . Revista de Economia e Administração
Brito, G. A. S. Assaf Neto, A., & Corrar, L. J.	2009	Sistema de classificação de risco de crédito: uma aplicação para companhias abertas no Brasil. Revista contabilidade & finanças
Guimarães & Alves	2009	Previsão de Insolvência: um modelo baseado em índices contábeis com utilização da análise discriminante.
Guimarães, A. & Moreira, T. B	2009	Previsão de Insolvência: um modelo baseado em índices contábeis com utilização da análise discriminante. Revista. Econ. contemp.
Gevert, V. G., Lindebck Da Silva, A. C., Gevert, F., & Ales	2010	Modelos de Regressão Logística, Redes Neurais e Support Vector Machine (SVMs) na Análise de Crédito a Pessoas Jurídicas.
Horta, Borges, Carvalho & Alves	2011	Previsão de insolvência: Uma estratégia para balanceamento da base de dados utilizando variáveis

		contábeis de empresas brasileiras, Sociedade, Contabilidade e Gestão
Mendes, Frega & Da Silva	2012	Fatores Determinantes para Definição de Modelos de Previsão de Insolvência: Uma Revisão de Paradigma.
Silva, J.C., Wienhage, P., Souza, R.P., Bezerra, F.A., & Lyra, R.L.	2012	Capacidade Preditiva de Modelos de Insolvência: com base em Números Contábeis e Dados Descritivos. Revista de Educação e Pesquisa em Contabilidade
Carvalho, F. A. A., Francisco, J. D. S. A., & Rui, A. M. H	2014	Seleção de Atributos na Previsão de Insolvência: Aplicação e Avaliação usando Dados Brasileiros Recentes
Horta, Alves & Carvalho	2014	Seleção de Atributos na Previsão de Insolvência: Aplicação e Avaliação Usando Dados Brasileiros Recentes. Revista de Administração Mackenzie
Pereira, V. S., & Martins, V. F.	2015	Estudos de previsão de falências - uma revisão das publicações internacionais e brasileiras de 1930 a 2015
Soares, R. A., & Rebouças, S. M. D. P.	2015	Avaliação do desempenho de técnicas de classificação aplicadas à previsão de insolvência de empresas de capital aberto brasileiras. Revista ADM
Hijazi, M., & Fernando Moreira, L.	2015	A contribuição dos modelos de previsão de insolvência na prevenção de custos de falência: uma proposta de um novo modelo a partir de índices financeiros em empresas de capital aberto no Brasil
Willer do Prado, J., Giarola Vilamaior, A., Cardoso Campos, A., & Barcellos Pinheiro do Nascimento	2020	Previsão da Insolvência Empresarial Utilizando Redes Neurais Artificiais. Revista Gestão e Desenvolvimento
Soares, C. S., Marin, L. O., Degenhart, L., & Krüger, C	2021	Aplicação de Modelos de Previsão de Insolvência nas Empresas do Setor Aéreo Brasileiro. Revista Contabilidade e Controladoria
Júnior, F. J. S., Gomes, A. K. de L. J., Câmara, R. P. de B., & Filho	2022	A Influência da Responsabilidade Social Corporativa na Previsão de Insolvência Empresarial

O modelo de classificação de crédito desenvolvido por Brito et al. (2009) utilizou uma amostra de 60 empresas da Bovespa entre 1994 e 2004, divididas em 30 insolventes e 30 solventes. Foram avaliados 25 índices comumente usados nesse tipo de modelo, calculados a partir dos demonstrativos do penúltimo ano antes da falência. O modelo empregou regressão logística (*Logit*) para classificar as empresas em dois grupos (0 ou 1), utilizando um ponto de corte de 0,5. O desempenho do modelo alcançou 93,3% de acurácia para empresas solventes e 86,7% para empresas insolventes, resultando em um total de 90% de classificações corretas para as 60 empresas analisadas.

Scapel (2008) reforçou que os modelos mais utilizados e comuns de predição de insolvência são os que fazem análise discriminante. Contudo, para contrapor esse fato, o autor propôs em seu trabalho um modelo com uso da técnica de *Support Vector Machine* (SVM), que tem como objetivo fazer a classificação binária de duas classes em um hiperplano. A amostra utilizada por Scapel (2008) foi composta de empresas solventes e insolventes, sendo o número diferentes entre si, fato esse que é problemático nos estudos de análise de discriminantes (Costenaro, 2021). O modelo se mostrou bastante efetivo quando comparado como modelos de análise discriminantes utilizados no estudo, atingindo uma taxa de acerto global de 87,8% fazendo com que as três variáveis: LC (ativo circulante/passivo circulante); GA (receita total/ativo total); ROA (lucro líquido / ativo total) escolhidas no modelo apresentaram um ótimo desempenho em prever a realidade financeira das empresas.

Mendes et al. (2015) testaram o modelo criado por Sanvicente e Minardi (1998) que usa análise discriminante para prever a insolvência, com objetivo de constatar sua capacidade preditiva ao longo do tempo, baseando-se no estudo de Pinheiro et al. (2007) que fizeram essa validação após nove anos da construção do estudo. Provou-se a eficácia do modelo criado por Sanvicente e Minardi (1998) após quatorze anos sua elaboração, para comprovar a eficácia do modelo os autores Mendes et al. (2015) utilizaram uma base de quarenta e duas empresas considerando o período de oito anos de 2005 a 2012, os dados foram colhidos de empresas listadas na Bovespa. Os resultados

corroboram com o resultado obtido por Pinheiro et al. (2007) mostrando o potencial do modelo de prever a insolvência das empresas.

Soares e Rebouças (2015) avaliaram o desempenho de técnicas de classificação de insolvência para empresas brasileiras de capital aberto, onde os métodos empregados foram: análise discriminante, regressão logística, árvores de classificação e regressão e redes neurais. A amostra contemplou 21 empresas insolventes e 66 empresas solventes e o período analisado foi 2002 a 2012. Os resultados demonstraram um bom desempenho entre essas técnicas, sendo que a técnica de redes neurais teve maior assertividade.

A utilização de modelos avançados, como técnicas de aprendizado de máquina e redes neurais, na predição de insolvência tem sido pouco explorada. Uma das possíveis razões para essa lacuna é a falta de familiaridade com essas novas técnicas, que são consideradas caixas pretas e podem apresentar desafios em termos de interpretabilidade e usabilidade para aqueles fora do campo da ciência da computação (Lee & Shin, 2020; Pereira & Martins, 2015).

É importante destacar que os estudos anteriores sobre predição de insolvência geralmente se concentraram em empresas de médio e grande porte, sem uma definição clara ou explicação adequada da amostra utilizada (Pereira & Martins, 2015). No entanto, pesquisas mais recentes têm se dedicado a abordar essa questão de forma mais rigorosa, realizando validações detalhadas e fornecendo informações mais precisas sobre a seleção da amostra (Soares et al., 2021; Lemos & Oliveira, 2012; Brito et al. 2009; Scarpel, 2008).

Além disso, estudos mais recentes têm considerado o tamanho das empresas como um aspecto relevante, incluindo empresas de micro e pequeno porte em suas análises, como o estudo de Lemos (2009), Lemos e Oliveira (2012) e Hirsch (2013). Essa abordagem ampliada permite uma compreensão mais abrangente da insolvência e contribui para o desenvolvimento de modelos mais precisos e aplicáveis a diferentes tipos de negócios. Dessa forma, é possível obter *insights* valiosos sobre a saúde financeira das empresas, independentemente de seu porte.

2.3.8 Os indicadores financeiros utilizados nos modelos de previsão de insolvência

A análise financeira, conforme explicado por Silva (2012), consiste no exame das informações contidas nas demonstrações financeiras para compreender e avaliar diversos aspectos e medir seu desempenho por meio de indicadores. Segundo Pereira e Martins (2015), os indicadores são baseados na comparação de magnitudes. A ideia é que os dados isolados contêm alguma informação, mas adquirem um significado financeiro ainda maior quando combinados em um coeficiente. Isso inclui a capacidade de pagamento da empresa por meio da geração de caixa, a capacidade de remunerar os investidores gerando lucro em níveis compatíveis com suas expectativas, o nível de endividamento e a qualidade do endividamento, além das políticas operacionais e seus impactos na necessidade de capital de giro da empresa.

Matias (2017) ressalta que o desempenho financeiro das empresas está diretamente relacionado ao ambiente econômico em que estão inseridas. De acordo com Soares et. (2019), uma boa prática de gestão pressupõe a utilização de ferramentas de gestão, além dos demonstrativos contábeis e financeiros, para avaliar sua performance para tomada de decisão, buscando-se sempre o equilíbrio entre a liquidez e a rentabilidade. Portanto, é essencial realizar uma análise da conjuntura macrofinanceira e setorial para uma avaliação completa da empresa.

Estudos realizados no Brasil, de acordo com Souza e Correa (2014), apontam que a implementação da gestão por indicadores financeiros é pouco comum nas micro, pequenas e médias empresas. Isso se deve à ausência de práticas de gestão, falta de qualificação e infraestrutura limitada dessas empresas. Essas limitações dificultam o uso de sistemas de mensuração de desempenho que englobam tanto medidas financeiras quanto indicadores não financeiros.

Observa-se que as demonstrações financeiras desempenham um papel fundamental na previsão de insolvência das empresas sendo fonte primária de informações. Os indicadores utilizados nos modelos são oriundos do balanço patrimonial (BP) e demonstrativo do resultado do exercício (DRE), que para empresas de capital aberto têm sua divulgação sendo obrigatória pela

Lei da S/A, 6.404/76 (Soares et al., 2019; Santos, 2021; Pereira & Martins, 2015). Não há existência de obrigatoriedade de divulgação de demonstrativos para MPEs, sendo que tem sido um desafio para medir o desempenho dessas empresas, e desta maneira, tem-se empregado a utilização de indicadores não financeiros para se alcançar tal objetivo (Filipe et al., 2016; Souza & Correa, 2014).

Com base no levantamento realizado, destaca-se os principais indicadores financeiros utilizados nos modelos de previsão de insolvência para as MPEs. A tabela 8 demonstra o resumo e sua operacionalização.

Tabela 8: Indicadores utilizados pelos modelos de previsão de insolvência para MPEs

Indicador Financeiro	Operacionalização
Liquidez Seca	(Ativo Circulante- Estoques / Passivo Circulante
Liquidez corrente	Ativo Circulante / Passivo Circulante
Liquidez Geral	(Ativo Circulante + Realizável a Longo Prazo / Exigível Total)
Retorno sobre o Patrimônio Líquido	Lucro Líquido / Patrimonio Líquido
Giro do Ativo	Vendas / Ativo
Margem Líquida	Lucro Líquido / Vendas
Alavancagem financeira	Capital de Terceiros / Lucro Líquido
Estoque existente para cada real do ativo total	Estoques / Ativo Total
Contas a Receber existente para cada real do ativo total	Contas a Receber / Ativo Total
Obrigações com Fornecedores	Fornecedores / Vendas
Prazo Médio de Recebimento de Vendas (PMRV)	PMRV (Clientes x 360/ Vendas)
Quantidade de Períodos de Estoque	(Estoque / CMV) / CPV
Quantidade de Capital realizado	Capital Realizado / Patrimônio Líquido
Caixa operacional sobre Total do Ativo	Fluxo de Caixa Operacional / Total do Ativo
Caixa operacional sobre Total do Passivo	Fluxo de Caixa Operacional / Total do Passivo
Resultado operacional sobre total do ativo	EBIT / Ativo total
Lucro Líquido sobre o patrimônio líquido	Lucro Líquido / Patrimônio Líquido
Capital de Giro sobre as vendas	Capital de Giro / Vendas

Conforme Souza e Correa (2014), um sistema de mensuração de desempenho, para obter resultados favoráveis, frequentemente define-se categorias de medição. As categorias encontradas para classificação de insolvência para pequenos e médios negócios cobrem os principais aspectos de mensuração de performance, tais como, alavancagem financeira, liquidez da empresa, rentabilidade, cobertura de juros, que normalmente são usadas para análise geral como objetivo de identificar o desempenho e solidez da empresa (Andreeva et al. 2016). A tabela 9 demonstra este agrupamento.

Tabela 9: Agrupamento de categorias de medição de desempenho das empresas

Categoria	Descrição
Alavancagem	Estrutura de Capital e fonte de financiamentos
Liquidez	Índice Corrente, Índice de Liquidez do Acionista, Liquidez Geral
Rentabilidade	Margem EBITDA, Margem de Lucro, ROE
Atividade / Escala / Tamanho	Total de Ativos, número de funcionários, número de administradores
Fluxo de Caixa	Fluxo de Caixa Operacional
Crescimento	Vendas e Lucro

Note: Elaborado pelo autor com base em Filipe et al. (2016).

Destaca-se que os indicadores de liquidez, tais como, os de liquidez imediata, seca, corrente e geral, são comumente utilizados para analisar e prever a insolvências de empresas, e são frequentemente utilizados nos modelos preditivos (Hirsch, 2013). O índice de liquidez imediata é obtido através da divisão das disponibilidades pelo passivo circulante. Tal índice representa o valor que a empresa dispõe para saldar suas dívidas no curto prazo. Para se obter o índice de liquidez seca, se faz por meio do valor do estoque e valor das despesas do exercício posterior onde subtrai-se do ativo circulante. Este indicador expõe a capacidade da empresa de pagar sua dívida no curto prazo, tendo como base os ativos circulantes. Por sua vez, a liquidez corrente se traduz no principal índice utilizado para avaliar a capacidade de pagamento de uma empresa, sua base de cálculo se faz pela divisão do ativo circulante pelo passivo circulante. Entende-se pela literatura que os índices de liquidez apresentam uma referência de avaliação devendo ser maior que 1 (um), que significa que a entidade se encontra em situação financeira favorável, portanto, solvente, e caso o índice seja menor que 1 (um) pode-se afirmar que empresa se encontra em situação de insolvência (Soares et al. 2019; Hirsch, 2013). Entretanto, a análise feita por Filipe et al. (2016) demonstrou que os indicadores de liquidez que nem sempre estes indicadores são melhores que os demais índices financeiros para se avaliar MPEs estudadas.

Nas palavras de Souza e Correa (2014), as MPEs têm características organizacionais e de desempenho que as tornam diferentes das grandes empresas. Entretanto, não se pode deixar de observar a importância dos mecanismos de mensuração de performance para qualquer tipo de empresa para gestão e tomada de decisão. Uma vez que há a existência de diversos indicadores (Costenaro, 2021; Pereira & Martins, 2015; Souza & Correa, 2014; Hirsch, 2013; Lemos & Oliveira, 2012). Assim, a responsabilidade recai sobre o analista financeiro observar quais indicadores fazem sentido para explicar o momento financeiro da empresa

2.4 Métodos e Técnicas para Predição de Insolvência

Houve um avanço significativo nas pesquisas relacionadas à previsão de insolvência, com a adoção de métodos mais avançados, como os baseados em aprendizado de máquina e inteligência artificial, conforme discutido nas seções anteriores. Na palavras de Lee e Shin (2020) esses métodos, são conhecidos como "caixa preta" (*black box*), têm se mostrado mais precisos em termos de interpretação e processamento dos dados (Sarkar et al., 2016).

Recentemente, os pesquisadores têm explorado métodos alternativos, ou seja, não convencionais, para analisar e prever a insolvência de empresas. Isso inclui o uso de técnicas de aprendizado de máquina, árvores de decisão, redes neurais artificiais, métodos de classificação baseados em regras difusas (*fuzzy rule-based*), análise de conjuntos aproximados, previsão baseada em casos, algoritmos genéticos e análise de histórico de eventos dinâmicos (Qu et al., 2019; Lee & Shin, 2020). Pode-se citar ainda técnicas como árvore de decisão (*Decision trees*), floresta aleatória

(*Random Forest*), máquinas de vetor de suporte (*SVM*), aprendizado ingênuo (*Naive Bayes*), *Cast Boost*, redes neurais artificiais. Essas abordagens mais sofisticadas têm contribuído para melhorar a precisão das previsões e fornecer insights valiosos para a tomada de decisões relacionadas à insolvência de empresas.

Dada a ampla variedade de algoritmos de aprendizado de máquina disponíveis, os gerentes e outras pessoas de negócio consideram difícil selecionar os melhores para resolver seus problemas. É amplamente conhecido que um único algoritmo de aprendizado de máquina não fornecerá o melhor desempenho em todas as instâncias de um determinado problema (Jabeur et al., 2021; Lee & Shin, 2020).

Empresas têm adotado o aprendizado de máquina e a inteligência artificial como medidas para mitigar o risco de insolvência. Esta pesquisa buscou explorar a literatura mais recente para entender o avanço e a aplicação dessas tecnologias no campo financeiro, não apenas na previsão de insolvência, ou falência propriamente, mas também em outras áreas das finanças.

O desenvolvimento e ajuste dos modelos de previsão de insolvência, como pontuação de crédito (*credit scoring*) e outros, eram tarefas realizadas por especialistas, demandando considerável quantidade de recursos e tempo. No entanto, com o surgimento de algoritmos de aprendizado de máquina e a distribuição em larga escala da inteligência artificial, houve avanços significativos nessa área, auxiliando os especialistas e reduzindo a carga de trabalho e tempo necessários para sua produção (Jabeur et al., 2021; Qu et al., 2019).

De acordo com Lee e Shin (2020), três tendências têm impulsionado a rápida adoção do aprendizado de máquina em diversos setores: 1) o surgimento da *big data*; 2) os avanços na tecnologia de processamento e armazenamento de dados; e 3) o progresso na pesquisa de aprendizado de máquina. Esses fatores têm facilitado a adoção do aprendizado de máquina, levando empresas e sociedade a se transformarem e inovarem.

Uma revisão sistemática realizada por Kezelj et al. (2021) abordou a prevenção de insolvência em corporações por meio do uso de algoritmos de inteligência artificial. Os resultados da revisão confirmaram que, após a crise financeira de 2008, o mercado financeiro, empreendedores, fornecedores de crédito e a sociedade em geral tornaram-se mais conscientes dessa questão. O receio de uma nova crise que poderia resultar em perda de empregos e prejuízos para as empresas levou à implementação de novas tecnologias para evitar a falência. Nesse contexto, as redes neurais, árvores de decisão e regressão logística, em consonância com os achados de Altman et al. (2017), são os métodos mais utilizados para prever a insolvência.

Lee e Shin (2020) argumentam que ao desenvolver serviços financeiros com aprendizado de máquina, é importante que as empresas considerem diversos aspectos, incluindo a relação entre inteligência artificial, aprendizado de máquina e métodos de aprendizado profundo. A relação entre aprendizado de máquina e inteligência artificial é de super conjunto-subconjunto, onde a inteligência artificial abrange uma ampla gama de áreas de aplicação, incluindo o aprendizado de máquina, que se concentra em tarefas como processamento de linguagem natural, reconhecimento de imagem e manipulação de objetos. Embora o aprendizado de máquina seja suficiente para ser considerado uma forma de inteligência artificial, é importante ressaltar que o aprendizado de máquina tem a inteligência artificial como seu fundamento (Russell & Norvig, 2022).

O aprendizado profundo é um subconjunto do aprendizado de máquina que surgiu em torno dos anos 2000, quando houve um renovado interesse nessa área devido aos avanços significativos na indústria de processamento e armazenamento de computadores (Jabeur et al., 2021; Lee & Shin, 2020; Qu et al., 2019; Kühl et al., 2019).

Nesse contexto, as grandes empresas estão adotando diferentes abordagens de aprendizado de máquina, incluindo agregação (*clustering*), classificação e previsão, o que é apontado como uma tendência. A técnica de agregação é empregada para agrupar objetos com base em sua similaridade em um espaço multidimensional. É considerada uma abordagem não supervisionada, utilizando uma função de distância para medir a semelhança entre os objetos. Por outro lado, a classificação é o processo de atribuir uma categoria ou classe a uma determinada observação. Após o

treinamento do modelo com os dados conhecidos, é possível realizar testes em novos dados não vistos anteriormente, resultando na classificação do objeto em uma determinada categoria. Por fim, o aprendizado de máquina é utilizado para identificar padrões nos dados e realizar previsões de eventos futuros. A diferença entre predição e classificação é que a classificação é voltada para inferir regras ou equações relevantes para a situação atual, enquanto a predição envolve antecipar o que ocorrerá no futuro (Lee & Shin, 2020).

Esta discussão se faz importante, pois existe uma série de preocupações em torno do uso de aprendizado de máquina, tais como, a questão da interpretabilidade, usabilidade e precisão do que se refere aos modelos preditivos. Um desafio comum para a usabilidade dos métodos de aprendizado de máquina são as escolhas (*trade-offs*) entre ter uma boa interpretabilidade e uma boa precisão, com a capacidade de explicar as decisões e ações tomadas para seus usuários (Lee & Shin, 2020; Sarkar et al., 2016).

Para Lee e Shin (2020), a precisão refere-se à medida de desempenho prática de um algoritmo, enquanto a interpretabilidade se refere à capacidade de explicar como as decisões são tomadas. Por exemplo, uma regressão linear simples é fácil de explicar, mas pode ter baixa precisão. Sobre este prisma, um modelo de regressão mais complexo pode ter alta precisão, mas é difícil de interpretar.

Ribeiro et al. (2016) discutiram amplamente a importância da interpretabilidade dos modelos de aprendizado de máquina, sugerindo que ela pode ser apresentada visualmente ou através de texto. É crucial que os modelos preditivos sejam interpretáveis para que os usuários possam confiar neles e tomar decisões com base em suas previsões. Caso contrário, se os modelos não forem compreendidos, é provável que não sejam utilizados, o que tem sido observado em diversas pesquisas nessa área.

Modelos de previsão de insolvência eficientes são essenciais para avaliar o risco de inadimplência das empresas. Isso é crucial para instituições bancárias ao decidir sobre linhas de crédito e para agências de classificação de risco ao avaliar a qualidade de crédito de emissores de obrigações de dívida (Ciampi, 2015).

De acordo com Addo et al. (2018), os algoritmos de aprendizado de máquina e inteligência artificial são impulsionados pela automação. Eles têm a capacidade de aprender com os dados e fazer previsões, imitando os processos cognitivos do cérebro humano. Esses algoritmos são dinâmicos, adaptando-se às mudanças nos dados e utilizando estatísticas e otimização matemática. Ao serem aplicados em modelos de *credit scoring*, podem melhorar a precisão e eficiência, especialmente ao conceder crédito micro e pequenas (MPEs) que frequentemente possuem dados financeiros e contábeis inconsistentes (Souza & Correa, 2014).

Diante desse cenário, a obtenção de dados de qualidade é um desafio contínuo (Lee & Shin, 2020), não apenas para fins de pesquisa, mas também para o desenvolvimento de produtos e serviços robustos para a sociedade. Além da qualidade dos dados, é fundamental assegurar a confiabilidade das decisões tomadas pelos aplicativos de aprendizado de máquina durante o uso em operações (Addo et al., 2018; Guégan & Hassani, 2018).

Conforme discutido por Duarte et al. (2020), com o aumento da disponibilidade de informações, surgiram vários estudos recentes que utilizam técnicas avançadas de aprendizado de máquina para previsão de insolvência. Essas pesquisas acadêmicas têm se concentrado em avaliar diferentes perspectivas de risco de crédito, abordando questões relacionadas a dificuldades financeiras, classificação de crédito e predição de insolvência, não somente para grandes empresas, mas também para as MPEs (Ciampi, 2015; Altman et al., 2017; Kezelj et al., 2021).

2.4.1 Previsão de Insolvência por meio de Inteligência Artificial e Aprendizado de Máquina

O aprendizado de máquina é um subconjunto da inteligência artificial (IA) que pode aprender padrões a partir de dados sem a necessidade de defini-los a priori (Lee & Shin, 2020; Kühl

et al., 2019). Face às tecnologias de aprendizado de máquina, avançam rapidamente, as empresas devem garantir que seus membros estejam mais familiarizados com essas tendências, que cada vez mais será introduzida em seu portfólio de serviços.

De acordo com a Accenture (2018), o aprendizado de máquina pode reduzir custos entre 20% e 25% em serviços bancários, operações de TI, infraestrutura e manutenção; gerar novas receitas em produtos e serviços; e melhorar a retenção e aquisição de clientes.

2.4.1. 2 Aprendizado de Máquina (*machine learning*)

De acordo com Faceli et al. (2011), a teoria de aprendizado de máquina está calcada no conceito de aprendizagem de máquina e este aspecto, além de notório, foi abordado previamente na literatura desta disciplina. Nesse contexto, diversos autores definem aprendizagem como a capacidade de um programa computacional melhorar o seu desempenho através de experiência. Afirma-se que um programa de computador aprende a partir de uma experiência E em relação a uma certa classe T de tarefas e medida de desempenho P , e se o seu desempenho nas tarefas T , tal como medido por P , melhora com a experiência E (Mitchell, 1997). Deste modo, o aprendizado de máquina, conforme Marsland (2015), consiste em fazer com que os computadores modifiquem ou adaptem suas ações para que estas se tornem mais precisas. Os problemas de aprendizado podem ser classificados em:

- **Supervisionados** - aprendizagem supervisionada é o termo usado sempre que o programa ou algoritmo é treinado sobre um conjunto de dados pré-definido de dados. Nesse sentido, os algoritmos fazem previsões com base em um conjunto de exemplos fornecidos previamente. A este conjunto dá-se o nome de treinamento, pois é a partir desse exemplos que será treinado para fazer generalizações. Algoritmos clássicos do aprendizado supervisionado incluem, por exemplo, análise de regressão linear, análise de regressão logística, máquina de vetor de suporte, árvores de decisões, florestas aleatórias (*random forest*), dentre outros.
- **Não supervisionados** - no aprendizado não supervisionado o algoritmo aprende padrões na entrada, embora não seja fornecido nenhum *feedback* explícito sobre qual classe os dados pertencem. A tarefa mais comum de aprendizagem não supervisionada é o agrupamento, isto é, a detecção de grupos de exemplos de entradas potencialmente úteis.

Nesse contexto, o problema de classificação é o mais estudado em aprendizado supervisionado e consiste em tomar vetores de entrada e decidir a qual das c classes eles pertencem com base nos exemplos de treinamento. Segundo Faceli et al. (2011), em problemas de classificação dois tipos de espaço devem ser considerados: o espaço X das instâncias ou objetos e o espaço Y das saídas ou categorias. Define-se como classificação binária, o espaço das saídas que pode ser identificado pelo conjunto $\{-1, +1\}$ ou $\{0, +1\}$. Assim, segundo Von Luxburg e Scholkopf (2011), com o objetivo de aprender, são apresentados ao algoritmo exemplos de treinamento devidamente rotulados com sua categoria correspondente. Portanto, um algoritmo de classificação é um procedimento que toma como entrada os exemplos de treinamento e produz como saída um classificador. Segundo Faceli et al. (2011) um algoritmo de aprendizado de máquina aprende uma função de aproximação que permite estimar o valor produzido pelo classificador para novas entradas.

De acordo com James et al (2013), o objetivo de determinar uma função que relacione os objetos de entrada as suas saídas pode estar associado a dois motivos principais: (1) prever as respostas para futuros objetos, tarefa conhecida como predição ou (2) melhor compreender o relacionamento entre os objetos de entrada e saída, tarefa conhecida como inferência. Em aprendizado de máquina supervisionado o objetivo é fazer previsão. Nesse contexto, frequentemente encaramos a função " f " como uma caixa-preta, o que significa que não é necessário conhecer sua forma exata, desde que ela seja capaz de gerar previsões precisas. Se considerarmos

o conjunto de pares de dados $\{(x_1, y_1) \dots (x_n, y_n)\}$ que foi utilizado para criar uma estimativa, representada por " $f^{\wedge}$ " da função " f ," em situações em que o foco é realizar previsões, a principal preocupação não reside na concordância entre $f^{\wedge}(x_i)$ e y_0 , mas sim na aproximação de $f^{\wedge}(x_0)$ e y_0 . Aqui x_0, y_0 denota um objeto de teste inédito, não empregado no treinamento do algoritmo de aprendizado. Para avaliar o desempenho de modelos preditivos, é fundamental dispor de um conjunto adicional de exemplos conhecido como conjunto de teste, composto por objetos previamente não observados. No entanto, essa abordagem apresenta o desafio de limitar a quantidade de dados disponíveis para o treinamento do modelo.

Para Masland (2015), ainda há a necessidade de avaliar a capacidade do treinamento realizado pelo classificador. Se o treinamento ocorrer por muito tempo, então o algoritmo se adapta aos dados, o que significa que os ruídos e imprecisões também passaram a ser aprendidos e o modelo não será capaz de generalizar e irá gerar um modelo mais complexo. Este fenômeno é conhecido como *overfitting* e o processo precisa ser interrompido antes que ele ocorra. De modo que um terceiro conjunto de dados se faz necessário para validar o aprendizado, isto é, para saber se o algoritmo está generalizado a cada etapa do processo. Portanto, três conjuntos de dados, ao final são necessários: treinamento, validação e teste.

2.4.2 Métodos de classificação

De acordo com Russell e Norvig (2022), uma árvore de decisão (*Decision Trees*) representa uma função que toma como entrada um vetor de valores de atributos e retorna uma "decisão", isto é, um valor de saída único. As árvores de decisão são estruturas gráficas, figura (3), que dividem iterativamente os dados com base em características, resultando em ramos que representam diferentes caminhos de decisão. Essa abordagem facilita a compreensão do processo decisório e a identificação de variáveis-chave que influenciam as previsões. A flexibilidade das árvores de decisão as torna particularmente adequadas para a análise de riscos financeiros e previsão de insolvência.




Figura 3: Classificador Árvore de Decisão

Nota. Zimmermann et al. (2018)

As florestas aleatórias (tradução do idioma inglês: *Random Forests*) consistem na cultivação de múltiplas árvores de decisão. Este método é empregado para efetuar classificações a partir de um vetor de entrada, o qual é submetido à análise de cada uma das árvores pertencentes à floresta, conforme ilustrado na figura (4). Cada árvore fornece uma classificação e, coletivamente, as árvores "votam" em favor de uma classe específica. A classificação final é determinada pela classe que recebe o maior número de votos, considerando todas as árvores da floresta.

Uma das características distintivas das florestas aleatórias é a sua robustez diante da escassez de dados, tornando-se capaz de lidar com conjuntos de dados contendo um grande número de atributos. Além disso, esse método é considerado facilmente interpretável em termos de sua capacidade preditiva.




Figura 4: Classificador Floresta Aleatória

Nota. IBM Disponível em: <<https://www.ibm.com/br-pt/topics/random-forest>>

A Regressão Logística (do inglês: *Regression Logistic*) é uma técnica estatística clássica usada para classificação. É especificamente adaptada à situação em que a variável dependente é dicotômica (ou binária). Na regressão logística, a variável dependente é o logaritmo natural dos *odds* (medida que indica dois fatores) de ocorrência de um fenômeno (probabilidade de ocorrência de um evento dividida pela probabilidade de não ocorrência) (Russel & Norvig, 2022). Segundo Gonçalves et al. (2013), a regressão logística é a técnica mais utilizada no mercado para desenvolvimento de modelos de insolvência e *credit scoring*, que prediz a probabilidade de um evento ocorrer, o qual pode estar entre 0 e 1.

2.4.2.2 Métricas de avaliação de modelos de classificação

A matriz de confusão é uma ferramenta crucial para avaliar o desempenho de um modelo de classificação em aprendizado de máquina. Ela fornece uma representação tabular das previsões feitas pelo modelo em comparação com os valores reais dos dados de teste. A matriz de confusão é particularmente útil quando se lida com problemas de classificação binária, onde há duas classes possíveis, como "positivo" e "negativo", "verdadeiro" e "falso", "classe 1" e "classe 0," entre outros. É composta por quatro elementos principais:

- **Verdadeiros Positivos (VP):** Representa os casos em que o modelo classificou corretamente uma instância como pertencente à classe positiva.
- **Falsos Positivos (FP):** Refere-se aos casos em que o modelo erroneamente classificou uma instância como pertencente à classe positiva, quando na verdade pertence à classe negativa. Esses são também conhecidos como erros do Tipo I.
- **Verdadeiros Negativos (VN):** São os casos em que o modelo classificou corretamente uma instância como pertencente à classe negativa.
- **Falsos Negativos (FN):** Indicam as situações em que o modelo erroneamente classificou uma instância como pertencente à classe negativa, quando na verdade pertence à classe positiva. Esses são conhecidos como erros do Tipo II.

De acordo Faceli et al. (201), a matriz de confusão ajuda a quantificar o desempenho do modelo, permitindo o cálculo de várias métricas de avaliação, incluindo:

- **Acurácia (*Accuracy*):** a proporção de previsões corretas em relação ao número total de previsões ($VP + VN$) em relação ao total ($VP + FP + VN + FN$). A acurácia é uma métrica geral de desempenho.
- **Precisão (*Precision*):** Avalia a proporção de verdadeiros positivos em relação a todos os exemplos classificados como positivos ($VP / (VP + FP)$). Essa métrica é útil quando é importante evitar falsos positivos.
- **Revocação (*Recall* ou *Sensibilidade*):** mede a proporção de verdadeiros positivos em relação a todos os exemplos da classe positiva no conjunto de dados ($VP / (VP + FN)$). É valioso quando é essencial evitar falsos negativos.
- **F1-Score:** É uma métrica que combina precisão e revocação, fornecendo uma única medida do desempenho do modelo. É particularmente útil quando há um equilíbrio entre a importância de precisão e revocação.

Além dessas métricas, a matriz de confusão também permite ao analista ou cientista de dados obter *insights* sobre os tipos de erros que o modelo está cometendo, ajudando a direcionar ajustes e melhorias no algoritmo ou no conjunto de dados. Em resumo, a matriz de confusão é uma ferramenta essencial na avaliação e aperfeiçoamento de modelos de classificação. Para indução e avaliação dos classificadores o conjunto de dados total deve ser particionado em três subconjuntos distintos: treinamento, validação e testes. Métodos de amostragem podem ser utilizados para este fim, de acordo com Faceli et al. (2011), os principais existentes são:

- **Holdout:** o conjunto de dados é dividido em uma porcentagem para treinamento ($1 - p$) para teste. A porcentagem para treinamento ainda pode ser dividida para obtenção do conjunto de validação. Normalmente as proporções 60% e 40% ou 70% e 30% são utilizadas. Uma desvantagem deste método é que ele não permite avaliar o quanto o desempenho de uma técnica varia quando diferentes combinações de objetos são apresentadas em seu treinamento (Faceli et al., 2011).
- **Validação Cruzada ou *K-fold Cross Validation*:** neste método, o conjunto de dados é particionado aleatoriamente em k subconjuntos e todos os subconjuntos participam do conjunto de treinamento e do conjunto de teste.
- **Técnicas de Redução de Dimensionalidade**

De acordo com Faceli et al. (2011), as técnicas de redução de dimensionalidade podem ser divididas:

- **Agregação** - onde mapeamos o espaço original de variáveis para um novo espaço com dimensões menores através da combinação lineares ou não lineares das variáveis do espaço original. Pode-se citar as técnicas de agregação a Análise de Componentes Principais (PCA), Análise Discriminante Linear (LDA) e Análise de Correlação Canônica.

- **Seleção de atributos**- essa abordagem visa selecionar um subconjunto de variáveis relevantes do conjunto original sem que nenhuma transformação seja realizada, o que mantém o significado físico e propriedades dos atributos originais. Pode-se citar as técnicas de seleção que incluem o coeficiente de Fisher Escor, Ganho da Informação e coeficiente da correlação.

De acordo com Horta et al. (2014), a seleção de atributos (SA) é uma etapa muito relevante na elaboração de modelos de previsão de insolvência. A SA desempenha papel essencial nesses modelos, sendo frequentemente realizada como etapa de pré-processamento. Na maioria dos estudos, parte-se de um conjunto inicial de variáveis que, frequentemente, são escolhidos em razão de sua popularidade na literatura específica, seu sucesso preditivo em pesquisas precedentes ou na seleção de variáveis utilizadas por analistas financeiros que medem a situação financeira da empresa. A figura (5) demonstra a técnica utilizada para seleção de atributos para fenômeno de predição de insolvência.




Figura 5: Técnica de seleção de atributo para o fenômeno de insolvência

Nota. Horta et al. (2014).

- **Balanceamento dos dados**

Parte do processo de pré-processamento de dados, o balanceamento de dados refere-se ao processo de equiparar, para um determinado conjunto de dados, a quantidade de amostras de cada classe disponível para análise, tornando-as igualmente representadas diante do processo de aprendizagem. A importância deste processo jaz no fato de que diversos modelos de classificação utilizados frequentemente em projetos corporativos e acadêmicos e que apresentam bons desempenhos de predição são projetados para trabalhar com conjuntos de dados balanceados. Entretanto, ao se trabalhar com conjuntos de dados e aplicações reais, o mais provável é que os dados disponíveis para análise estejam desbalanceados Faceli et al., (2011).

2.4.3 Estudos sobre predição de insolvência por meio de aprendizado de máquina

Destacam-se estudos recentes sobre a predição de insolvência utilizando técnicas de inteligência artificial por meio de aprendizado de máquina. Observa-se na tabela 10 uma ampla quantidade de trabalhos que abordam esse tema.

Tabela 10: Estudos recentes abordando inteligência artificial e técnicas de aprendizado de máquina sobre previsão de insolvência foram elaborados de 2017 a 2023.

Autor	Ano	Estudo
Ben Jabeur, S., & Serret, V.	2023	<i>Bankruptcy prediction using fuzzy convolutional neural networks</i>
Almeida, R., Sales, G., & Nunes, R. V. N.	2023	Predição de Insolvência de Empresas Através da Inteligência Artificial-Técnicas de Aprendizado de Máquina. REPAE-Revista de Ensino e Pesquisa em Administração e Engenharia, 9(1), 39-58.
Lakhchini, W	2022	<i>Artificial Intelligence & Machine Learning in Finance: A literature review</i>
Kristóf, T., & Virág, M	2022	<i>EU-27 bank failure prediction with C5.0 decision trees and deep learning neural networks.</i>
Wu, D., Ma, X., & Olson, D. L.	2021	<i>A comparative analysis of the UK and Italian small businesses using Generalized Extreme Value models</i>
Hoang, D., Wiegatz, K., Renée Adams, by, Benz, A., Ruckes, M., Silbereis, F., & Weber, M	2021	<i>Machine Learning Methods in Finance: Recent Applications and Prospects</i>
Kezelj et al	2021	<i>A Systematic Literature Review on Corporate Insolvency Prevention Using Artificial Intelligence Algorithms Empirical survey on the status of risk management in Austria and Slovak Republic</i>
Jabeur, S. ben, Gharib, C., Mefteh-Wali, S., & Arfi, W. ben.	2021	<i>CatBoost model and artificial intelligence techniques for corporate failure prediction.</i>
Duarte, D. L., & Barboza, F. L.M	2020	<i>Forecasting Financial Distress With Machine Learning – A Review</i>
Lee, I., & Shin, Y. J	2020	<i>Machine learning for enterprises: Applications, algorithm selection, and challenges</i>
Heo, W., Lee, J. M., Park, N., & Grable, J. E.	2020	<i>Using Artificial Neural Network techniques to improve the description and prediction of household financial ratio</i>
Prado, J. W., Vilamaior, A. G., Campos, A. C., & Nascimento, T. B. P.	2020	<i>Previsão de Insolvência Empresarial Utilizando Redes Neurais Artificiais</i>
Gajowniczek, K., Orlowski, A., & Ząbkowski, T.	2019	<i>Insolvency modeling with generalized entropy cost function in neural networks</i>
Altman, E., Barboza, F., & Kimura, H.	2017	<i>Machine learning models and bankruptcy prediction</i>

No estudo de Altman et al. (2017), foram testados modelos de aprendizado de máquina, como *Support Vector Machines*, *Bagging*, *Boosting* e *Random Forest*, para a previsão de falência com um ano de antecedência. O desempenho desses modelos foi superior quando comparado com os resultados de análise discriminante, regressão logística e redes neurais.

2.5 Agentes Inteligentes

Neste trabalho, foi adotada a definição fundamental de agentes conforme proposta por Russell & Norvig (2022), que é amplamente reconhecida e utilizada por acadêmicos e estudiosos. No entanto, iremos além dessa referência, faremos uso de outros autores, como Kirrane (2021), Girardi & Leite (2013), Weiss et al. (2010), Bordini et al. (2010) e Wooldridge (2009), para obtermos uma visão abrangente e global do panorama dos agentes inteligentes.

2.5.1 Conceito de agente

O conceito de agente abrange diversas definições que ilustram sua amplitude. A origem da ideia de agente está enraizada na inteligência artificial, em particular no campo da tecnologia de agente e sistemas multiagentes, isto é, diversos agentes interagindo em um ambiente (Russell & Norvig, 2022; Kirrane, 2021; Girardi & Leite, 2013; Wooldridge, 2009). As raízes desse conceito remontam à década de 1950. Nas últimas décadas, o conceito de agentes tem sido amplamente

adotado em diversos campos da ciência da computação, especialmente na área de engenharia de software (Weiss et al., 2010).

De acordo com Bordini et al. (2007) considera-se agente como um sistema reativo que exibe algum grau de autonomia no sentido de que delegamos alguma tarefa a ele, e o próprio sistema determina a melhor forma de realizar essa tarefa. Nesse sentido, o agente é tudo o que pode ser considerado capaz de perceber seu ambiente por meio de sensores e de agir sobre esse ambiente por intermédio de atuadores (Russell & Norvig, 2022). Para Weiss et al. (2010), um agente é uma unidade de software/hardware independente que pode lidar com suas tarefas de maneira baseada em conhecimento, flexível, interativa e autônoma.

Após estabelecer o conceito de agente, é de suma importância definir as características indispensáveis que um software deve possuir para ser qualificado como um agente. De acordo com a visão de Weiss et al. (2010) e reforçada por Russell e Norvig (2022), um agente é qualquer entidade, seja humana ou artificial (software ou hardware), que está imersa em um ambiente físico, virtual ou simulado e é capaz de ter:

Percepção: O agente é capaz de perceber seu ambiente por meio de sensores, como teclado, câmeras, microfones e protocolos de comunicação em sistemas multiagentes.

Ação: O agente pode agir sobre o ambiente por meio de atuadores, como tela do computador, alto-falante, impressora, funções internas que enviam mensagens a outros agentes, braços, pernas, entre outros.

Autonomia: O agente é capaz de tomar suas próprias decisões e estabelecer comportamentos proativos direcionados a metas estabelecidas, sem a interferência do usuário. Ele possui um grau de independência que o diferencia de um software comum.

Proatividade: Uma vez que o agente recebe um objetivo, é importante que ele se esforce para alcançá-lo. Ele busca ativamente a realização das metas estabelecidas.

Habilidade social: O agente tem a capacidade de cooperar e coordenar atividades com outros agentes, a fim de alcançar um objetivo comum. Isso envolve interações sociais e ações colaborativas.

Conforme Wooldridge e Jennings (1995), enfatizado por Kirrane (2021), os autores distinguem os agentes inteligentes entre fortes e fracos. O agente forte possui a capacidade de agir de forma autônoma, interagir com humanos e outros agentes, reagir às mudanças do ambiente e ser proativo na busca de seus objetivos. Além dessas características, existem diversas funções básicas do agente, que podem ser visualizadas na Tabela 11.

Tabela 11: Funções básicas dos Agentes Inteligentes

Função	Descrição
Racionalidade	Assume que os agentes não agem de maneira que seria contraproducente quando se trata de atingir seus objetivos
Responsabilidade	Envolve agir de acordo com o nível de autoridade que é confiado ao agente, seja por uma pessoa ou organização que o agente representa ou por outro agente
Mobilidade	Refere-se à capacidade de se mover em uma rede eletrônica, por exemplo, usando programação remota para executar tarefas em outras máquinas
Identificação	A capacidade de verificar a identidade de um agente se ele representa uma pessoa ou organização
Segurança	Envolve tomar medidas para proteger recursos contra uso indevido acidental ou intencional
Privacidade	Relaciona-se a estar atento à privacidade da pessoa ou organização que um agente representa, no entanto, mais amplamente, um agente deve respeitar a privacidade de qualquer pessoa com quem interage
Confiança	Envolve garantir que o sistema não transmita informações falsas intencionalmente

Ética	Envolve deixar o mundo como ele foi encontrado, limitar o consumo de recursos escassos e garantir resultados previsíveis, porém, em essência, isso pode ser interpretado como garantir que os agentes não causem danos.
Benevolência	Assume que os agentes não têm objetivos conflitantes entre si e, portanto, são bem-intencionados
Serviços de interoperabilidade, comunicação e intermediação	Os agentes precisam ser capazes de descobrir serviços e interagir com outros agentes
Verificação	Refere-se a mecanismos de governança que podem ser usados para verificar se tudo funciona conforme o esperado

Nota. Adaptado de Kirrane (2021)

2.5.2 Agentes racionais

Agentes inteligentes ou racionais, como os denominados por Russell e Norvig (2022), Weiss et al. (2010) e Bordini et al. (2007), são aqueles capazes de raciocinar com base em suas percepções e seu conhecimento do mundo, a fim de escolher as ações mais adequadas a realizar no ambiente para alcançar os seus próprios objetivos.

Nesse contexto, Russell e Norvig (2022) explicitam que a definição de racionalidade do agente em um determinado momento depende de quatro elementos: i) a medida de desempenho que estabelece o critério de sucesso; ii) o conhecimento prévio que o agente possui sobre o ambiente; iii) as ações que o agente pode realizar; v) a sequência de percepções que o agente teve até o momento. Para cada sequência de percepções possível, um agente racional deve selecionar uma ação que se espera que venha a maximizar sua medida de desempenho, dada a evidência fornecida pela sequência de percepções e por qualquer conhecimento interno do agente. Quando um agente se baseia no conhecimento anterior de seu projetista e não em suas próprias percepções, dizemos que o agente não tem autonomia. Um agente racional deve ser autônomo, aprendendo o que puder para compensar um conhecimento prévio parcial ou incorreto.

Um agente racional é aquele que age para alcançar o melhor resultado ou quando há incerteza o melhor resultado esperado. Em termos matemáticos, afirma-se que o comportamento do agente é descrito pela função do agente que mapeia qualquer sequência de percepções específica para uma ação. O agente racional é usado na teoria dos jogos e na teoria da decisão para nos ajudar a aplicar a inteligência artificial a vários cenários do mundo real (Russell & Norvig, 2022; Pal et al., 2020).

Segundo Kirrane (2021), a inteligência dos agentes de software é um tema polêmico na comunidade científica, dado que diferentes pesquisadores procuram características diferentes para definir inteligência no comportamento dos agentes. O que faz um agente ser chamado de inteligente é a sua capacidade de reagir racionalmente aos estímulos do ambiente no qual ele está inserido, sendo que seu grau de inteligência pode ser medido em função das ações que ele realiza. Algumas questões filosóficas e psicológicas sobre o significado de inteligência. Embora tenhamos evoluído bastante nessa área, ainda não temos ao certo que tipo de inteligência que se pode esperar dos agentes ou de outros sistemas de software inteligentes, ou melhor, os pesquisadores questionam, se é o mesmo tipo de inteligência encontrada nos seres humanos (Russell & Norvig, 2022).

Atualmente há um esforço da indústria em geral, bem como, pesquisadores para adicionar comportamento inteligente em agentes tanto físicos como virtuais. Devido ao aumento do *big data*, isto é, o grande volume de informação, dado pela alta capacidade de processamento, e aprendizado de máquina, as máquinas estão cada vez mais surpreendendo na capacidade de executar tarefas que outrora é campo dominado apenas por seres humanos. (Brynjolfsson & McAfee, 2015).

2.5.3 Classificação de agentes

De acordo com Russell e Norvig (2022), uma pergunta comum é se a inteligência artificial é capaz de gerar comportamento inteligente. Turing (1950) acreditava que sim e considerava essencial desenvolver formas de programar a inteligência nas máquinas. Atualmente, podemos observar que as tecnologias de aprendizado de máquina avançaram nessa direção, proporcionando uma variedade de métodos de aprendizado.

Na área dos agentes inteligentes, foram desenvolvidos diversos padrões e modelos para alcançar o objetivo de criar agentes com capacidade de inteligência (Wooldridge, 2009; Bordini et al. 2007; Müller, 1999). Neste trabalho, os principais tipos de agentes são abordados de forma a explorar os modelos de arquitetura mais comuns encontrados na literatura.

Agentes reativos são modelados no comportamento humano instintivo ou reflexivo. Quando se trata de agentes reativos, há um acoplamento estreito entre o que o agente percebe e como o agente age na forma de regras de ação de condição, figura (6). Esses agentes selecionam ações com base na percepção atual, ignorando o restante do histórico de percepções (Kirrane, 2021; Russell & Norvig, 2022).




Figura 6: Agentes Reativos Simples

Nota. Russell e Norvig (2022).

Para Kirrane (2021), o conhecimento de “como o mundo funciona”, seja ele implementado em circuitos booleanos simples ou em teorias científicas completas, é chamado de modelo do mundo, figura (7). Um agente que usa tal modelo denomina-se agente baseado em modelo (Russell & Norvig, 2022).




Figura 7: Agente baseado em Modelo

Nota. Russell e Norvig (2022).

Os agentes baseados em utilidade como exemplificado na figura (8), são semelhantes aos agentes baseados em objetivos, mas também possuem uma medida de utilidade usada para avaliar o nível de sucesso quando o objetivo é alcançado. Por exemplo, um agente cujo objetivo é ir da “Cidade A” para a “Cidade B” pode atingir esse objetivo levando de duas a quatro horas para completar o trajeto (Russell & Norvig, 2022).




Figura 8: Agente baseado em Utilidade

Nota. Russell e Norvig (2022).

2.5.4 Arquitetura de um agente de software

Girardi e Leite (2013) explicitam que uma arquitetura de software representa uma solução computacional que descreve a interação entre as partes de um sistema, proporcionando uma visão geral de sua estrutura. Os elementos fundamentais de uma arquitetura de software são os componentes, conectores e mecanismos de cooperação e coordenação. Os componentes são as unidades computacionais, como módulos, objetos ou agentes de software. As arquiteturas de software são representadas por meio de diagramas gráficos que seguem estilos arquitetônicos e padrões de projeto. Esses diagramas mostram como os componentes se conectam e são combinados de acordo com restrições específicas.

As arquiteturas de agentes podem ser classificadas em reativas, deliberativas ou híbridas. As arquiteturas reativas emulam comportamentos instintivos ou reflexivos, enquanto as deliberativas suportam diferentes formas de raciocínio automático. Existem também arquiteturas de aprendizado, que permitem que o agente melhore seu desempenho ao longo do tempo. As arquiteturas híbridas combinam características das arquiteturas reativas e deliberativas. Independentemente da arquitetura escolhida, todas as arquiteturas de agentes possuem componentes de software e interfaces que definem as capacidades do agente de alcançar objetivos propostos (Russell & Norvig, 2022; Kirrane, 2021; Girardi & Leite, 2013; Muller et al., 1998). A seguir, uma visão geral das entradas e interfaces externas comuns a todas as arquiteturas, conforme abordado na literatura de agentes inteligentes.

Ambiente - Agentes agem em seu ambiente, ou seja, ambiente do problema que se deseja resolver, possivelmente juntos com outros agentes. Quando falamos de agentes de software, o ambiente de internet é um espaço complexo com uma variedade de diferentes tecnologias de comunicação em rede, dispositivos, endereço de recursos, aplicações e agentes artificiais e humanos.

Medida de Desempenho - quando se trata de avaliar a eficácia de um agente é necessário definir o sucesso em termos do estado do ambiente. Aqui há necessidade de qualidades desejáveis, levando em consideração que pode haver objetivos conflitantes tornando necessário avaliar e gerenciar escolhas tomadas (em inglês usa-se o termo *trade-offs*).

Sensores - Os agentes de software percebem o mundo por meio de uma variedade de sensores, por exemplo, teclado, câmeras, microfone, portas de rede, arquivos em diretórios etc., que podem ser usados pelos agentes para perceber mudanças em seu ambiente.

Atuadores - Agentes de software são capazes de realizar ações por meio de uma variedade de atuadores, por exemplo, tela, impressora, fones de ouvido, portas de rede etc., que podem ser usados por agentes para agir em seu ambiente.

Nesse contexto, Russell e Norvig (2022) especificam o ambiente de tarefas do agente, tabela 12, onde os ambientes de tarefas, são essencialmente os “problemas” para os quais os agentes racionais são as “soluções”. Usa-se critérios de avaliação de medida de desempenho, ambiente, atuadores e sensores, o acrônimo PEAS (em inglês: *Performance, Environment, Actuators, and Sensors*) foi estabelecido para simplificar estas características, para obter uma melhor compreensão dos objetivos de alto nível dos vários agentes e examinar as interfaces e entradas externas (Kirrane, 2021).

Tabela 12: Exemplo de Agentes Inteligentes com as características da especificação PEAS

Tipo de Agente	Medida de Desempenho	Ambiente	Atuadores	Sensores
----------------	----------------------	----------	-----------	----------

Motorista de táxi	Viagem segura, rápida, dentro da lei, confortável, maximização dos lucros	Estradas, outros tipos de tráfego, pedestres, clientes	Direção, acelerador, freio, sinal, buzina, visor	Câmeras, sonar, velocímetro, GPS, acelerômetro, sensores do motor, teclado.
Filtro de e-mails	Aliviar a carga de leitura do usuário	Mensagens, usuários	Aceitar ou rejeita mensagens	Mensagens
Tutor de português	Melhorar o desempenho do estudante	Conjunto de estudantes	Imprimir exercícios, sugestões, correções	Palavras digitadas

Nota. Adaptado de Russell e Norvig (2022)

2.5.4.1 Arquitetura reativa de agente

Agentes reativos são modelados com base no comportamento humano instintivo ou reflexivo. Nessas arquiteturas, há uma forte conexão entre a percepção do agente e sua ação, expressa através de regras de ação condicionais. Os principais componentes encontrados em arquiteturas reativas são regras de ação condicional, sensores, atuadores e o ambiente que fornece percepções e ações disponíveis para o agente. A arquitetura reativa é particularmente adequada quando é necessária uma resposta imediata a uma percepção específica. Sua principal vantagem reside na rapidez com que o agente pode agir diante de uma determinada situação, permitindo uma resposta ágil e direta (Girardi & Leite, 2013; Russell & Norvig, 2022). Kirrane (2021) resalta alguns elementos importantes na arquitetura reativa do agente, incluindo: i) **regras de condição-ação** - o agente simplesmente recupera a ação associada a uma determinada condição percebida por seu(s) sensor(es) e usa a ação para dar instruções ao(s) atuador(es); ii) **estado** - os agentes reativos mais avançados mantêm o estado na forma de informações sobre o mundo e interações anteriores com o ambiente. Dada uma nova percepção, o agente escolhe uma ação com base tanto na percepção atual quanto em seu histórico de percepções anteriores.

2.5.4.2 Arquitetura avançada para agentes inteligentes

O aprendizado em agentes inteligentes pode ser resumido como um processo de modificação de cada componente do agente, a fim de levar os componentes a um acordo mais íntimo com as informações de realimentação disponíveis, melhorando assim o desempenho global do agente. Agentes de *softwares* básicos não tem aprendizado, eles agem de acordo com suas percepções definidas no projeto do agente. Entretanto, dada novas percepções o agente deve ser reprogramado (Russell & Norvig, 2022; Kirrane, 2021).

Nesse sentido, agentes que aprendem em tempo de execução (*runtime*) podem mudar o seu comportamento de acordo com as mudanças no ambiente (Girardi & Leite, 2013). Para esse tipo de agente, percepções devem ser usadas não somente para agir, mas também melhorar a habilidade do agente de se comportar no futuro. Segundo a concepção de Russell e Norvig (2022), os agentes de aprendizagem figura (9), têm quatro componentes conceituais: aprendizado, desempenho, crítico e gerador de problemas. O elemento de aprendizado, responsável pela execução de aperfeiçoamento do agente. Já o elemento de desempenho, fica responsável pela seleção das ações externas, é considerado o agente completo, ele recebe percepções e decide sobre as ações. O componente de aprendizado utiliza o elemento crítico sobre como o agente está funcionando e determina de que maneira o elemento de desempenho deve ser modificado para funcionar melhor no futuro. Sendo que o elemento crítico do agente, informa ao elemento de desempenho como o

agente deve se comportar em relação a um padrão fixo de desempenho. O crítico se faz necessário porque as próprias percepções não oferecem nenhuma indicação do sucesso do agente. Por fim, o elemento do agente com aprendizagem é o gerador de problemas. Ele é responsável por sugerir ações que levarão a experiências novas e informativas. O ponto é que, se o elemento de desempenho tivesse a possibilidade, ele continuaria a realizar as melhores ações, com base no conhecimento que tem. A principal função do gerador de problemas é sugerir ações exploratórias.

Durante a construção do elemento de aprendizagem é necessário definir a técnica de aprendizagem a ser utilizada. Conforme já mencionado, técnicas bem conhecidas de aprendizado de máquina são aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. (Russell & Norvig, 2022; Kirrane, 2021; Girardi & Leite, 2013).




Figura 9: Agente com Modelo de Aprendizagem

Nota. Russell e Norvig (2022).

2.5.4.3 Arquitetura híbrida de agente

Os componentes arquitetônicos reativos e deliberativos individuais descritos até agora podem ser organizados em camadas horizontais e/ou vertical. Na camada horizontal, cada componente de software é conectado diretamente a um sensor e um atuador. Neste tipo de arquitetura cada camada funciona como um agente independente. Uma vantagem de organizar arquiteturas em camadas horizontais é a clara separação dos diferentes comportamentos dos agentes dentro da arquitetura, onde cada camada pode agir independentemente da outra, até mesmo em paralelo (Kirrane, 2021; Girardi & Leite, 2013; Muller, 1999; Wooldridge & Jennings, 1995).

Nesse sentido, Kühl et al. (2019) propuseram um *framework conceitual*, composto de uma arquitetura em camadas de agentes, tendo como base os conceitos fundamentais de Russell e Norvig (2015) de agir (*action*) e pensar (*thinking*). Objetiva-se neste *framework* entender a função do aprendizado de máquina dentro da inteligência artificial.

A proposta apresentada por Kühl et al. (2019) oferece uma maneira de mapear diferentes tarefas e componentes de aprendizado de máquina para as capacidades de agentes inteligentes. Ao considerarmos as capacidades de ação e pensamento de um agente inteligente, podemos traduzir esses elementos em termos de design de software. Podemos inferir que as capacidades de ação podem ser relacionadas a camada de apresentação (*front-end*), enquanto a parte de pensamento pode

ser considerada como camada de execução (*back-end*). No entanto, outros autores como Weiss et al. (2010), Bordini et al. (2007) e Muller (1999), podem discordar dessa visão demonstrada na figura (10), argumentando que os sensores e atuadores residem dentro do próprio agente, e não no ambiente em que o agente está atuando.




Figura 10: Framework Conceitual para entendimento da função de aprendizado de máquina na inteligência Artificial

Nota. Adaptado de Kuhl et al. (2019).

Observa-se que o modelo elaborado é composto por algumas camadas (*layers*) sendo: **Front-end** - principal *interface* de interação com ambiente e é responsável pela apresentação de informações para o usuário. Pode assumir muitas formas, nesse cenário o agente pode ter um alto nível de abstração, como uma interface web interpretada por uma máquina ou um aplicação lida por humanos. No modelo proposto o *front-end* requer dois componentes técnicos, sensores e atuadores.

Executing Back-end- tem como função prover funcionalidade necessárias, como capacidade de pensar de forma inteligente do agente. Entretanto, os agentes precisam aprender e aplicar o conhecimento adquirido, nesse sentido a próxima camada deve ser implementada.

Learning Back-end - o aprendizado de máquina se faz uma camada relevante. Conforme abordado em tópicos anteriores, pode ser feito através do aprendizado supervisionado ou não supervisionado, onde são necessários vários processos para construir, ou seja, treinar o modelo, bem como, adequar os modelos de aprendizado de máquina, entre outros processos para implementar os modelos em um ambiente real.

Na literatura, encontramos exemplos de arquiteturas híbridas, como SOAR, que foi uma das primeiras propostas nesse sentido. SOAR desenvolveu um ambiente que se traduz em um framework que suporta a criação de agentes conforme suas definições. Outros exemplos são ACT-R (*Adaptive Control of Thought-Rational*) e INTERRAP (*Integration of Reactive Behavior and Rational*

Planning). Percebe-se que, para resolver problemas mais complexos, é necessário pensar em estruturas mais sofisticadas que permitam a divisão do problema em camadas, facilitando o alcance do objetivo desejado. As arquiteturas híbridas são uma escolha comum para os projetistas de agentes inteligentes, dependendo da natureza do problema que se pretende resolver (Kuhl et al., 2019; Girardi & Leite., 2013; Weiss et al., 2010; Muller, 1999).

2.5.5 Sistema multiagente

Um sistema multiagente (SMA) é composto por dois ou mais agentes, cada um deles dotado da capacidade de perceber eventos no ambiente por meio de sensores, realizar raciocínio e tomar ações no ambiente através de atuadores. Os agentes que fazem parte de um SMA podem assumir uma variedade de papéis com o objetivo de realizar tarefas automatizadas, adaptando-se às mudanças no ambiente e interagindo de forma cooperativa ou competitiva com outros agentes. A seleção das ações a serem executadas é baseada nas condições percebidas no ambiente onde cada agente está inserido. A inteligência dos agentes se manifesta na habilidade de escolher as ações mais apropriadas para alcançar seus objetivos individuais ou coletivos (Russell & Norvig, 2022; Wooldridge, 2009).

De acordo com Wooldridge (2009), um agente é considerado inteligente quando exibe quatro características essenciais: autonomia, reatividade, pró-atividade e habilidades sociais. Isso significa que um agente é uma entidade computacional inserida em um ambiente que possui a capacidade de agir de maneira flexível e independente para atingir os objetivos definidos no projeto. Essas características fundamentais garantem que o agente possa tomar decisões autônomas, responder a estímulos do ambiente, tomar a iniciativa para alcançar seus objetivos e interagir de maneira socialmente competente, tornando-o verdadeiramente inteligente.

Conforme exposto na *seção (2.5.3)* os agentes podem ser classificados de acordo com sua atuação no ambiente através de seu comportamento: reativo simples, reativo baseado em modelo, baseado em objetivo, baseado em utilidade e baseado em aprendizado. O ambiente no qual o agente está inserido pode ser classificado de acordo com características específicas do mesmo, bem como o acesso a recursos disponíveis. A complexidade do projeto SMA está diretamente ligada às propriedades do ambiente, as quais podem ser: observável vs. parcialmente observável; estático vs. dinâmico; determinístico vs. não determinístico; discreto vs. contínuo; episódico vs. sequencial (Russell & Norvig, 2022).

2.5.6 Metodologia e modelagem dos agentes

Weiss et al. (2010) salienta que desenvolver software baseado em agente requer, como qualquer outro tipo de software, uma abordagem sistemática de construção, que apoie e conduza uma equipe de desenvolvimento ao longo de todas as fases do processo de produção de software. Um processo metodológico apoiado na engenharia de software visa descrever todos os elementos necessários para se desenvolver um sistema de software. Portanto, uma metodologia usa uma linguagem de modelagem para capturar e descrever requisitos do futuro sistema, modela dos componentes da arquitetura e detalhes de sua interação, traz diversas formas de se pensar sobre os modelos, desenvolve um processo estruturado para orientar pessoas nas atividades e agrega ferramentas para apoiar os processos de desenvolvimento.

A metodologias de desenvolvimento de sistemas, conhecida como paradigma de programação orientada a objetos (POO), bastante divulgada na década de 1990. Agora tem-se visto o surgimento de diversas metodologias inovadoras orientadas a agentes (AO) ou programas orientados a agentes (POA). A modelagem POA necessita de ferramentas e técnicas de modelagem específicas, diferente da linguagem de modelagem unificada (traduzido do idioma inglês: *Unified Modeling Language* - UML). Na modelagem POA podem ser analisados os estados mentais e crenças dos agentes, em vez de estados de máquinas; planos e ações, em vez de procedimentos; métodos de comunicação, negociação, interação e capacidade social, em vez de funcionalidades de entrada e saída; objetivos e entre outros aspectos dos agentes. No entanto, a UML pode contribuir na

modelagem de fases relacionadas à implementação de um SMA por meio de diagramas de sequência, classes, estados entre outros.

Nesse sentido, a metodologia de desenvolvimento de software Tropos, derivado do grego tropos, que representa uma figura de linguagem que leva a uma mudança, tem em seu cerne a modelagem orientada a objetivos (*goal modeling*), sendo que sua abordagem é explorar a flexibilidade requerida pela modelagem POA, que diferentemente da UML concebe modelos no nível do conhecimento ao modelar programas orientados a objetivos e não somente em níveis de programação.

Sendo assim, Tropos define uma metodologia de desenvolvimento de software para sistemas de software orientados a agentes baseados no *framework I** (*Intentional Strategic ActorRelationships modeling* - iStar), é estruturado em dois modelos: modelo de Dependência Estratégica (DE) e modelo de Razão Estratégica (RE). O modelo DE é utilizado para descrição das intenções de processos em termos de relacionamento de dependência e atores. Já o modelo RE fornece a descrição estratégica de processos, levando em consideração elementos processuais e análise de metas que deverão ser cumpridas pelos atores. Assim, permite modelar as funcionalidades de uma aplicação baseada em objetivos por meio de diagramas. Cada um dos diagramas, conforme ilustrado na figura (11), possuem componentes visuais utilizados para representar graficamente atores, agentes e papéis (*Actor, Agent, Role*), objetivos (*Goal, Soft-Goal*), tarefas e planos (*Task/Plans*) e recursos (*Resource*).



Figura 11: Elementos visuais do framework I*

Outro tipo de componente da notação utilizado para relacionamento entre os demais componentes e os atores é uma seta vazada, como pode ser visualizado na figura (12), esta seta é utilizada para viabilizar os diversos tipos de relações entre atores. Em um relacionamento de dependência existem dois tipos de atores: ator dependência e ator dependido, e entre eles fica o componente de dependência. O framework *I** Permite dois tipos de dependência entre atores: a dependência por meta-objetivo e a dependência por objetivo. Nas relações de dependência, o componente dependente só pode ser usado no máximo por dois atores que, neste caso, são o ator dependente e o ator dependido.

Componente da notação utilizado para relacionamento entre os demais componentes e os atores é uma seta vazada, como pode ser visualizado na figura (12). Esta seta é utilizada para viabilizar os diversos tipos de relações entre atores. Em um relacionamento de dependência existem dois tipos de atores: ator dependência e ator dependido, e entre eles fica o componente de dependência. O framework *I** Permite dois tipos de dependência entre atores: a dependência por meta-objetivo e a dependência por objetivo. Nas relações de dependência, o componente dependente só pode ser usado no máximo por dois atores que, neste caso, são o ator dependente e o ator dependido.




Figura 12: Modelo de dependência entre atores

A metodologia Tropos engloba praticamente todas as cinco fases de desenvolvimento de software, com o objetivo de dar apoio desde a análise de requisitos iniciais até a implementação. As fases incluem os requisitos iniciais, os requisitos finais, o projeto arquitetural, o projeto detalhado e a implementação.

- **Fase de Requisitos iniciais:** foca no entendimento do problema através da compreensão do contexto organizacional, no qual o sistema a ser desenvolvido será implementado. Durante esta fase os engenheiros de requisitos modelam os *stakeholders*, como atores sociais, que dependem uns dos outros e que têm intenções de atingir objetivos, realizar tarefas e fornecer recursos. A análise realizada nesta fase é orientada a objetivos, onde cada objetivo é analisado sob o ponto de vista de seus atores, resultando em conjunto de dependências entre pares de atores.
- **Fase de Requisitos Finais:** nesta fase ocorre o refinamento do modelo de DE e RE concebidos na fase anterior. Durante a análise dos requisitos finais, os modelos conceituais desenvolvidos na fase anterior são revisados e estendidos para incluir novos atores, que representam tanto o sistema a ser desenvolvido quanto os seus subsistemas. Para realizar o projeto do modelo DE na fase de Requisitos Finais, os atores devem ser relacionados por meio de novos pares de dependência junto aos atores do ambiente operacional do sistema que foram identificados na fase anterior. Estas dependências relacionadas ao sistemas devem refletir responsabilidades atribuídas ao mesmo, de forma contribuir com as necessidades dos *stakeholders*. Essas dependências são utilizadas para descrever os requisitos funcionais e não funcionais do sistemas a ser desenvolvido (Dalpiaz et al., 2016).
- **Fase de Projeto Arquitetural:** o projeto arquitetural serve para definir a arquitetura global do sistema em sua estrutura como subsistemas, interconexões e controle de dados. A arquitetura de um sistema pode ser considerado um modelo, relativamente pequeno e intelectualmente gerenciável da estrutura do sistema que descreve como seus componentes trabalham juntos. Na metodologia Tropos, subsistemas são representados como atores e interconexões de dado/controle são representados como dependência entre os atores (Pimentel & Castro, 2018).
- **Fase de Projeto Detalhado:** a fase de projeto detalhado lida com a especificação do micro nível dos agentes, estando preocupada em apresentar detalhes adicionais para cada componente do sistema. Isto inclui aspectos dos agentes que envolvem a comunicação e seus comportamentos. Para um melhor nível de detalhamento, o ideal é que a plataforma de implementação já tenha sido escolhida.

Fase de Implementação: na fase de implementação deve ocorrer o mapeamento do projeto detalhado para linguagem computacional. A metodologia Tropos em si não menciona nada quanto à fase de implementação. No entanto, devido a metodologia ter um alto refinamento dos sistema na sua última fase, algumas ferramentas CASE que suportam a metodologia Tropos cobrindo a fase de implementação e montando o esqueleto do código. Estas ferramentas geram esqueletos de código para o *framework* com JACAMO, JADDEX, JADE, PADE. Em geral, a programação de sistemas multiagentes não é trivial, portanto há necessidade de utilização de um *framework* de programação.

PADE - *Python Agent DEvelopment* é um *framework* para desenvolvimento, execução e gerenciamento de sistemas multiagentes em ambientes de computação distribuída escrito em linguagem Python (GREI-UFC, 2019). PADE é software livre, licenciado sob os termos da licença MIT, desenvolvido pelo Grupo de Redes Elétricas Inteligentes (GREI) do Departamento de Engenharia Elétrica da Universidade Federal do Ceará e utiliza as bibliotecas do projeto Twisted para implementar a comunicação entre os nós da rede. O PADE foi desenvolvido considerando os requisitos para sistema de automação e oferece os seguintes recursos: abstração para implementação dos agentes utilizando Orientação a Objetos; ambiente de execução de agentes inteiramente em código Python; módulo para a implementação dos protocolos definidos pela FIPA; módulo para construção e tratamento de mensagens no padrão FIPA-ACL (*Agent Communication Language - ACL*), além de permitir o envio de objetos serializados como conteúdo das mensagens ACL. PADE provê a implementação de comportamentos cíclicos e temporais, a interação com banco de dados, entre outras funcionalidades. Os criadores do PADE afirmam que o framework é de fácil instalação e configuração, multiplataforma, podendo ser instalado e utilizado em hardwares embarcados que executam sistema operacional Linux, como *Raspberry Pi*, bem como, o sistema operacional Windows. Encontra-se disponível tanto o código, quanto exemplos de utilização do *framework* no *GitHub* que podem ser baixados, instalados e executados por meio de comandos presentes em sua documentação. Acessível em: < <https://pade.readthedocs.io/pt-br/latest/> >

2.5.6.1 Bibliotecas e linguagem de programação

Em ciência da computação, uma biblioteca de linguagem de programação é um conjunto de subprogramas, funções, classes e dados pré-compilados que podem ser usados por programas escritos em uma determinada linguagem de programação. As bibliotecas fornecem uma maneira de reutilizar código e dados, o que pode reduzir o tempo de desenvolvimento e aumentar a qualidade do software.

- **SciPy** - é uma ferramenta de código aberto para trabalhar com computação científica na linguagem Python, que acopla outras bibliotecas formando um ecossistema baseado em Python, criado com o intuito de facilitar o desenvolvimento de cálculos matemáticos e estatísticos. Entre as bibliotecas contidas no SciPy estão NumPy e Matplotlib. (<https://www.scipy.org>)
- **NumPy** - usada principalmente para realizar cálculos em arrays multidimensionais. Fornece um grande conjunto de funções e operações que ajudam os programadores a executar cálculos numéricos das mais diversas natureza. Ainda de acordo com (<https://numpy.org/>) essa lib é interoperável, performática, fácil de usar e de código aberto.
- **Pandas** - possui código aberto, voltada à análise e manipulação de dados que permite trabalhar de forma rápida e eficiente com arquivos do tipo csv (Comma Separated Values), sendo esse formato presente na maioria dos datasets disponíveis para experimentos (<https://pandas.pydata.org/>).
- **Scikit-learn** - biblioteca de aprendizado de máquina desenvolvida em linguagem Python, de código aberto. Ela inclui vários algoritmos de classificação, regressão, agrupamento,

entre outros e foi projetada para interagir com bibliotecas Python numéricas e científicas como por exemplo a NumPy (<https://scikit-learn.org/stable/>).

2.6 Modelo conceitual da pesquisa

Tendo por base os tópicos apresentados, decorrentes da revisão de literatura efetuada, elaborou-se o modelo conceitual da pesquisa (Figura 13) para melhor interpretação desta pesquisa.

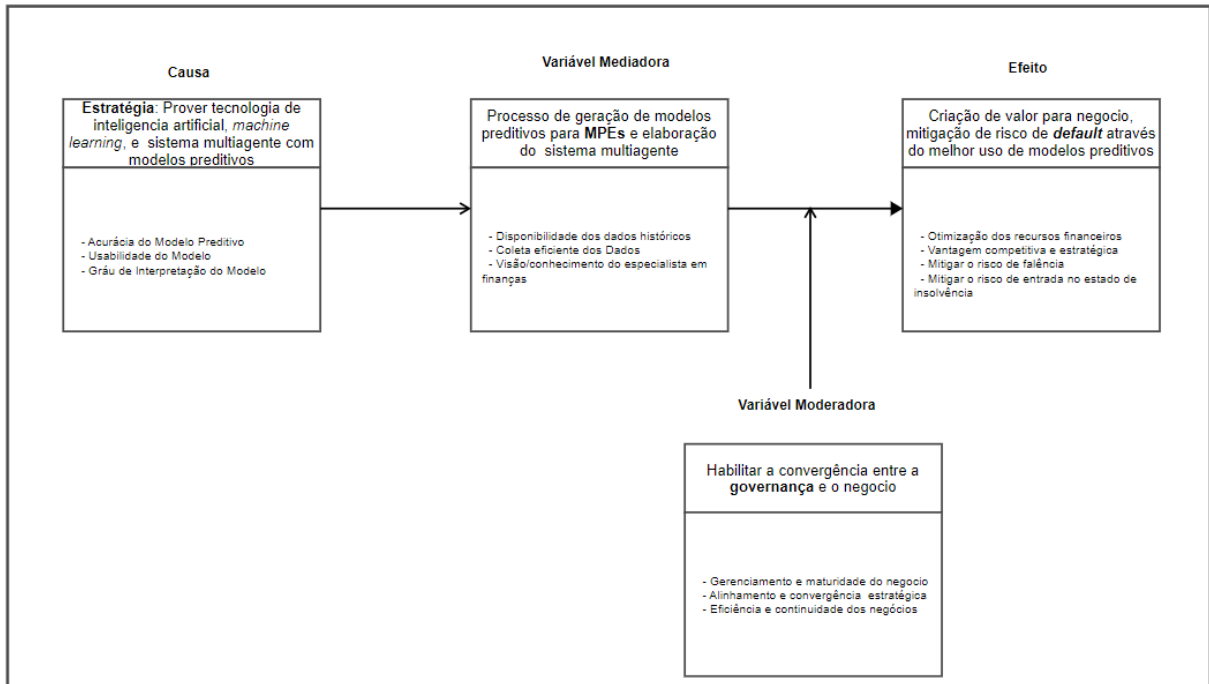


Figura 13: Modelo conceitual da pesquisa

Nota. Adaptado de Glenn Remoreras disponível em: <<https://glennremoreras.com/tag/libby-boxes/>>

O modelo proposto busca sintetizar o desafio enfrentado pelas empresas ao implementar uma estratégia efetiva de utilização de tecnologias emergentes, como aprendizado de máquina e inteligência artificial. A causa dessa abordagem é a oportunidade de empregar novas tecnologias no contexto da empresa visando otimizar os recursos disponíveis.

No caminho que entre a causa e o efeito desejado, podem existir variáveis mediadoras que impactam a conquista do resultado esperado. Neste caso, a disponibilidade e qualidade dos dados desempenham o papel de conectar a causa ao resultado desejado. Além disso, variáveis moderadoras, como a gestão e governança da organização, podem exercer influência e moderar o resultado durante a execução da estratégia.

Dessa forma, o objetivo da empresa, como entidade de negócios, poder ser interpretado como: fornecimento de tecnologias, tais como, o aprendizado de máquina, inteligência artificial por meio da abordagem de aprendizado de máquina e agentes inteligentes para viabilizar a construção de um processo eficiente de previsão de insolvência para organização, tendo a intenção de apoiar os responsáveis a tomar melhores decisões na empresa.

Conforme abordado em tópicos anteriores, existe uma série de desafios para se implementar uma estratégia absorvendo as capacidades da inteligência artificial. Entretanto, devido ao novo contexto que o mundo se encontra, se faz necessários que as, micro, pequenas, médias ou grandes empresas se adaptem e exponham este novo cenário.

3. METODOLOGIA

3.1 Estratégia da pesquisa

Conforme Peffers et al. (2007), uma metodologia é um sistema de princípios, práticas e procedimentos aplicados para um ramo específico de conhecimento. Assim, a metodologia deve ajudar os pesquisadores a produzir e apresentar o conhecimento com confiança e qualidade. Nesse sentido, de acordo com Gil (2021), um método científico é entendido como uma série de passos que se utiliza para obter um conhecimento confiável, ou seja, livre da subjetividade do pesquisador e mais próximo possível da objetividade empírica.

O presente trabalho foi desenvolvido por meio da modalidade de estudo bibliográfico, nas palavras de Santos (2012), qualquer que seja o campo pesquisado, sempre será necessária uma pesquisa bibliográfica, que proporciona um conhecimento prévio do estágio em que se encontra o assunto, já que procura explicar o problema a partir de referências teóricas publicadas em documentos. Para tanto utilizou-se a metodologia *design science research* (DSR) que tem como ponto de partida a revisão sistemática da literatura para formalização da face e diagnóstico do problema que se pretende resolver (Gregor & Hevner, 2013).

Gil (2021) argumenta que o método estatístico caracteriza-se por ter razoável grau de precisão, portanto, este estudo é classificado como quantitativo (Cervo & Bervian, 2007). Ainda podemos entender este estudo como sendo descritivo o qual não há interferência do pesquisador. De acordo com Marconi e Lakatos (2021) utiliza-se este tipo de pesquisa para conseguir informação ou acontecimento acerca de uma questão para o qual se procura uma hipótese ou descobrir novos fenômenos. Portanto, esta pesquisa está fundamentada na aplicação da teoria estatística da probabilidade uma vez que utiliza modelos de aprendizagem de máquina que tem suas raízes solidificadas nos cálculos da esperança matemática, isto é, a probabilidade (Facelli et al., 2011).

3.1.1 População e amostra

A população objeto desta pesquisa é constituída por micro e pequenas empresas estabelecidas em diversos estados do Brasil. Essas empresas são uma das principais forças econômicas do país, que abriga um vasto universo de micro e pequenas negócios que desempenham um papel fundamental na economia local (Sebrae, 2022). Os dados para esta pesquisa foram adquiridos mediante a colaboração de um escritório de contabilidade localizado na cidade de São Caetano do Sul, do qual o pesquisador é sócio proprietário. Este escritório presta serviços contábeis a uma ampla variedade de micro e pequenas empresas. Nesse sentido, as empresas assinam um contrato de prestação de serviço onde são inseridas as clausuras referentes à Lei de Proteção e Dados (LGPD) onde garante a manipulação de dados sensíveis pelo escritório. Para manter o sigilo das informações em conformidade com LGPD esta pesquisa utiliza-se dos dados sem exposição de informações específicas das empresas. Adicionalmente, informações suplementares da amostra foram obtidas através da Central Balanços que estão abertos ao público conforme a aceitação de participação pela empresa. Este é um serviço fornecido pelo governo disponibilizado por meio da receita federal via um *website*, que consolida as informações dos demonstrativos das empresas com origem no sistema de público de escrituração digital conhecido como Sistema Público de Escrituração Contábil (SPED), sendo a participação pela empresa feita de forma voluntária.

O escritório contábil disponibilizou informações de doze (12) empresas, das quais, após análise, oito (8) foram categorizadas como solventes e quatro (4) como insolventes. Adicionalmente, dados provenientes da Central de Balanços, disponibilizado pelo SPED, foram utilizados, totalizando oito (8) empresas, das quais cinco (5) foram classificadas como insolventes e três (3) como solventes após análise minuciosa. Cumpre ressaltar que algumas empresas possuem apenas um (1) ano de registro, enquanto outras apresentam informações referentes a períodos que variam entre dois (2) e quatro (4) anos. Em virtude disso, uma linha (instância) foi gerada para cada ano de existência das empresas, permitindo a classificação anual quanto à solvência ou insolvência. Este procedimento proporcionou a construção de uma base histórica para o modelo de

aprendizado de máquina. Deste modo, a quantidade total de instâncias excede o número de empresas, totalizando vinte e duas (22) empresas para um total de trinta e quatro (34) instâncias. Desse total, vinte e três (23) registros foram classificados como solventes, enquanto onze (11) foram classificados como insolventes, conforme ilustrado na figura (14).

	SOLVENTES	INSOLVENTES
Empresas	23	11
34		

Figura 14: Quantidade de instâncias (empresas) solvente e insolvente

Enfatize-se que foi utilizada a receita bruta anual das empresas como referência, desta forma considera-se microempresa o limite anual de R\$ 360.000,00 e para as empresas de pequeno porte, faturamento anual entre R\$360.000,00 e R\$4,8 milhões. Por fim, considera-se como empresas solventes, a organização que possui o índice de liquidez corrente maior do que um. Já, em relação a empresa insolvente, considera-se as empresas que possuem o índice de liquidez menor do que um.

3.1.2 Coleta de Dados

A obtenção dos dados envolveu a exportação dos demonstrativos contábeis, especificamente o Balanço Patrimonial (BP) e os Demonstrativos do Resultado do Exercício (DRE), do sistema ERP (*Enterprise Resource Planing*) Contábil. A seleção dos dados foi realizada considerando o período compreendido entre janeiro de 2020 a julho de 2023, proporcionando assim um intervalo temporal representativo para análise histórica. Para coleta dos dados foram executadas as seguintes etapas:

- Extração manual das informações do Balanço Patrimonial
- Extração manual das informações do Demonstrativo do Resultado do Exercício
- Extração manual do relatório de coeficientes financeiros
- Navegação no website da Central de Balanços como objetivo de mapear o processo de filtragem e encontro das informações
- Criação de processo automático de extração de informações por meio da técnica de *Web Scraping* que consiste fazer a leitura automática em páginas da Internet interpretando os dados exibidos e transformando em modelo que possa ser utilizado por sistema interno.

Os dados foram extraídos do sistema ERP Contábil Domínios pelo escritório de contabilidade e compartilhados via Google Drive em formato de arquivo Excel. Dados coletados da Central de Balanços foram armazenados também em formato Excel para serem manipulados na fase de engenharia de dados.

Engenharia de Dados

Engenharia de dados é uma área de conhecimento que se dedica à construção e gerenciamento de infraestrutura de dados. É responsável por projetar, desenvolver e manter sistemas que coletam, armazenam, processam e disponibilizam os dados para análise e uso posterior. Neste projeto, foram utilizadas algumas práticas da engenharia de dados sendo:

- Extração, Transformação e Carregamento (ETL) – processo crucial na engenharia de dados. Consiste em extrair dados de diferentes fontes, transformá-los de acordo com as necessidades e carregá-los em um local centralizado para análise. A extração de dados para o projeto de aprendizado de máquina deu-se através exportação das demonstrações contábeis das empresas do sistema ERP contábil e da Central de Balanços. A transformação dos dados deu-se através da manipulação dos dados em arquivos Excel utilizando linguagem computacional Python, onde foi possível trabalhar dados categóricos, numéricos, bem como, fazer o complemento de informações faltantes ou mesmo sua remoção por completo.
- Modelagem de dados – é um processo essencial na construção de sistemas. Consiste em definir a estrutura e as relações dos dados, permitindo a organização e integração entre diferentes fontes de informações. A modelagem de dados para o projeto de MAS4PI-ML deu-se através da organização e integração dos dados econômico-financeiro de um sistema ERP Contábil e os dados disponíveis na Central de balanço. Feito a integração dos dados, gerou-se um conjunto de dados chamado de *dataset* contendo todas as informações necessárias para consumo do algoritmo de aprendizado de máquina. O *dataset* contém as variáveis preditoras, bem como, a variável alvo (*target*).

A figura(15) representa o fluxo de informações para análise de insolvência para micro e pequenas empresas. Observa-se que existe uma atualização constante de informações na base de dados financeira das empresas, onde são gerados métricas e indicadores para análise e classificação da empresa. Desta forma o fluxo de dados foi automatizado através do processo de ETL facilitando sua utilização em escala.




Figura 15: Fluxo de informações para análise de insolvência das MPEs

3.1.2.1 Análise exploratória dos dados

A análise e exploração dos dados é apontada como a fase inicial do processo de estudo dos dados coletados. Nesta etapa os dados serão sintetizados através da aplicação de fórmulas

estatísticas e técnicas de visualização. A análise das características por meio de medidas de estatísticas descritivas e de métodos gráficos permite a compreensão acerca do comportamento dos dados e descobertas de padrões e tendências que podem ser úteis nas etapas seguintes do processo de extração do conhecimento dos dados e na modelagem do modelo preditivo.

Visualização dos Dados

A figura (16) demonstra a faixa de faturamento da amostra dos dados coletados. Observa-se que há uma grande parte das empresas com faturamento de até 100 mil reais, ainda é possível visualizar a classificação de solvente e insolvente para cada faixa de faturamento.




Figura 16: Faixa de Faturamento das Micro e Pequenas Empresas

A figura (17) demonstra a classificação das empresas conforme o enquadramento proposto pelo Sebrae. Destaca-se que empresas na faixa de faturamento de até 100 mil reais geralmente são empresas enquadradas como MEI e são mais sensíveis à insolvência tendo uma alta taxa de mortalidade (Sebrae,2022).




Figura 17: Enquadramento das Empresas conforme a disposição do Sebrae

A figura (18) demonstra os setores de atuação das micro e pequenas empresas. Observa-se que a maioria das MPEs está concentrada na prestação de serviço.




Figura 18: Setor de atuação das Micro e Pequenas Empresas

A figura (19) demonstra o enquadramento do regime tributário das micro e pequenas empresas. Observa-se que a maioria é optante do Simples Nacional o que favorece as empresas com a redução e simplificação de pagamentos de impostos para o governo.




Figura 19: Regime Tributário das Micro e Pequenas Empresas

3.2 Abordagem Metodológica (DSR)

Este estudo adota a *Design Science Research* (DSR) como abordagem metodológica. A fundamental característica de aplicar o método DSR é que a pesquisa é centrada na evolução de uma "ciência de projeto" (*design science*). De acordo com Gregor e Hevner (2013), reforçado por Dresch et al. (2015), o DSR tem foco na importância da definição de classes de problemas e dos artefatos gerados no âmbito da pesquisa. Para Aken (2004), as classes de problemas podem consistir em uma organização para a trajetória e o desenvolvimento do conhecimento em um *design science*. No entanto, sempre que possível, as soluções propostas devem ser passíveis de generalização para uma determinada classe de problemas, permitindo assim que outros pesquisadores ou profissionais façam uso do conhecimento em outros contextos (Gregor & Hevner, 2013; Hevner & Chatterjee, 2010). A abordagem DSR contribui para o avanço no desenvolvimento da pesquisa com base no conhecimento do Tipo 2 (Mode 2), refere-se a um conhecimento multidisciplinar, onde as pesquisas orientadas a esse tipo de conhecimento estão preocupadas em resolver problemas complexos relevantes, que consideram o contexto ou ambiente em seus resultados serão aplicados. Por consequência, o conhecimento desenvolvido pela DSR é explicativo, e sendo assim,

pretende projetar, desenvolver e prescrever uma solução funcional e satisfatória (Dresch, 2018; Lacerda et al., 2013; Hevner et al., 2004; Peffers et al., 2007; Dresch et al., 2015).

Posto isto, a adoção desta metodologia visa auxiliar a gestão das MPEs contribuindo na manutenção dos negócios que decretam falência antes de completar cinco anos. A metodologia DSR irá contribuir de forma efetiva desenvolvendo artefatos simples, porém eficazes, voltados à solução do problema de insolvência das micro e pequenas empresas (Ferreira et al., 2022).

Este estudo visa apresentar uma solução satisfatória para o contexto das micro e pequenas empresas no Brasil no que tange ao fenômeno de insolvência no sentido de abrandar a taxa de mortalidade dessas organizações. Nesse sentido, é proposto o desenvolvimento de dois artefatos; no primeiro artefato é feita a elaboração de um sistema multiagente autônomo com capacidade de aprendizado, e o segundo é a geração de um modelo de aprendizado de máquina para prever o estado de insolvência para as MPEs (que será utilizado pelo primeiro artefato). O primeiro artefato irá atuar observando o ambiente de empresa como ferramenta de auxílio para previsão de insolvência e tomada de decisão.

Para alcançar os objetivos deste estudo foram seguidas as diretrizes propostas por Dresch et al. (2015) que tem suas bases fundamentadas em diversos trabalhos seminais (Gregor & Havner, 2013, Peffers et al. 2007; Hevner et al. 2004), de forma que dez (10) etapas são descritas na tabela 13.

Tabela 13: Diretrizes Metodologia para condução de pesquisa DSR

Etapa	Descrição
Identificação do Problema	Questão de pesquisa formalizada: Como a elaboração de sistema multiagente baseado em aprendizado de máquina pode auxiliar na predição de insolvência de micro e pequenas empresas no Brasil?
Revisão Sistemática da Literatura	Formalização das faces do problema de insolvência nas empresas, especialmente nas MPEs, compreender o ambiente externo das MPEs no ambiente de empreendedorismo no Brasil e taxa de mortalidade das empresas (ambiente externo da empresa), revisão sistemática da literatura em sobre insolvência nas empresas e nas MPEs, revisão da teoria fundamental sobre agente inteligente e suas aplicações na resolução de problemas nos diversos setores atividades econômicas para o desenvolvimento de artefato(s).
Identificação dos artefatos e configuração das classes de problemas	Identificação de artefatos produzidos na literatura, que tentam resolver o problema de insolvência (Constructos, Modelos, Métodos, <i>Design Propositions</i> , Soluções satisfatória explicitadas) ou soluções elaboradas em outras áreas que que seja possível replicar elementos na resolução do problema de insolvência nas empresas. Entendimento da estrutura da classe de problema que a predição de insolvência se encontra para generalização da solução. Verificação de soluções e modelos propostos de agentes inteligentes que resolveram problemas comuns em diversas áreas das empresas.
Propostas de artefatos para resolver o problema específico	Proposição de dois artefatos para resolução do problema de insolvência. 1. Geração de um modelo de aprendizado de máquina que prever a insolvência para MPEs. 2. Elaboração de um sistema multiagente autônomo com capacidade de

aprendizado (utiliza o modelo de aprendizado de máquina gerado no passo anterior) que irá atuar no ambiente de empresa com ferramenta de auxílio para previsão de insolvência e tomada de decisão.

Projeto do artefato selecionado	Explicitação de todas as técnicas e ferramentas utilizadas para o desenvolvimento dos artefatos (modelo de aprendizado de máquina e construção do agente inteligente). Apresentação dos tópicos de identificação detalhada da amostra (MPEs selecionadas) e insumos para serem consumidos pelo modelo aprendizado de máquina para predição. Detalhamento da arquitetura do sistema multiagente, quais são as suas camadas (<i>layers</i>) e tecnologias que serão utilizadas para sua implementação.
Desenvolvimento do artefato	Construção dos artefatos: desenvolvimento do modelo de aprendizado de máquina e agente inteligente com base na especificação arquitetural determinada no projeto dos artefatos, os artefatos (sistema multiagente e modelo preditivo) devem ficar no estado funcional.
Avaliação do artefato	A partir do modelo de previsão de insolvência por meio de aprendizado de máquina, ocorre a elaboração do sistema multiagente que usa modelo preditivo gerado. Um teste se faz necessário para entender se os artefatos gerados contribuem para resolução de problema de insolvência das MPEs. É apresentado como será a validação dos artefatos pelas empresas ou partir de dados simulados. Pode-se gerar heurísticas de contingência (refazer determinada parte dos artefatos) tendo como resultado o artefato validado. Pesquisa na prática: a validação do artefato pretende ser feita por pessoas especializadas tanto na área contábil (contadores) como na área financeira, contando com a colaboração de empresas (MPEs) para validação dos artefatos.
Explicitação das aprendizagens	A explicitação dos fatos que funcionaram na validação dos artefatos gerados, bem como os pontos de insucesso, são realizados, gerando assim conhecimento do campo prático e teórico da pesquisa. Por exemplo, se o modelo de aprendizado de máquina gerou a acurácia desejada, e o agente inteligente construído trabalhou de forma autônoma no ambiente da empresa etc.
Conclusões	Exposição dos resultados obtidos na pesquisa, apontando as limitações desta pesquisa, tal como, insuficiência de dados da MPEs.
Generalização para uma classe de problemas	Os resultados obtidos na construção de validação dos artefatos (modelo de aprendizagem de máquina e sistema multiagente) podem ser expandidos para uma classe de problemas (tomada de decisão nas empresas, por exemplo) ou como pode ajudar em problemas similares.

Nota. Adaptado de Dresch et al. (2015)

3.2.1 Revisão Sistemática da Literatura

Nas palavras de Peffers (2007), corroborando com Hevner et al. (2004), faz-se necessário que o pesquisador realize a imersão na literatura acerca do fenômeno que se está pesquisando. Assim pode-se verificar as lacunas, desafios e soluções que já foram identificadas para o tratamento do problema da pesquisa.

Nesse sentido, realizou-se uma revisão sistemática da literatura (RSL) com o objetivo de se aprofundar no tema da insolvência das empresas, sendo utilizadas diversas fontes de informação. Foram consultados bancos de teses e dissertações digitais, assim como periódicos nacionais

indexados no portal Periódicos dos portais Capes, SPELL e Scielo. Além disso, foi feita uma busca na base de dados *Web of Science*. O período selecionado para a pesquisa foi de 2013 a 2023, abrangendo os últimos dez anos. A busca foi direcionada para as áreas de economia, econometria, negócios financeiros, contabilidade e gestão. Foram incluídos apenas trabalhos cujo objetivo estava relacionado à predição de insolvência em empresas.

A pesquisa efetuada para seleção de trabalhos contemplou as seguintes palavras chaves em português “insolvência”, “predição de insolvência”, “aprendizado de máquina”. Já no âmbito internacional, o levantamento focou nas principais publicações de periódicos contidos na base *Science Direct* e *Scopus*. Para pesquisa realizada em periódicos internacionais utilizou as palavras chaves no idioma inglês, sendo “*bankruptcy*”, “*insolvency prediction*”, “*machine learning*”, “*financial distress*”, “*insolvency*”. Foram excluídos os materiais que apontavam para: livros, capas de livros, obras duplicadas, trabalhos que focaram extremamente em prever modelos não no campo da insolvência e cujo escopo estava fora do objeto desta pesquisa foram rejeitados. O levantamento selecionou um volume de 186 artigos, sendo que 147 são internacionais e 39 são estudos nacionais que abrangem a insolvência.

Algumas contribuições têm adicionado informações sobre o contexto que MPEs operam, como abordado por Crosato et al. (2021). Nesse sentido um resultado é que, devido à disponibilidade de dados e parâmetros diferentes, a pesquisa realizada apresenta diferentes algoritmos para evitar a insolvência com uma tendência para a prevenção da insolvência para MPEs (Lee & Shin, 2020; Kezelj et al., 2021).

Observou-se uma série de estudos, no horizonte de dez anos salientado, constituída de revisões sistemáticas de literatura. Estudos como os de Lee & Shin (2020), Kezelj et al. (2021), Duarte et al. (2020), Pereira e Martins (2015) e Gissel et al. (2007) são excelentes trabalhos de revisão bibliográfica, dentre os quais apresentam um olhar para pesquisas que abordam a aplicação de novas tecnologias nas MPEs, como por exemplo o de Que et al. (2019) entre outros, onde encontra-se o foco desta obra a figura (20) demonstra as etapas concluídas na RSL.




Figura 20: Etapas executadas na revisão sistemática da literatura

Para agentes inteligentes observou-se a fundamentação da teoria de agentes. Nesse sentido, trabalhos como os de Russell e Norvig (2022), Kirrane (2021), Girardi e Leite (2013) e Weiss et al. (2010) foram analisados. Foram consultados trabalhos de revisão bibliográfica de Anjomshoe et al. (2019) e Iqbal et al. (2016), bem como, autores referenciados sobre este tema, Bordini et al. (2007), Muller (1998) e Wooldridge e Jennings (1995) entre outros estudos, tendo como objetivo entender a aplicação prática de agentes inteligentes.

3.2.1 Identificação dos artefatos e configuração das classes de problemas

O presente estudo compreende os artefatos selecionados procurando fazer a junção do modelo de predição de insolvência por meio de um sistema multiagente com capacidade de aprendizado, com o intuito de gerar uma solução satisfatória que possa ser útil no auxílio das micro e pequenas empresas.

Segundo Hevner et al. (2004) e Peffers et al. (2007), um artefato pode ser entendido como um constructo, modelos, métodos e instâncias da solução. Com base nessa definição, Gregor & Hevner (2013) destacam a importância de identificar artefatos como propostas de solução e utilizá-los como ponto de partida na pesquisa do fenômeno estudado.

Existe uma discussão em curso sobre a definição conceitual da classe de problema, como apontado por Lacerda et al. (2013). Não há consenso entre os autores Gregor e Hevner (2013), Hevner et al. (2010) e Peffers et al. (2021) nesse aspecto. Diante desse debate, adotaremos a definição proposta por Dresch et al. (2015), que descreve a classe de problema como a organização de um conjunto de problemas práticos ou teóricos que contenham artefatos úteis para ação nas organizações.

Com base nessas considerações, este estudo procurou identificar, com base na literatura, os artefatos previamente construídos para abordar o problema de insolvência nas micro e pequenas empresas, mas não limitando-se a eles, e classificá-los em diferentes categorias de problemas. No contexto brasileiro, destaca-se o modelo proposto por Lemos e Oliveira (2012), no qual os autores utilizam a análise discriminante como método para gerar o artefato. Esse modelo é baseado na coleta de dados financeiros e na extração de indicadores financeiros dos demonstrativos contábeis das empresas. No entanto, durante a pesquisa, não foram encontradas evidências de artefatos específicos relacionados ao aprendizado de máquina aplicado às MPEs no Brasil.

No contexto internacional, destaca-se o estudo de Crosato et al. (2021), para prever o risco de *default* de pequenos negócios na Espanha, onde são gerados dois artefatos, sendo um modelo de regressão logística e um modelo de análise discriminante. Os artefatos consomem duas fontes de dados, sendo a primeira via balanço das empresas (*offline*) e a segunda via mecanismo de coleta de dados online (*web scraping*) nos sites das empresas. Pode-se citar ainda o estudo de Tobback et al. (2017), que investigou a predição de insolvência em pequenas e médias empresas na Bélgica. O estudo gerou um modelo que usa a técnica de aprendizagem de máquina (*ensemble*), que é uma técnica que combina o resultado de múltiplos modelos em busca de produzir um melhor modelo preditivo. Para tanto, o estudo utilizou dados não somente de origem financeira, mas também informações sobre diretores e gerentes das empresas. A tabela 14 demonstra alguns artefatos gerados para prever a insolvência nas empresas e os atribui a uma classe de problema.

Tabela 14: Artefatos selecionados para previsão de insolvência das MPEs

Artefato	Técnica	Classe do Problema	Autor
Modelo de previsão	Análise discriminante	Análise de problemas e apoio a tomada de decisão	Lemos & Oliveira, (2012)

Modelo de previsão	Regressão Logística e Análise discriminante	Análise de problemas e apoio a tomada de decisão	Crosato et al. (2021)
Modelo de previsão	Ensemble	Análise de problemas e apoio a tomada de decisão	Tobback et al. (2017)

Procurou-se identificar artefatos acerca de agentes inteligentes, inicialmente buscou-se por artefatos dentro das áreas de administração, contabilidade, finanças e contabilidade, posteriormente, observou artefatos no campo da ciência da computação e sistemas de informação. Nesta etapa, foi selecionado o trabalho de Moraes e Nagano (2009) que propuseram um sistema de informação contábil por meio de uma abordagem orientada a objetos com sistema de agentes inteligentes, tendo como artefato gerado um modelo de sistema de informação para auxiliar diferentes tipos de usuários para tomada de decisão. O estudo foi feito de forma conceitual e não há evidências de aplicação prática. Destaca-se que os autores do estudo não são oriundos da área de contabilidade e finanças e que não foram identificados artefatos semelhantes na área de administração, finanças e contabilidade.

No intuito de verificar as bases de modelagem para agentes inteligentes, selecionou-se o artefato gerado por Kuhl et al. (2019), sendo um *framework* conceitual fundamentado nos princípios essenciais de Russell e Norvig (2015, 2022) sobre agentes inteligentes, o qual foi abordado em detalhes no referencial teórico. A tabela 15 explicita os artefatos selecionados.

Tabela 15: Artefatos selecionados de agentes inteligentes

Artefato	Técnica	Classe do Problema	Autor
Sistema de Informação Contábil	Modelo REA (recursos econômicos, eventos econômicos e agentes econômicos) e Modelagem de sistemas	Sistema de Informação	Moraes & Nagano, (2009)
Framework Conceitual de Agentes Inteligentes	Modelagem	Modelagem e Melhoria no processo	Kuhl et al. (2019)

3.2.2 Proposta de artefatos para resolução do problema específico

Com objetivo de desenvolver uma solução satisfatória em um estado funcional, esta pesquisa traz uma proposta com dois artefatos para resolver o problema específico de previsão de insolvência para micro e pequenas empresas, conforme mencionado anteriormente, e relacionados a seguir:

- **Sistema Multiagente (SMA)** – o sistema será composto por três agentes que irão se comunicar entre si, tendo autonomia para alcançar executar suas tarefas e seus objetivos. Os agentes irão observar ambiente da empresa são descritos da seguinte maneira: 1) o agente *Enterprise Diagnostic Agent* - EDA é responsável por fazer o diagnóstico de insolvência da empresa através da leitura dos dados que são compostos por métrica e indicadores financeiros e compartilhar o relatório de avaliação da empresa como os demais agentes; 2) *Propose Procedure Agent* - PPA tem o objetivo de propor tratamentos financeiros para auxiliar

a empresas a resolver o problema de insolvência ou outro problema financeiro; 3) Por fim, o agente *Insoveny Monitoring Agent* - IMA será responsável por fazer o monitoramento de indicadores financeiros conforme configurações feitas de forma personalizada, identificado algum problema será enviado uma altera usuários do sistema para verificar a situação e agir preventivamente.

- **Modelo Preditivo** – tem como objetivo o aprendizado do padrão dos dados das micro e pequenas empresas, fazendo a correta previsão da saúde financeira da empresa, isto é, classificando se a empresa está no estado de solvente ou insolvente. Este artefato será utilizado pelo sistema multiagente expandido com capacidade de atuação para auxílio das empresas.

3.2.3 Projeto e desenvolvimento dos artefatos

Esta subseção visa detalhar as ferramentas, técnicas e metodologias utilizadas na especificação dos artefatos propostos. Para desenvolvimento da solução de sistema multiagente foi utilizada a metodologia conforme figura (21). A primeira etapa da metodologia incluiu o entendimento do problema, conforme os fundamentos teóricos apresentados. Na segunda etapa, foi elaborado o pré-projeto de agentes utilizando o modelo PEAS (*Performance, Environment, Actuators, Sensors*). Na terceira etapa, foi feita a modelagem dos agentes utilizando a metodologia Tropos, sendo composta pelos diagramas de requisitos iniciais, finais, projeto arquitetural, projeto detalhado e diagramas de implementação (UML).




Figura 21: Metodologia utilizada no trabalho para solução de Agentes Inteligentes

No desenvolvimento da solução de modelo preditivo foi utilizado o *checklist* da ciência de dados. De acordo com Géron, (2019), o *checklist* serve como guia para que o cientista de dados obtenha resultados em seus experimentos. Na segunda etapa foi utilizado o processo de criação e seleção do modelo preditivo conforme figura (22).




Figura 22: Processo de Criação e Seleção do Modelo Preditivo

Nota. Adaptado de Marland (2015).

Para a validação dos artefatos foi utilizada a abordagem experimental, onde foi testado os componentes dos artefatos de modo individual utilizando-se dados reais. Nesse sentido o sistema multiagente foi validado por meio de dois experimentos, sendo o experimento 1 para validação da efetividade e do agente EDA, e o experimento 2, para validação dos agentes PPA e IMA. Já para validação do artefato de modelo preditivo foi feita por meio de três experimentos, sendo que cada experimento tem objetivo de trabalhar os dados e apresentá-lo para um ou mais algoritmo de aprendizado de máquina. Destaca-se que para seleção do melhor modelo utilizou a técnica de validação cruzada no experimento 3.

Após a solução gerada pelos artefatos atingir seu estado funcional, foi projetado um instrumento de validação que contém todas as etapas de execução da solução pelo público-alvo da pesquisa, a técnica utilizada foi a Teste (*white box*), conforme tabela 16, que demonstra as técnicas de validação utilizadas. As seções subsequentes abordam o projeto do sistema multiagente e do modelo preditivo por meio de técnicas de aprendizado de máquina de acordo com seu respectivo detalhamento.

Tabela 16: Métodos e técnicas para avaliação de artefatos

Forma de Avaliação	Métodos e técnicas propostas
Experimental	Experimento controlado: estudar o artefato em um ambiente controlado para verificar suas qualidades (por exemplo, usabilidade, interpretabilidade e precisão). Simulação: executar o artefato com dados artificiais
Teste	Teste funcional (<i>black box</i>): executar as interfaces do artefato para descobrir possíveis falhas e identificar defeitos. Teste estrutural (<i>white box</i>): realizar testes de cobertura de algumas métricas para implementação do artefato (por exemplo, caminhos para a execução).

Nota. Adaptado de Dresch et al. (2015).

3.2.3.1 Elaboração do Sistema Multiagente

O presente trabalho apresenta uma solução baseada em agentes inteligentes com capacidade de aprendizado de máquina para previsão, tratamento e monitoramento do estado de insolvência das micro e pequenas empresas. A solução foi implementada através de um sistema multiagente (SMA) intitulado *Multiagent System for Predict Insolvency* (MAS4PI). O SMA é composto por três agentes que se comunicam entre si, e também, com um sistema de interface Web chamado *solver.ai*, utilizado para coleta das informações contábil e financeira da empresa e apresentação do diagnóstico de insolvência das MPEs. O objetivo dos agentes é coletar, analisar os dados gerados pelo sistema contábil-financeiro e fornecer informações importantes aos profissionais que auxiliam a empresa na tomada de decisão. O desenvolvimento do MAS4PI foi acompanhado por uma contadora, a qual compartilhou informações sobre histórico de dados das empresas, bem como auxiliou no entendimento e interpretação das contas contábeis. Na etapa de elaboração do conhecimento dos agentes teve a colaboração de um consultor financeiro, o qual trouxe suas contribuições acerca dos objetivos de cada agente. A utilização de um sistema multiagente é justificada devido à complexidade do ambiente das empresas, onde um único agente teria seu desempenho comprometido. Nesse sentido a composição de um sistema multiagente sendo três agentes cooperando entre si faz medida do desempenho do agente PPA (agente que propõe tratamento financeiro) e do agente IMA (agente que monitora o desempenho da empresa) seja maximizada pelo agente EDA (agente que o faz o diagnóstico de insolvência e compartilha o resultado) com demais agentes.

Pré-projeto de Agentes

A proposição do modelo teve seu início mediante a formulação do pré-projeto dos agentes, empregando o paradigma PEAS para a identificação do ambiente de atuação dos agentes, assim como para o delineamento das suas propriedades intrínsecas. Na sequência é apresentado a definição dos agentes do MAS4PI, seguido da especificação PEAS de cada agente.

- ***Enterprise Diagnostic Agent - EDA*** - o agente analisador da empresa tem como principal objetivo coletar dados da empresa sobre sua saúde financeira no banco de dados ou pela via arquivo de rede. O agente deve analisar os dados e fazer um relatório avaliando a situação da empresa em comparação com os dados históricos, caso haja. Essa análise permite que o agente faça as previsões de insolvência da empresa. Este relatório deve ser enviado aos agentes [PPA e IMA].
- ***Propose Procedure Agent - PPA*** - o agente que propõe o procedimento é responsável por analisar o relatório de avaliação gerado pelo EDA e verificar se a empresa necessita de procedimento especial. Esse procedimento contempla a aplicação de métodos para que a empresa deixe o estado de insolvência. O agente pode especificar o tratamento que a empresa deve aplicar por meio dos profissionais responsáveis por administrar ou auxiliar as empresas. Os profissionais podem acatar ou não a sugestão enviada pelo sistema e seguir com a implementação das medidas sugeridas.
- ***Insolvency Monitoring Agent - IMA*** - o agente que realiza o monitoramento também recebe o relatório de diagnóstico da empresa enviado pelo agente EDA. Com base na situação de insolvência da empresa, o agente verifica se está em um intervalo aceitável. Caso não esteja, o agente poderá indicar a intervenção dos profissionais para entender a saúde financeira da empresa. Assim como o PPA, este agente irá enviar alertas ao sistema de diagnóstico de saúde financeira para auxiliar os profissionais, bem como, os tomadores de decisão da empresa.

Importante destacar que os profissionais responsáveis por auxiliar a empresa na tomada de decisão, seja ele o proprietário, contadores e os que atuam na área financeira, terão a responsabilidade de aceitar as indicações e sugestões de procedimentos para recompor a saúde financeira da empresa.

A tabela 17 demonstra a especificação PEAS para o agente responsável pelo diagnóstico de saúde financeira. Observa-se a especificação da medida de desempenho, seu ambiente, atuadores e sensores, assim o agente de forma autônoma procura cumprir o seu objetivo.

Tabela 17: Especificação PEAS - Enterprise Diagnostic Agent - EDA

P (performance)	As previsões da insolvência com base nos dados históricos da empresa requer acurácia de pelo menos 85%.
E (environment)	Apresentação da empresa com características, tais como: parcialmente observável; estocástico; sequencial; estatístico; discreto; multiagente.
A (actuators)	Determinação da situação de insolvência da empresa: coletar e analisar dados (empresa e insolvência), comparar com dados anteriores e prever o estado de insolvência; compartilhar as informações por meio de um relatório de avaliação com os demais agentes [PPA e IMA]
S (sensors)	Base de dados com as informações financeiras-contábeis e/ou diretório de rede compartilhado que possa ser observado pelo agente através de um módulo automatizado de leitura e escrita de dados

Nota. P= medida de desempenho; E= ambiente do agente; A=atuador; S=sensor. Adaptado de Russel & Norvig (2022).

A tabela 18 demonstra a especificação PEAS para o agente PPA responsável por propor um tratamento financeiro com objetivo de resolver eventuais problemas de insolvência. Observa-se a especificação da medida de desempenho, seu ambiente, atuadores e sensores, de forma que o relatório compartilhado pelo agente de diagnóstico é percebido de forma autônoma pelo agente que trabalha para cumprir o seu objetivo.

Tabela 18: Especificação PEAS - Propose Procedure Agent - PPA

P (performance)	Feitas as recomendações de procedimentos especiais para tratar o problema de insolvência que se assemelham às recomendações de um profissional de finanças, administradores ou contadores que auxiliam empresas nessas condições
E (environment)	Apresentação da empresa com características, tais como: parcialmente observável; estocástico; sequencial; estatístico; discreto; multiagente
A (actuators)	Análise do diagnóstico de insolvência; indicação de um novo procedimento para resolver a situação de insolvência
S (sensors)	Diagnostico de avaliação da empresa fornecido pelo agente EDA

Nota. P= medida de desempenho; E= ambiente do agente; A=atuador; S=sensor. Adaptado de Russel & Norvig (2022).

A tabela 19 demonstra a especificação PEAS para o agente IMA responsável pelo monitoramento e envios de alertas. Observa-se a especificação da medida de desempenho, seu ambiente, atuadores e sensores, assim o agente consome o relatório compartilhado pelo agente diagnostico é percebido de forma autônoma pelo agente que trabalha para cumprir o seu objetivo.

Tabela 19: Especificação PEAS - Insolvency Monitoring Agent - IMA

P (performance)	Feito o monitoramento do desempenho da empresa que se assemelha às análises feitas por um profissional de finanças, administradores ou contadores.
E (environment)	Apresentação da empresa com características, tais como: parcialmente observável; estocástico; sequencial; estatístico; discreto; multiagente.
A (actuators)	Análise do diagnóstico de insolvência; indicação do momento para nova coleta de informações e cálculo da próxima previsão.
S (sensors)	Diagnóstico de avaliação da empresa fornecido pelo agente EDA

Nota. P= medida de desempenho; E= ambiente do agente; A=atuador; S=sensor. Adaptado de Russel & Norvig (2022).

O ambiente é definido como parcialmente observável, no contexto competitivo (ambiente externo) onde as empresas se encontram, pois os agentes só podem observar o que foi informado no sistema financeiro/contábil (ambiente interno). É definido como estocástico, pois o próximo estado do ambiente não pode ser completamente determinado pelo estado atual ou pela ação executada do agente. É definido como sequencial, já que a decisão ou ação de um agente pode afetar uma decisão futura. Apesar do ambiente da empresa ser totalmente dinâmico, os dados serão coletados de forma assíncrona da base de dados do sistema quando acessível ou em rede (Intranet) da empresa, via arquivo de dados gerado pela sistema, e dependerá da entrada das informações pelos profissionais da empresa, o que caracteriza a característica estática do ambiente. O ambiente inclui um número finito de valores específicos, como a quantidade de indicadores financeiros/contábeis da empresa, sendo assim dito como discreto. O ambiente é multiagente por que inclui mais de um agente.

4. APRESENTAÇÃO DA PROPOSTA DE SOLUÇÃO

Foi utilizada a metodologia Tropos para detalhamento do SMA, por meio dos diagramas de requisitos iniciais, requisitos finais e do projeto arquitetural, seguindo a referida ordem e contemplando a evolução do processo de modelagem da solução.

4.1 Fases da proposta de solução

4.1.1 Fase de requisitos iniciais

O diagrama de requisitos iniciais apresenta os *stakeholders* do domínio que são definidos como atores: empresa, profissionais de finanças, a interface web Solver.ai, e os agentes. São destacadas as ocorrências das dependências e trocas de recursos entre as entidades. A figura (23) demonstra o fluxo de informações entre os principais elementos sistêmicos para alcançar o resultado, conforme relacionado a seguir:

- **Empresa** - ambiente onde são geradas as informações contábeis financeira, feitas as análises necessárias para tomada de decisão para melhor gestão do negócio, de forma que em caso de degradação, será recomendada uma espécie de tratamento para a situação financeira, ou seja, um conjunto de ações que podem ser executadas no intuito de evitar a insolvência total da empresa.
- **Profissionais** de que auxiliam as empresas – pessoas das áreas de finanças e contabilidade com papel de ajudar a manter a organização das informações financeiras e contábeis e observar indicadores de desempenho da empresa. Onde os profissionais podem fazer o diagnóstico, verificar recomendações de tratamento e ainda monitorar e receber alertas sobre o desempenho da organização.
- **Interface Solver.ai** – responsável por armazenar a informações geradas pela empresa.

- **Agentes** – atuam como um observador externo recebendo percepções de novos registros de dados da empresa e atuam por meio de suas ações para auxiliar a gestão do negócio.




Figura 23: Diagrama para captura de requisitos iniciais

4.1.2 Fase de requisitos finais

Os requisitos finais, conforme figura (24), é possível ver a decomposição dos agentes e seus objetivos internos.

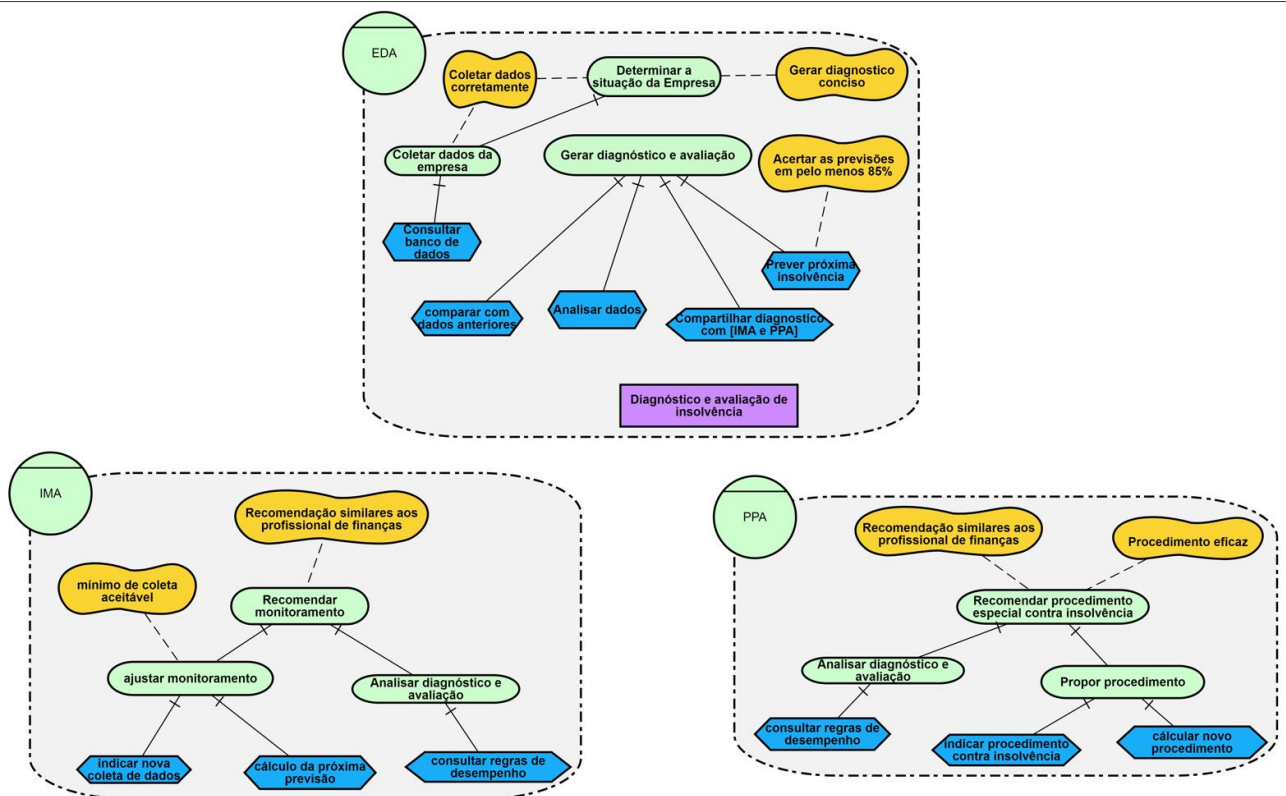


Figura 24: Diagrama de requisitos finais

Nota: EDA = agente de diagnóstico de insolvência; PPA = agente que propõe tratamento financeiro; IMA = agente que faz monitoramento de indicadores e envia alertas

4.1.3 Fase de projeto arquitetural

A visão geral do projeto arquitetural na figura (25) demonstra a relação entre cada componente do sistema e seus atores. Observa-se que a interface web (solver.ai) intermedia a relação entre o módulo de agentes, isto é, a plataforma de diagnóstico de saúde financeira e o sistema financeiro contábil. O sistema de agentes é baseado em aprendizado, onde utilizou-se do subsistema de aprendizado de máquina, para fazer as previsões e compartilhar o resultado com os demais agentes.




Figura 25: Arquitetura do Sistema Multiagente (MAS4PI)

4.1.4 Projeto detalhado

Essa fase tem como objetivo especificar os recursos e interações entre os agentes. Destaca-se a importância de se definir a plataforma de implementação para melhor detalhamento. Os diagramas de sequência e atividades da UML foram utilizados para facilitar o entendimento das ações que devem ser programadas em linguagem computacional.

A figura (26) apresenta as trocas de mensagens que vão ocorrer entre a empresa e profissionais de finanças, os profissionais de finanças e interface solver.ai e a comunicação entre os agentes EDA, PPA e IMA.




Figura 26: Diagrama de sequência referente a fase de projeto detalhado

O diagrama de atividades para cada um dos agentes (EDA, PPA e IMA) foi elaborado, figura (27). O diagrama apresenta o fluxo de atividades que deve ser executado por cada um dos agentes para concluir seus respectivos objetivos.




Figura 27: Diagrama de atividades referente a fase de projeto detalhado.

4.2 Implementação da proposta

Nesta seção, são apresentados os detalhes da implementação do sistema MAS4PI. O sistema é composto por três sistemas integrados, sendo um deles uma interface que serve para a entrada e visualização dos dados pelos profissionais de finanças (solver.ai). O outro é o próprio SMA, que utiliza o *framework* PADE para implementação dos comportamentos dos agentes. O modelo de aprendizagem do agente foi implementado através do projeto de aprendizado de

máquina (MAS4PI-ML) onde foi selecionado o modelo preditivo a ser utilizado conforme detalhado na *seção (5.4)*. Por fim, o raciocínio dos agentes foi desenvolvido na forma de base de regras, espelhando os conhecimentos de um especialista em finanças.

As informações manipuladas pelo MAS4PI serão armazenadas em um banco de dados *NoSQL* por meio do Sistema Gerenciador de Banco de Dados (SGBD) *MongoDB*. O *MongoDB* é orientado a documentos e a estrutura organizacional dos dados gera um documento do tipo JSON (*Javascript Object Notation*) contendo chaves e valores onde os atributos ficam armazenados. A figura (28), demonstra a estrutura de objetos (coleções) no geradas dentro do banco de dados.

	_id	name	cnpj	createdAt	modifiedAt	_v
1	ObjectID("651414c7184620eade...")	"SPA"	"20814176000177"	"27/09/2023 08:39:36.273"	"27/09/2023 08:39:36.273"	0
2	ObjectID("65141561394620eade...")	"TONIS LUCAS"	"26306536000123"	"27/09/2023 08:43:36.273"	"27/09/2023 08:43:36.273"	0
3	ObjectID("65141561394620eade...")	"GUGA FLEURY CONSULTORIA"	"496236500001"	"27/09/2023 08:45:36.273"	"27/09/2023 08:45:36.273"	0
4	ObjectID("651422970675409f6d1...")	"GUGA FLEURY CONSULTORIA"	"496236500001"	"27/09/2023 08:45:36.273"	"27/09/2023 08:45:36.273"	0
5	ObjectID("651b79fc13978ac428...")	"TRX CONSULTORIA"	"456236500001"	"02/10/2023 08:45:36.273"	"02/10/2023 08:45:36.273"	0

Figura 28: Estrutura de documentos gerado no MongoDB

A coleção empresa (*Enterprise*) representa como os dados das empresas são estruturados. A figura (29), demonstra o modelo de dados conceitual o qual cada entidade representará uma coleção na base de dados do MongoDB e seus relacionamentos.




Figura 29: Modelos de dados conceitual para o sistema MAS4PI

4.2.1 A interface solver.ai

O sistema de diagnóstico e monitoramento de insolvência das micro e pequenas empresas denominado (solver.ai) é um sistema de interface web que tem como objetivo receber os dados das empresas. Além disso, os profissionais de finanças, dentre outros, podem fazer a manutenção

desses dados (inserir, atualizar, listar e pesquisar). Entretanto as atividades mais relevantes do sistema são: leitura das métricas ou indicadores econômico-financeiros; demonstrar o diagnóstico de insolvência, permitir a visualização da recomendação de tratamento financeiro; e exibir alertas por meio do monitoramento dos indicadores de performance. Destaca-se que a funcionalidade de recomendação para as empresas caberá aos profissionais de finanças ou tomadores de decisão acatarem ou não tal sugestão.

A interface *solver.ai* foi desenvolvida pelo autor deste trabalho valendo-se de sua experiência na área de desenvolvimento de software. Para desenho de interface utilizou-se a ferramenta *figma* (ferramenta para práticas de design de interface) em conjunto com as boas práticas de experiência de usuário (traduzido do idioma inglês *UX*), que é o processo o oferecer o que usuário quer, sendo necessário entender o que ele precisa, fazendo com que o mesmo se sinta satisfeito e os produtos sejam fáceis de usar (Andrade, 2021). As tecnologias utilizadas foram a linguagem de programação Javascript, mais especificamente os *frameworks* React.js para a camada de apresentação (*front-end*) e Node.js como (*back-end*). A base de dados utilizada é NoSQL MongoDB disponível pela ferramenta Web Atlas. A figura (30) apresenta a tela inicial para acesso a plataforma de diagnóstico de suade financeira.



Figura 30: Tela inicial para acesso a plataforma *solver.ai*

A figura (31), demonstra a interface pelo o qual é feito o diagnóstico da saúde financeira do negócio. A estratégia adotada foi a quebra da execução em passos (*steps*) do diagnóstico financeiro, de modo a facilitar a usabilidade do sistema, relacionados a seguir: 1) Carregamento dos dados, onde pode-se realizar a importação dos dados da empresa por meio de um modelo de planilha de Excel, entretanto, é possível também seguir sem dados, desse modo o sistema irá gerar dados aleatórios previamente configurado para que se possa avançar para passo seguinte; 2) Visualização das métricas e indicadores, uma vez que foi importado o arquivo ou gerado com os dados simulados, para uma simples visualização e conferência, figura (32) ; 3) Avaliação financeira, em que, nessa etapa, os dados são enviados para cadastro no banco de dados, e o agente de diagnóstico EDA é responsável por perceber que há novos dados para serem coletados e pela execução do diagnóstico da saúde financeira para uma ou mais empresas conforme os dados carregados; e, finalizado este processo, serão apresentadas na tela as etapas de execução do processamento do modelo e resultado do diagnóstico de predição, conforme demonstra a figura (33).



Figura 31: Carregamento dos dados na interface solver.ai



Figura 32: Visualização de dados na interface solver.ai



Figura 33: Resultado do Diagnóstico de saúde financeira na interface solver.ai

Finalizadas as etapas descritas anteriormente pode-se visualizar as empresas. A figura (34) demonstra a interface da aplicação solver.ai referente à exibição da lista do histórico das empresas, no qual foi realizado, como exemplo, o diagnóstico de saúde financeira para algumas empresas. A coluna *status* apresenta o resultado do diagnóstico feito pelo agente EDA; a coluna *tratamento* refere-se à execução do agente PPA, o qual propõe algum tipo de tratamento para empresa e por fim, a coluna *alerta* diz respeito à execução do agente IMA, o qual apresenta algum tipo de notificação aos profissionais de finanças ou tomadores de decisão do negócio. Tanto o agente PPA quanto o agente IMA utilizam as informações compartilhadas pelo agente diagnostico para propor o tratamento financeiro ou enviar algum alerta com base no monitoramento.




Figura 34: Histórico de Empresas com diagnóstico na interface solver.ai

Observa-se que a coluna tratamento pode ser expandida clicando-se em seu nome para exibição dos seus detalhes, sendo que o mesmo pode ser feito para coluna alerta. A figura (35) demonstra a exibição das informações referente ao tratamento financeiro proposto, sendo a redução das despesas operacionais. Já a figura (36) exibe detalhes do alerta emitido para empresa, sendo um alerta critico de acordo com monitoramento do índice de liquidez o qual apresentou uma queda no seu desempenho.




Figura 35: Detalhes do tratamento financeiro recomendado.




Figura 36: Detalhes do envio de alerta

4.2.2 O Sistema multiagente MAS4PI

O projeto MAS4PI foi desenvolvido utilizando o *framework* PADE facilitando a comunicação entre os agentes por meio do protocolo FIPA. Além disso, utilizou-se as bibliotecas da linguagem computacional Python para implementação de requisitos funcionais do sistema. O submódulo MAS4PI-ML foi implementado utilizando as bibliotecas (*scikit-learn*) da linguagem

programação Python que dão suporte aos projetos de aprendizado máquina. O processo de criação e seleção do modelo foi descrito nas *seções (4.2.3 e 5.4)* respectivamente. Após escolha do modelo, o processo foi automatizado para leitura e recebimento dos novos dados, bem como, o processo de geração da predição de insolvência das empresas via agente EDA. Os resultados são compartilhados com os agentes PPA e IMA para propor algum tratamento, fazer o monitoramento de indicadores de desempenho e enviar alertas à interface solver.ai.

A figura (37) demonstra o conhecimento exercido, bem como a percepção recebida de um novo diagnóstico pelo agente PPA. Observam-se as regras internas, baseadas no conhecimento de um especialista em finanças, para tomar ação de recomendar algum tipo de tratamento. Neste trabalho, foi proposto um tratamento padrão para empresas diagnosticadas no estado de insolvência e, nesse sentido, é recomendado a gestão de fluxo de caixa como ponto de partida para que a empresa trabalhe para geração de caixa futuro, com o objetivo de manter capital de giro suficiente para cobrir suas despesas operacionais. Em caso da empresa estar no estado de solvente, esse tratamento pode ou não ser indicado. Pontua-se que essa abordagem foi selecionada devido ao cenário das micro e pequenas empresas não realizarem a manutenção de caixa conforme observação salientada pelos consultores financeiros do Sebrae.




Figura 37: Representação do conhecimento do agente PPA.

A figura (38) demonstra o conhecimento exercido, bem como a percepção recebida de um novo diagnóstico pelo agente IMA, de forma que o agente observa suas regras internas baseadas no conhecimento de um especialista de finanças e toma uma ação de enviar uma notificação de alerta sobre desempenho da empresa. Embora exista diversas métricas que possam ser monitoradas pelo agente IMA, para este experimento e teste da funcionalidade foram implementados os indicadores referentes à estrutura de liquidez, ou seja, o agente estará observando a evolução e/ou degradação do indicador de liquidez corrente, seca e imediata. Para a estrutura de capital monitora-se o indicador do lucro operacional. Referente aos indicadores essenciais de atividades, o monitoramento feito para os indicadores de prazo médio de recebimento – PMR; prazo médio de estocagem – PME e prazo médio de pagamento - PMP. No que tange a indicadores de rentabilidade, a receita líquida e lucro líquido são observados pelo sistema com o objetivo de enviar notificações de alertas. O monitoramento dos demais indicadores podem ser implementados

futuramente no núcleo do agente e podem ser personalizados de acordo com necessidade de monitoramento de cada empresa.




Figura 38: Representação do conhecimento do agente IMA.

4.2.3 Elaboração do modelo preditivo

O presente trabalho apresenta uma solução baseada em aprendizado de máquina para criação e seleção de um modelo preditivo capaz de prever se a empresa é classificada como solvente ou insolvente no contexto das micro e pequenas empresas. A solução foi implementada através de um submódulo do sistema SMA intitulado *Multiagent System for Predict Insolvency - Machine Learning* (MAS4PI-ML).

Neste estudo experimenta-se a abordagem de utilização de diversos algoritmos de classificação, sendo eles: Floresta Aleatória, Árvore de Decisão e Regressão Logística. Justifica-se uso árvores de decisão e floresta aleatórias pela facilidade dos algoritmos em lidar com dados categóricos e numéricos, além do fato de fornecer uma boa interpretação dos resultados (Russell & Norvig, 2022; Faceli et al. 2011). O uso do algoritmo de regressão logística é justificado pelo fato de ser comumente utilizado no problema predição de insolvência de acordo com Gonçalves et al. (2013),

Para este subprojeto de pesquisa o problema de negócio é traduzido como: o modelo deve aprender com base no conjunto de dados selecionado a ser capaz de prever qual classificação a empresa está se está, isto é, solvente ou insolvente compreendendo todas as suas métricas e/ou indicadores. O processo de extração, transformação e carregamento (ETL) foi automatizado via SMA, o qual monitora/percebe as informações recebidas na base de dados e consome fazendo as devidas transformações gerando o conjunto de dados. Os dados originais contêm métricas e indicadores econômico-financeiros:

- **Ano** - refere-se ao ano em que as informações foram coletadas e que conduz ao pagamento de menos impostos
- **Enquadramento CNAE** - feito conforme a proposição feita pelo governo. Observa-se que as empresas foram enquadradas como ME devido ao seu código

de atividade não ser suportado pelo MEI e o governo utiliza informações como faturamento, porém observa qual atividade será exercida de forma a enquadrar a empresa no momento de sua criação.

- **Setor** – refere-se ao setor de atuação das empresas. Observa-se que nos dados coletados as empresas atuam nos setores de comércio e serviço.
- **Enquadramento Sebrae** - representa uma classificação estipulada pelo Sebrae conforme a faixa de faturamento. Observa-se que as empresas em alguns anos poderiam ter sido enquadradas como MEI de comércio e serviços.
- **Regime de Tributação** - conhecido como regime fiscal, é um conjunto de regras e diretrizes que estabelecem como a empresa deve calcular, declarar e pagar seus impostos ao governo. A escolha do regime tributário é uma decisão fundamental para as micro e pequenas empresas, pois afeta diretamente a carga tributária, os procedimentos fiscais e as obrigações contábeis da empresa. No Brasil, os principais regimes tributários são: Simples Nacional, Lucro Real e Lucro Presumido.
- **Segmento de Atuação** - refere-se à área de negócio ou setor da economia em que uma empresa opera.
- **Ativo** - é uma conta do balanço patrimonial que representa o conjunto de bens e direitos que a empresa possui.
- **Ativo circulante** - engloba os ativos que podem ser convertidos em dinheiro ou consumidos no decorrer de um ano.
- **Ativo não circulante** - compreende os ativos que não são esperados para serem convertidos em dinheiro a curto prazo, como propriedades, investimentos de longo prazo e ativos intangíveis.
- **Total Caixa** - soma em dinheiro disponível no caixa da empresa, incluindo tanto o caixa físico quanto o disponível em contas bancárias.
- **Passivo** - representa as obrigações e dívidas das empresas, que incluem empréstimos, contas a pagar e outros compromissos financeiros.
- **Passivo Circulante** - inclui as obrigações de curto prazo que devem ser liquidadas no prazo de um ano, como contas a pagar e empréstimos de curto prazo.
- **Receita Faturada** - total de renda gerada pela empresa a partir de vendas de seus produtos ou serviços, antes de quaisquer deduções.
- **Estoque** - produtos e mercadorias mantidos pela empresa para venda ou uso posterior na produção.
- **Contas a pagar anual** - representa o total das obrigações a serem pagas pela empresa ao longo de um ano.
- **Contas a receber** - são valores que os clientes devem à empresa por produtos e serviços já entregues, mas que ainda não foram pagos.
- **Liquidez Corrente** - métrica que compara os ativos circulantes como passivo circulante, avaliando a capacidade da empresa de cumprir suas obrigações de curto prazo.
- **Liquidez Seca** - métrica similar a liquidez corrente, mas exclui o estoque dos ativos circulantes, fornecendo uma visão mais conservadora da capacidade de pagamento no curto prazo.
- **Lucro Líquido** - representa o lucro total da empresa após a dedução de todas as despesas, incluindo custos operacionais, juros e impostos.
- **Total de vendas** - refere-se à receita total gerada pelas vendas de produtos e serviços durante um período específico.
- **Despesas operacionais** - são custos relacionados à operação normal do negócio, como salários, aluguel, utilitários e despesas gerais.

- **Caixa operacional** - refere-se ao resultado do fluxo de caixa das operações de negócios da empresa, indicando a entrada e saída de dinheiro relacionadas às atividades operacionais.
- **Capacidade de Geração de Caixa** - refere-se à capacidade da empresa de gerar fluxo de caixa positivo a partir de suas atividades operacionais.
- **Custo de Vendas** - representa os custos diretos associados à produção ou aquisição de produtos vendidos pela empresa.
- **Imposto sobre as vendas** - tributo aplicado sobre o valor das vendas e devido à autoridade tributária. A empresa coleta o imposto sobre seus clientes e posteriormente repassa ao governo.
- **Classificação da Empresa** - indica se empresa pertence à classe solvente, isto é, saudável financeiramente ou, insolvente, aquela com dificuldades financeiras.
- **Média de Faturamento Mensal** - refere-se à média do valor faturado calculado pelo valor total de faturamento dividido pelo número total de meses do ano.
- **Média de Lucro Mensal** - representa a média de lucro obtido pela empresa, sendo calculado pelo valor total de lucro dividido pelo número de meses do ano.

Após o processo de ETL é gerado o *dataset*, o qual será apresentado ao modelo para ser treinado. Nesse experimento, foi selecionado um conjunto de vinte e nove (29) variáveis, que são chamadas de preditoras (variáveis dependentes do modelo), consistindo algumas delas em indicadores de solvência da empresa e outras em informações gerais, bem como indicadores econômico-financeiros, tabela 20. A variável alvo foi definida pela variável classificação (variável independente do modelo), tabela 21, isto é, corresponde à situação que queremos prever, ou seja, a probabilidade de uma empresa estar solvente ou insolvente. Neste estudo usa-se conceito de variável *dummy*, que é a transformação de variável texto para variável numérica. Assim, a classificação pode conter dois valores, sendo o valor 0 para classificação insolvente e 1 para classificação solvente.

Tabela 20: Variáveis Dependentes do Conjunto de dados

Variáveis Preditoras	Dataset	Nome
1		Ano
2		Enquadramento Sebrae
3		Enquadramento CNAE
4		Setor
5		Regime tributário
6		Segmento de atuação
7		Ativo
8		Ativo circulante
9		Ativo não circulante
10		Total de caixa
11		Passivo
12		Passivo Circulante
13		Receita Faturada
14		Estoque
15		Contas a Pagar Anual
16		Contas a receber
17		Liquidez corrente
18		Liquidez Seca
19		Liquidez imediata
20		Lucro Líquido
21		Total de Vendas
22		Despesas operacionais
23		Caixa operacional
24		Capacidade de Geração de Caixa
25		Impostos sobre as vendas
26		Média de Faturamento Mensal

27
28

Média de Lucro Mensal
Faixa de Faturamento

Tabela 21: Variável Independente do Conjunto de dados

Variável Alvo	Target	Dataset	Nome
		1	Classificação

4.2.4. Avaliação dos Artefatos

Para que a pesquisa demonstre uma certo grau de confiabilidade é necessário que os artefatos produzidos sejam validados no ambiente externo para qual o artefato foi projetado. Há alguns tipos de validações, sendo: observacional, analítica, experimental, teste e descritiva (Dresch et al., 2015; Gregor & Hevner, 2013).

5. APRESENTAÇÃO E ANALISE DOS RESULTADOS

5.1 Avaliação dos artefatos por experimentos

Para que a pesquisa demonstre uma certo grau de confiabilidade é necessário que os artefatos produzidos sejam validados no ambiente externo para qual o artefato foi projetado. Há alguns tipos de validações, sendo: observacional, analítica, experimental, teste e descritiva (Dresch et al., 2015; Gregor & Hevner, 2013).

Este estudo utilizou a abordagem experimental para validação dos artefatos produzidos, isto é, estudo do artefato dentro do ambiente controlado. Os artefatos foram validados por meio da simulação em um ambiente virtual, com dados gerados que representam cenários da realidade das micro e pequenas empresas.

5.1.1 Validação do artefato – sistema multiagente

5.1.2 Experimento 1

O experimento 1 tem como objetivo verificar se o agente EDA consegue de forma autônoma e flexível fazer a previsão de insolvência por meio de aprendizado de máquina. A figura (39) demonstra o fluxo de executado pelo agente para alcançar o seu objetivo.




Figura 39: Fluxo de execução do agente EDA para gerar diagnóstico de insolvência

Observa-se na figura (39) que para cumprir o seu objetivo o agente deve carregar o modelo previamente treinado em memória, fazer ingestão dos novos dados e apresentá-lo ao modelo preditivo e gerar o relatório de diagnóstico de insolvência para que os demais agentes possam utilizar como base em processos subsequentes. O algoritmo selecionado para validação é o classificador de floresta aleatória (*Random Forest*) que obteve uma melhor performance de execução na etapa de treinamento e validação dos modelos, tais como, Arvore de decisão e Regressão Logística. Uma vez de posse dos dados do *dataset* final, (passo 4) e carregado o modelo preditivo (passo 5), uma série de procedimentos é executada (passo 6), conduzindo à sua finalização (passo 7). A figura (40) demonstra a exibição de cada passo executado pelo agente EDA durante o processo de geração do diagnóstico de insolvência para uma ou mais empresas.

Iniciando o processo de Previsão de Insolvência					
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.01	→	Carregando Modelo Preditivo Floresta Aleatória	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.03	→	Importando os novos dados para execução do modelo	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.04	→	Removendo os valores ausentes	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.05	→	Criando faixa de faturamento para enquadrar a empresa	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.06	→	Selecionando as variáveis preditoras do dataset original	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.07	→	Selecionando as variáveis categoricas do dataset	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.08	→	Aplica OneHotEncoder nas variáveis categoricas	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.09	→	Normaliza as variáveis preditoras	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.10	→	Gera as Previsões de Insolvência das empresa(s)	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.11	→	Adiciona as novas colunas no dataset	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.12	→	Cria o relatório com o diagnostico de insolvência	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.13	→	Exibe o Relatório de Previsões de Insolvência	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.14	→	['Empresa', 'Ano', 'Previsão', 'Probabilidade']	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.15	→	('AXZ', '2021', 'INSOLVENTE', 0.36%)	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.16	→	(ATG, '2022', 'SOLVENTE', 0.58%)	✓
[EDAAgent]	[RandomForestClassifier]	03/10/2023 23:33:32.02	→	Compartilha o Relatório como PPAAegnt / IMAAgent	✓
Finalizando o processo de Previsão de Insolvência					

Figura 40: Processo de execução do Agente EDA e compartilhamento do relatório de insolvência.

Observa-se que o agente EDA é capaz de fazer a leitura de novos dados de forma reativa, fazendo o seu tratamento de forma autônoma e cumprir o seu objetivo de gerar o relatório de diagnóstico de insolvência e por fim compartilhar os dados com os demais agentes. Os dados das empresas submetidas ao processo de validação são dados de empresas reais e, por questões de confiabilidade das informações, os nomes foram trocados para ilustrar todo o processo. Nota-se que a empresa AXZ foi diagnosticada como insolvente no ano de 2021, isto é, a empresa encontrava-se com dificuldades financeiras, dada uma probabilidade de 36% de acordo com classificador. Já, a empresa ATG, referente aos dados do ano de 2022, foi diagnosticada como solvente, isto é, a empresa não apresentava dificuldades financeiras neste ano de fechamento. Para confrontar o resultado apresentado pelo agente EDA por meio do modelo preditivo, foi feita uma análise dos dados do *dataset*, bem como os dados dos demonstrativos, observando os principais indicadores utilizados pelo consultor financeiro do Sebrae, a fim de validar a assertividade do diagnóstico. Analisando os indicadores de liquidez corrente e liquidez seca para a empresa AXZ para o ano de 2021, evidencia-se que seu valor é 0,6 e 0,2 respectivamente apontando para um problema de liquidez uma vez que os índices estão abaixo de 1. Desta forma, o diagnóstico feito pela planilha disponibilizada pelo consultor Sebrae (Anexo – Indicadores de liquidez) aponta que a empresa AXZ está em estado de insolvência, salientando que o agente acertou em seu diagnóstico. Para a empresa ATG observando seus indicadores de liquidez corrente e seca, nota-se que a empresa possui uma liquidez corrente 1,2, isto é, acima de 1 apontando uma boa capacidade financeira, já o indicador de liquidez seca está em 0,2 indicando que a empresa não possui ativos líquidos suficientes para cobrir todas as suas obrigações de curto prazo, mesmo após a venda de

estoque o que pode ser sinal de alerta pois a empresa pode vir a enfrentar dificuldades em honrar suas obrigações imediata. O resultado da análise dos dados da empresa demonstra que, mesmo com liquidez seca abaixo de 1, a empresa ainda é saudável pelo índice de liquidez corrente. Portanto, o resultado apresentado pelo agente está correto em classificar a empresa no estado de solvente para o ano de 2022.

Concluindo a análise do experimento 1, pode-se dizer que o agente EDA consegue prever resultados semelhantes aos especialistas em finanças ao diagnosticar a situação financeira das MPEs. O modelo preditivo possui uma acurácia de 96% de acordo com processo de validação cruzada que selecionou o melhor modelo a ser utilizado em produção para o experimento. Adicionalmente, o agente consegue compartilhar o relatório de insolvência com os demais agentes (PPA e IMA) para recomendar ações de tratamento, monitoramento e envio de alertas.

5.1.3 Experimento 2

O objetivo do experimento 2 é comparar as recomendações de tratamento e monitoramento feitas pelo MAS4PI com as dos profissionais de finanças. A sistematização do experimento contém as mesmas etapas do experimento 1. As demais etapas são apresentadas na sequência:

- O modelo preditivo - o conhecimento do agente utilizado para fazer as recomendações foi baseado no aprendizado indutivo, enquanto o consultor financeiro do Sebrae focado em MPEs utilizou seu conhecimento, baseado em estudos realizados e experiência de consultorias já realizadas para as micro e pequenas empresas.
- Conjunto de dados (dataset) - foram coletados novos dados de empresas sendo duas (2) empresas para serem analisadas tanto pelos agentes como pelo profissional de finanças.
- Métrica de validação - comparação entre as respostas do MAS4PI em relação a dos profissionais de finanças.

A tabela 22, demonstra as recomendações de tratamento feitas pelo sistema MAS4PI versus um especialista em finanças. O tratamento foi indicado pelo agente PPA conforme sua base de conhecimento implementada. Em situações que os dados não são precisos, o agente não é capaz de indicar um tratamento ou, ainda assim, indicar o tratamento inadequado ao cenário. Destaca-se que não há evidência na literatura de um agrupamento de tratamentos específicos para micro e pequenas empresas. Os tratamentos recomendados pelo agente foram agrupados com base em conversas feitas com o consultor financeiro do Sebrae com o objetivo de materializar sua experiência e conhecimento prático dos pequenos negócios.

Tabela 22: Tratamentos Recomendados

Tipo de Tratamento	Descrição	MAS4PI- PPA
Redução de despesas operacionais	As despesas operacionais são aquelas ligadas diretamente aos gastos essenciais do negócio, comumente ligadas ao bom funcionamento da empresa	Recomendado
Gestão de Fluxo de Caixa	O objetivo desse procedimento é apurar o saldo disponível no momento e projetar o futuro, para que exista sempre capital de giro acessível tanto para o custeio da operação da empresa	Recomendado
Reestruturação Financeira	Renegociação de dívidas com credores para estender prazos de pagamento ou reduzir taxas de juros. Consolidação de dívidas para simplificar pagamentos. Exploração de opções de refinanciamento.	Recomendado

Redução de Impostos	Existem medidas legais que podem ser adotadas para reduzir o impacto da carga tributária sobre uma atividade	Recomendado
---------------------	--	-------------

A tabela (23), demonstra o monitoramento de indicadores feitos pelo agente IMA, e seu envio de alerta. Os indicadores são observados mediante uma configuração por empresa, o que garante que o agente irá levar em consideração o seu contexto, pois cada empresa é administrada de forma diferente. Os indicadores são avaliados pelo especialista que, na prática, sinaliza ou alerta o empresário sobre algum problema mediante sua análise. Nesse sentido, ao incorporar o raciocínio exercido pelo especialista e observados os dados das empresas selecionadas, o agente conseguiu através de seu monitoramento enviar alertas específicos antecipando ou mesmo expondo eventuais problemas na empresa.

Tabela 23: Monitoramento de indicadores para envio de alertas

Monitoramento de Desempenho	Descrição	MAS4PI- IMA
Indicadores de Liquidez	Monitoramento dos índices de liquidez • Corrente, • Seca • Imediata	Monitora/Envio de Alerta
Atividades	Monitoramento de atividades essenciais: • Prazo médio de Recebimento – PMR; • Prazo médio de Estocagem – PME; • Prazo médio de Pagamento – PMP	Monitora/Envio de Alerta
Estrutura de Capital	Indicador de desempenho: • Lucro operacional	Monitora/Envio de Alerta
Rentabilidade	Indicadores de desempenho da rentabilidade: • Lucro líquido • Receita líquida	Monitora/Envio de Alerta

Os dados das empresas selecionadas, e preenchidos conforme o apontamento feito por uma contadora, foram tabulados contendo as recomendações do especialista em finanças focado em MPEs e as recomendações geradas pelo MAS4PI, conforme demonstra a tabela 24 e descrito na sequência:

- As recomendações de tratamento do MAS4PI foram analisadas de acordo com as recomendações do especialista em finanças, as quais coincidiram em 85% dos casos.
- Em relação às recomendações de monitoramento e envio de alerta, o MAS4PI coincidiu com as recomendações dos especialistas em finanças em 75%.

Tabela 24: Comparação entre especialista em finanças e o MAS4PI

Comparação	Recomendação de Tratamento	Monitoramento e envio de Alerta
Especialista em Finanças vs MAS4PI	85%	75%

5.2 Validação do Artefato – Modelo Preditivo

Esta seção tem como objetivo demonstrar o processo de validação realizado. Para isso, foram efetuou-se três experimentos. No experimento 1, utilizou-se o algoritmo de Arvore de Decisão. No experimento 2, treinou-se o classificador Floresta Aleatória. No experimento 3,

utilizaram-se três algoritmos, sendo os dois algoritmos citados anteriormente e o classificador de Regressão Logística. Por fim, foi feita a seleção do modelo que obteve o melhor desempenho por meio da técnica de validação cruzada.

5.2.1 Experimento 1

Após coleta, processamento e preparação dos dados, o experimento 1 foi conduzido com o objetivo de verificar a capacidade do algoritmo de Arvore de Decisão de se ajustar aos dados, para tanto, foram seguidas as etapas sugeridas para um projeto de ciência de dados conforme o processo de criação/seleção do modelo apresentado na *seção (5.4)* e as demais etapas são descritas na sequência:

- Separação dos dados em um conjunto de dados de treino, teste e validação usa-se uma amostra estratificada para se obter uma amostra dos dados que melhor representam a realidade para ser usada no momento de validação do modelo. É necessário realizar a separação dos dados de testes e somente apresentá-lo ao modelo no final do processo, de modo a verificar se o modelo está generalizando o padrão dos dados.
- Apresentação dos dados de treino para o modelo preditivo (Arvore de Decisão).
- Validação do modelo através dos dados de testes.
- Medir o desempenho do modelo conforme as métricas estabelecidas.

• Separação dos Dados

O conjunto de dados é frequentemente dividido em 70% de dados para treino do modelo preditivo e 30% dos dados são separados para etapa de validação, isto é, os dados de validação não são apresentados para o modelo com objetivo de se verificar se o modelo está realmente aprendendo o padrão dos dados. Para treinamento do modelo preditivo é necessário fazer a separação em dados de treino, teste e validação, seguindo a seguintes etapas:

- Gerar a variável X (variáveis preditoras), que são as métricas e indicadores das empresas.
- Gerar a variável Y (variável alvo) com os rótulos de cada empresa em um ano específico.
- Gerar o conjunto de dados de validação do modelo.

• Preparação dos dados e treinamento do Modelo Preditivo

Os modelos preditivos de aprendizado de máquina trabalham de melhor forma com os dados numéricos, nesse sentido é necessário fazer a transformação da variável Y (*target*) para número, uma vez que seu conteúdo é formato de texto. Utilizamos a técnica conhecida como *One Hot Encoder* que faz a transformação da variável e valores numéricos, no caso da variável Y temos uma classe binária, isto é, a empresa pode estar classificada em solvente ou insolvente. Ainda o modelo preditivo trabalha de melhor forma com dados numéricos na mesma escala, nesse sentido, é necessário padronizar os dados normalizando-os. Utilizamos a técnica de normalização padrão (do inglês *Standard Scaler*) que faz a padronização dos dados (variáveis preditoras) para mesma escala. Utiliza-se a técnica de *pipeline* (fluxo de transformações) de dados para transformar as variáveis texto e variáveis numéricas antes de treinar o modelo. Após feitas essas transformações, aplicamos o algoritmo de aprendizado de máquina, o classificador Arvore de Decisão (*Decision Trees*), sendo que neste momento não foram indicados para o fluxo de transformação de dados quais seriam as variáveis categóricas e quais seriam as variáveis numéricas, deixando a cargo do *pipeline* decidir e aplicar as transformações.

• Validação do Experimento 1

Para o processo de validação foi utilizado o conjunto de dados de teste separado previamente na etapa de separação dos dados para o modelo preditivo. Ao fazer a predição com os dados de validação, o classificador Floresta Aleatória obteve uma pontuação de 66.66% de acerto para uma acurácia de 78.5%.

Conclui-se que, no experimento 1, o algoritmo Arvore de Decisão está sub ajustando aos dados (em inglês *underfitting*) das micros e pequenas empresas, sendo necessário trabalhar melhor os dados, para que o algoritmo possa se ajustar melhor ao conjunto de treinamento.

5.2.2 Experimento 2

O segundo experimento foi conduzido com o objetivo de trabalhar melhor os dados para apresentação ao modelo de aprendizado de máquina, em que foi utilizada a etapa de separação dos dados do experimento 1, sendo que as demais etapas seguem descritas:

- Separação dos dados em conjuntos de treino, teste e validação.
- Separação de todas as variáveis categóricas do conjunto de dados.
- Separação de todas as variáveis numéricas do conjunto de dados.
- Aplicação da técnica de imputação de valores numéricos quando há valores ausentes utilizando a média dos dados.
- Aplicação da técnica de imputação de valores categóricos quando há valores ausentes pela constante de valor dos dados.
- Aplicação da técnica de escala mínimo e máxima escala (*Min and Maximum Scaler*) para padronização dos dados numéricos.
- Aplicação de técnica de *One Hot Encoder* para transformação das variáveis categóricas em valores numéricos.
- Criação de *pipeline* de transformação de dados especificando as variáveis categóricas e numéricas.

- **Preparação dos dados para o Modelo Preditivo**

Utilizou-se a técnica de *pipeline* de dados para transformar as variáveis texto e variáveis numéricas antes de treinar o modelo conforme figura (41). Após feitas essas transformações, o algoritmo de aprendizado de máquina Floresta Aleatória foi aplicado e, neste momento, foram indicadas as variáveis categóricas e numéricas para o fluxo de transformação de dados.




Figura 41: Configuração para transformação de dados modelo Floresta Aleatória

- **Validação do Experimento 2**

Para o processo de validação do experimento 2 foi utilizado o conjunto de dados separado previamente na etapa de separação dos dados de treino e teste para o modelo preditivo. Ao fazer a predição com os dados de validação o algoritmo Árvore de decisão após todas as transformações nos dados pontuação obtida foi de 100% de acerto com uma acurácia de 87.5%. As variáveis mais

importantes para o modelo são liquidez corrente (16%), total de caixa (15%) e liquidez seca (14%). O resultado confirma que essas variáveis são frequentemente utilizadas na prática, conforme observação do especialista em finanças das MPEs. Observou-se que algumas variáveis, tais como; ano, faixa do valor de receita faturada, passivo circulante e custos de vendas, não são relevantes para o modelo preditivo e podem ser eliminadas do conjunto de dados.

Conclui-se, com o experimento 2, que o algoritmo Árvore de Decisão está se sobre ajustando (em inglês *Overfitting*) aos dados referentes às micros e pequenas empresas, fazendo-se necessário trabalhar melhor os dados ou mesmo fazer o balanceamento das classes (solvente e insolvente). Adicionalmente, outros algoritmos de aprendizado de máquina, tais como, o Regressão Logística dentre outros, poderiam ser utilizados para verificar qual algoritmo se ajustar melhor ao conjunto de dados, e assim, se conduzir para a devida generalização.

5.2.3 Experimento 3

O experimento 3 foi conduzido com o objetivo de trabalhar melhor os dados e apresentá-los a diversos algoritmos de aprendizado de máquina. As etapas executadas estão descritas na sequência:

- Preparação dos dados para o modelo preditivo por meio do pipeline de transformação de dados criado nos experimentos anteriores para tratamento das variáveis categóricas, numéricas, tratamento dos valores ausentes, transformação de variáveis texto em valores numéricos e, por fim, padronização de dados na mesma escala.
 - Treinamento dos modelos (Árvore de Decisão, Floresta Aleatória e Regressão Logística).
 - Balanceamento do conjunto de dados.
 - Validação das métricas de desempenho dos modelos.
- **Preparação dos dados para o Modelo Preditivo**
Neste experimento, novamente foi utilizada a técnica de *pipeline* de dados para a preparação dos dados, sendo que a figura (42) demonstra cada algoritmo e suas configurações.




Figura 42: Configuração para transformação de dados para os modelos preditivos

- **Balanceamento dos dados**

A figura (43) demonstra que o conjunto de dados está desbalanceado, isto é, observa-se que a variável alvo (classificação) que atribui a empresa em solvente ou insolvente está desproporcional com menor quantidade para classificação insolvente. Para resolver o problema de desbalanceamento foi utilizada a técnica de balanceamento de dados conhecida como "*Oversampling* - SMOTE", que consiste em criar sinteticamente novas observações da classe minoritária, com o objetivo de igualar a proporção das classes de empresas.




Figura 43: Conjunto de dados desbalanceado

Após a execução do balanceamento dos dados observa-se pela figura (44) que as classes (solvente e insolvente) estão igualitárias no conjunto de dados.




Figura 44: Conjunto de dados após o balanceamento

- **Validação do Experimento 3**

Para o processo de validação do experimento 3 foi utilizado o conjunto de dados separado previamente na etapa de separação dos dados de treino e teste para o modelo preditivo, porém os dados foram balanceados na tentativa de melhorar a performance dos modelos. Após as transformações feitas nos dados os modelos foram devidamente treinados, foi gerada a matriz de confusão para cada modelo utilizado, os resultados são explicitados na tabela 25.

Tabela 25: Métricas de Avaliação dos modelos de classificação

Matriz de Confusão Floresta Aleatória	Precisão	Recall	F1-Score
Empresas Insolventes	0.96	0.88	0.77
Empresas Solventes	0.96	0.80	0.80

Acurácia		0.91		
Matriz de Confusão Arvore de Decisão		Precisão	Recall	F1-Score
Empresas Insolventes		1.00	0.62	0.77
Empresas Solventes		1.00	0.80	0.80
Acurácia		0.87		
Matriz de Confusão Regressão Logística		Precisão	Recall	F1-Score
Empresas Insolventes		0.33	0.50	0.40
Empresas Solventes		0.88	0.78	0.82
Acurácia		0.72		

Entre as métricas utilizadas, destaca-se a métrica da matriz de confusão para o algoritmo de floresta aleatória, que apresenta uma precisão de 0.96, e uma acurácia de 0.91 em sua previsão, já o *recall* refere-se o quanto o modelo acertou individualmente em cada modalidade em falsos positivos e falsos negativos.

As figuras (45 e 46) demonstram as variáveis mais importantes consideradas pelo modelo de Floresta Aleatória e Regressão Logística, respectivamente.




Figura 45: Variáveis importantes para o classificador Floresta Aleatória




Figura 46: Variáveis importantes para o classificador de Regressão Logística

5.4 Avaliação de desempenho e seleção do melhor modelo preditivo

Após a experimentação de alguns possíveis modelos de classificação, é necessário escolher o melhor dentre os modelos utilizados. Para a escolha do melhor modelo foi utilizada a técnica de validação cruzada *K-fold*, onde divide-se aleatoriamente o conjunto de treinamento em 10 conjuntos distintos chamados de partes (*folds*), então treina-se e se avalia um determinado modelo 10 vezes, escolhendo uma parte (*fold*) diferente em cada uma delas para avaliação e treinando-se nas outras 9 partes. O resultado é um vetor contendo as 10 pontuações de avaliação. A validação cruzada permite obter não apenas uma estimativa do desempenho do modelo, mas também uma medida de precisão, isto é, o seu desvio padrão. Observa-se na tabela 26, que o melhor modelo é o classificador Floresta Aleatória, pois o estimador alcançou uma acurácia média de 96% do total de dez execuções com configurações diferentes e ainda obteve o menor desvio padrão para o total de execuções geradas. Em segundo lugar, o classificador Árvore de decisão, com acurácia média de 87%, apresenta um bom desempenho e pode-se trabalhar os dados para melhorar sua performance. Por fim, o classificador de Regressão logística teve pior desempenho para o conjunto de dados

obtendo uma acurácia média de 53%, o que impossibilita sua utilização para previsão de insolvência para a amostra das micro e pequenas empresas.

Tabela 26: Seleção do melhor Modelo Preditivo

Classificador	Pontuação (score)	Acurácia	Acurácia Média (validação cruzada)	Desvio Padrão (validação cruzada)
Floresta Aleatória	0.96	0.88	0.96	0.10
Árvore de Decisão	0.87	0.80	0.87	0.16
Regressão Logística	0.85	0.50	0.53	0.23

5.5. Validação por público-alvo da pesquisa

A solução projetada tem foco nas micro e pequenas empresas, que podem utilizar a ferramenta para melhorar a gestão de seus negócios. Entretanto, a solução pode ser utilizada por pessoas especializadas na área contábil (contadores), bem como profissionais da área financeira que atuam em entidades de suporte às MPEs, entre outros. A tabela 27 demonstra o público-alvo considerado para validação da solução em estado funcional.

Tabela 27: Público-alvo de validação da solução projetada

Público-alvo	Descrição
Micro e Pequena Empresa (MPEs)	Micro e pequenos empresários utilizaram a solução para verificar se as expectativas projetadas são atendidas.
Contadores	Profissionais devidamente habilitados e responsáveis, seja pelo seu próprio escritório contábil, seja prestador de serviço para empresa contábil, e ainda podendo atuar com profissional autônomo, que acompanha de perto o dia a dia das micro empresas, buscando validar se os artefatos gerados auxiliam na prestação de serviço para MPEs no que tange a saúde financeira das empresas.
Profissionais da área financeira	Executivos de finanças, analistas financeiros e outros, que lidam com diversas situações nas empresas, sendo profissionais habilitados e proficientes em gestão financeira, para auxiliar empresas em sua estrutura de capital, captação de recursos financeiros junto a bancos e zelar pela saúde financeira da organização. Podem auxiliar na validação dos artefatos provendo <i>feedbacks</i> sobre os resultados gerados, tanto do modelo de aprendizado de máquina, bem como, da eficiência do agente inteligente.
Entidade de apoio ao empreendedor	Colaboração da entidade de apoio empreendedor Sebrae que disponibiliza consultores financeiros para auxiliar as MPEs em sua gestão financeira e estratégica

Para validação da pesquisa foi elaborado o instrumento de validação, o qual foi utilizado juntamente ao público alvo, sendo: 1) seleção dos perfis conforme o público alvo da pesquisa; 2) jornada de validação, descrevendo o processo a ser executado; 3) etapas detalhadas de validação da

solução proposta; 4) Formulário de *feedback* de validação da pesquisa, onde após o público ter utilizado o protótipo gerado, foi capturado a experiência e as percepções do público validador, por meio de uma série de perguntas. A tabela 28 exibe os participantes e função das pessoas validadoras, destaca-se que o tipo de validação foi assistida, ou seja, por meio de uma reunião online o acompanhou-se todo o processo executado por cada usuário.

Destaca-se a importância dos perfis dos micro e pequenos empresários, consultores financeiros e contadores e essenciais no processo de validação da solução em seu estado funcional.

Enfatiza-se que para concepção do instrumento de validação, utilizou-se técnicas e práticas, adotadas pela área de UX, que pode ser definida como uma maneira de pensar e conceber todos os aspectos da interação entre o usuário e experiência completa do produto, do início ao fim (Andrade, 2021).

Tabela 28: Público Avaliador da Pesquisa

Avaliadores	Tipo de Validação	Data
Consultor Financeiro I (Sebrae)	Assistida	05/10/2023
Microempresário I	Assistida	22/12/2023
Consultor Financeiro II (Sebrae)	Assistida	06/01/2024
Contadora	Assistida	07/01/2024
Microempresário II	Assistida	08/01/2024

A tabela 29 demonstra o detalhamento das etapas detalhadas do instrumento de validação. O objetivo foi elucidar o usuário sobre todos os passos necessários para gerar o diagnóstico financeiro buscando fornecer clareza ao processo. As etapas foram compartilhadas de modo gráfico (Apêndice A – Instrumento de Validação da Pesquisa), no entanto foram exibidas aqui em formato de tabela para melhor visualização.

Tabela 29: Etapas de Validação da Solução SMA

Etapa	Atividade	Descrição
1	Obter dados econômico-financeiros	Obtenção das informações contábeis/financeiras nos relatórios balanço patrimonial e demonstrativo do resultado do exercício (DRE). Os dados podem ser disponibilizados em formato PDF ou arquivo excel (CSV)
2	Acessar a plataforma de diagnóstico financeiro	Acesso à interface solver.ai
3	Preparação dos dados para o diagnóstico financeiro	Preenchimento das informações de métricas e indicadores financeiros conforme o modelo disponibilizado pela plataforma
4	Carregamento dos dados financeiros	Acesso à interface solver.ai no menu diagnóstico financeiro para fazer o <i>upload</i> do arquivo com as informações do negócio.
5	Conferência dos dados carregados	Realização da visualização das métricas e indicadores financeiros verificando se os dados foram carregados corretamente
6	Solicitação de Diagnóstico da saúde financeira	Tudo pronto com os dados! Realização da solicitação do diagnóstico de saúde financeira para sua empresa

7	Resultado do Diagnóstico de saúde financeira	Visualização do resultado do diagnóstico de saúde financeira em tela. A plataforma faz a previsão da situação financeira da empresa por meio do modelo preditivo.
8	Recomendação de Tratamento financeiro	Visualização das recomendações de ações que podem auxiliar na recuperação e manutenção da saúde financeiro de seu negócio.
9	Monitoramento de Desempenho	Acompanhamento do desempenho e recebimento de alertas por meio do monitoramento automático de métricas e/ou indicadores financeiros (liquidez, rentabilidade, estrutura de capital, etc.)
10	Decisão Estratégica	Análise das informações de diagnóstico e recomendações feitas pela plataforma como insumos para tomada de decisão estratégica de seu negócio

O instrumento de validação foi enviado por e-mail para cada participante, posteriormente foi agendada uma reunião online onde foi feito o processo de teste e validação da solução. Discussões e anotações foram feitas durante todo o processo com intuito de captar pontos essenciais dos feedbacks, por fim, os participantes responderam um formulário disponibilizado via ferramenta website *TypeForm* com nove (9) perguntas de múltipla escolha e uma (1) pergunta aberta para que cada participante contribuísse com seu *feedback* sobre a solução (Apêndice B – Formulário de Feedback após Validação da Pesquisa). Os resultados são demonstrados na sequência.

5.5.1 Feedback 1: Validação dos artefatos por especialistas Sebrae

Com o intuito de submeter os artefatos desenvolvidos à avaliação especializada, estabeleceu-se contato com o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae), reconhecido por sua expertise em consultoria voltada para micro e pequenas empresas. Duas reuniões foram agendadas com consultores financeiros do Sebrae para realizar a validação dos artefatos propostos. As reuniões foram conduzidas por meio de videoconferência, iniciando-se com a apresentação e contextualização do projeto de pesquisa. Em seguida, foram percorridas as etapas de validação delineadas pelo instrumento de validação previamente elaborado. Por fim, abriu-se espaço para que os consultores expressassem seus *feedbacks* e contribuições em relação à pesquisa, os quais serão detalhadamente descritos na sequência.

O consultor financeiro do Sebrae que possui mais de 15 anos de experiência na área financeira e presta serviço de consultoria vinculado ao Sebrae há mais de 3 anos com foco no atendimento de micro e pequenos negócios. Após o entendimento geral da solução, o profissional destacou a “importância de direcionar a solução para profissionais da contabilidade e advogados”, ressaltando a influência crucial desses grupos na implementação e adoção da solução, uma vez que com frequência esses grupos recomendam e fornecem suporte a diversas ferramentas aos empresários. Identificou o fluxo de caixa negativo como um fator crítico para a insolvência, salientando a necessidade de abordar questões fundamentais, como precificação e entendimento de indicadores. Observou também que os “indicadores de liquidez apontados pelo modelo preditivo como variáveis importantes são, de fato, utilizadas na prática na análise de micro e pequenos negócios para o diagnóstico financeiro”. Adicionalmente, recomendou a inclusão de indicadores como, ROE/ROA, Prazo Médio de Estoque, e interpretação detalhada do Demonstrativo do Fluxo de Caixa (DFC) futuro dentro da plataforma.

A segunda validação ocorreu por meio de outro consultor que possui mais de 20 anos de experiência no mercado financeiro, com diversas pós-graduações na temática, que também atuou na academia como pesquisador e professor universitário, fazendo parte atualmente do grupo GAN4, empresa credenciada ao Sebrae, que fornece profissionais preparados para apoiar o micro e pequeno empresário. O processo de validação teve duração de duas horas, onde o consultor expôs suas contribuições. Enfatizou a importância da pesquisa e a necessidade da criação de ferramentas adaptadas para o contexto específico das MPEs. Entretanto, embora a pesquisa caminhe para atingir o objetivo junto às micro e pequenas empresas, o especialista propôs adequar, ainda mais, a linguagem utilizada na plataforma para torná-la mais acessível aos microempreendedores individuais (MEIs), considerando suas particularidades dentro do contexto empresarial. Nesse sentido, recomendou a inversão da base da pirâmide empresarial, isto é, as métricas e indicadores apresentadas na plataforma estariam comunicando com os pequenos e médios empresários, fazendo-se necessário priorizar a comunicação com o microempresário.

Corroborando com o 1º. consultor, foi proposta a incorporação do movimento de caixa (Demonstrativo do Fluxo Caixa – DFC) como elemento fundamental na análise financeira, dada a importância desse instrumento para as MPEs.

Acerca do modelo preditivo de insolvência foi destacada a importância de alimentar o modelo proposto com a estrutura de planos de contas do Demonstrativo do Resultado do Exercício (DRE) Gerencial, enfatizando a necessidade de integração eficiente dos dados contábeis na análise preditiva. Desse modo, foi apresentada uma justificativa robusta do DRE Gerencial, elucidando a relevância das diversas métricas dentro do contexto das micro e pequenas empresas. O consultor ressaltou que, como não há existência de obrigatoriedade do MEI de ter uma contabilidade, a prática das micro e pequenas empresas é a da não disponibilidade do demonstrativo balanço patrimonial, justificando assim o uso do DRE gerencial, o qual atende o contexto dos pequenos negócios.

Por fim, alertou sobre a necessidade de evitar erros conceituais na plataforma, destacando a importância da precisão e correta interpretação dos conceitos apresentados para garantir a confiabilidade do modelo preditivo como ponto de partida para melhorar a gestão das micro e pequenas empresas.

5.5.2 Feedback 2: Validação dos Artefatos por Micro e Pequenos Empresários

Com o objetivo de verificar se a solução projetada cumpre com objetivo de facilitar a gestão de pequenos negócios, a ferramenta foi validada por micro e pequenos empresários com o intuito de colher suas percepções acerca das informações apresentadas na plataforma.

A validação conduzida por um pequeno empreendedor que atua na gestão de diversas empresas que prestam serviços no setor público, proporcionou críticas construtivas ao analisar a proposta da pesquisa. Observou que as ferramentas de mercado utilizadas na gestão financeira de sua empresa não oferecem um diagnóstico da saúde financeira de seu negócio, limitando-se a apresentar as informações sem uma análise mais aprofundada da situação financeira. De forma que trouxe uma percepção positiva sobre a facilidade e acessibilidade da ferramenta gerada no estudo em fornecer diagnóstico de saúde financeira, indicando uma eficácia na apresentação das informações. Com relação às recomendações de tratamento feitas pela ferramenta foi observado pelo usuário que as mesmas são simples e vão além do diagnóstico financeiro e poderiam ser levadas em consideração na tomada de decisão.

Ressaltou que muitos empresários reconhecem suas falhas, mas carecem de ferramentas práticas para orientar e apontar ações corretivas, enfatizando a demanda por soluções efetivas na resolução de problemas financeiros. A base de dados proveniente da contabilidade foi criticada por não refletir adequadamente a realidade enfrentada pelos micro e pequenos negócios, indicando uma desconexão entre os dados contábeis e vivência empresarial. Corroborando com consultor Sebrae, pontuou que a prática comum é uso do DRE Gerencial, pois é uma orientação feita pelos

contadores, além de estratégias fiscais, mencionada como uma realidade na gestão financeira das empresas, indicando a complexidade e nuances das práticas contábeis.

Um segundo microempreendedor individual, que fornece café para pequenos comércios, contribuiu para a validação de uma ferramenta. Ele destacou que as empresas categorizadas como MEI carecem de apoio no que tange à conscientização sobre quais informações são cruciais para o registro. Esta constatação foi feita durante a etapa de carregamento de dados, quando percebeu que não possuía todas as informações necessárias sobre seu negócio.

Adicionalmente, ressaltou a questão do tratamento recomendado pelo agente após a etapa de diagnóstico. Ele sugeriu a inclusão de etapas educacionais na ferramenta para esclarecer os empresários sobre os conceitos de gestão financeira. Ele também propôs a adição de informações sobre canais de crédito, pois, em sua visão, os micro e pequenos empresários estão constantemente em busca de capital para manter seus negócios em funcionamento. Portanto, uma vez que eles tenham acesso à ferramenta de gestão e diagnóstico financeiro, seria interessante auxiliá-los nesta questão.

Em relação ao monitoramento e ao envio de alertas, foi enfatizado que é crucial receber notificações proativas do sistema sobre a performance dos indicadores. Isso se deve ao fato de que o controle desses indicadores é frequentemente realizado de maneira rudimentar, por meio de planilhas. Este método pode resultar em retrabalho constante para adicionar ou modificar as métricas estabelecidas. Muitos empreendedores acabam não realizando a gestão por indicadores devido a essas dificuldades. Portanto, a implementação de alertas proativos pelo sistema é de suma importância para aprimorar a gestão dos negócios.

5.5.3 Feedback 3: Validação dos Artefatos por Contadores

A solução projetada foi validada por contadores que prestam serviços de contabilidades seja por meio de seus escritórios contabilidade, seja por meio de empresas que fornecem esses serviços a micro e pequenas empresas. Os *feedbacks* e contribuições são detalhados a seguir:

- **Limitações dos softwares atuais de gestão financeira:** A contadora ressaltou que os softwares de gestão financeira atuais proporcionam uma visão consolidada dos extratos bancários, oferecendo aos empresários uma visualização antes inexistente. No entanto, aponta que a simples exibição de informações consolidadas não é suficiente para diagnosticar a saúde financeira da empresa, deixando essa complexa tarefa a cargo do empresário.
- **Simplificação do resultado do diagnóstico financeiro:** Sugere-se a remoção da coluna “probabilidade” no resultado do diagnóstico de saúde financeira, visando facilitar a interpretação por parte do empresário. Aponta que, em seu ponto de vista, “consegue compreender os resultados e diagnósticos apresentados”. No entanto, ressalta que, para usuários leigos, compreensão pode ser complexa. Embora seja um desafio, recomenda-se a melhoria utilizando uma linguagem menos técnica.
- **Substituição de termos técnicos:** Observa-se a recomendação para substituir o termo “insolvência” pela palavra “falência”, considerando que insolvência é termo técnico que pode não ser amplamente compreendido pelo micro e pequeno empresário.
- **Acessibilidade da ferramenta:** Inicialmente a ferramenta pode ser útil para profissionais especializados, dada a complexidade das informações apresentadas, tais como, as recomendações de tratamento. Destaca a necessidade de simplificar ainda mais o conteúdo exposto para facilitar o seu uso.
- **Explicação adicional nos tratamentos:** Propõe a inclusão de uma opção na exibição do tratamento recomendado que forneça uma breve explicação do que se refere cada tratamento, contribuindo para uma compreensão mais efetiva do procedimento a ser executado pela organização.

- **Dashboard para tomada de decisão:** Sugere-se a criação de uma área de *dashboard* com gráficos e os principais indicadores do negócio, visando auxiliar na tomada de decisão.
- **Potencial diferencial da ferramenta:** Destaca-se que solução projetada entrega um trabalho diferenciado e crucial para empresas em geral. Expressa a falta de um sistema de diagnóstico financeiro no mercado que faça a previsão de insolvência para micro e pequenas empresas, considerando este ponto como um diferencial significativo.

5.5.4 Feedback geral sobre o preenchimento do formulário

Uma vez que foi utilizado UX como experiência completa do usuário nas etapas de validação. Nesta fase utilizamos a pesquisa de experiência do usuário (do inglês: *UX Research*), que trata sobre pesquisas relacionadas a descoberta, entendimentos e validações sobre a experiência do usuário em relação algum produto (Silva et al, 2021).

Nesse sentido com relação ao processo do uso da ferramenta, foram capturadas impressões dos avaliadores a respeito da solução após sua utilização, por meio de um preenchimento de um formulário com algumas perguntas que seguem relacionadas e são encontradas no (Apêndice B- Formulário de Validação da Pesquisa).

A figura (47), demonstra o resultado para questão: Como você avalia o processo de obtenção dos dados econômico-financeiros?




Figura 47: Processo de obtenção dos dados da empresa

Observamos que 60% dos participantes encontraram dificuldade em obter informações contábeis. Evidencia-se o desafio para obter dados uma vez que muitas das empresas não fazem o registro de informações do negócio por meio de uma contabilidade.

A figura (48), demonstra o resultado para questão: Como foi o processo de preenchimento das informações de métricas e indicadores econômico-financeiro pelo modelo disponibilizado?




Figura 48: Preenchimento das informações da empresa

Observa-se que 33.3% dos participantes apresentaram dificuldade no entendimento e por sua vez, no respectivo preenchimento de algumas informações. Esse ponto reforça que tanto a linguagem contábil e financeira utilizada na ferramenta deve ser ajustada para melhorar o entendimento dos usuários.

A figura (49) demonstra o resultado para a questão: Como você avalia a etapa de resultado de diagnóstico financeiro para empresa?




Figura 49: Avaliação do resultado do diagnóstico financeiro

Evidencia-se que 60% dos participantes responderam que a predição feita pela ferramenta estava em conformidade com o momento atual da empresa, demonstrando que é possível interpretar o resultado do modelo preditivo e confiar no resultado apresentado. Destaca-se que 40% dos resultados apresentados foram incorretos, evidenciando que o modelo preditivo falhou em prever a situação correta da empresa. Faz-se necessário retornar ao ciclo de treinamento do modelo trabalhando-se melhor os dados para melhorar a sua acurácia.

A figura (50) demonstra o resultado para questão: Como você avalia a etapa de tratamento proposto?




Figura 50: Avaliação do tratamento proposto.

Observa-se que há um misto de opiniões, evidenciando-se que as recomendações de tratamentos propostos pela solução estão de acordo com a situação atual empresa (80%), e que as recomendações estão de disposta de forma intuitiva. Entretanto, 50% responderam que as recomendações são complexas para serem executar na prática, ainda 20% apontam que as recomendações fornecidas são genéricas fato que pode ser explicado pela falta de conhecimento em técnicas de gestão financeira por parte dos usuários ou que a ferramenta é muito complexa.

A figura (51) demonstra o resultado para questão: Como você avalia a opção de monitoramento de desempenho do negócio?

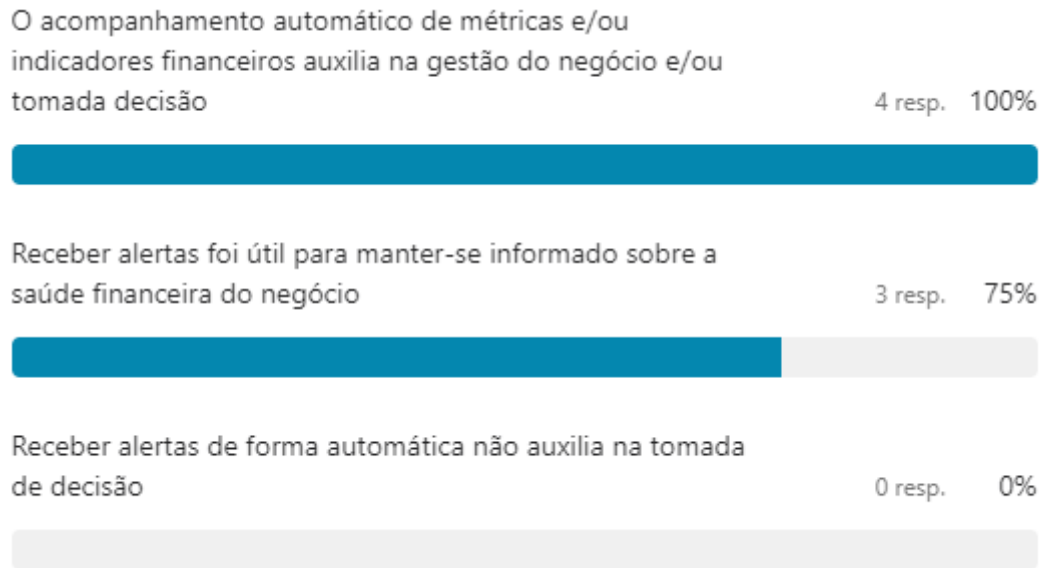


Figura 51: Monitoramento de Desempenho

Destaca-se que 100% dos participantes apontaram que o acompanhamento automático de métricas e indicadores financeiros auxiliar na tomada de decisão. Já receber alertas sobre a saúde financeira obteve 75% das respostas. Esse ponto pode ser explicado pelo fato que na prática das empresas não há uma diversidade de ferramentas que tenham monitoramento automático, sendo que maiorias das ferramentas tem uma opção de visualização de métricas, porém não enviam alertas e não há possibilidade de configurá-las de forma personalizadas quais indicadores deseja-se monitorar.

A figura (52) demonstra o resultado para questão: Como você avalia a etapa de decisão estratégica como base nas informações fornecidas pela plataforma?




Figura 52: Validação da etapa de Decisão de Estratégica

Observa-se que 80% dos participantes apontaram que considerariam as informações de diagnóstico e tratamento financeiro para tomar decisões mais assertivas para o negócio. Evidencia-

se que 60% do público participante entende que as informações fornecidas pela solução proposta auxiliam na tomada estratégica de decisões para o futuro do negócio. Enquanto, que 20% não considerariam as informações. Fato que pode ser explicado pelo desafio de se colocar em práticas as ações recomendadas.

A figura (53) demonstra o resultado para questão: Qual foi sua experiência de navegação na plataforma, houve dificuldade em alguma etapa?




Figura 53: Experiência de Navegação na Solução

Referente a experiência de utilização da solução, de forma geral não houve dificuldade de navegação na solução proposta como evidenciado por 80% dos participantes. Entretanto, destaca-se que 40% dos usuários tiveram dificuldade na etapa de obtenção dos dados, fato que pode ser explicado pela prática das micro e pequenas empresas de não ter seus dados em conformidade com contabilidade fazendo-se apenas apuração necessária para não incorrer em multa pelo governo.

Conclui-se que a partir dos resultados do formulário de feedback, foi possível identificar que a solução proposta apresenta potencial para auxiliar as micro e pequenas empresas na gestão financeira e suportá-las na tomada de decisão estratégica. No entanto, é necessário realizar alguns ajustes para melhorar a experiência de uso e aplicabilidade das informações fornecidas.

5.6 Explicitação das aprendizagens

O objetivo desta seção do DSR é elucidar as aprendizagens adquiridas durante o processo de pesquisa, os aspectos que funcionaram, os que não funcionaram e as decisões que impactaram o projeto:

- **Ausência de Agrupamento de Recomendações:** Observou-se a inexistência de um agrupamento consolidado em torno das recomendações de tratamento para aprimorar a saúde financeira das micro e pequenas empresas. A literatura existente é escassa em trabalhos que sugerem algumas ações, e quando o fazem, as empresas já se encontram em estágios avançados de insolvência, tal como em recuperação judicial (Sacramone et al., 2020). De acordo com os especialistas do Sebrae, é necessário analisar o caso de cada empresa e determinar a melhor recomendação de intervenção. Assim, uma estrutura racional baseada em métricas replicando o conhecimento de um especialista foi montada para recomendar um tratamento, ponto que pode ser configurado de forma personalizada pelo micro e pequeno empresário, respeitando que cada empresa atua em setores com ambientes internos e externos diferentes.
- **Modelo de Previsão de Insolvência:** A pesquisa partiu do pressuposto de que seria possível gerar um modelo de previsão de insolvência por meio dos demonstrativos financeiros, sendo balanço patrimonial e demonstrativo do resultado. No entanto, verificou-se que poucas micro e pequenas empresas realizam a contabilidade, especificamente os microempreendedores individuais, não gerando informações contábeis relevantes, fato confirmado pelo consultor do Sebrae e contadores, tanto na etapa de coleta de dados quanto na validação da pesquisa. Dessa forma, o modelo preditivo baseado na informação direta desses demonstrativos não funciona na prática para a maioria dos cenários. Aprendeu-se que a utilização do DRE Gerencial como fonte primária das informações atende de maneira mais ampla as micro e pequenas empresas, onde se deve coletar novos dados e refazer o treinamento do modelo preditivo.
- **Construção do Modelo Preditivo:** Para a construção do modelo preditivo, foram utilizados diversos algoritmos de aprendizado de máquina na fase de treinamento, fazendo-se uso de métodos e técnicas avançadas para a seleção do melhor modelo. Evidenciou-se que um único modelo pode não se ajustar bem aos dados das micro e pequenas empresas, e que algumas métricas podem ser removidas devido à baixa importância na previsão do modelo. Enfatiza-se que a coleta de informações é uma etapa essencial e crítica e deve ser realizada com extrema diligência para a construção de modelos preditivos.
- **Monitoramento de Desempenho:** O monitoramento de desempenho do negócio por meio de indicadores é referenciado na literatura de gestão empresarial. Nesse contexto, existem diversas abordagens e frameworks, tais como o *Balanced Scorecard* (BSC), entre outros, para suportar este processo. No entanto, não foi encontrado na prática dos pequenos negócios ferramentas acessíveis que façam isso de forma automática, sem exigir

um grande esforço e conhecimento de práticas de gestão. A solução projetada procurou sistematizar esse processo, entregando o monitoramento de indicadores personalizado por empresa, ou seja, cada empresa pode decidir e configurar quais os indicadores que pretende monitorar e delegar para o agente de monitoramento que envie alertas quando necessário.

- **Sistema Multiagente:** No início desta pesquisa, idealizou-se a construção de um único agente inteligente que seria responsável por suportar o processo de previsão de insolvência das empresas. Porém, no decorrer do projeto, verificou-se que apenas um agente teria um desempenho abaixo do esperado, dado o complexo exercício de lidar com questões de saúde financeira do negócio. Nesse sentido, foi proposta uma solução de sistema multiagente que funcionou atendendo às expectativas projetadas. A especificação do ambiente dos agentes, sua medida de desempenho, seus sensores e atuadores, bem como suas características sociais de comunicação, elevaram o desempenho do SMA.
- **Protótipo da solução de diagnóstico financeiro:** A implementação da interface do solver.ai, empregando práticas de experiência do usuário (UX), possibilitou uma visualização intuitiva das informações resultantes da interação entre os agentes. Uma das dificuldades encontradas pelos usuários foi a coleta de informações para o diagnóstico da saúde financeira, uma etapa que foi quase completamente negligenciada durante a fase de validação. Para atenuar essa questão, foi introduzida a funcionalidade de simulação de dados, permitindo a realização de todo o processo de iteração com a solução e a obtenção de feedbacks sobre sua eficácia.

Em síntese, a pesquisa proporcionou aprendizados valiosos sobre a gestão financeira de micro e pequenas empresas, destacando a necessidade de abordagens personalizadas, flexíveis e adaptáveis. As lições aprendidas não apenas contribuem para o avanço do conhecimento acadêmico, mas também oferecem orientações práticas para profissionais e empreendedores que buscam melhorar a saúde financeira de seus negócios.

5. PRINCIPAIS CONCLUSÕES E POTENCIAIS CONTRIBUIÇÕES

O objetivo desta pesquisa foi elaborar um sistema multiagente para previsão de insolvência por meio de aprendizado de máquina para micro e pequenas empresas brasileiras. Para isso, foi proposta e implementada uma solução baseada em agentes inteligentes para diagnosticar a saúde financeira das empresas, classificando-as quanto ao estado de insolvência. A solução visou contribuir para a redução da alta taxa de mortalidade dos micro e pequenos negócios, dada a sua relevância na economia no cenário nacional. Além disso, visou automatizar e compartilhar os procedimentos e conhecimentos dos profissionais especialistas em finanças, possibilitando um tratamento preventivo e intensivo das empresas em situação de insolvência ou mesmo com outros problemas financeiros.

Com base no estudo realizado, por meio da pesquisa de referência do Sebrae e da Lei Geral de Micro e Pequenas empresas, pode-se afirmar que essas empresas representam 98% do negócios do país, motivo pelo qual a Constituição Federal estabelece um regime diferencial para as micro e pequenas empresas. No entanto, a pesquisa revelou que a taxa de mortalidade dessas empresas é considerada acima da média quando comparada a outros países, sendo que as empresas encerram suas atividades antes de completar cinco anos de existência. Isso pode ser observado pelos números de encerramento, que são de 21,6% para microempresas e 17% para pequenas empresas.

A revisão da literatura evidenciou que a combinação de diferentes técnicas para prever o fenômeno da insolvência é uma abordagem promissora. No entanto, foram encontrados poucos trabalhos que abordassem as micro e pequenas empresas utilizando técnicas avançadas como aprendizado de máquina. Alguns trabalhos procuram replicar os métodos de previsão de insolvência feitos para o contexto das grandes empresas. Nesse sentido, não foram identificados

trabalhos com o foco na previsão de insolvência de micro e pequenas empresas utilizando sistemas multiagente. Este trabalho apresenta uma solução inovadora nesse sentido.

A partir da metodologia de Design Science Research (DSR), foram gerados dois artefatos nesta dissertação: 1) o sistema multiagente (SMA) e 2) o modelo preditivo de insolvência. Na etapa de projeto e construção do artefato de sistema multiagente, deu-se por meio da definição do problema de insolvência das micro e pequenas empresas, pré-projeto dos agentes utilizando-se a especificação PEAS, a modelagem de agentes feita por meio da metodologia Tropos, seguindo suas fases de definição dos requisitos iniciais/finais, definição da sua arquitetura sistêmica, a implementação dos agentes por meio do *framework* PADE e a interface solver.ai para manipulação e visualização dos resultados. Destacou-se na fase de treinamento dos modelos de aprendizado de máquina que as variáveis mais importantes para prever a insolvência das empresas são: indicador de liquidez corrente e seca, o total de caixa, a capacidade de geração de caixa e a geração de caixa operacional. Esse resultado vai de encontro com os achados na prática pelos consultores do Sebrae no apoio diário aos micro e pequenos negócios. O modelo preditivo foi construído seguindo o processo de criação e seleção, que envolveu a coleta e preparação dos dados. Destaca-se que um dos desafios dessa pesquisa deu-se na obtenção de dados reais das micro e pequenas empresas devido a não conformidade das empresa junto a contabilidade. Na escolha das variáveis preditoras, empregou-se a técnica de seleção de atributos. Quanto ao algoritmo de aprendizado de máquina, as etapas de treinamento e validação foram realizadas para avaliar o desempenho do modelo.

Para o SMA, foram realizados dois experimentos como prova de conceito, demonstrando a capacidade do agente de prover o diagnóstico de saúde financeira com uma taxa de acerto de 96% e compartilhar o relatório com os demais agentes, bem como, o de fazer recomendações de tratamento, monitoramento e alertas para as empresas.

Para o modelo preditivo de insolvência, foram realizados três experimentos com o objetivo de selecionar o melhor modelo de classificação, utilizando dados de empresas reais. Os métodos utilizados foram floresta aleatória (*random forest*), árvore de decisão e regressão logística. O método de aprendizado de máquina floresta aleatória foi eleito o melhor método de classificação, considerando o seu desempenho pelo método de validação cruzada. Esse método apresenta a vantagem de lidar facilmente com atributos numéricos ou categóricos e, também, é bastante utilizado em procedimentos de seleção de variáveis.

O processo de validação da pesquisa foi realizado com três grupos de usuários: consultores financeiros, micro e pequenos empresários e contadores. A validação foi realizada por meio de um formulário como nove perguntas de múltipla escolha e uma pergunta aberta. Além disso, foi realizada uma validação assistida com cada participante, onde foi possível acompanhar o processo de uso da ferramenta e coletar *feedbacks* qualitativos. O *feedback* dos especialistas foi positivo, destacando a importância da solução proposta para o diagnóstico da saúde financeira de micro e pequenas empresas. Os pontos destacados da etapa de validação são:

- Adaptação da linguagem utilizada na plataforma para torná-la mais acessível aos micro e empreendedores individuais (MEI).
- Alimentação do modelo preditivo de insolvência com a estrutura de planos de contas do DRE gerencial.
- Inclusão de etapas educacionais na ferramenta para esclarecer os empresários sobre conceitos de gestão financeira.
- Dificuldade na obtenção de dados contábeis, o que pode ser explicado pela falta de obrigatoriedade da contabilidade para micro e pequenos empresários.
- As recomendações de tratamento são complexas para se executar na prática, o que pode ser explicado pela falta de conhecimento em técnicas de gestão financeira.
- A necessidade da criação de *dashboard* para tomada de decisão, com gráficos e os principais indicadores do negócio.

Observando o feedback dos usuários validadores, pode-se concluir que a solução proposta tem potencial para atender as necessidades de micro e pequenas empresas. No entanto, são

necessárias melhorias na usabilidade e na acessibilidade da ferramenta para torná-la acessível a um público menos especializado em gestão financeira.

No que tange as aprendizagens, foram adquiridos *insights* valiosos nesta pesquisa. As aprendizagens destacadas são:

- Ausência de agrupamento consolidado de recomendações de tratamento do financeiro e a literatura existente é escassa em trabalhos que sugerem ações para aprimorar a saúde financeira das micro e pequenas empresas.
- O monitoramento de desempenho de empresas por meio de indicadores é referenciado na literatura de gestão empresarial, mas na prática das MPEs não foram encontradas ferramentas acessíveis que o façam de maneira automática.
- A criação de um modelo preditivo por meio de demonstrativos financeiros não atende o cenário das micro empresas, pois essas empresas não estão obrigadas a ter um contabilidade. Nesse sentido, o DRE gerencial aparece como uma alternativa viável para alimentar o modelo preditivo com informações da realidade dessas empresas.
- A utilização de um sistema multiagente foi detectada, pois no início desta pesquisa idealizou-se a construção de único agente inteligente para suportar a processo de previsão insolvência da empresas, mas verificou-se que apenas um agente teria um desempenho abaixo do esperado.
- A implementação da interface de diagnóstico financeiro, empregando práticas de experiência do usuário (UX), possibilitou uma visualização intuitiva das informações resultantes da interação entre os agentes.

Sendo assim, este estudo objetivou contribuir apresentando uma solução inovadora para a previsão de insolvência de micro e pequenas empresas. A solução é baseada em um sistema multiagente que utiliza aprendizado de máquina para diagnosticar a saúde financeira das empresas e fazer recomendações de tratamento. Os resultados do estudo mostram que a solução tem uma boa capacidade de predição e recomendação, sendo uma alternativa viável para o auxílio na gestão e tomada de decisão das micro e pequenas empresas.

6.1 Limitações da pesquisa

Esta pesquisa apresenta algumas limitações significativas. A previsibilidade da insolvência, que inicialmente foi considerada viável através dos demonstrativos financeiros, revelou-se um desafio devido à falta de contabilidade adequada em muitas dessas empresas. Consequentemente, a quantidade de dados coletados representa uma pequena amostra, considerando a diversidade das micro e pequenas empresas.

Embora os dados obtidos tenham se mostrado eficazes de forma experimental, para o treinamento completo de um modelo de aprendizado de máquina, é necessário coletar um volume maior de dados. Isso permitirá melhorar as métricas de desempenho do modelo. Portanto, a necessidade de uma coleta de dados mais abrangente é uma limitação importante desta pesquisa.

6.2 Recomendações para trabalhos futuros

Apesar dos resultados promissores, a solução requer aprofundamento e evolução. Pesquisas futuras podem ser direcionadas para expandir a base de conhecimento baseada em regras, a fim de aprimorar a capacidade dos agentes em relação ao processo de recomendação de tratamento, bem como, em termos de monitoramento e envio de alertas. Pode-se considerar a utilização de aprendizado de máquina em cada um desses agentes, com o objetivo de expandir suas capacidades, aumentar suas habilidades em alcançar seus objetivos e ajustar sua medida de desempenho.

Embora o modelo preditivo tenha obtido bons resultados, ainda é possível aplicar outras técnicas de aprendizado de máquina (por exemplo, Máquinas de Vetores de Suporte, Redes Neurais), ou ainda, aplicar algoritmos que utilizem aprendizado não supervisionado para explorar seu potencial de classificação das empresas. Trabalhos futuros também podem adotar o uso do Demonstrativo de Resultados do Exercício Gerencial como fonte primária de informações, o que exigiria a coleta de novos dados e o treinamento do modelo preditivo.

6. GENERALIZAÇÃO PARA UMA CLASSE DE PROBLEMA

A seção 3.2.1 discorreu sobre a existência de alguns artefatos que são atribuídos a classes específicas de problemas, tais como tomada de decisão, sistemas de informação e aprimoramento de processos. Estes artefatos, quando gerados, fornecem uma solução satisfatória com o intuito de auxiliar na resolução de uma variedade de problemas dentro de seu respectivo contexto.

Levando em consideração a abordagem adotada nesta pesquisa, que se baseia na metodologia *Design Science Research* (DSR), os artefatos produzidos oferecem contribuições valiosas que podem ser generalizadas para uma ou mais classes amplas de problemas no contexto da gestão financeira de micro e pequenas empresas. O artefato sistema de multiagente (SMA) pode ser generalizado para um sistema de informação complexo, auxiliando as organizações na tarefa de gestão. O modelo preditivo pode ser generalizado para a classe de problemas de tomada de decisão, auxiliando na melhoria dos processos de gestão, dada a prerrogativa de previsibilidade da situação futura da empresa. As aprendizagens adquiridas, juntamente com as soluções propostas, podem ser aplicadas de maneira adaptativa e flexível em cenários similares onde a tomada de decisões estratégicas se faz necessária.

7. REFERÊNCIAS

- Accenture. (2018). Redefine banking with artificial intelligence. (https://www.accenture.com/_acnmedia/pdf-68/accenture-redefine-banking.pdf, recuperado em 07 de julho, 2023).
- Abellán, J., & Mantas, C.J. (2014). Improving experimental studies about ensembles of classifiers for bankruptcy prediction and credit scoring. *Expert Syst. Appl.*, 41, 3825-3830.
- Abreu, J. M. C. D. (2023). Deveres dos administradores antes da insolvência.
- Addo, P.M., Guégan, D., & Hassani, B.K. (2018). Credit Risk Analysis Using Machine and Deep Learning Models. *ERN: Other Econometrics: Econometric & Statistical Methods - Special Topics (Topic)*.
- Aken, J.E. (2004). Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules. *Journal of Management Studies*, 41, 219-246.
- Andrade, N.A. D. (2021). *Customer experience (CX)*. Editora Saraiva. <https://integrada.minhabiblioteca.com.br/books/9786589881810>
- Almeida, R., Sales, G., & Nunes, R. V. N. (2023). Predição de Insolvência de Empresas Através da Inteligência Artificial-Técnicas de Aprendizado de Máquina. *REPAE-Revista de Ensino e Pesquisa em Administração e Engenharia*, 9(1), 39-58.
- Altman, E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate Bankruptcy. *The Journal of Finance*, 23(4), 589-609.
- Altman, E.I., Sabato, G., & Wilson, N. (2010). The value of non-financial information in small and medium-sized enterprise risk management.

- Andrade, J. P., & Lucena, W. G. L. (2018). Análise de desempenho dos modelos de previsão de insolvência e a implementação das Normas Internacionais de Contabilidade. *Revista Ciências Administrativas*, 24(2).
- Andreeva, G., Calabrese, R., & Osmetti, S.A. (2014). A comparative analysis of the UK and Italian small businesses using Generalized Extreme Value models. *Eur. J. Oper. Res.*, 249, 506-516.
- Aoki, V. C. G., & Badalotti, R. M. (2014). Dificuldades e perspectivas no acesso de micro e pequenas empresas a linhas de crédito públicas: o caso de Chapecó. *Revista de Administração Pública*, 48, 1305-13
- Azevedo, S.C. (2012). A importância dos fluxos de caixa na análise da solvência, liquidez e visibilidade das empresas.
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417.
- Beaver, W.H. (1966). Financial Ratios As Predictors Of Failure. *Journal of Accounting Research*, 4, 71-111.
- Bordini, R. H., Hunber. J. F. Wooldridge. M. (2007). *Programming Multi-Agent Systems in Agentspeak Using Jason*. Wiley-Interscience.
- Bordini, R. H., & Dastani, M. (2010). Guest editorial: Special issue on the European Workshop on Multi-Agent Systems (EUMAS).
- Boissier, O., Bordini, R. H., Hubner, J., & Ricci, A. (2020). *Multi-agent-oriented programming: programming multi-agent systems using JaCaMo*. Mit Press.
- Bratman, M. (1987). Intention, plans, and practical reason.
- Bratman, M.E., Israel, D.J., & Pollack, M.E. (1988). Plans and resource-bounded practical reasoning. *Computational Intelligence*, 4.
- Brito, G. A. S. Assaf Neto, A., & Corrar, L. J. (2009). Sistema de classificação de risco de crédito: uma aplicação para companhias abertas no Brasil. *Revista contabilidade & finanças*, 20, 28-43
- Brynjolfsson, E. & McAfee. (2016). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton & Company
- Callado, A. A. C., & de Melo, W. A. (2018). Ferramentas e informações gerenciais em micro e pequenas empresas. *RAUnP-ISSN 1984-4204-Digital Object Identifier (DOI): [http://dx. doi. org/10.21714/raunp.10\(3\).53-65](http://dx.doi.org/10.21714/raunp.10(3).53-65)*.
- Camargos, M. A. D., Camargos, M. C. S., Silva, F. W., Santos, F. S. D., & Rodrigues, P. J. (2010). Fatores condicionantes de inadimplência em processos de concessão de crédito a micro e pequenas empresas do Estado de Minas Gerais. *Revista de Administração Contemporânea*, 14, 333-352.
- Central de Balanços (<https://www.gov.br/centraldebalancos/#/demonstracoes>, recuperado em 25 de janeiro, 2024)
- Cervo, A. L.; & Bervian, P. A. (2007). *Metodologia Científica*. 6ª ed. São Paulo: Pearson Prentice Hall.
- Chalhoub, L., Kirch, G., & Terra, P.R. (2015). Fontes de caixa e restrições financeiras: evidências das firmas listadas na BMF & Bovespa.
- Ciampi, F. (2015). Corporate governance characteristics and default prediction modeling for small enterprises. An empirical analysis of Italian firms. *Journal of Business Research*, 68(5), 1012-1025.
- Costenaro, H. V. (2021). Comparação de desempenho dos modelos de previsão de insolvência entre aqueles criados após 2005 e modelos tradicionais.
- Crosato, L., Domenech, J., & Liberati, C. (2021). Predicting SME's default: Are their websites informative? *Economics Letters*, 204, 109888.
- Dalpiaz, F., Franch, X., and Horkoff, J. (2016). *istar 2.0 language guide*. Available at <https://arxiv.org/pdf/1605.07767.pdf>, recuperado em 10 de novembro, 2023

- Dresch, A., Lacerda, D. P., & Júnior, J.A.V. A. (2015). Design Science Research: método de pesquisa para avanço da ciência e tecnologia. Grupo A. <https://integrada.minhabiblioteca.com.br/books/9788582605530>
- Dresch, A.P. (2018). Desenvolvimento científico em design science para a engenharia de produção: formulações conceituais e análise empírica.
- Dornelas, J. C. A. (2008). Empreendedorismo: transformando ideias em negócios (2ª edição). Rio de Janeiro: Elsevier.
- Duarte, D.L., & Barboza, F. (2020). Forecasting Financial Distress with Machine Learning – A Review. *Future Studies Research Journal: Trends and Strategies*, 12, 528-574.
- Faceli, K., Lorena, A.C., Gama, J., & Carvalho, A.C. (2011). Inteligência artificial: uma abordagem de aprendizado de máquina.
- Filipe, S.F., Grammatikos, T., & Michala, D. (2016). Forecasting Distress in European SME Portfolios.
- Fitzpatrick, P. J. (1932). A comparison of the ratios of successful industrial enterprises with those of failed companies.
- Ferreira, E. B., Souza, V., A. L. F., Segura, L. C., & Abreu, R. (2022). Adoção da Metodologia Design Science Research nas Pesquisas das Micros, Pequenas e Médias Empresas
- Ferreira, F. F. P., Cruz, A. F. D., Pimenta, D. P., & Cunha, M. F. D. (2011). Estrutura de capital e alavancagem financeira em micro e pequenas empresas goianas.
- Ferreira, L. F. F., Oliva, F. L., Santos, S. A. D., Grisi, C. C. D. H., & Lima, A. C. (2012). Análise quantitativa sobre a mortalidade precoce de micro e pequenas empresas da cidade de São Paulo. *Gestão & Produção*, 19, 811-823.
- Géron, A. (2019). *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow. Conceitos, Ferramentas e Técnicas para a construção de Sistemas Inteligentes*. Rio de Janeiro: Alta Books
- Gevert, V. G., Lindebck Da Silva, A. C., Gevert, F., & Ales, V. T. (2010). Modelos de Regressão Logística, Redes Neurais e Support Vector Machine (SVMs) na Análise de Crédito a Pessoas Jurídicas. 1–26
- Giannopoulos, G., & Sigbjornsen, S. (2019). Prediction of Bankruptcy Using Financial Ratios in the Greek Market. *Theoretical Economics Letters*.
- Gil, A. C. (2019). *Métodos e Técnicas de Pesquisa Social*, 7ª edição. Grupo GEN. <https://integrada.minhabiblioteca.com.br/books/9788597020991>
- Girardi, R., & Leite, A. (2013). A Survey on Software Agent Architectures. *IEEE Intell. Informatics Bull.*, 14, 8-20.
- Gissel, J.L., Giacomino, D.E., & Akers, M.D. (2006). A Review of Bankruptcy Prediction Studies: 1930 to Present.
- Gregor, S.D., & Hevner, A.R. (2013). Positioning and Presenting Design Science Research for Maximum Impact. *MIS Q.*, 37, 337-355.
- Guégan, D., & Hassani, B.K. (2018). Regulatory learning: How to supervise machine learning models? An application to credit scoring. *The Journal of Finance and Data Science*.
- Guimarães, A. L. D. S., & Alves, W. O. (2009). Prevendo a insolvência de operadoras de planos de saúde. *Revista de Administração de Empresas*, 49, 459-471.
- Guimarães, A., & Moreira, T. B. S. (2008). Previsão de insolvência: um modelo baseado em índices contábeis com utilização da análise discriminante. *Revista de Economia Contemporânea*, 12, 151-1
- Hevner, A.R., & Chatterjee, S. (2010). Design Research in Information Systems.
- Hevner, A.R., March, S.T., Park, J., & Ram, S. (2004). Design Science in Information Systems Research. *MIS Q.*, 28, 75-105.
- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2008). Design science in information systems research. *Management Information Systems Quarterly*, 28(1), 6.

- Hinton, G.E., Deng, L., Yu, D., Dahl, G.E., Mohamed, A., Jaitly, N., Senior, A.W., Vanhoucke, V., Nguyen, P., Sainath, T.N., & Kingsbury, B. (2012). Deep Neural Networks for Acoustic Modeling in Speech Recognition. *IEEE Signal Processing Magazine*, 29, 82.
- Hirsch, G. (2013). Aplicabilidade dos modelos de previsão de insolvência nas micro e pequenas empresas.
- Horta, R. A. M., Alves, F. J. D. S., & Carvalho, F. A. A. D. (2014). Seleção de atributos na previsão de insolvência: aplicação e avaliação usando dados brasileiros recentes. *RAM. Revista de Administração Mackenzie*, 15, 125-151.
- Iqbal, S., Altaf, W., Muhammad, A., Mahmood, W., & Khan, M.U. (2016). Application of intelligent agents in healthcare: review. *Artificial Intelligence Review*, 46, 83-112.
- Jabeur, S.B., Gharib, C., Mefteh-Wali, S., & Arfi, W.B. (2021). CatBoost model and artificial intelligence techniques for corporate failure prediction. *Technological Forecasting and Social Change*, 166, 120658.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112). New York: Springer.
- Kanitz, S. C. (1978). Como prever falências. São Paulo: McGraw-Hill
- Kasgari, A.A., Salehnezhad, S.H., & Ebadi, F. (2013). A Review of Bankruptcy and its Prediction. *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 3, 274-277.
- Kezelj, T., & Gruenbichler, R. (2021). A Systematic Literature Review on Corporate Insolvency Prevention Using Artificial Intelligence Algorithms. *Journal of Strategic Innovation and Sustainability*.
- Kirrane, S. (2021). Intelligent software web agents: A gap analysis. *Journal of Web Semantics*, 71, 100659
- Kühl, N., Goutier, M., Hirt, R., & Satzger, G. (2019). Machine Learning in Artificial Intelligence: Towards a Common Understanding. *Hawaii International Conference on System Sciences*.
- Lacerda, D.P., Dresch, A.P., Proença, A., Antônio, J., & Júnior, V. (2013). Design Science Research: método de pesquisa para a engenharia de produção Design Science Research: a research method to production engineering.
- Lemos, L. F. B., & Soares, R. O. (2012). Previsão de insolvência em micro e pequenas empresas utilizando indicadores contábeis. *REGEPE Entrepreneurship and Small Business Journal*, 1(3), 104-134
- Lee, I., & Shin, Y. J. (2020). Machine learning for enterprises: Applications, algorithm selection, and challenges. *Business Horizons*, 63(2), 157-170.
- Lucena, P.S. (2003). Semantic Agent, uma plataforma para desenvolvimento de agentes inteligentes.
- Marconi, M. A.; & Lakatos E. M. (2021). Fundamentos da Metodologia Científica. 9ªed. São Paulo: Atlas
- Marland, S. (2015). *Machine learning: an algorithmic perspective* (2a ed). CRC Press: Taylo & Francis Group
- Mantas, C.J., & Abellán, J. (2014). Credal Decision Trees to Classify Noisy Data Sets. *Hybrid Artificial Intelligence Systems*.
- Mateos-Ronco, A., & Mas, Á.L. (2011). Developing a business failure prediction model for cooperatives: Results of an empirical study in Spain. *African Journal of Business Management*, 5, 10565-10576.
- Melo, L.L., Bortoluzzo, A.B., & Venezuela, M.K. (2022). Relevância do fluxo de caixa operacional para previsão de falência das empresas brasileiras abertas. *Revista de Gestão dos Países de Língua Portuguesa*.
- Mendes, I.O., Frega, J.R., & Silva, W.V. (2015). Fatores Determinantes para Definição de Modelos de Insolvência: Uma Revisão de Paradigma
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill Science/Enginner/Math

- Moraes, M.B., & Nagano, M.S. (2009). Sistemas de informação contábeis: uma abordagem orientada a objetos com agentes inteligentes. *Jistem Journal of Information Systems and Technology Management*, 6, 463-482.
- Muñoz-Izquierdo, N., Camacho-Miñano, M., Segovia-Vargas, M.J., & Pascual-Ezama, D. (2018). Is the External Audit Report Useful for Bankruptcy Prediction? Evidence Using Artificial Intelligence. *International Journal of Financial Studies*.
- Nunes, R. V., & Sales, G. A. W. (2020). Quais as Condições de Liquidez e Insolvência das Empresas Estatais S/A não Financeiras? *Revista de Contabilidade e Gestão Contemporânea UFF*, 3(1), 76-87.
- Pal, C., Leon, F., Paprzycki, M., & Ganzha, M. (2020). A Review of Platforms for the Development of Agent Systems. *ArXiv*, abs/2007.08961.
- Prado, J. W., Vilamaior, A. G., Campos, A. C., & do Nascimento, T. B. P. (2020). Previsão Da Insolvência Empresarial Utilizando Redes Neurais Artificiais. *Revista Gestão e Desenvolvimento*, 17(2), 136-162.
- Peffer, K., Tuunanen, T., Rothenberger, M.A., & Chatterjee, S. (2007). A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, 24, 45 - 77.
- Pereira, V. S., & Martins, V. F. (2015). Estudos de previsão de falências—uma revisão das publicações internacionais e brasileiras de 1930 a 2015. *Revista Contemporânea de Contabilidade*, 12(26), 163-196.
- Pimentel, J. and Castro, J. (2018). piStar Tool-A Pluggable Online Tool for Goal Modeling. In *Proceeding of the IEEE 26th International Requirements Engineering Conference*. 13, 16
- Putnam, H. (Ed.). (1975). *Minds and machines*. In *Philosophical Papers* (Vol. 2, pp. 362–385). chapter, Cambridge: Cambridge University Press.
- Qu, Y., Quan, P., Lei, M., & Shi, Y. (2019). Review of bankruptcy prediction using machine learning and deep learning techniques. *International Conference on Information Technology and Quantitative Management*.
- Rezende, C. V., de Almeida, N. S., & Lemes, S. (2015). Impacto das IFRS na assimetria de informação evidenciada no mercado de capitais brasileiro. *Revista de Contabilidade e Organizações*, 9(24), 18-30.
- Ribeiro, M., Singh, S., & Guestrin, C. (2016). “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
- Rosário, E. M. (2012). *Manual de direito da insolvência*. Almedina.
- Russell, S. J., & Norvig, P. (2022). *Inteligência Artificial: Uma Abordagem Moderna* (4th ed.). Grupo GEN. <https://integrada.minhabiblioteca.com.br/books/9788595159495>
- SaaS. (2017). The Enterprise AI Promise: Path to Value. *Report*, 1–26.
- Sacramone, M. B., Waisberg, I., Nunes, M. G., & Scardoa, R. (2020). O processo de insolvência e o tratamento das microempresas e empresas de pequeno porte em crise no Brasil. *Pensar—Revista de Ciências Jurídicas*, 25(3), 2317-2150.
- Sales, G. A. W., & Nunes, R. V. (2020). Quais as Condições de Liquidez e Insolvência das Empresas Estatais S/S não Financeiras. *Revista de Contabilidade Contemporânea*, 1–12
- Santos, J. A. D. (2012). *Metodologia Científica*. 2ª ed. São Paulo: Cengage Learning.
- Santos, P. V. S., Lima, N. V. M., & Carvalho, L. F. (2018). Um estudo acerca da sobrevivência de micro e pequenas empresas (MPes). *Simpósio de Engenharia de Produção do Vale do São Francisco—XIX SEP/VSF, Juazeiro, SEPRONE*.
- Santos, V. D., Bennert, P., Figueiredo, G. H., & Beuren, I. M. (2018). Uso dos instrumentos de Contabilidade Gerencial em pequenas e médias empresas e seu fornecimento pelo escritório de Contabilidade. *Pensar contábil*, 20(71).
- Santos, A. S. D. (2021). Previsão de insolvência corporativa: uma análise de empresas brasileiras de capital aberto por meio de aprendizado de máquina.

- Sarkar, S., Weyde, T., Garcez, A.S., Slabaugh, G.G., Dragicevic, S., & Percy, C. (2016). Accuracy and Interpretability Trade-Offs in Machine Learning Applied to Safer Gambling. CoCo@NIPS.
- Scarpel, R. A. (2008). Previsão de insolvência de empresas utilizando support vector machine. *Revista de Economia e Administração*, 7(3).
- Sebrae. (2018). Pesquisa Sebrae As Fintechs e os Pequenos Negócios.
- Silva, J.C., Wienhage, P., Souza, R.P., Bezerra, F.A., & Lyra, R.L. (2012). Capacidade Preditiva de Modelos de Insolvência: com base em Números Contábeis e Dados Descritivos. *Revista de Educação e Pesquisa em Contabilidade*
- Silva, C. C. (2017). Recuperação Judicial de Empresas e sua Efetividade no Brasil. *Novos Direitos*, 4(1), 37-47.
- Silva, L.D., Meneguzzi, F., & Logan, B.S. (2020). BDI Agent Architectures: A Survey. *International Joint Conference on Artificial Intelligence*.
- Silva, R.D.S. E., Kai, F. O., & Trevisan, N. M. et al. (2021). Customer Experience. Grupo A. <https://integrada.minhabiblioteca.com.br/books/9786556900490>
- Soares, P. H., Faria, J. A., & Oliveira, J.J. (2019). Análise das Demonstrações Contábeis: uma Proposta de Referência de Índices de Liquidez para Empresas Brasileiras. *ConTexto-Contabilidade em Texto*, 19(43)
- Soares, R. A., & Rebouças, S. M. D. P. (2015). Avaliação do desempenho de técnicas de classificação aplicadas à previsão de insolvência de empresas de capital aberto brasileiras. *Revista ADM. MADE*, 18(3), 40-61.
- Soares, C. S., Marin, L. O., Degenhart, L., & Krüger, C. (2021). Aplicação de Modelos de Previsão de Insolvência nas Empresas do Setor Aéreo Brasileiro. *Revista de Contabilidade e Controladoria*, 13(2).
- Souza, A. E., & Correa, H. L. (2014). Indicadores de desempenho em pequenas e médias empresas. *Revista Pensamento Contemporâneo em Administração*, 8(3), 118-136.
- Schwab, K. (2018). A quarta revolução industrial. (1ª edição). Edipro.
- Tinoco, M.H. (2013). Financial distress and bankruptcy prediction using accounting, market and macroeconomic variables.
- Tinoco, M.H., & Wilson, N. (2013). Financial distress and bankruptcy prediction among listed companies using accounting, market, and macroeconomic variables. *International Review of Financial Analysis*, 30, 394-419.
- Tobback, E., Bellotti, T., Moeyersoms, J., Stankova, M., & Martens, D. (2017). Bankruptcy prediction for SMEs using relational data. *Decision Support System.*, 102, 69-81.
- Volk, M. (2013). Estimating Probability of Default and Comparing It to Credit Rating Classification by Banks. *Corporate Governance & Economics eJournal*.
- Von Luxburg, U., & Schölkopf, B. (2011). Statistical learning theory: Models, concepts, and results. In *Handbook of the History of Logic* (Vol. 10, pp. 651-706). North-Holland.
- Wang, W., & Zhou, Y. (2022). A Double Penalty Model for Ensemble Learning. *Mathematics*.
- Weiss, G., Braubach, L. & Giorgini, P. (2010). *Intelligent Agents*.
- Wooldridge, M., & Jennings, N.R. (1995). Intelligent agents: theory and practice. *The Knowledge Engineering Review*, 10, 115 - 152.
- Wooldridge, M. J. (2009). *An Introduction to Multiagent Systems* (2nd ed.): John Wiley & Sons.
- Wu, S., Irsoy, O., Lu, S., Dabrowski, V., Dredze, M., Gehrmann, S., Kambadur, P., Rosenberg, D., & Mann, G. (2023). BloombergGPT: A Large Language Model for Finance. *ArXiv*, abs/2303.17564.

8. APÊNDICES

8.1 Apêndice A – Instrumento de Validação da Pesquisa Jornada de Validação



Etapas de Detalhadas de Validação da Solução Proposta



8.2 Apêndice B – Formulário de Feedback após Validação da Pesquisa

Formulário de Feedback de Validação

Esse é um formulário para que você possa nos fornecer um *feedback* (são apenas dez questões) sobre as etapas de validação do projeto de pesquisa do mestrado profissional, referente a plataforma de diagnóstico de saúde financeira para Micro e Pequenas Empresas.

Qual sua função/cargo de atuação? (Selecione mais de uma opção, caso atue em mais de uma função).

- ☐ Analista Financeiro (a)
- ☐ Contador (a)
- ☐ Advogado (a)
- ☐ Consultor (a) Financeiro

- ☐ Empreendedor (a) / Empresário
- ☐ Executivo de Finanças (CFO)
- ☐ Assistente Financeiro
- ☐ Coordenador (a) Financeiro
- ☐ Micro Empresário (a)
- ☐ Outros

Como você avalia o processo de obtenção dos dados econômico-financeiros?

- ☐ Houve dificuldade em obter as informações contábeis
- ☐ A integração com o contador foi eficiente e fácil de realizar
- ☐ Não houve dificuldade em obter as informações

Como foi o processo de preenchimento das informações de métricas e indicadores econômico-financeiros no modelo disponibilizado pela plataforma?

- ☐ Achei fácil de preencher as informações
- ☐ Foi difícil preencher e entender algumas informações
- ☐ Não preenchi as informações

Como foi a sua experiência na etapa de conferência dos dados?

- ☐ Os dados foram apresentados de maneira clara
- ☐ Identificou algum problema ou discrepância nos dados carregados
- ☐ A visualização estava de forma intuitiva
- ☐ A visualização não está de forma intuitiva

Como você avalia a etapa de resultado de diagnóstico financeiro da empresa?

- ☐ As informações foram apresentadas de maneira compreensível
- ☐ A previsão da situação financeira da empresa atendeu às minhas expectativas
- ☐ A predição da situação financeira foi aderente com momento atual da empresa
- ☐ O diagnóstico de predição da situação financeira foi incorreto

Como você avalia a etapa de tratamento proposto?

- ☐ As recomendações para melhorar a saúde financeira do negócio são claras intuitiva
- ☐ As recomendações para melhorar a saúde financeira do negócio são complexas
- ☐ As recomendações de para melhorar a saúde financeira do negócio são muito genéricas
- ☐ As recomendações de para melhorar a saúde financeira do negócio estão de acordo com situação atual da empresa

Como você avalia a opção de monitoramento de desempenho do negócio?

- ☐ Receber alertas foi útil para manter-se informado sobre a saúde financeira do negócio
- ☐ O acompanhamento automático de métricas e/ou indicadores financeiros auxilia na gestão do negócio e/ou tomada decisão
- ☐ Receber alertas de forma automática não auxilia na tomada de decisão

Como você avalia a etapa de decisão estratégica como base nas informações fornecidas pela plataforma?

- ☐ As informações fornecidas pela plataforma auxilia na tomada de decisão estratégica no negócio
- ☐ Levaria em consideração as informações de diagnóstico, tratamento e alertas para tomar decisões mais assertiva para o negócio
- ☐ Não levaria em consideração as informações de diagnóstico financeiro, tratamento e alertas para tomar decisões

Qual foi sua experiência de navegação na plataforma, houve dificuldade em alguma etapa?

- ☐ Não houve dificuldade a navegação na plataforma foi intuitiva
- ☐ Houve alguma dificuldade em encontrar as informações necessárias
- ☐ Dificuldade na etapa 1 - Obtenção dos dados
- ☐ Dificuldade na etapa 2 - Acessar plataforma
- ☐ Dificuldade na etapa 3 - Preparação dos dados para diagnóstico
- ☐ Dificuldade na etapa 4 - Carregamentos dos dados
- ☐ Dificuldade na etapa 5 - Conferência dos dados carregados
- ☐ Dificuldade na etapa 6 - Solicitação dos diagnóstico de saúde financeira
- ☐ Dificuldade na etapa 7- Resultado do diagnóstico de saúde financeira
- ☐ Dificuldade na etapa 8 - Recomendação de tratamento financeiro
- ☐ Dificuldade na etapa 9 - Monitoramento de desempenho

Descreva o que você achou da plataforma, caso tenha alguma sugestão de melhoria, fique à vontade para nos dizer.

Texto livre (opcional)

9. ANEXOS

RELATÓRIO DA CONSULTORIA SEBRAE – CONSULTOR I

Apontamentos do cliente (observações do cliente):
ANÁLISE DE PROJETO

Diagnóstico do consultor:

O Rafael apresentou sua tese de mestrado, onde no decorrer de sua apresentação foram levantados pontos importantes vistos de fora.


Resumo dos assuntos discutidos:

- Indicadores de performance financeiros

Encaminhamento/recomendações:

- Enviado ao cliente a planilha de indicadores financeiros.

PLANILHA DE INDICADORES FINANCEIROS – GRAFICOS DE LIQUIDEZ



INDICADORES DE LIQUIDEZ - EXEMPLO ILUSTRATIVO

CAPACIDADE DE LIQUIDAR AS DIVIDAS NO CURTO PRAZO

Liquidez	1º TRIMESTRE 2022	2º TRIMESTRE 2022	3º TRIMESTRE 2022	4º TRIMESTRE 2022	analise horizontal
Ativo Circulante	1.359	1.855	2.158	955	
Estoques	522	618	340	382	
Disponibilidades	427	375	501	380	
Ativo Realizável a Longo Prazo	-	-	-	-	
Passivo Circulante	269	311	271	30	
Passivo Realizável a Longo Prazo	-	-	-	-	
Liquidez Corrente	5,06	5,97	7,97	31,40	18%
Liquidez Seca	3,12	3,98	6,72	18,84	28%
Liquidez Imediata	1,59	1,21	1,85	12,49	-24%

RELATORIO DA CONSULTORIA SEBRAE – CONSULTOR II

Apontamentos do cliente (observações do cliente): Demanda recebida (SIC): SUPORTE DE ESPECIALISTA EM FINANÇAS PARA MICRO E PEQUENAS EMPRESAS
Diagnóstico do consultor: - escritório de contabilidade - mestrado em controladoria, finanças - presta consultoria aos pequenos negócios Dor: está fazendo pesquisa do mestrado e busca ajuda de especialistas para acompanhamento e validação do projeto de pesquisa
Resumo dos assuntos discutidos: - a pedido do cliente, o atendimento foi direcionado para que a consultoria pudesse contribuir com análise e considerações sobre sua pesquisa do mestrado. - orientações e discussão sobre a estrutura do DRE gerencial
Encaminhamento/recomendações: - compartilhamento de material complementar * Material sobre DRE

Mogi das Cruzes, 06 de dezembro de 2023.

GUIA DE PARA INTERPRETAÇÃO E UTILIZAÇÃO DO DRE GERENCIAL

DRE (Demonstrativo do Resultado do Exercício)

Levando-se em consideração que o LUCRO é o principal objetivo das empresas, o DRE é de extrema importância para que possamos avaliar o desempenho da empresa e principalmente dos seus gestores.

A estrutura do DRE deve ser padrão para todas as empresas, deve-se apenas personalizar se o item e/ou conta for representativo no resultado. Devemos levar em consideração nesses casos que, “Nem sempre o que serve para uma empresa é bom para a outra. Há diferenças de legislação tributária, de desempenho por setor de atividade, de sazonalidade, entre outros fatores”.

Se a empresa diagnosticada for uma franquia verifique o modelo do DRE entregue pela franqueadora, pois o franqueador já conhece bem o negócio e disponibilizará ao empreendedor um modelo de atuação definido, com referências de resultados e métricas. “Esse material auxiliará para a construção de uma DRE real”. Se não houver um modelo, utilize os dados disponibilizados pelo franqueador; histórico de vendas, dados sobre o crescimento do setor, a concorrência; o que ajudará a melhorar o relatório e permitirá projeções dentro da realidade do negócio.

DICA: É importante que o DRE demonstre corretamente o dia-a-dia da empresa, portanto se faz necessário a separação da Pessoa Física (proprietário[s]) da Pessoa Jurídica (empresa), como exemplo a parcela do financiamento de um bem pessoal (veículo) entre as despesas da empresa distorce o resultado final e a obriga a desembolsar valores que não dizem respeito diretamente ao dia-a-dia da operação. Qualquer distorção na montagem da DRE irá afetar a interpretação dos resultados e o diagnóstico da situação da empresa.

Conceito do DRE

O DRE é um relatório Contábil elaborado em conjunto com o Balanço Patrimonial e descreve as operações realizadas pela empresa em um determinado período (Exercício Social). Deve ser elaborada obedecendo o princípio do Regime de Competência (tudo que compete ao mês: Receitas e Despesas, devem ser lançados no próprio mês, mesmo não recebidas ou pagas no próprio mês).

Objetivo do DRE

Demonstrar a formação do resultado líquido em um exercício através do confronto das receitas e despesas, gerando informações significativas para tomada de decisão.

Análise do DRE

A análise do DRE é extremamente simples. O DRE permite observar, no tempo o progresso ou não e tendências sobre as seguintes informações:

Análise Vertical*, verifica quanto, percentualmente, cada conta de custo e despesa (individualmente) impacta no resultado das vendas da empresa. É importante monitorar se os percentuais permanecem estáveis e identificar as contas que estão se distanciando dos valores orçados tomando medidas imediatas para colocá-las de volta aos parâmetros definidos pelo orçamento original da empresa.

Análise Horizontal*, verifica o impacto das contas de custos e despesas proporcionalmente ao aumento ou diminuição das receitas de vendas. A análise horizontal, monitora, mês a mês, a produtividade e a rentabilidade.

* Os resultados são apresentados num formato padrão e complementados por percentuais calculados através da relação entre as diversas contas e a receita de vendas possibilitando uma análise de tendências.

ITENS E/OU CONTAS

1. FATURAMENTO

Demonstra a evolução ou não das receitas de vendas no tempo e sua tendência, permitindo também a análise conforme as respectivas fontes de receita (Vendas de produtos/mercadorias e/ou serviços), segmentos de mercado e regiões e etc. **Importante mapear e identificar as fontes de receitas da empresa, pois assim fica mais fácil projetar o faturamento ou receita do negócio (Orçado X Realizado);** Deve-se lançar todas as vendas efetuadas à vista e à prazo “por competência”, ou seja, tudo que compete ao mês (receitas de vendas) deve ser lançado no próprio mês. O lançamento nos campos: Vendas à vista ou à Prazo auxiliará a compreender/verificar como ocorrem as vendas da empresa.

2. CUSTO DOS PRODUTOS/MERCADORIAS/SERVIÇOS VENDIDOS

Demonstra a composição dos custos relativos aos produtos (CPV – Custo do Produto Vendido) /mercadorias (CMV – Custo da Mercadoria Vendida) ou serviços (CSV – Custo do Serviço Vendido). A composição dos custos é essencial para formação de preços e apuração da margem de contribuição do produto/mercadoria/serviço. Sendo que, a correta apuração de custos (CPV/CMV/CSV) é muito importante para a verificação do lucro real obtido com as vendas;

3. DESPESAS VARIÁVEIS

São aquelas que variam conforme o volume de vendas.



DICA: Despesas variáveis - Variam de acordo ou proporcionalmente com o volume de vendas (geralmente são despesas diretas).

3.1. IMPOSTOS INCIDENTES SOBRE VENDAS – Permite a análise de acréscimos e reduções conforme o regime tributário em contrapartida ao Planejamento Tributário efetuado pela empresa. A estrutura fiscal e tributária pode, ao mesmo tempo, melhorar a rentabilidade ou simplesmente inviabilizar os preços de seus produtos e serviços;

3.2. DESPESAS DE VENDAS (comissões, fretes, seguro de transporte, propaganda, taxas do cartão de débito/crédito e etc.) - Demonstra os valores gastos no processo (anterior e posterior) de vendas da empresa. Financeiramente em relação ao pagamento das comissões sobre as vendas é interessante atrelar o pagamento do percentual da comissão à forma de recebimento; Para reduzir despesas da força de vendas podemos automatizar o seu processo, como exemplo a comunicação pode ser efetuada via WhatsApp e os pedidos podem ser enviados por e-mail (reduz o índice de pedidos enviados errados) e etc; A Taxa do cartão de débito/crédito cobrada pelas operadoras de cartões influencia diretamente na formação do preço de venda dos produtos/mercadorias/serviços. A concentração das vendas em uma das operadoras de crédito é uma alternativa para a negociação de taxas mais baixas para a operação da empresa. Também verifique qual opção de pagamento (débito ou crédito) representa maior volume na sua empresa para concentrar a negociação nessa opção, mesmo que o resultado da negociação represente uma taxa maior na opção de crédito pouco utilizada. Negocie em conjunto, consulte os lojistas da sua rua e/ou região antes de negociar com a(s) operadora(s) de crédito, verifique quais são as bandeiras mais utilizadas e as taxas cobradas. Essa pesquisa lhe trará argumentos de negociação com a operadora escolhida, outra forma é verificar se há acordos em conjunto com os lojistas da rua e/ou região. É importante ter todas as informações financeiras organizadas para uma melhor negociação; Fidelize os clientes antigos, com a necessidade de cortar custos, mantenha o foco nos clientes mais leais à marca ou que têm maior potencial de compra e reduza o investimento em novos nichos ou em consumidores que não conhecem o seu produto/mercadoria/serviço, vale lembrar que, “custa” muito mais a prospecção de novos clientes do que manter os antigos; Redes Sociais, como exigem um baixo investimento, as redes sociais podem ser novos canais para a divulgação do produto/mercadoria/serviço e de promoções da empresa; Se for necessário reduzir o investimento em Marketing Concentre-se no que for estratégico para a empresa, não faça cortes horizontais reduzindo proporcionalmente todos os produtos/mercadorias/serviços. Calcule quais itens contribuem mais para o lucro da empresa e corte no orçamento os produtos marginais, que são responsáveis pela menor parte do lucro; Faça Parcerias, que pode ser com o seu revendedor para divulgar os produtos/mercadorias/serviços e aumentar a receita sem a necessidade de mais investimentos em marketing e/ou em uma “marca parceira” – Também uma alternativa para gastar menos com publicidade e marketing é unir-se a outra marca e dividir custos e despesas;

4. MARGEM DE CONTRIBUIÇÃO OU LUCRO BRUTO – Demonstra o crescimento ou decréscimo da Margem de Contribuição, permitindo verificar e identificar seu principal motivador. Com os valores obtidos pelo cálculo da margem de contribuição é possível saber exatamente quanto sua empresa precisa vender para chegar ao lucro ou para atingir os valores orçados. Além disso, também é possível avaliar isoladamente qual é a contribuição de um determinado produto, mercadoria ou serviço, com isso é possível comparar, por exemplo, a margem de contribuição de um produto, mercadoria ou serviço com o da empresa toda para obter melhores resultados. Importante, ao conhecer exatamente quanto a sua empresa lucra ou não é possível adaptar as estratégias e, portanto, melhorar os resultados da empresa. Dessa maneira, a margem de contribuição pode ajudar na tomada de decisões para aumentar as vendas, trocar os fornecedores ou reajustar os preços, garantindo a saúde financeira da empresa.

5.DESPESAS FIXAS (Administrativas e bancárias)



São aqueles que permanecem inalteradas, independentemente do volume de vendas ou produção.

Demonstra os demais gastos efetuados pela empresa que não compõem o custo dos produtos, das mercadorias nem dos serviços vendidos. As despesas operacionais fixas são, por conseguinte, aqueles gastos necessários para a exploração das atividades da empresa.

DICA: É importante verificar e analisar a sua representatividade sobre a receita das vendas (análise vertical) e a sua evolução no tempo (análise horizontal), auxiliando em programas de redução de despesas da empresa. Normalmente para a implantação de programas de controle e redução de custos e despesas, pedimos que os custos e as despesas da empresa sejam lançados em uma planilha por um período mínimo de 12 meses para que se possa verificar a evolução dos mesmos no tempo e montar estratégias para o seu controle e/ou redução.

EXEMPLOS:

5.1. DESPESAS COM PESSOAL - Permite a verificação e análise dos gastos da empresa com salários/encargos e benefícios dos seus funcionários, sendo que, é muito comum a empresa não montar um fundo de reserva para demissões dos funcionários, ficando refém principalmente de funcionários que não correspondem operacionalmente e deveriam ser substituídos, pois nesses casos a empresa não tem reservas para utilizar no processo de demissão ocasionando problemas no seu fluxo de caixa. **Importante** também nos casos de substituição de funcionários colocar na “ponta do lápis” o cálculo da rescisão, pois devemos levar em consideração não somente o que é mensurável (valor da rescisão). Deve-se somar a isso os gastos com contratação e treinamento do novo funcionário, se a intenção for trocar funcionários antigos (salários maiores) por salários menores, também deve-se considerar o tempo que estes levarão para chegar ao nível de conhecimento dos demitidos. **Outro erro comum** é, a empresa também não montar um fundo de reserva para o pagamento do 13º. Salário e Férias dos funcionários. Em relação ao 13º. Salário, a empresa por não provisioná-lo durante o ano acaba ficando refém das suas vendas de final de ano ou de instituições financeiras (empréstimos) e que neste caso acarreta despesas financeiras para a empresa. **Como resolvemos isso?** Minimamente para amenizar o problema a empresa deve formar uma reserva a partir do valor da sua folha de pagamentos somado a mais 1/3 CF (Constituição Federal) de férias. Pega-se o valor total divide-se por 12 (meses) e vem reservando 1/12 avos mensalmente em uma aplicação financeira para ser utilizado em rescisões (se necessário), pagamento do 13º. Salário e das Férias (devemos levar em consideração que as férias nada mais é do que a antecipação do salário do funcionário com o acréscimo do 1/3 determinado na Constituição Federal). Importante também orçar o valor das despesas com pessoal levando-se em consideração a inflação do período (reajuste salarial) e os benefícios que constam no acordo coletivo da categoria dos funcionários da sua empresa.

OUTRAS DICAS para a redução das despesas com pessoal – **Otimize a jornada de trabalho**, reveja os processos; **Adote o Banco de Horas**, uma alternativa para reduzir os gastos com horas extras; **Verifique a cesta de benefícios colocada à disposição dos seus funcionários, uma pergunta que deve ser feita:** Será que os meus funcionários utilizam todos os benefícios que a empresa coloca à disposição? Pode ser uma alternativa para a redução de despesas (não esqueça de verificar o acordo coletivo da categoria); **Férias Coletivas**, pode ser feito no final do ano ou quando há sazonalidade na demanda pelos produtos ou serviços da empresa. Com esse procedimento a empresa economiza com as despesas de manutenção da sua infraestrutura (água, luz, telefone e etc...); **Terceirização**, o processo de terceirização pode ser uma maneira de economizar com pessoal, desde que as funções não incluam a atividade-fim da empresa E; **Cuidado com as formas de contratação**, deve-se sempre tomar cuidado com as formas de contratação dos funcionários para evitar despesas com multas e processos trabalhistas (passivo trabalhista). **Importante** salientar que um passivo trabalhista elevado pode inviabilizar uma empresa.

5.2. DESPESAS BANCÁRIAS – Demonstra as despesas operacionais relativas ao relacionando da empresa com o banco, como exemplo, o **Aluguel de uma máquina de cartão de débito/crédito**. Quais vantagens a empresa tem no aluguel: Reduz a necessidade de capital de giro próprio para financiamento ao cliente; Evita burocracia na elaboração de cadastro e da avaliação de risco para as vendas; Elimina os riscos de inadimplência (comuns nos cheques); Evita perdas com assaltos, fraudes com cheques e manuseios de valores. **Quais desvantagens** a empresa tem no aluguel: as taxas cobradas (aluguel, administração, antecipação de recebíveis, adesão) e o custo da linha telefônica para a sua utilização. Podemos reduzir essa despesa ampliando a possibilidade de novos negócios através da utilização da maquininha, como recarga de celulares, vale pedágio, gás eletrônico, etc; e através de pesquisa e negociação de bandeiras e taxas.

OUTRAS DICAS para a redução das despesas bancárias - Visualize a movimentação financeira da sua empresa pelo menos uma vez por mês, para saber a real necessidade de serviços bancários, e economizar. Sempre que não se conhece essa demanda, cria-se despesas bancárias dispensáveis; É também importante comparar entre os diversos bancos do mercado os pacotes de serviços voltados à pessoa jurídica, conhecendo os produtos desses agentes, você passa a ter base para negociar valores mais atrativos para o seu negócio ou até mesmo o poder, se necessário, de optar pela troca do parceiro financeiro; Lembre-se de conferir (conciliar) o extrato bancário da empresa, para que não ocorram despesas bancárias desnecessárias ou indevidas e; Faz-se fundamental consultar periodicamente o Sistema de Divulgação de Tarifas dos Serviços Financeiros da [Federação Brasileira dos Bancos \(FEBRABAN\)](#) (para pessoas jurídicas e físicas). Assim fica mais fácil comparar as taxas de cada instituição financeira.

- 5.3. **DESPESAS COM CUSTO DE OCUPAÇÃO (“Taxa de Esforço”)** – Demonstra as despesas operacionais relativas as verbas de locação, que para as lojas de Shopping são as despesas de aluguel, condomínio, fundo de promoção, IPTU, luz, água e ar condicionado e para as lojas de rua são as despesas de aluguel, IPTU, luz, água, ar condicionado e segurança. **DICA:** É importante verificar e analisar a sua representatividade sobre a receita das vendas (análise vertical) e a sua evolução no tempo (análise horizontal), podendo auxiliar em programas de redução de despesas da empresa. A verificação e análise também é importante porque demonstra se a operação da loja está custando mais ou menos do que o orçado, e, conseqüentemente, se está atingindo o resultado orçado e/ou desejado para aquela loja.
6. **RESULTADO OPERACIONAL** – Demonstra a evolução e projeção do lucro ou prejuízo da operação conforme as tendências observadas nos itens anteriores. O resultado operacional mostra a capacidade da empresa em gerar caixa através da própria operação, sem contar com outros tipos de receitas, como exemplo as financeiras: aplicações financeiras, valorização do dólar; engenharia financeira, fiscal e tributária. Uma operação saudável possui margem de contribuição suficiente para pagar as despesas fixas e gerar caixa.
7. **DESPESAS E/OU RECEITAS FINANCEIRAS** – Permite monitorar o nível de endividamento ou estratégia de financiamento da empresa.
8. **RESULTADO LÍQUIDO DO EXERCÍCIO** – Demonstra a capacidade de geração de caixa e possível necessidade de redimensionamento preventivo da exigência do seu fluxo de caixa. **DICA:** Para o **LUCRO** da empresa, utilizar a **regrinha do 1/3**. 1/3 do lucro, reinvestida na empresa; 1/3 do lucro forme o capital de giro e 1/3 do lucro destine aos sócios (dividendos).

EXEMPLO DA ESTRUTURA DO DRE GERENCIAL

DEMONSTRATIVO DE RESULTADO DO EXERCÍCIO - D.R.E.						
	MÊS	ANO	VALOR	%		
Faturamento	Vendas a vista		R\$ 200.000,00	100%		
	À Prazo		R\$ -	0%		
	(+) VENDAS/FATURAMENTO		R\$ 200.000,00	100%		
CMV	(-) CUSTO DA MERCADORIA VENDIDA		R\$ 180.000,00	90%		
	Cálculo do Custo da Mercadoria Vendida					
	Valor pago pelas mercadorias (incluindo todos os impostos)					
	(=) RESULTADO COM VENDAS		R\$ 20.000,00	10%		
Despesas Variáveis	Impostos		R\$ 500,00	0%		
	Comissões sobre Vendas			0%		
	Taxa Administradora de cartão		R\$ 1.016,00	1%		
	Frete			0%		
				0%		
	(+) VENDAS/FATURAMENTO		R\$ 1.516,00	1%		
	MARGEM DE CONTRIBUIÇÃO ou LUCRO BRUTO		R\$ 178.484,00	9%		
Cálculo da Margem de Contribuição						
	Vendas / Faturamento	(+)	R\$ 200.000,00	100%		
	Custo da Mercadoria Vendida (CMV)	(-)	R\$ 180.000,00	90%		
	Despesas Variáveis	(-)	R\$ 1.516,00	1%		
	Margem de Contribuição >>>>>>>>>>		R\$ 18.484,00	9%		
Margem de Contribuição: Indica o % ou valor que sobra das vendas, menos o custo direto variável e as despesas variáveis. Margem de Contribuição representa o quanto a empresa tem para as despesas fixas e gerar o lucro líquido						
Despesas Fixas	Água			0,0%		
	Energia Elétrica			0,0%		
	Aluguel + IPTU			0,0%		
	Salários			0,0%		
	FGTS - Salários			0,0%		
	INSS - Empresa - Salários			0,0%		
	Provisão 13º e Férias + 1/3			0,0%		
	FGTS - Provisão 13º e Férias + 1/3			0,0%		
	INSS - Empresa - Provisão 13º e Férias + 1/3			0,0%		
	Provisão Multa FGTS - Dispensa sem justa causa			0,0%		
	Vale-Transporte			0,0%		
	Cesta Básica			0,0%		
	Plano de Saúde			0,0%		
	Pró-Labore			0,0%		
	Encargos sobre Pró-Labore			0,0%		
	Contador			0,0%		
	Telefone			0,0%		
	Internet			0,0%		
	PDD - Provisão para Devedores Duvidosos			0,0%		
	Material de Consumo			0,0%		
	Serviços de Terceiros			0,0%		
	Seguros			0,0%		
	Alarmes			0,0%		
	Combustível			0,0%		
	Manutenção de Veículo			0,0%		
	Programa de Computador (Software)			0,0%		
	Marketing			0,0%		
	Despesas Bancárias			0,0%		
	Aluguel Máquina de cartão			0,0%		
	Outras....			0,0%		
	DESPESAS FIXAS			R\$ 12.000,00	6%	
	(=) RESULTADO OPERACIONAL (LUCRO/PREJUÍZO)			R\$ 6.484,00	3%	
PONTO DE EQUILÍBRIO			R\$ 129.842,03	65%		
Cálculo Do Ponto de Equilíbrio						
	Despesas Fixas		R\$ 12.000,00			
	Margem de Contribuição (/)		9%			
	Ponto de Equilíbrio >>>>>>>>>>		R\$ 129.842,03			
Ponto de Equilíbrio: Indica o valor ou quantidade que a empresa precisa vender para cobrir o custo das mercadorias vendidas, as despesas variáveis e as despesas fixas.						
(-) DESPESAS FINANCEIRAS			R\$ 5.700,00	3%		
Juros Bancários				0%		
Amortizações (Financiamento e Dívidas)			R\$ 5.700,00	3%		
(=) RESULTADO OPERACIONAL (LUCRO/PREJUÍZO)			R\$ 160.784,00	80%		
PONTO DE EQUILÍBRIO - APÓS DESPESAS FINANCEIRAS			R\$ 191.516,99	96%		
Cálculo Do Ponto de Equilíbrio						
	Despesas Fixas (+)		R\$ 12.000,00			
	Despesas Financeiras (+)		R\$ 5.700,00			
	Margem de Contribuição (/)		9%			
	Ponto de Equilíbrio >>>>>>>>>>		R\$ 191.516,99			
Ponto de Equilíbrio: Indica o valor ou quantidade que a empresa precisa vender para cobrir o custo das mercadorias vendidas, as despesas variáveis e as despesas fixas.						

