



Universidade de Brasília
Instituto de Ciências Exatas
Departamento de Ciência da Computação

***Machine Learning* na Prevenção de Paralisações em
Obras Públicas:**

Estudo de Caso em Infraestrutura Educacional

Lucas Fonseca Gonçalves

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Orientador
Prof. Dr. Ari Mariano

Brasília
2025

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

G635m Gonçalves, Lucas Fonseca
Machine learning na prevenção de paralisações em obras públicas: estudo de caso em infraestrutura educacional / Lucas Fonseca Gonçalves; orientador Ari Melo Mariano. Brasília, 2025.
169 p.

Dissertação(Mestrado Profissional em Computação Aplicada) Universidade de Brasília, 2025.

1. Modelo preditivo. 2. Machine learning. 3. Infraestrutura educacional. 4. Obras públicas. 5. CRISP-DM. I. Mariano, Ari Melo, orient. II. Título.



Universidade de Brasília
Instituto de Ciências Exatas
Departamento de Ciência da Computação

***Machine Learning* na Prevenção de Paralisações em
Obras Públicas:**

Estudo de Caso em Infraestrutura Educacional

Lucas Fonseca Gonçalves

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Prof. Dr. Ari Melo Mariano (Orientador)
PPCA/UnB

Prof. Dr. Mathias Schneid Tessmann
IDP

Prof. Dr. João Gabriel de Moraes Souza
PPCA/UNB

Brasília
2025

Dedicatória

Dedico esta dissertação aos meus pais, pelo amor incondicional e apoio em cada passo de minha vida. Seus ensinamentos e valores me inspiram diariamente.

Agradecimentos

Ao fim desta jornada acadêmica, tenho muito a agradecer.

Primeiramente, a Deus, por ter me dado forças nos momentos mais difíceis e guiado meus passos quando tudo parecia incerto.

Ao meu pai, Joaquim, meu maior incentivador e entusiasta. Foi graças ao seu estímulo inicial que aceitei o desafio de ingressar no mestrado. Seu exemplo de dedicação acadêmica sempre foi uma inspiração em minha trajetória.

À minha mãe, Nara, minha calmaria em meio às tempestades. Seu apoio foi o contrapeso essencial na balança da pressão acadêmica.

Ao meu irmão, Matheus, companheiro de vida e amigo verdadeiro. Nossa amizade, que transcende os laços de sangue, foi uma fonte constante de força e equilíbrio.

Aos meus familiares, em especial àqueles que moram na Alemanha, que, embora distantes fisicamente, mantiveram-se presentes em minha vida através do contato constante; e aos meus padrinhos, que sempre torcem por meu sucesso.

Aos professores do programa de pós-graduação, em especial ao meu orientador, pela paciência, direcionamento e conhecimentos compartilhados. Suas contribuições foram fundamentais para o desenvolvimento deste trabalho.

Aos colegas do FNDE, pela colaboração e disponibilidade em compartilhar informações cruciais para a realização desta pesquisa.

Aos amigos que fiz durante minha vida, companheiros de jornada que tornaram o caminho menos árduo e mais prazeroso, através de conversas e trocas de experiências.

A todos que, direta ou indiretamente, contribuíram para a conclusão desta etapa.

Meus sinceros agradecimentos.

“A criação bem-sucedida da inteligência artificial pode ser o maior evento da história da humanidade. No entanto, também pode ser o último, a menos que aprendamos a evitar os riscos”

(Stephen Hawking)

Resumo

A infraestrutura educacional desempenha um papel importante na facilitação do acesso ao ensino, na melhoria dos resultados acadêmicos e na redução das taxas de evasão escolar. Entretanto, o cenário brasileiro é marcado por um elevado índice de paralisação de obras públicas educacionais, o que prejudica a expansão e a qualidade da oferta de educação infantil e resulta em considerável desperdício de recursos públicos. Este estudo tem como objetivo elaborar um modelo preditivo de obras com risco de paralisação, fundamentado em técnicas de *machine learning* e guiado pela metodologia CRISP-DM. Utilizando bases de dados provenientes do Fundo Nacional de Desenvolvimento da Educação (FNDE) ligadas ao programa Proinfância, foram identificadas variáveis-chave que exercem influência direta na paralisação das obras. A análise identificou cinco atributos críticos que influenciam a paralisação das obras, com os seguintes pesos: a quantidade de dias desde a última vistoria (32,87%), a condição de a obra ser ou não vinculada (26,06%), o tipo de paralisação (15,51%), os valores empenhados no projeto (13,14%) e os valores disponibilizados pelo FNDE (7,08%). O modelo de *deep learning* desenvolvido demonstrou elevado desempenho, alcançando uma acurácia de 94,79% na identificação de obras com alto risco de paralisação. Além disso, foi desenvolvida uma ferramenta de simulação interativa que permite a análise de diversos cenários de risco, contribuindo para a otimização do monitoramento das obras. Esta abordagem prática oferece subsídios para que gestores públicos adotem medidas preventivas eficazes, garantindo a continuidade e a qualidade das construções, impulsionando a melhoria da infraestrutura educacional no Brasil e otimizando a utilização dos recursos públicos.

Palavras-chave: Modelo Preditivo; *Machine Learning*; Infraestrutura Educacional; Obras Públicas; CRISP-DM.

Abstract

Educational infrastructure plays a crucial role in facilitating access to education, improving academic outcomes, and reducing school dropout rates. However, the Brazilian context is marked by a high incidence of halted public educational construction projects, which undermines the expansion and quality of early childhood education and results in significant public resource wastage. This study aimed to develop a predictive model for identifying construction projects at risk of suspension, based on machine learning techniques and guided by the CRISP-DM methodology. Utilizing databases from the National Fund for the Development of Education (FNDE) associated with the Proinfância program, key variables that directly influence project suspension were identified. The analysis pinpointed five critical attributes that impact the suspension of construction projects, with the following weights: the number of days since the last inspection (32.87%), whether the project is linked or not (26.06%), the type of suspension (15.51%), the funds committed to the project (13.14%), and the funds provided by the FNDE (7.08%). The developed deep learning model demonstrated high performance, achieving an accuracy of 94.79% in identifying projects with a high risk of suspension. Furthermore, an interactive simulation tool was developed that allows the analysis of various risk scenarios, thereby contributing to the optimization of project monitoring. This practical approach provides robust support for public managers to implement effective preventive measures, ensuring the continuity and quality of constructions, enhancing the educational infrastructure in Brazil, and optimizing the utilization of public resources.

Keywords: Predictive Model; Machine Learning; Educational Infrastructure; Public Works; CRISP-DM.

Sumário

1. Introdução.....	17
1.1. Problema da Pesquisa	21
1.2. Justificativa.....	22
1.3. Objetivos	22
1.3.1. Objetivo geral.....	22
1.3.2. Objetivos específicos.....	23
1.4. Estrutura dos Capítulos	23
2. Revisão Da Literatura Com Enfoque Meta-Analítico	24
2.1. Etapa 1 - Preparação da pesquisa	25
2.2. Etapa 2 – Apresentação e inter-relação dos dados	27
2.2.1. Evolução do tema ano a ano	27
2.2.2. Registro mais antigo.....	28
2.2.3. Coocorrência de palavras-chaves	29
2.2.4. Autores que mais publicam	31
2.2.5. Países e Instituições	32
2.2.6. Artigos mais citados.....	34
2.2.7. Análise de palavras-chaves.....	36
2.3. Etapa 3 - Detalhamento, modelo integrador e validação por evidências.	38
2.4. Adição de novos termos à pesquisa bibliográfica	47
3. Referencial Teórico	52
3.1. Políticas públicas.....	52
3.2. Proinfância	54
3.3. Gestão de riscos.....	59
3.4. Gestão de riscos no setor público	60
3.5. Gestão de riscos no FNDE	66
3.6. <i>Data Science e Machine Learning</i>	69
4. Método De Pesquisa	77
4.1. Tipo de pesquisa.....	78
4.2. Local de estudo	79
4.3. Objeto de estudo	80

4.4.	Procedimento metodológico	80
4.5.	Software utilizado.....	81
5.	Resultados	83
5.1.	CRISP-DM.....	83
5.2.	Etapas 2 e 3 do CRISP-DM - Entendimento e preparação dos dados	86
5.2.1.	Tratamento de outliers.....	90
5.2.2.	Estrutura da Base Inicial	91
5.3.	Etapas 4 do CRISP-DM - Modelagem.....	115
5.3.1.	<i>Dataset I</i>	117
5.3.2.	<i>Dataset II</i>	118
5.3.3.	<i>Dataset III</i>	121
5.4.	Etapas 5 do CRISP-DM - Avaliação	123
5.4.1.	Curvas ROC e AUC.....	125
5.4.2.	<i>Deep Learning</i> como modelo preditivo	128
5.4.2.1.	Processo de implementação do <i>Deep Learning</i>	130
5.4.2.2.	Modelo de Produção do Algoritmo de <i>Deep Learning</i>	135
5.4.3.	Otimização de hiperparâmetros.....	136
5.4.4.	Matriz de confusão	139
5.4.5.	Peso das variáveis	140
5.4.6.	<i>Lift chart</i>	142
5.5.	Etapas 6 do CRISP-DM - Implantação	144
5.5.1.	Simulador preditivo de obras.....	144
5.5.2.	Implementação do simulador no processo de monitoramento de obras.	147
5.6.	Síntese dos principais resultados e implicações.....	147
6.	Considerações Finais.....	150
6.1.	Limitações da pesquisa	151
6.2.	Recomendações.....	151
7.	Referências Bibliográficas	154
APÊNDICE I	166	
APÊNDICE II	167	
ANEXO I	168	

Lista de Figuras

Figura 1: Modelo TEMAC.....	24
Figura 2: Evolução do número de publicações - Web of Science.....	28
Figura 3: Evolução do número de publicações – Scopus.....	28
Figura 4: Coocorrência de palavras-chaves - Web of Science.....	29
Figura 5: Coocorrência de palavras-chaves – Scopus.....	30
Figura 6: Autores que mais publicam sobre a temática pesquisada – Web of Science.....	31
Figura 7: Autores que mais publicam sobre a temática pesquisada – Scopus.....	32
Figura 8: Países que mais publicam - Web of Science	32
Figura 9: Países que mais publicam – Scopus	33
Figura 10: Publicações por instituição - Web of Science	33
Figura 11: Publicações por instituição – Scopus	34
Figura 12: Nuvem de palavras	37
Figura 13: Mapa de calor de cocitação - Web of Science.....	38
Figura 14: Mapa de calor de cocitação – Scopus.....	40
Figura 15: Mapa de calor de Bibliographic Coupling - Web of Science	41
Figura 16: Mapa de calor de Bibliographic Coupling – Scopus	42
Figura 17: Modelo Integrador	45
Figura 18: Possíveis aplicações de IA na construção civil.....	50
Figura 19: Fachada Frontal Tipo 1.....	56
Figura 20: Fachada Frontal Tipo 2.....	57
Figura 21: Fachada Frontal Ampliação Módulo Infantil.....	57
Figura 22: Modelo de Gerenciamento de Riscos.....	64
Figura 23: Obras paralisadas por setor.....	65
Figura 24: Tendência de pesquisa por Data Science.....	69
Figura 25: Fluxograma de aprendizado supervisionado	71
Figura 26: Função matemática de problema de classificação.....	72
Figura 27: Exemplo de Árvore de Decisão	73
Figura 28: Exemplo de gráfico de KNN.....	73
Figura 29: Exemplo de gráfico de Naive Bayes	74
Figura 30: Exemplo de gráfico de Regressão Logística.....	74
Figura 31: Exemplo de gráfico de SVM.....	75
Figura 32: Exemplo de Rede Neural	75
Figura 33: Exemplo de Deep Neural Network	76
Figura 34: Método de Pesquisa	77
Figura 35: Mapa do Distrito Federal	79
Figura 36: Framework CRISP-DM.....	84
Figura 37: Base inicial – Ciclo	92
Figura 38: Base inicial - Ano Termo/Convênio.....	92
Figura 39: Base inicial - Quantidade de Obras	93
Figura 40: Base inicial – Situação	94
Figura 41: Base inicial - % Executado Instituição Acumulado.....	95

Figura 42: Base inicial - Última Vistoria Instituição.....	96
Figura 43: Base inicial – Fonte	96
Figura 44: Base inicial – Esfera	97
Figura 45: Base inicial – Tipologia.....	98
Figura 46: Base inicial - Valores FNDE	99
Figura 47: Base inicial - Valores Pagos	100
Figura 48: Base inicial – Vigência	101
Figura 49: Base inicial - N° alunos (2 turnos)	102
Figura 50: Base inicial - N° alunos (integral)	102
Figura 51: Base inicial – Restrições.....	103
Figura 52: Base inicial – Inconformidades.....	104
Figura 53: Base inicial – Vinculada.....	105
Figura 54: Base inicial - Tipo de Paralisação	106
Figura 55: Base inicial - Quantidade Dias Última Vistoria.....	107
Figura 56: Base inicial - Valor Contrato	108
Figura 57: Base inicial - Valores Pactuados.....	109
Figura 58: Base inicial - Valores Empenhados	110
Figura 59: Base inicial - Tipo de RI.....	111
Figura 60: Base inicial - Divisão RI	112
Figura 61: Base inicial - Modalidade de Licitação	113
Figura 62: Base inicial - Prazo de Vigência	114
Figura 63: Resultados dataset I	117
Figura 64: Resultados dataset II	120
Figura 65: Curvas ROC	126
Figura 66: Processo de Deep Learning.....	131
Figura 67: Fluxograma do processo de Deep Learning	132
Figura 68: Arquitetura do modelo I	135
Figura 69: Arquitetura do modelo otimizado	137
Figura 70: Matriz de confusão.....	139
Figura 71: Peso das variáveis	141
Figura 72: Lift Chart	143
Figura 73: Simulador	145

Lista de Tabelas

Tabela 1: Áreas pesquisadas - Web of Science	26
Tabela 2: Áreas pesquisadas – Scopus	26
Tabela 3: Artigos mais citados.....	36
Tabela 4: Consolidação dos principais trabalhos	45
Tabela 5: Artigos mais citados relacionados a Machine Learning e gestão de riscos ..	50
Tabela 6 - Obras do Proinfância	58
Tabela 7: Base inicial – Ciclo	92
Tabela 8: Base inicial - Ano Termo/Convênio.....	93
Tabela 9: Base inicial - Quantidade de Obras.....	93
Tabela 10: Base inicial – Municípios.....	94
Tabela 11: Base inicial – UF	94
Tabela 12: Base inicial – Situação.....	95
Tabela 13: Base inicial - % Executado Instituição Acumulado	95
Tabela 14: Base inicial – Fonte.....	97
Tabela 15: Base inicial – Esfera.....	97
Tabela 16: Base inicial – Tipologia	98
Tabela 17: Base inicial - Valores FNDE.....	99
Tabela 18: Base inicial - Valores Pagos.....	100
Tabela 19: Base inicial – Vigência.....	101
Tabela 20: Base inicial – Restrições	103
Tabela 21: Base inicial – Inconformidades	104
Tabela 22: Base inicial – Vinculada	105
Tabela 23: Base inicial - Tipo de Paralisação.....	106
Tabela 24: Base inicial - Quantidade Dias Última Vistoria	107
Tabela 25: Base inicial - Valor Contrato.....	108
Tabela 26: Base inicial - Valores Pactuados.....	109
Tabela 27: Base inicial - Valores Empenhados.....	110
Tabela 28: Base inicial - Tipo de RI.....	111
Tabela 29: Base inicial - Divisão RI.....	112
Tabela 30: Base inicial - Modalidade de Licitação.....	113
Tabela 31: Base inicial - Empresa Contratada.....	113
Tabela 32: Base inicial - Prazo de Vigência.....	114
Tabela 33: Resultados dataset III (Acurácia, Erro de Classificação, F Measure, Precision).....	122
Tabela 34: Resultados dataset III (Recall, Desvio Padrão, Tempo de Treinamento, Tempo Total)	123
Tabela 35: AUC.....	126
Tabela 36: Resultados modelo I.....	135
Tabela 37: Comparação entre modelos	138

Tabela 38: Resultados modelo II	138
Tabela 39: Comparação entre métricas de desempenho.....	139

Lista de Equações

Equação 1: Distância euclidiana entre dois pontos.....	91
Equação 2: Acurácia	123
Equação 3: Erro de Classificação.....	124
Equação 4: Precision.....	124
Equação 5: Recall.....	124
Equação 6: F-measure	124
Equação 7: Especificidade.....	125
Equação 8: Ativação do Neurônio Artificial	129

Lista de Abreviaturas e Siglas

AUC Area Under the Curve

CGU Controladoria-Geral da União

CRISP-DM Cross-Industry Standard Process for Data Mining

CGEST Coordenação-Geral de Infraestrutura Educacional do FNDE

CGIMP Coordenação-Geral de Implementação e Monitoramento de Projetos Educacionais do FNDE

CNN Redes Neurais Convolucionais

DIGAP Diretoria de Gestão, Articulação e Projetos Educacionais do FNDE

ESG Environmental, Social and Governance

FLM Fast Large Margin

FNDE Fundo Nacional de Desenvolvimento da Educação

FNN Redes Neurais Feedforward

IA Inteligência Artificial

KNN K-Nearest Neighbors

MEC Ministério da Educação

MGI Ministério da Gestão e da Inovação em Serviços Públicos

MPO Ministério do Planejamento e Orçamento

MSE Mean Squared Error

PAR Plano de Ações Articuladas

PAR2 Plano de Ações Articuladas versão 2

PDDE Programa Dinheiro Direto na Escola

PMBOK Project Management Body of Knowledge

PNAE Programa Nacional de Alimentação Escolar

PNATE Programa Nacional de Apoio ao Transporte do Escolar

PNE Plano Nacional de Educação

PNLD Programa Nacional do Livro e do Material Didático

PPP Public-Private Partnership

PR AUC Precision-Recall Area Under the Curve

Proinfância Programa Nacional de Reestruturação e Aquisição de Equipamentos para a Rede Escolar Pública de Educação Infantil

R² Coeficiente de Determinação

RMSE Root Mean Squared Error

RNN Redes Neurais Recorrentes

ROC Receiver Operating Characteristic

SIMEC Sistema Integrado de Monitoramento Execução e Controle

SVM Support Vector Machine

TCU Tribunal de Contas da União

TEMAC Teoria do Enfoque Meta Analítico Consolidado

Capítulo 1

Introdução

A educação é considerada um direito fundamental social e dever do Estado na Constituição Federal do Brasil. Ela é garantida como um direito de todas as pessoas e deve ser ministrada de forma gratuita e obrigatória até o nível fundamental [1]. A Constituição também estabelece que a educação deve ser laica e visar o desenvolvimento integral da pessoa, além de promover a igualdade de oportunidades. A educação é uma das principais ferramentas para o desenvolvimento individual e coletivo de uma sociedade. Além disso, ela é fundamental para o desenvolvimento econômico de um país, pois permite a formação de mão-de-obra qualificada e aumenta a produtividade do país.

No Brasil, o Ministério da Educação (MEC) é o órgão responsável por planejar, organizar e coordenar a educação. Por meio do Plano Nacional de Educação (PNE), foi estabelecido as diretrizes para a educação no país ao longo de uma década [2]. Esse plano prevê ações para melhorar a qualidade da educação e promover a inclusão social.

De acordo com a OCDE, o setor público brasileiro investe 5,4% do PIB em educação, acima da média dos países da OCDE [3]. Entretanto, países que gastam menos, como Colômbia, México e Uruguai, tiveram melhores desempenhos em testes internacionais de avaliação de estudantes, o que demonstra a lacuna de eficiência existente no Brasil [4]. Da alocação do investimento, a maior parte é destinada para o ensino superior [3]. Mediante esse fato, a OCDE sugere a realocação dos gastos com educação superior para os ensinos pré-primário, fundamental e médio, visando

o aumento de eficiência [3]. A oportunidade de acesso à educação básica de qualidade estimula a procura por níveis subsequentes de ensino e diminui o índice de evasão de estudantes menos favorecidos do sistema educacional [5]. A ampliação ao acesso ao ensino fundamental que se deu no passado aconteceu devido a políticas públicas que atingiram a população menos privilegiada financeiramente, que foi historicamente excluída [6] [3]. Esse desafio se torna ainda maior após as dificuldades apresentadas pela pandemia Covid-19 [7].

De acordo com a OCDE, alguns dos fatores que afetam a qualidade educacional são: políticas educacionais adotadas, instalações destinadas para a educação, custo de acesso à educação, qualificação dos recursos humanos empregados [8].

Fatores que influenciam na qualidade da educação vêm sendo tema de estudo de cientistas de diversos países [9] [10] [11] [12] [13].

Na Indonésia, [10] elencaram fatores que influenciam na qualidade de educação local. Entre eles destaca-se a qualidade das instalações. Escolas com requisitos mínimos de sala de aula, centro esportivo, biblioteca, laboratório, área de recreação suportaram a hipótese de melhora no processo de aprendizado.

Cientistas do Iêmen [11] também identificaram alguns fatores que impediram o país de alcançar as metas relacionadas à educação. Novamente, a qualidade das instalações foi apontada como sendo fator determinante.

No Paquistão, pesquisadores identificaram a falta de infraestrutura básica nas escolas e aulas, ausência professores, ausência de mecanismo de monitoramento e avaliação de sistema e avaliação, entre outros fatores que afetam a qualidade educação na zona rural local [12]

Esses fatos são corroborados pelo estudo de Widodo [13] que analisou os fatores que afetam a qualidade da educação em áreas subdesenvolvidas. O resultado desse apontou que a infraestrutura possui participação importante na qualidade educacional.

Salas de aula, laboratórios e equipamentos, ou seja, a infraestrutura educacional, são elementos cruciais dos ambientes de aprendizagem em escolas e universidades. Evidências apontam que projetos que abrangem infraestrutura de qualidade facilita um melhor ensino, melhora os resultados dos alunos e reduz as taxas de evasão, entre outros benefícios [14]. Um estudo britânico demonstrou que o ambiente e fatores relacionados à infraestrutura explicam em 16% a evolução acadêmica de alunos da educação básica [15]. Isso demonstra a importância do projeto arquitetônico ser planejado levando em consideração fatores como a entrada de luz natural nas salas de aula e a estimulação dos sentidos visuais.

Um importante estudo global publicado pelo Banco Mundial [16] consolidou diversos estudos da temática e avaliou o impacto que a infraestrutura pode ter no aprendizado. Os achados foram categorizados em cinco grandes áreas.

A primeira área diz respeito ao acesso à escola. Há evidências que escolas preferencialmente pequenas, com turmas pequenas e distribuídas em uma distância razoável da moradia do aluno podem maximizar o benefício educacional.

Em seguida, deve-se atentar para a segurança das escolas. Alguns fatores que diminuam a chance de evasão escolar são: escolas bem construídas, fornecimento de serviços básicos como água, saneamento e eletricidade, infraestrutura que possui espaços abertos.

Posteriormente, há evidências que o espaço deve beneficiar o aprendizado. Controle de temperatura, iluminação, estimulação ambiental visual são alguns dos fatores que garantem um espaço saudável.

A quarta área elencada pelo Banco Mundial diz respeito a maximizar os benefícios da pedagogia. Esforçar-se para atender aos objetivos do Ambiente de Aprendizagem Inovadora da OCDE; construir escolas que sejam espacialmente flexíveis para que, a longo prazo, possam apoiar, em vez de obstruir, quaisquer mudanças ou desenvolvimentos na prática pedagógica; implementar inovações pedagógicas.

Por último, há a área de planejamento e implementação eficaz das ideias. Essa perspectiva se refere à existência de diálogo contínuo entre planejadores, educadores e projetistas de instalações.

No cenário brasileiro, o Fundo Nacional de Desenvolvimento da Educação (FNDE), desempenha papel vital nessa temática. O Fundo, que é uma autarquia federal vinculada ao Ministério da Educação (MEC), tem como função financiar projetos e programas relacionados à educação básica e alfabetização [17]. Entre suas principais atribuições estão a distribuição de recursos financeiros para a construção e reforma de escolas, a aquisição de materiais didáticos e equipamentos pedagógicos, e a implementação de programas de formação de professores.

Ao longo dos 55 anos de existência, o Fundo, criado pela Lei nº 5.537 de 1968 realiza trabalho importante em variadas frentes. Gerir ações e programas de âmbito nacional, além de financiar projetos de ensino e pesquisa, são o cerne da autarquia.

Entre os programas geridos pelo FNDE, há o Programa Dinheiro Direto na Escola (PDDE), o Programa Nacional de Alimentação Escolar (PNAE), o Programa Nacional de Apoio ao Transporte do Escolar (PNATE), Programa Caminho da Escola, Programa Nacional do Livro e do Material Didático (PNLD), entre outros.

Nesse sentido, o Programa Nacional de Reestruturação e Aquisição de Equipamentos para a Rede Escolar Pública de Educação Infantil (Proinfância), instituído pela Resolução nº 6, de 24 de abril de 2007, é o principal foco deste estudo. Esse Programa visa aprimorar a infraestrutura escolar, referente ao ensino infantil. O Programa possui dois pilares principais: a construção de creches e pré-escolas, com projetos padronizados; e a aquisição de mobiliário e equipamentos para as escolas de educação infantil [18]. Tais pilares estão correlacionados com a Meta I do PNE definido pela Lei 13.005/2014.

META 1 - Universalizar, até 2016, a educação infantil na pré-escola para as crianças de 4 (quatro) a 5 (cinco) anos de idade e ampliar a oferta de educação infantil em creches de forma a atender, no mínimo, 50% (cinquenta por cento) das crianças de até 3 (três) anos até o final da vigência deste PNE. [2]

A quantidade de creches e pré-escolas é fator determinante para se alcançar a meta prevista, ainda que tardiamente. Entretanto, o FNDE, que atualmente é responsável por monitorar 13.433 obras (dado do dia 24 de janeiro de 2023), excluindo as que já foram concluídas, lida com uma série de riscos que podem afetar negativamente o desenvolvimento da educação no Brasil. Embora a Portaria nº 57, de 4 de janeiro de 2019, da Controladoria-Geral da União (CGU), estabeleça o gerenciamento de riscos para a integridade no âmbito da administração pública, incluído o Fundo Nacional de Desenvolvimento da Educação, tais medidas, detalhadas no Plano de Integridade do FNDE, envolvem majoritariamente questões de prevenção da corrupção.

Estabelece orientações para que os órgãos e as entidades da administração pública federal direta, autárquica e fundacional adotem procedimentos para a estruturação, a execução e o monitoramento de seus programas de integridade e dá outras providências. [19]

Para questões relacionadas aos riscos dos processos e do Proinfância, é de responsabilidade do próprio FNDE gerenciá-los e mitigá-los da melhor maneira. Nessa temática, este estudo visa auxiliar os gestores a tomarem melhores decisões.

1.1. Problema da Pesquisa

De acordo com dados do Fundo Nacional de Desenvolvimento da Educação, até o dia 24 de janeiro de 2023 havia 244 obras paralisadas frente à 900 obras em execução do Proinfância. Embora tais dados sejam dinâmicos e mudam a cada dia, é evidente a janela de oportunidade existente para a implementação de um modelo de gerenciamento de riscos eficiente para o Proinfância, com o intuito de garantir a qualidade do processo de monitoramento de obras e diminuir a probabilidade de obras públicas relacionadas ao Programa serem paralisadas.

Dessa forma, a questão motivadora para a realização da pesquisa é: como identificar obras públicas ligadas ao Proinfância com risco de serem paralisadas?

1.2. Justificativa

Esta pesquisa se justifica socialmente ao contribuir com a celeridade das construções de creches e pré-escolas, tendo em vista que esse é o escopo do Programa Nacional de Reestruturação e Aquisição de Equipamentos para a Rede Escolar Pública de Educação Infantil (Proinfância). A finalização dessas obras traz consequências positivas para a sociedade em geral, como o aumento da oferta de vagas escolares e emprego do dinheiro público de maneira efetiva.

Este estudo também busca aprimorar a gestão de projetos públicos à medida que utiliza técnicas de ciência de dados para acompanhar a execução dos projetos e gerenciar riscos inerentes da temática proposta.

No aspecto científico, foi verificado nas bases de dados *Web of Science* e *Scopus*, principalmente, que o número de publicações e citações a respeito do tema proposto está em crescimento contínuo nesta década (figuras 2 e 3), o que sinaliza o interesse científico no assunto.

Para a linha de pesquisa de Gestão de Riscos com Computação Aplicada, este estudo se justifica à medida que buscará propor solução para o problema de pesquisa com o emprego de técnicas de gerenciamento de riscos, *big data* e aplicação de *machine learning* na base de dados estudada para criar um modelo preditivo.

1.3. Objetivos

1.3.1. Objetivo geral

O presente estudo tem por objetivo desenvolver um modelo preditivo de obras do programa Proinfância com risco de paralisação fundamentado em técnicas de

machine learning, com o intuito de identificar e antecipar os riscos de paralisação das obras públicas educacionais vinculadas ao programa.

1.3.2. Objetivos específicos

Para alcançar o objetivo geral proposto, os seguintes objetivos específicos foram estabelecidos:

- Identificar os riscos associados a obras públicas por meio de revisão sistemática da literatura científica;
- Compreender o processo de monitoramento de obras do FNDE;
- Determinar os principais fatores que implicam na paralisação de obras do Proinfância;
- Propor meio para implementação do modelo preditivo na rotina do FNDE.

1.4. Estrutura dos Capítulos

Este estudo científico está estruturado da seguinte forma: o Capítulo 2 aborda o enfoque meta-analítico, usando as bases *Web of Science* e *Scopus* de forma principal e auxiliada por outras detalhadas ao longo do trabalho. O Capítulo 3 apresenta o referencial teórico que aborda, entre outros pontos, as políticas públicas educacionais no Brasil e o gerenciamento de riscos no setor público. O Capítulo 4 apresenta o método empregado na pesquisa. No Capítulo 5 são mostrados os resultados. O Capítulo 6 traz as considerações finais e sugestões para futuras pesquisas. Por fim, o Capítulo 7 apresenta as referências bibliográficas.

Capítulo 2

Revisão Da Literatura Com Enfoque Meta-Analítico

Mariano e Rocha [20], discorre sobre a importância da revisão bibliográfica para se obter uma pesquisa satisfatória em um trabalho científico. Neste estudo, foi utilizada a Teoria do Enfoque Meta Analítico Consolidado (TEMAC), desenvolvida pelos autores. A metodologia TEMAC é composta por três fases: preparação da pesquisa; apresentação e inter-relação dos dados; detalhamento e validação por evidências. O modelo TEMAC é representado na figura a seguir:

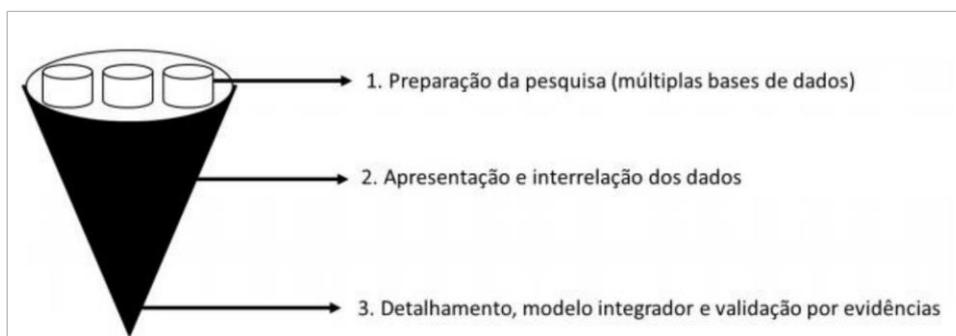


Figura 1: Modelo TEMAC (Fonte: [20]).

Conforme observa-se na figura 1, o modelo consiste em ir-se refinando os artigos relevantes à medida que a pesquisa for sendo realizada. O modelo TEMAC, respaldado por princípios bibliométricos, permite a identificação de *fronts* de pesquisa e abordagem histórica de determinado tema [20].

2.1. Etapa 1 - Preparação da pesquisa

Fontes confiáveis e o uso de bases de dados consolidadas em pesquisas científicas garantem a validade e a precisão dos resultados além de auxiliar a garantir que as conclusões da pesquisa sejam sólidas [20]. Ademais, isso se faz essencial para a construção de uma comunidade científica confiável, onde os resultados podem ser comparados e replicados para fins de verificação e validação.

Essa necessidade de se ter uma base de dados com boa reputação perante a comunidade científica e pelo nível de informação disponível, direcionou essa pesquisa ao uso da base *Web Of Science* e *Scopus* como bases principais, auxiliada por outras bases.

Procurou-se estabelecer relação entre os termos pertinentes ao projeto para a pesquisa na base de dados. Inicialmente, pesquisou-se pelos termos correspondentes em inglês para “gestão de riscos em obras públicas de educação”. Entretanto, os resultados obtidos não foram satisfatórios. Foi então realizada uma nova busca. Desta vez, pelos termos "*Risk Management*", acrescido do operador booleano AND e "*Public Sector*", para trazer os trabalhos relacionados com os dois termos, foi buscado ainda os termos "*Risk Management*", acrescido do operador booleano AND e "*Public Works*". Outro termo pesquisado foi "*Educational Public Policies*". A pesquisa retornou 631 resultados na base *Web of Science* e 1.279 resultados na base *Scopus*. O espaço temporal pesquisado foi a partir do ano 2000 até o final de 2024.

O próximo passo foi refinar a pesquisa para obter resultados mais pertinentes ao tema de pesquisa. As áreas pesquisadas em ambas as bases de dados podem ser observadas nas tabelas 1 e 2.

Web of Science	
Área	Nº de publicações
<i>Management</i>	92
<i>Engineering Civil</i>	68
<i>Environmental Sciences</i>	64
<i>Business Finance</i>	62
<i>Public Administration</i>	59
<i>Economics</i>	50
<i>Business</i>	47
<i>Education Educational Research</i>	47
<i>Computer Science Information Systems</i>	31
<i>Engineering Industrial</i>	29
<i>Environmental Studies</i>	26
<i>Social Sciences Interdisciplinary</i>	23
<i>Construction Building Technology</i>	22
<i>Computer Science Interdisciplinary Applications</i>	19
<i>Computer Science Theory Methods</i>	18
<i>Operations Research Management Science</i>	18
<i>Engineering Multidisciplinary</i>	15
<i>Political Science</i>	14
<i>Mathematics Interdisciplinary Applications</i>	9
<i>Humanities Multidisciplinary</i>	6
<i>Multidisciplinary Sciences</i>	4
<i>Engineering Manufacturing</i>	1

Tabela 1: Áreas pesquisadas - *Web of Science* (Fonte: Própria).

Scopus	
Área	Nº de publicações
<i>Engineering</i>	443
<i>Social Sciences</i>	375
<i>Business, Management and Accounting</i>	322
<i>Computer Science</i>	265
<i>Economics, Econometrics and Finance</i>	161
<i>Environmental Science</i>	150
<i>Decision Sciences</i>	108
<i>Multidisciplinary</i>	10

Tabela 2: Áreas pesquisadas - *Scopus* (Fonte: Própria).

Após realizada a filtragem das áreas de interesse deste estudo, a pesquisa resultou em 497 resultados na base *Web of Science* e 1167 na base *Scopus*.

2.2. Etapa 2 – Apresentação e inter-relação dos dados

A segunda fase do modelo TEMAC consiste em inter-relacionar as informações obtidas e realizar análises sobre o padrão de publicações referente à temática proposta.

Nesta seção será apresentado a evolução do tema ano a ano, o registro mais antigo encontrado, análise acerca da coocorrência de palavras-chaves, bem como análise das palavras-chaves presentes nos resumos, autores, países e instituições que mais publicam sobre o tema e os artigos mais citados.

2.2.1. Evolução do tema ano a ano

A partir dos trabalhos obtidos com a pesquisa nas bases de dados, iniciou-se a etapa de análise das publicações.

Dos 497 artigos encontrados na base do *WoS*, 46,7% foram publicados nos últimos cinco anos, ao passo que do total obtido na base *Scopus*, aproximadamente 34,5% foram publicados nesse mesmo período. Por meio dos gráficos apresentados nas figuras 2 e 3, é possível perceber um aumento no número de publicações ano após ano e a linha de tendência em crescimento, o que demonstra que o assunto está em voga.

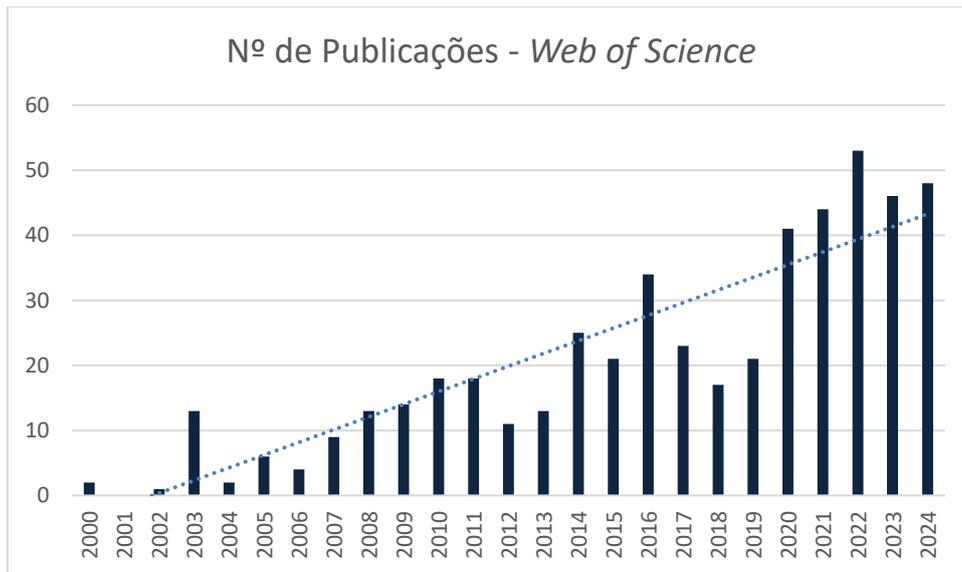


Figura 2: Evolução do número de publicações - *Web of Science* (Fonte: Própria).

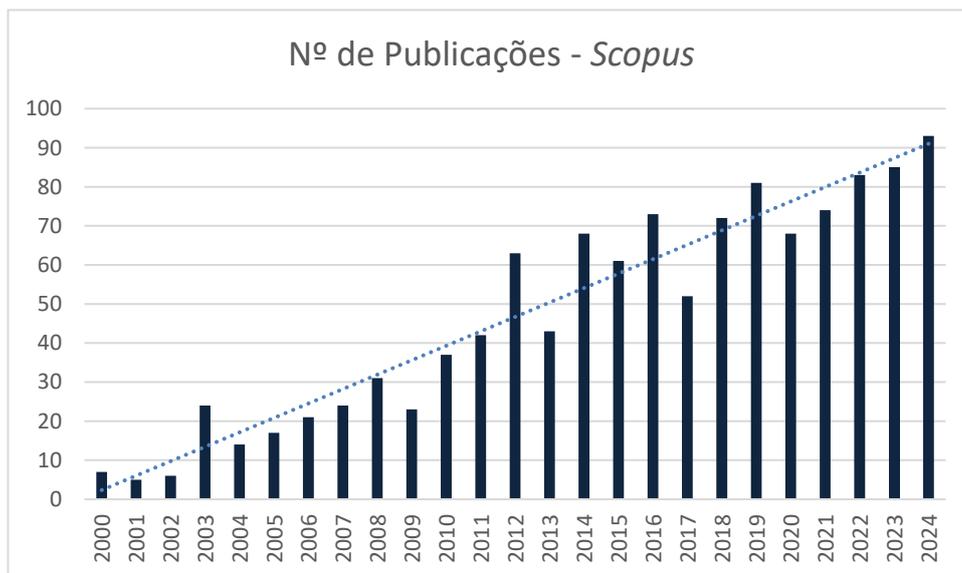


Figura 3: Evolução do número de publicações – *Scopus* (Fonte: Própria).

2.2.2. Registro mais antigo

O registro mais antigo existente em ambas as bases de dados no período pesquisado é o trabalho “*PROTEUS, a technical and management model for aquatic risk assessment of industrial spills*” [21]. Nesse estudo, os autores descrevem um novo modelo de avaliação de riscos ambientais em projetos industriais marítimos.

em conjunto com palavras ligadas a ele, como “*cyber-security*” e “*computer crime*”, é o que possui interesse temporal mais recente.

2.2.4. Autores que mais publicam

Dentre os autores que mais publicam sobre o tema, Enrico Bracci é o que aparece em destaque na base de dados do WoS, consequência de seus estudos associados a gestão de riscos no setor público.

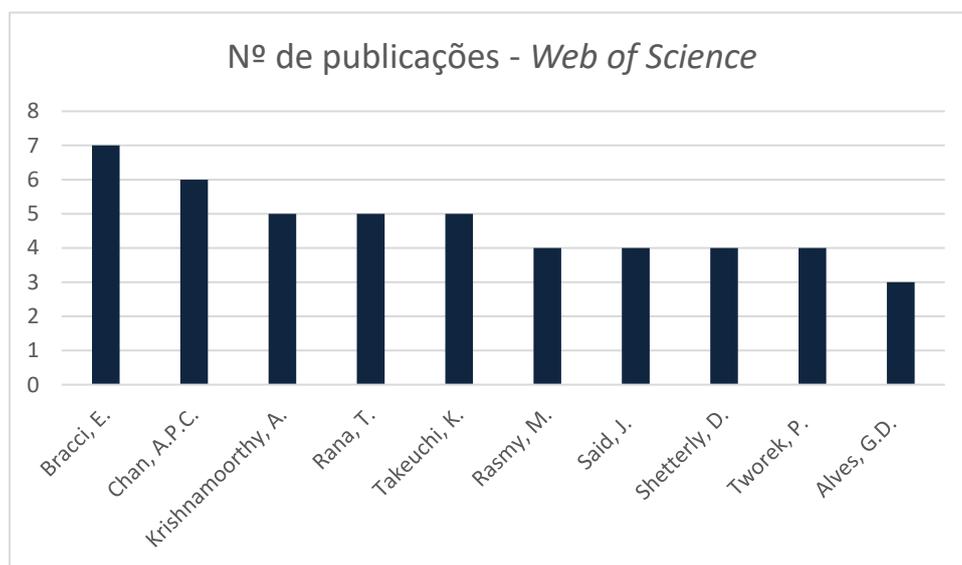


Figura 6: Autores que mais publicam sobre a temática pesquisada – *Web of Science* (Fonte: Própria).

Ao se analisar a base Scopus, os autores que mais publicam são Albert P.C. Chan, da Universidade Politécnica de Hong Kong, que possui foco em estudar gerenciamento de riscos por meio da lógica Fuzzy, e Paolo Trucco, da Universidade Politécnica de Milão, que se destaca pelos estudos de eventos inesperados em infraestruturas críticas.

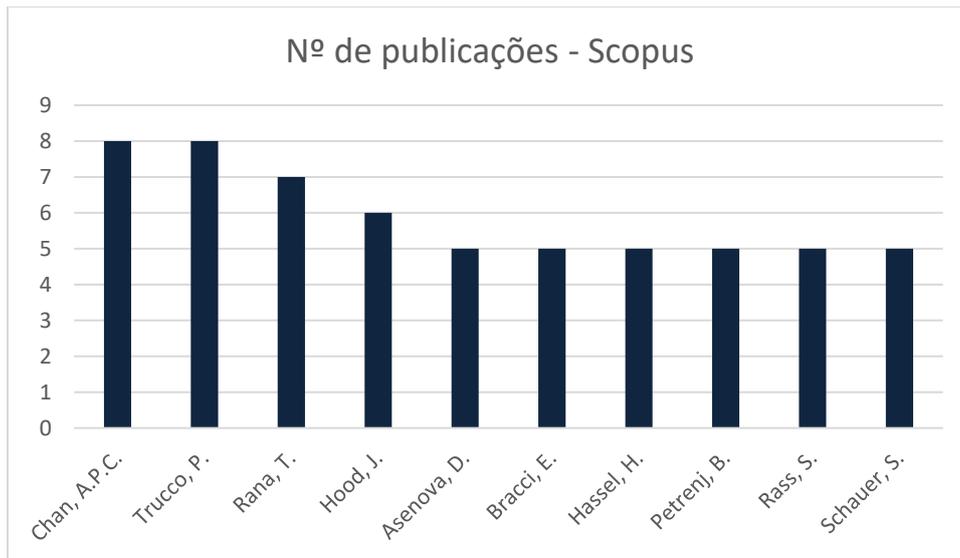


Figura 7: Autores que mais publicam sobre a temática pesquisada – *Scopus* (Fonte: Própria).

2.2.5. Países e Instituições

Entre os países que mais publicam acerca do tema o Brasil aparece na primeira posição no *Web of Science*, com 72 publicações, e na terceira posição na base *Scopus*, com 75 publicações. Isso demonstra que pesquisadores brasileiros estão interessados em estudos da área.

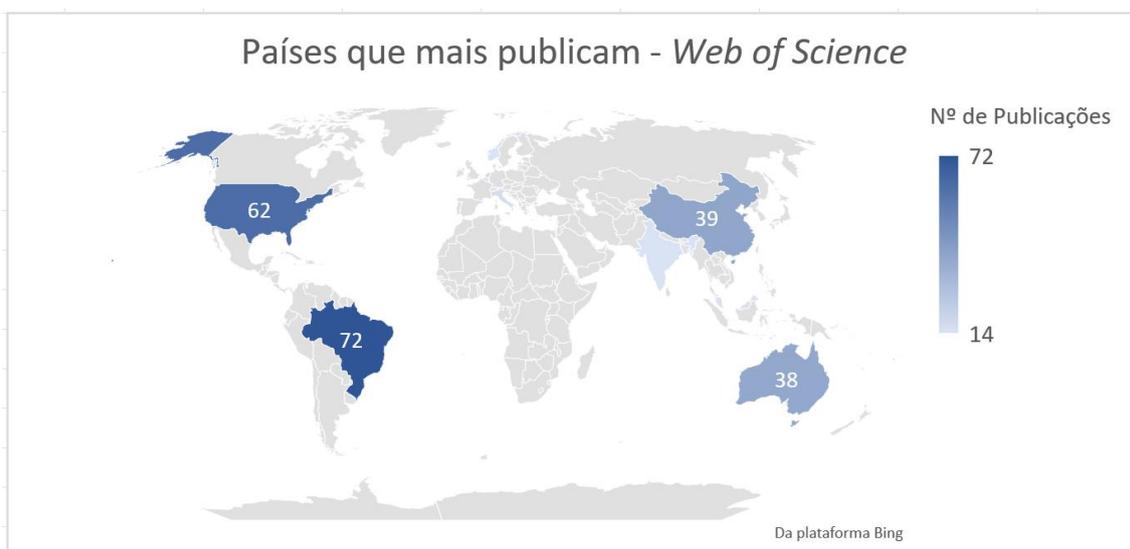


Figura 8: Países que mais publicam - *Web of Science* (Fonte: Própria).

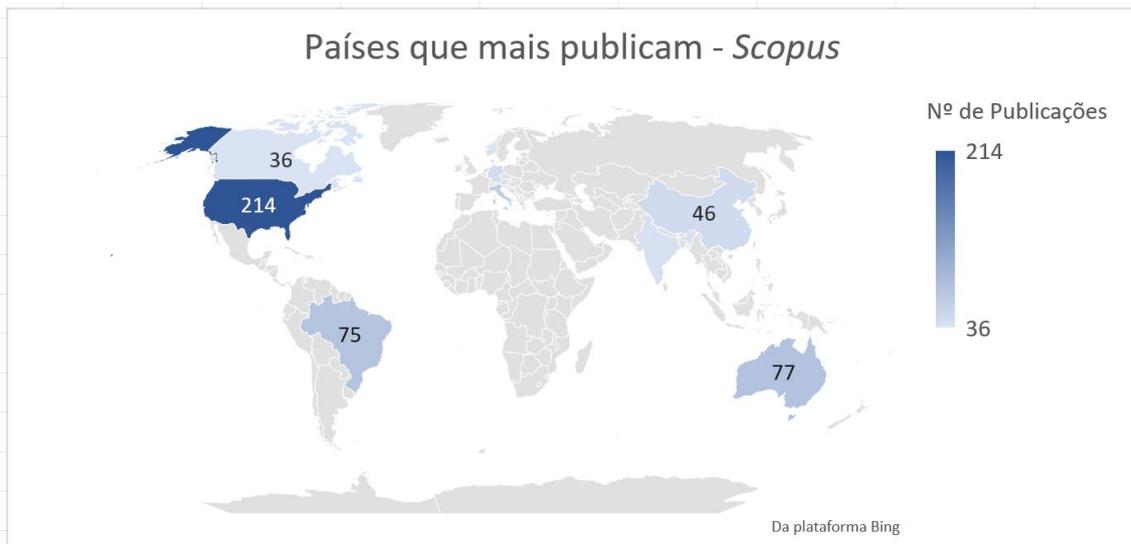


Figura 9: Países que mais publicam – *Scopus* (Fonte: Própria).

Esse fato é reforçado ao se analisar o gráfico de barras das instituições que mais publicam, onde se destaca a presença da Universidade de Brasília (UnB) entre as dez afiliações destacadas em ambas as bases de dados.

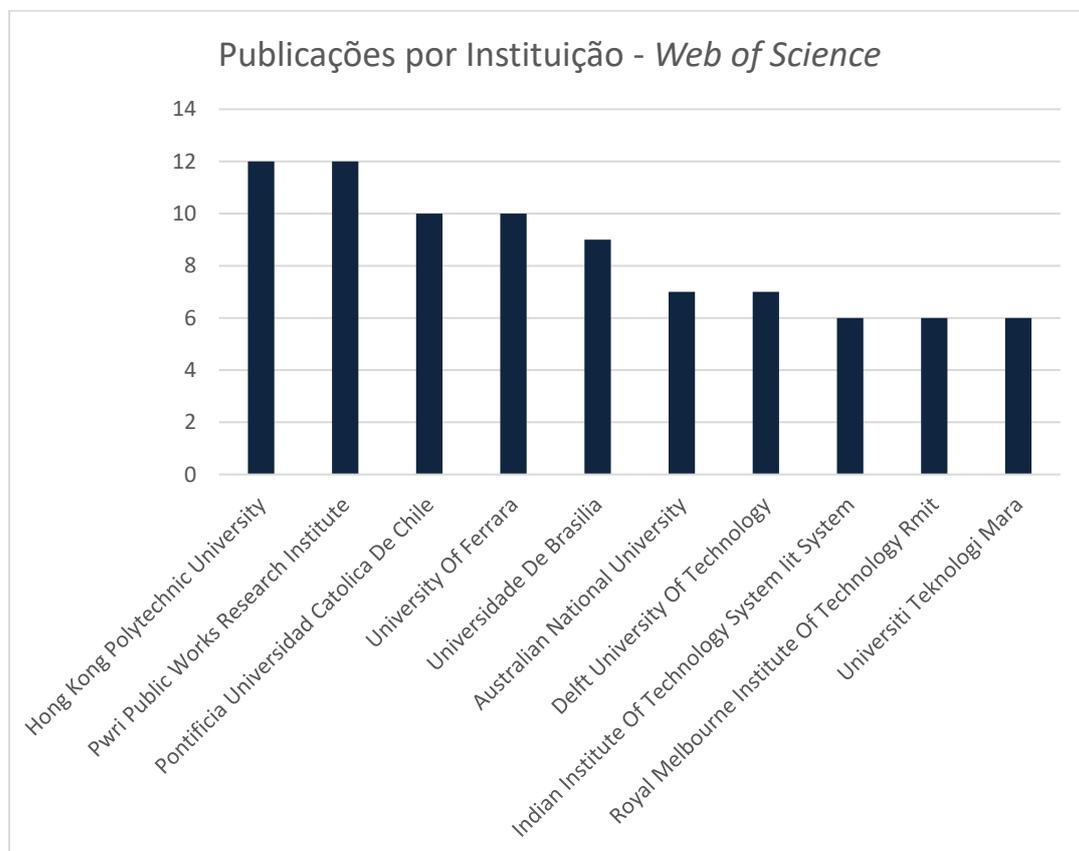


Figura 10: Publicações por instituição - *Web of Science* (Fonte: Própria).

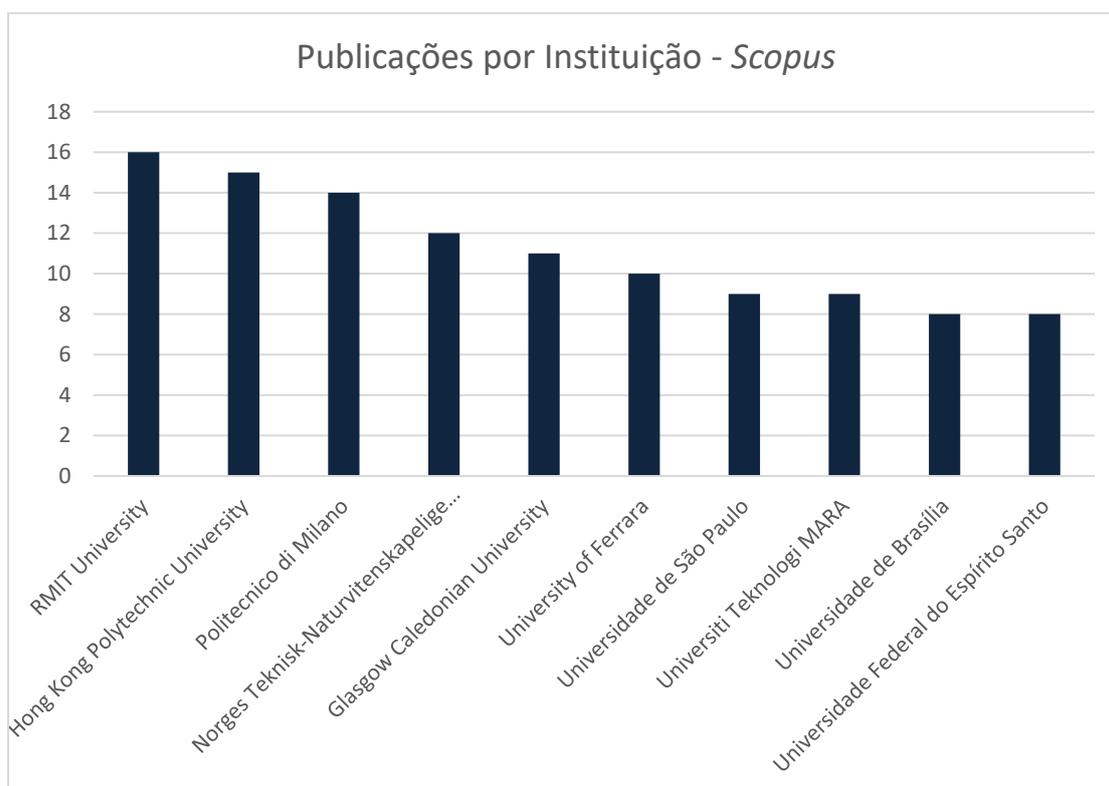


Figura 11: Publicações por instituição – *Scopus* (Fonte: Própria).

Nota-se a presença da Universidade de Brasília (UnB) na quinta posição do ranking *WoS* e na nona posição na base *Scopus*. Na base *WoS*, a instituição onde mais se publica artigos referentes à temática é a Hong Kong Polytechnic University, localizada na China. Já na base *Scopus*, a RMIT University, localizada na Austrália, é a que mais publica sobre o tema.

2.2.6. Artigos mais citados

Ao se adentrar na análise dos artigos científicos, o mais citado presente na base do *Web of Science* é o trabalho “*Should we build more large dams? The actual costs of hydropower megaproject development*” [27]. Nesse estudo, os autores testaram modelos para prever o estouro do orçamento e cronograma em projetos de construções de megabarragens.

Na base *Scopus*, o artigo “*The allocation of risk in PPP/PFI construction*

projects in the UK” [30] é o destaque, com 685 citações. Nele, os autores estudam a alocação de riscos em obras realizadas por meio de parceria público privada.

Web of Science		
Título	Autores	Citações
Should we build more large dams? The actual costs of hydropower megaproject development	Ansar, Atif; Flyvbjerg, Bent; Budzier, Alexander; Lunn, Daniel	469
Preferred risk allocation in China's public-private partnership (PPP) projects	Ke, Yongjian; Wang, ShouQing; Chan, Albert P. C.; Lam, Patrick T. I.	308
Empirical Study of Risk Assessment and Allocation of Public-Private Partnership Projects in China	Chan, Albert P. C.; Yeung, John F. Y.; Yu, Calvin C. P.; Wang, Shou Qing; Ke, Yongjian	232
Risk and risk management in software projects: A reassessment	Bannerman, Paul L.	177
Risk Allocation in Public-Private Partnership Infrastructure Projects: Comparative Study	Ke, Yongjian; Wang, ShouQing; Chan, Albert P. C.	153
Risk-Neutral Pricing Approach for Evaluating BOT Highway Projects with Government Minimum Revenue Guarantee Options	Ashuri, B.; Kashani, H.; Molenaar, K. R.; Lee, S.; Lu, J.	137
Outsourcing: assessing the risks and benefits for organisations, sectors and nations	Harland, C; Knight, L; Lamming, R; Walker, H	133
A contingency theory perspective on the risk management control system within Birmingham City Council	Woods, Margaret	133
Conceptual Framework for the Performance Measurement of Public-Private Partnerships	Liu, Junxiao; Love, Peter E. D.; Davis, Peter R.; Smith, Jim; Regan, Michael	88
Environmental risk mapping of pollutants: State of the art and communication aspects	Lahr, Joost; Kooistra, Lammert	86
Scopus		
Título	Autores	Citações
The allocation of risk in PPP/PFI construction projects in the UK	Bing, L., Akintoye, A., Edwards, P.J., Hardcastle, C.	685
New public management: The cruellest invention of the human spirit?	Lapsley, I.	387
Risk allocation in the private provision of public infrastructure	Ng, A., Loosemore, M.	357
Preferred risk allocation in China's public-private partnership (PPP) projects	Ke, Y., Wang, S., Chan, A.P.C., Lam, P.T.I.	356
Risk and risk management in software projects: A reassessment	Bannerman, P.L.	281

Achieving best value in private finance initiative project procurement	Akintoye, A., Hardcastle, C., Beck, M., Chinyio, E., Asenova, D.	281
Selection of performance objectives and key performance indicators in public-private partnership projects to achieve value for money	Yuan, J., Zeng, A.Y., Skibniewski, M.J., Li, Q.	268
Empirical study of risk assessment and allocation of public-private partnership projects in China	Chan, A.P.C., Yeung, J.F.Y., Yu, C.C.P., Wang, S.Q., Ke, Y.	225
Role of public private partnerships to manage risks in public sector projects in Hong Kong	Shen, L.-Y., Platten, A., Deng, X.P.	224
Outsourcing: Assessing the risks and benefits for organisations, sectors and nations	Harland, C., Knight, L., Lamming, R., Walker, H.	206

Tabela 3: Artigos mais citados (Fonte: Própria).

Após refinamento da base de artigos encontrada e análise dos parâmetros mencionados anteriormente, como os artigos mais citados pela comunidade científica, foi realizada uma análise qualitativa daqueles que poderiam ser de grande valia para esta pesquisa, por possuir correlação direta com o tema. Dentre as várias publicações relevantes para a área, para esta pesquisa destaca-se o artigo *“The Brazilian scientific production on risk management in the public sector: a bibliometric analysis”* [32], que apresenta o estado da arte, em 2020, do tema gestão de riscos no setor público. Outro trabalho relevante para esta pesquisa é o *“New development: Enabling enterprise risk management maturity in public sector organizations”* [33]. Nesse, os autores apresentam um framework para gerenciamento de riscos no setor público. O artigo *“Risk management in the public sector: a structured literature review”* [26], autor já supramencionado como sendo um dos que mais publicam em relação ao tema, consolidam o conhecimento de 63 artigos científicos da base de dados Scopus em um único trabalho.

2.2.7. Análise de palavras-chaves

A análise de palavras-chaves permite a identificação de termos que aparecem

frequentemente nos artigos publicados relacionados ao tópico e na listagem de palavras-chaves feita pelos autores. A figura 12 apresenta a nuvem de palavras, criada com o auxílio do website “Tagcrowd.com”, com o intuito de verificar quais são as palavras-chaves que mais aparecem nos artigos pesquisados. Para a criação da nuvem, foi realizada integração entre as bases de dados *Scopus* e *Web of Science*.



Figura 12: Nuvem de palavras (Fonte: Própria).

As cinco palavras que mais aparecem são "*risk*", "*management*", "*public*", "*sector*" e "*education*".

A presença dessas palavras, correlacionadas com outras importantes para a temática deste estudo, como a menção à infraestrutura, presente por exemplo no trabalho “*The allocation of risk in PPP/PFI construction projects in the UK*” [30], onde os autores analisam projetos de infraestrutura pública em busca de um *Value For Money (VFM)* satisfatório e alocação de riscos em PPPs, demonstra que a linha de pesquisa proposta está de acordo com o interesse da comunidade acadêmica sobre o tema. A criação de frameworks e modelos de riscos, palavras também muito citadas e comuns nesses tipos de estudos, bem como a avaliação de parcerias público-privadas para melhorar a qualidade da educação, também presente na nuvem de palavras, vem avançando à medida que as contribuições fornecidas por estes estudos são percebidas [26] [30].

2.3. Etapa 3 - Detalhamento, modelo integrador e validação por evidências

Com o intuito de investigar de maneira detalhada a temática proposta, foi realizado um estudo de acoplamento bibliográfico (*bibliographic coupling*) e cocitações. Para isso, os dados obtidos por meio das bases *Web of Science* e *Scopus* foram inseridos no software *VOSviewer*, versão 1.6.19, para se criar os mapas de calor que serão apresentados.

A análise de cocitação afere o grau de ligação entre dois ou mais artigos, de acordo com o número de documentos onde esses artigos são citados simultaneamente [34]. Assim, é possível identificar os autores que têm uma linha de pesquisa semelhante.

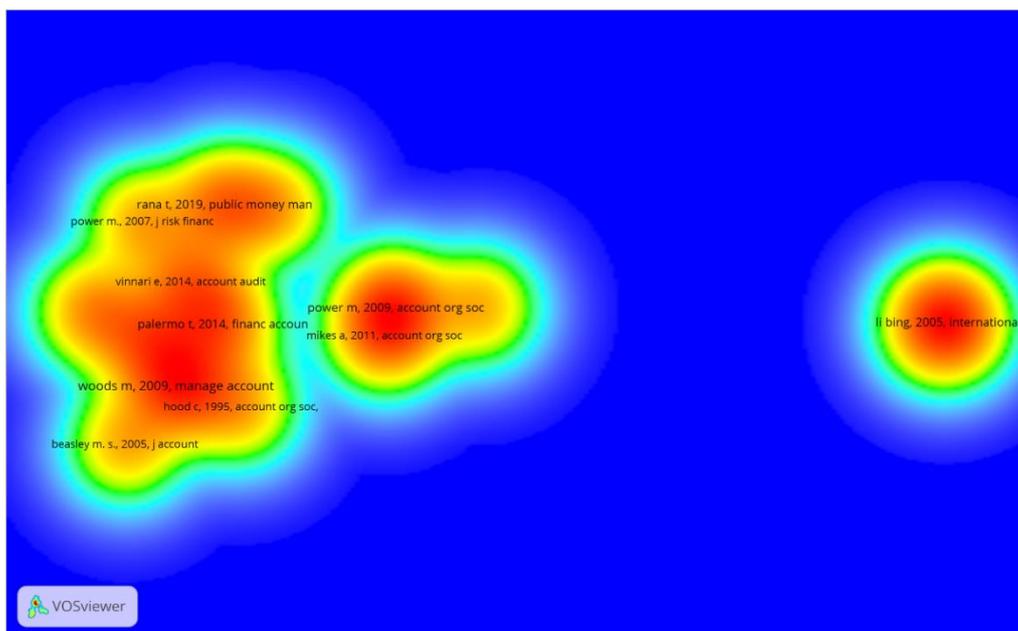


Figura 13: Mapa de calor de cocitação - *Web of Science* (Fonte: Própria. Extraída de *VOSviewer*).

O mapa de calor mostrado na figura 13 apresenta três clusters formados pelos artigos da base *Web of Science*.

O cluster mais a esquerda, formado, entre outros, pelos autores Palermo, que escreveu “*Accountability and expertise in public sector risk management: a case study*”, Vinnari e Skærbæk, autores de “*The uncertainties of risk management: A*

field study on risk management internal audit practices in a Finnish municipality”, Margaret Woods, que escreveu “*A contingency theory perspective on the risk management control system within Birmingham City Council*”, estudam principalmente o gerenciamento de riscos voltado para auditoria interna no setor público. Palermo aborda a questão num estudo de caso em uma organização governamental do Reino Unido, Vinanri e Skærbæk estuda o caso de um município na Finlândia e Woods estuda a Câmara Municipal de Birmingham [35] [36] [37].

O cluster central apresenta uma forte concentração entre os trabalhos dos autores Michael Power, intitulado “*The risk management of nothing*” e Anette Mikes com o trabalho “*From counting risk to making risk count: Boundary-work in risk management*”. Após a revisão das pesquisas desses autores, verifica-se que eles possuem uma linha similar, o que esclarece serem citados juntos frequentemente. Possuem o elo em comum o interesse pelos estudos em gerenciamento de riscos voltado para o setor financeiro. Power, que escreveu seu trabalho logo após a crise financeira de 2009, questiona a efetividade dos meios de gestão de riscos que estavam sendo adotados até então [38] . Ao passo que Mikes, inspirado pelo trabalho de Power, estuda como grandes bancos estavam aplicando o gerenciamento de riscos na prática [39].

Já o cluster que possui destaque o trabalho de Bing Li “*Bayesian technique framework for allocating demand risk between the public and private sector in PPP projects*” que considera a abordagem em parcerias público-privadas para a alocação de risco e estuda como distribuir a responsabilidade de gerenciamento de risco entre o cliente público e o contratante privado [40].

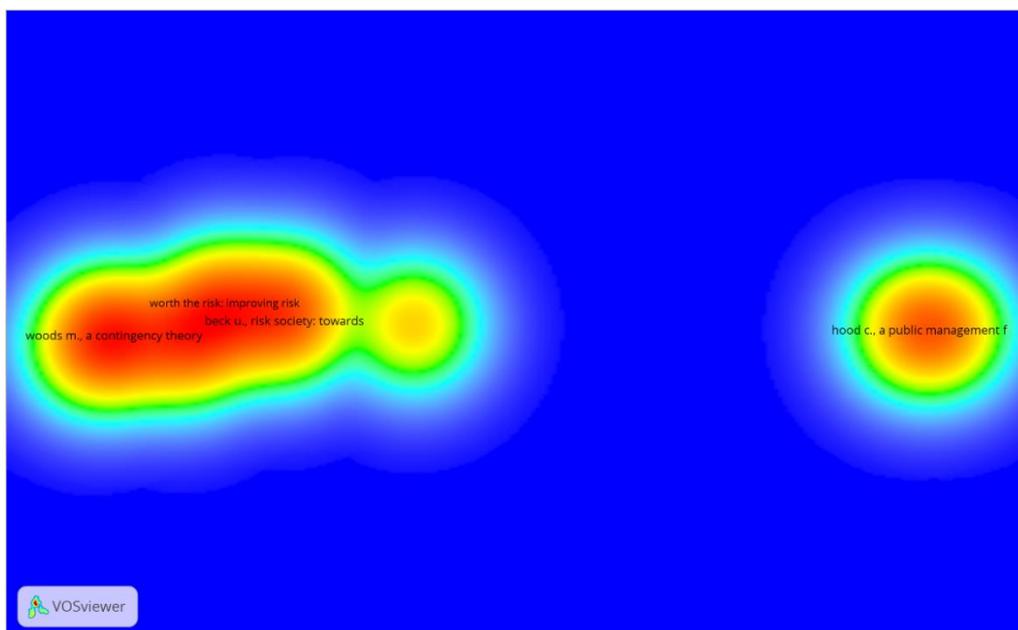


Figura 14: Mapa de calor de cocitação – *Scopus* (Fonte: Própria. Extraída de *VOSviewer*).

A base Scopus apresenta dois grupos principais de cocitações. O primeiro grupo, formado pelos autores Ulrich Beck, autor de “*The risk society and beyond*” e Margaret Woods, já mencionada anteriormente, reúne uma ampla gama de questões centradas principalmente em riscos sociais como referência para criação de políticas públicas [37] [41].

Já o cluster centrado no nome de Christopher Hood, autor de “*A public management for all seasons?*” discute principalmente as ideias conhecidas como “a nova gestão pública” e como esse método pode melhorar a prestação de serviços públicos [42].

O acoplamento bibliográfico, método proposto em 1963 por Michael M. Kessler, é um meio de se agrupar artigos científicos e técnicos com base em unidades de ligação bibliográfica. Nesse método, uma unidade de ligação (acoplamento) entre determinado número de artigos é determinada por um item de referência compartilhado por ambos [43].

Para elaboração dos mapas de calor de acoplamento bibliográfico, foi trabalhado com um período temporal mais restrito, a partir de 2020 até o presente

momento, pois esse tipo de análise está relacionado aos fronts de pesquisa identificados por meio do mapeamento bibliométrico e, portanto, se faz importante a utilização de trabalhos mais recentes.

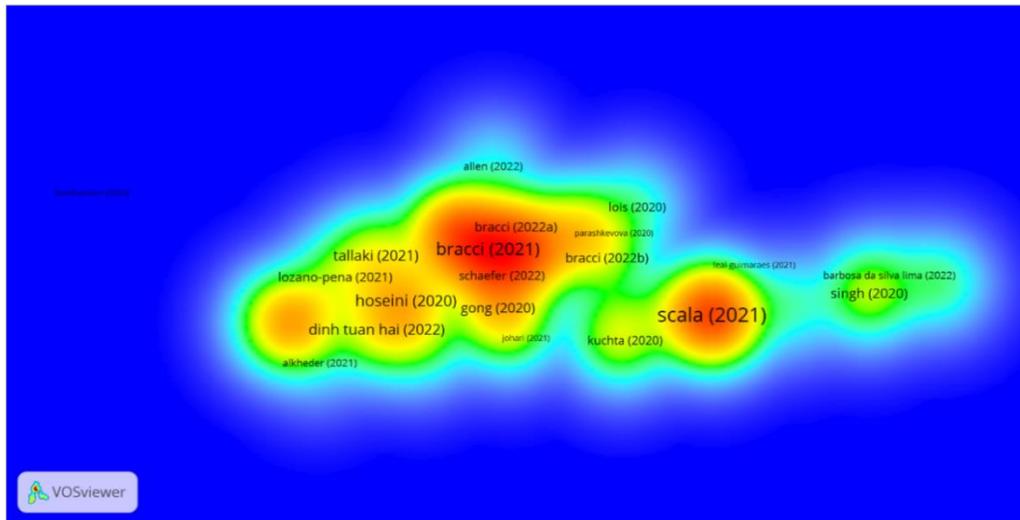


Figura 15: Mapa de calor de *Bibliographic Coupling - Web of Science* (Fonte: Própria. Extraída de *VOSviewer*).

Por meio do mapa de calor da figura 15, elaborado a partir da base de dados do *Web of Science*, nota-se uma forte relação entre os trabalhos de Enrico Bracci et al., com *“Risk management in the public sector: a structured literature review”* [26], onde os autores analisam o estado da arte da temática de gerenciamento de riscos no setor público, e o trabalho de Fabienne-Sophie Schäfer et al., *“Stakeholder pressure as a driver of risk management practices in public administrations”* [44] onde os autores estudam o impacto que a pressão dos stakeholders exercem na gestão de riscos de instituições públicas. O trabalho de Barbara Scala e Claire Lindsay intitulado *“Supply chain resilience during pandemic disruption: evidence from healthcare”* [45], também apresenta uma mancha concentrada no mapa apresentado. Nele, as autoras investigam a resiliência da cadeia de suprimentos de saúde do setor público aplicado ao contexto da pandemia Covid-19.

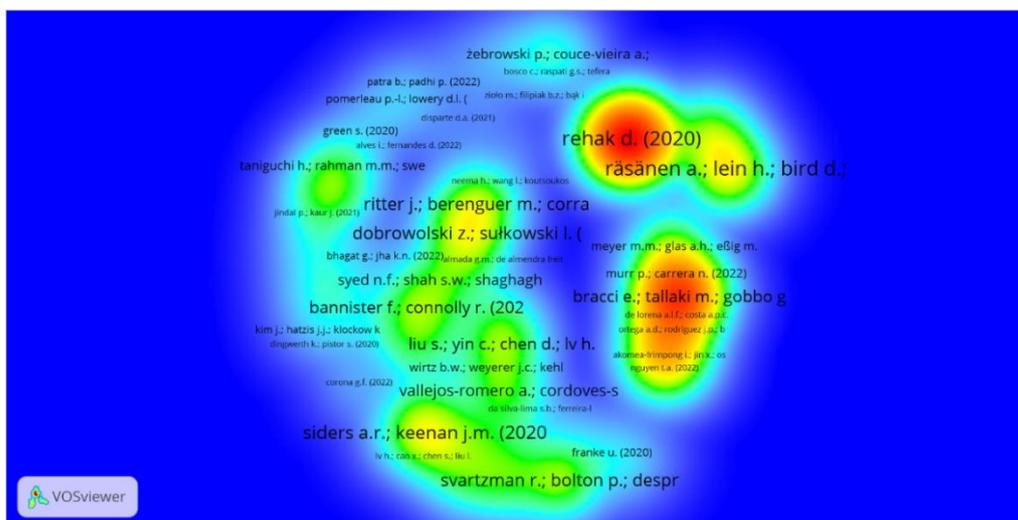


Figura 16: Mapa de calor de *Bibliographic Coupling* – *Scopus* (Fonte: Própria. Extraída de *VOSviewer*).

O mapa elaborado pelos artigos provenientes da base *Scopus*, mostrado na figura 16, apresenta uma variada gama de linhas de pesquisas em voga. Contudo, há dois clusters que exibem uma concentração maior.

O primeiro é formado pelos artigos de David Rehak, chamado “*Assessing and strengthening organisational resilience in a critical infrastructure system: Case study of the Slovak Republic*” [46], que avalia riscos de infraestruturas consideradas críticas para um país e o impacto que uma potencial falha poderia ocasionar, e o estudo de Aleksí Räsänen denominado “*Conceptualizing community in disaster risk management*” [47], que discute a gestão de riscos de desastres, bem como a resiliência da comunidade envolvida e o papel do setor público.

O outro cluster em destaque abrange os artigos de Bracci [26], já mencionado anteriormente, Peter Murr e Nieves Carrera com o artigo “*Institutional logics and risk management practices in government entities: evidence from Saudi Arabia*” [48], onde os autores buscam compreender como as lógicas de instituições públicas influenciam a adoção e implementação de práticas de gestão de risco, entre outros autores com linhas de pesquisas similares.

De forma a ampliar o leque de artigos relacionados como forma de produzir

um artigo científico fortemente embasado, foi realizada uma nova pesquisa, pelos mesmos termos supramencionados na base do Google Acadêmico, onde foram filtrados apenas os principais trabalhos relevantes para esta pesquisa.

Posteriormente, foi realizada a consolidação das pesquisas encontradas nas três bases de dados e definição dos trabalhos mais relevantes para este estudo com base na relevância temática para este trabalho e com base na relevância científica, definida com base no número de citações de cada artigo. Os resultados obtidos foram consolidados na tabela a seguir:

Título	Autores	Principais Contribuições
A Gestão De Riscos Do Programa Nacional De Reestruturação E Aquisição De Equipamentos Para A Rede Escolar Pública De Educação Infantil – Proinfância	Camila Lima Milhomem	Estudo realizado no âmbito do FNDE e que possui grande correlação com a pesquisa proposta. Analisou como a adoção de uma metodologia de gestão de riscos possibilita a tomada de decisões que possam impactar positivamente na conclusão das obras do Proinfância.
Gestão E Controle De Recursos Públicos: Um Estudo Dos Mecanismos De Controle Interno Nas Obras De Infraestrutura No Âmbito Do FNDE	Karoline Cunha Sousa	Estudo realizado no âmbito do FNDE e que possui grande correlação com a pesquisa proposta. Estudou mecanismos de controle interno, com foco administrativo, utilizados pelo FNDE durante a implementação das obras de infraestrutura escolar.

Título	Autores	Principais Contribuições
Risk management in the public sector: a structured literature review	Enrico Bracci, Mouhcine Tallaki; Giorgia Gobbo; Luca Papi	Este trabalho analisa o estado da arte e consolida o conhecimento de 63 artigos científicos da base de dados Scopus em um único trabalho com o objetivo de definir os temas emergentes em gestão de riscos no setor público.
Risk Management In Public Sector Organizations: A Case Study	Karolina Zofia Kapuscinska; Marek Matejun	O artigo aborda as características únicas e os princípios básicos da gestão de riscos em organizações do setor público e apresenta um exemplo de implementação prática desse conceito com base no <i>New Public Management</i> e <i>Lean Government</i> .
Application of risk management in Public Works organisations in Chile	Michiel Wolbers	Analisa o estado atual da aplicação da gestão de riscos no Chile e determina as melhorias necessárias para melhorar a aplicação da gestão nas obras públicas do Chile.
The Brazilian scientific production on risk management in the public sector: a bibliometric analysis	Naiara Taise Sousa Nunes; Samuel Cavalcante Mota; Augusto César de Aquino Cabral; Sandra Maria dos Santos	Investiga a produção científica de artigos sobre gestão de riscos com enfoque no setor público, publicada em periódicos nacionais.
New development: Enabling enterprise risk management maturity in public sector organizations	Habib Mahama; Mohamed Elbashir; Steve Sutton;	Os autores apresentam uma estrutura para gerenciamento de riscos em nível macro em organizações do setor público.

Título	Autores	Principais Contribuições
	Vicky Arnold	
Risk allocation in the private provision of public infrastructure	Andrew Ng; Martin Loosemore	O artigo apresenta um estudo de caso do projeto New Southern Railway, na Austrália. É analisada a lógica por trás das decisões sobre distribuições de risco entre os setores público e privado e suas consequências.

Tabela 4: Consolidação dos principais trabalhos (Fonte: Própria).

Diante das análises realizadas, foi construído um Modelo Integrador, retratado na figura 17, a fim de consolidar os conhecimentos obtidos.

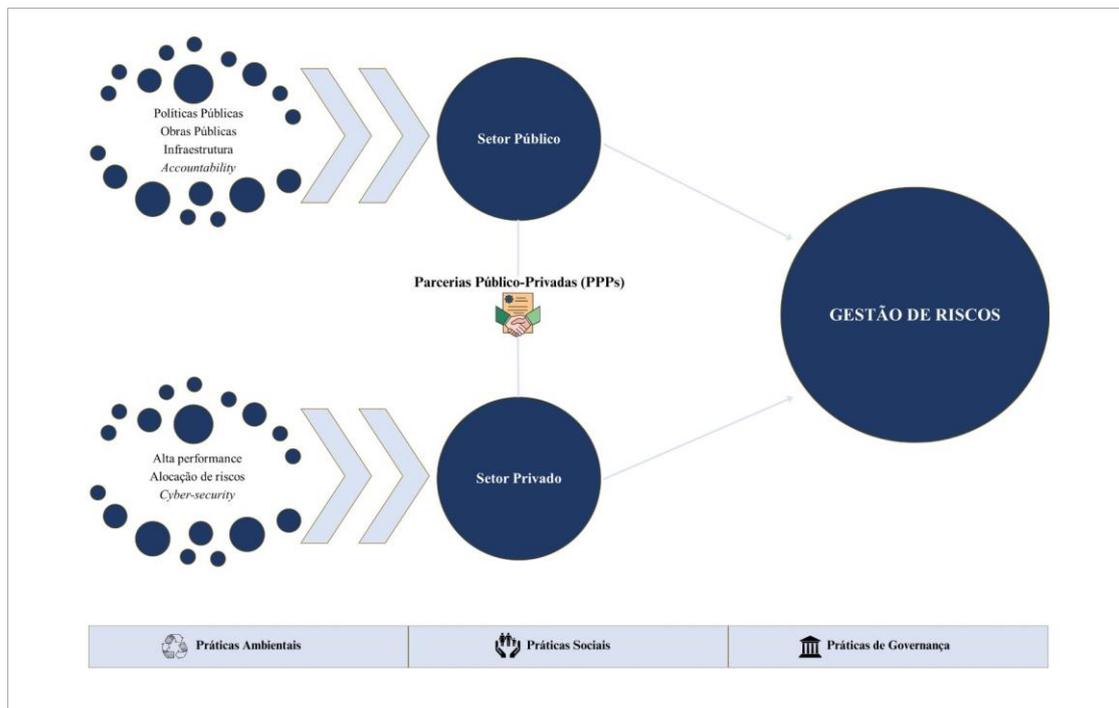


Figura 17: Modelo Integrador (Fonte: Própria).

O modelo apresentado demonstra as principais vertentes de aplicação dos estudos de gestão de riscos, que são o setor público e setor privado. Uma tendência descoberta a partir da revisão da literatura é o interesse da comunidade científica em estudar como a interação entre esses dois setores acontece e quais os benefícios em potencial. Parcerias público-privadas (PPPs) é o principal mecanismo para que

características inerentes de cada setor se unam para agregar valor ao serviço.

Evidência disso é que, mediante os parâmetros adotados, o artigo mais citado da base *Scopus*, “*The allocation of risk in PPP/PFI construction projects in the UK*” [30] , realiza uma abordagem sobre as PPPs e afirma que essa é uma maneira eficaz de se obter uma boa relação qualidade/preço em projetos de infraestrutura pública. Outro benefício em potencial que o artigo investiga é a alocação de risco para fora do setor público, mediante acordos contratuais.

Outra tendência notada a partir da revisão da literatura realizada e que está presente no modelo integrador é o pensamento ESG, acrônimo para *Environmental, Social and Governance*, como pilares de sustentação. Esse termo, cunhado em 2004 pelo documento “*Who Cares Wins*”, criado pelo Pacto Global da ONU em conjunto com o Banco Mundial, instiga instituições a refletirem e perseguirem práticas sustentáveis para fatores ambientais, sociais e de governança [49] [50]. A importância e relevância que o termo ganhou é visível e pode ser comprovada por variados fatores:

- As menções a ESG na internet aumentaram significativamente nos últimos anos. O uso do termo em debates online aumentou mais de 500% de 2019 para 2020 [51].
- Pesquisadores da universidade de Harvard demonstraram que empresas com altas pontuações em sustentabilidade tendem a ser mais rentáveis do que as demais. [52]. Segundo estudo da PwC, fundos alinhados com o pensamento ESG, tiveram desempenho 9% superior a seus pares não ESG entre 2010 e 2019 [53].
- Segundo o Morgan Stanley, em pesquisa realizada na América do Norte, Europa e Ásia, 95% dos investidores institucionais investem, ou estão cogitando, em ativos sustentáveis e 80% dos investidores institucionais enxergam investimentos sustentáveis como uma estratégia de mitigação de risco [54].
- 45% dos investidores institucionais acreditam que retornos sociais e ambientais são tão importantes quanto retornos financeiros [54].

- Levantamento realizado pela Morningstar e pela Capital Reset mostra que, no Brasil, fundos ESG captaram R\$ 2,5 bilhões em 2020 [51] [55].
- Pesquisa da Peterson Institute for International Economics, demonstra que práticas de diversidade e inclusão, abrangidas nos critérios ESG, também são fatores importantes. Companhias onde pelo menos 30% dos líderes são mulheres, são, em média, 15% mais rentáveis do que aquelas que não adotam diversidade de gênero. [56]

Entre as vertentes ESG mais almeçadas por empresas estão questões ambientais, principalmente ligadas à gestão de resíduos, e de governança, especificamente relacionadas a práticas de criação de mecanismos internos de compliance que inibam práticas desleais internas [51].

Fatores ESG também são alvos de estudos da comunidade científica, o que justifica a presença dessas práticas como base do modelo integrador (figura 17). O termo “desastre”, relevante na figura 12, pode ser conectado a fatores ESG. O artigo “*Conceptualizing community in disaster risk management*” [47], já mencionado neste estudo, aborda o gerenciamento de riscos em casos de desastres e possíveis consequências ambientais e sociais. Nessa mesma linha, está o estudo “*Assessing and strengthening organisational resilience in a critical infrastructure system: Case study of the Slovak Republic*” [46]. Outros estudos, como o “*Empirical study of risk assessment and allocation of public-private partnership projects in China*” [22], abordam questões ligadas à governança das instituições.

2.4. Adição de novos termos à pesquisa bibliográfica

O desenvolvimento do trabalho, em conjunto com a decisão de se utilizar *Machine Learning* neste estudo, fez emergir a necessidade de realização de uma nova pesquisa por trabalhos existentes, dessa vez mais específica nos pontos que serão abordados nesta dissertação. Para isso, foi realizada uma nova busca nas bases do

Web of Science e *Scopus* com o objetivo de enriquecer a base teórica.

Devido a grande quantidade de artigos ligados a *Machine Learning* e gerenciamento de riscos, optou-se por tornar a pesquisa mais específica em relação ao tema, o que direcionou a pesquisa a três possíveis combinações de termos:

- ("machine learning" AND "project management" AND "risk management")
- OR ("machine learning" AND "public works" AND "risk management")
- OR ("machine learning" AND "construction" AND "risk management")

A pesquisa, realizada no espaço temporal de dez anos (2014-2024), retornou 99 resultados na base *Web of Science* e 142 na base *Scopus*. Após refinamento nas áreas ligadas ao tópico, encontrou-se 51 resultados relevantes no *WoS* e 120 no *Scopus*.

Os dez artigos mais citados de cada base de dados foram consolidados na tabela 5.

Web of Science		
Título	Autores	Citações
Applications of machine learning methods for engineering risk assessment - A review	Hegde, Jeevith; Rokseth, Borge	156
Deep learning in the construction industry: A review of present status and future innovations	Akinosho, Taofeek D.; Oyedele, Lukumon O.; Bilal, Muhammad; Ajayi, Anuoluwapo O.; Delgado, Manuel Davila; Akinade, Olugbenga O.; Ahmed, Ashraf A.	148
Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges	Abioye, Sofiat O.; Oyedele, Lukumon O.; Akanbi, Lukman; Ajayi, Anuoluwapo; Delgado, Juan Manuel Davila; Bilal, Muhammad; Akinade, Olugbenga O.; Ahmed, Ashraf	132
Machine Learning Algorithms for Construction Projects Delay Risk Prediction	Gondia, Ahmed; Siam, Ahmad; El-Dakhakhni, Wael; Nassar, Ayman H.	114

Risk assessment and management of excavation system based on fuzzy set theory and machine learning methods	Lin, Song-Shun; Shen, Shui-Long; Zhou, Annan; Xu, Ye-Shuang	106
Big Data and Its Applications in Smart Real Estate and the Disaster Management Life Cycle: A Systematic Analysis	Munawar, Hafiz Suliman; Qayyum, Siddra; Ullah, Fahim; Sepasgozar, Samad	61
A knowledge-based risk management tool for construction projects using case-based reasoning	Okudan, Ozan; Budayan, Cenk; Dikmen, Irem	55
A review on flood management technologies related to image processing and machine learning	Munawar, Hafiz Suliman; Hammad, Ahmed W. A.; Waller, S. Travis	36
Machine learning-based regional scale intelligent modeling of building information for natural hazard risk management	Wang, Chaofeng; Yu, Qian; Law, Kincho H.; McKenna, Frank; Yu, Stella X.; Taciroglu, Ertugrul; Zsarnoczay, Adam; Elhaddad, Wael; Cetiner, Barbaros	34
Machine learning model for delay risk assessment in tall building projects	Sanni-Anibire, Muizz O.; Zin, Rosli Mohamad; Olatunji, Sunday Olusanya	17
Scopus		
Título	Autores	Citações
Deep learning in the construction industry: A review of present status and future innovations	Akinosho T.D., Oyedele L.O., Bilal M., Ajayi A.O., Delgado M.D., Akinade O.O., Ahmed A.A.	195
Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges	Abioye S.O., Oyedele L.O., Akanbi L., Ajayi A., Davila Delgado J.M., Bilal M., Akinade O.O., Ahmed A.	187
Machine Learning Algorithms for Construction Projects Delay Risk Prediction	Gondia A., Siam A., El-Dakhakhni W., Nassar A.H.	132
A knowledge-based risk management tool for construction projects using case-based reasoning	Okudan O., Budayan C., Dikmen I.	72
Deep Learning Models for Health and Safety Risk Prediction in Power Infrastructure Projects	Ajayi A., Oyedele L., Owolabi H., Akinade O., Bilal M., Davila Delgado J.M., Akanbi L.	43
Performance analysis of advanced decision tree-based ensemble learning algorithms for landslide susceptibility mapping	Kutlug Sahin E., Colkesen I.	34
Predicting delays in software projects using networked classification	Choetkiertikul M., Dam H.K., Tran T., Ghose A.	32
Big data platform for health and safety accident prediction	Ajayi A., Oyedele L., Delgado J.M.D., Akanbi L., Bilal M., Akinade O., Olawale O.	28

Risk identification, assessments, and prediction for mega construction projects: A risk prediction paradigm based on cross analytical-machine learning model	Chattapadhyay D.B., Putta J., Rama Mohan Rao P.	25
Deep learning and Boosted trees for injuries prediction in power infrastructure projects	Oyedele A., Ajayi A., Oyedele L.O., Delgado J.M.D., Akanbi L., Akinade O., Owolabi H., Bilal M.	21

Tabela 5: Artigos mais citados relacionados a Machine Learning e gestão de riscos (Fonte: Própria).

A identificação dos artigos mais citados demonstra aqueles que são valorizados pela comunidade científica e, por sua vez, possibilita que o estudo tenha uma base teórica robusta. Entre os artigos apresentados na tabela 5, se percebe repetição de alguns trabalhos em ambas as bases de dados, a exemplo do trabalho “*Deep learning in the construction industry: A review of present status and future innovations*” [57], que estudou como o *Deep Learning*, um tipo de algoritmo de *Machine Learning*, está sendo empregado na indústria de construção civil. Os autores chegaram à conclusão de que há espaço para se avançar com a utilização de *Deep Learning* na indústria, principalmente quando comparado com outros algoritmos de ML.

Outro artigo que aparece em destaque em relação ao número de citações em ambas as bases de dados é “*Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges*” [58]. Esse trabalho buscou compreender qual o estado atual da aplicação de inteligência artificial na indústria de construção civil, quais os desafios encontrados e quais as potenciais avenidas de crescimento. Foi descoberto que variados campos de IA possuem aplicação em uma gama de tópicos, como apresenta a figura 18.

AI Subfields	Construction Application Areas																
	Health and Safety	Scheduling	Cost Estimation	Legal (Contracts & Conflict Management)	Supply chain & Logistics	Site Monitoring & Performance Evaluation	Material Management	Offsite Assembly	Plant and Equipment Management	Project Planning	Knowledge Management	Design	Risk Management	Temporary Structures	Bids/ Tenders	Energy Management	Sustainability
Machine Learning	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓		
Computer Vision	✓			✓	✓	✓	✓	✓	✓	✓	✓	✓					
Automated Planning & Scheduling		✓								✓							
Robotics						✓	✓	✓	✓	✓	✓	✓	✓				
Knowledge-based Systems	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓		✓	✓	✓
Natural Language Processing	✓			✓		✓	✓			✓	✓		✓				
Optimisation	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓			

Figura 18: Possíveis aplicações de IA na construção civil (Fonte: [58]).

O artigo “*Applications of machine learning methods for engineering risk assessment – A review*” [59] revisa publicações que utilizam algoritmos de *Machine Learning* aplicados a avaliação de riscos ligados a engenharia. Entre os achados, se destaca a descoberta que 17 indústrias diferentes exploraram o uso de ML para gerenciar riscos. A indústria automotiva lidera o ranking de aplicações, seguido pela de construção civil.

Outro artigo relevante para a temática que está sendo estudada, é o “*Machine learning algorithms for construction projects delay risk prediction*” [60]. Nele, os autores investigaram algoritmos de ML para prever riscos de paralisação de obras. No conjunto de dados (*dataset*) utilizado, o modelo *Naive Bayes* foi o mais adequado. Todavia, se ressalta que o algoritmo ideal depende dos dados disponíveis em cada *dataset*.

Em resumo, a adição dos novos termos à pesquisa bibliográfica possui grande valia para o desenvolvimento do trabalho e os artigos encontrados irão balizar a execução deste estudo.

Capítulo 3

Referencial Teórico

3.1. Políticas públicas

Políticas públicas são ações estruturadas e sistemáticas implementadas pelo Estado com o objetivo de atender demandas sociais e alcançar metas e objetivos definidos em âmbito coletivo e são tomadas por aqueles que representam legalmente o coletivo. Ou seja, política pública pode ser entendida como um processo que objetiva resolver uma questão pública [61] [62].

Conjunto de políticas, programas e ações do Estado, diretamente ou por meio de delegação, com objetivo de enfrentar desafios e aproveitar oportunidades de interesse coletivo. [63]

A definição de política pública, por envolver ações que o Poder Público realiza para cumprir os deveres relativos aos direitos dos cidadãos, envolve a definição de diretrizes, alocação de recursos e implementação de programas e projetos em áreas específicas, como saúde, educação, segurança, meio ambiente, entre outras [64].

No âmbito educacional, a implementação de uma nova política pública envolve alguns aspectos críticos e que devem ser observados. Novas políticas estão sujeitas à interpretação dada pelos profissionais que atuam em variados níveis hierárquicos de cada unidade educacional, por exemplo [64] [65]. Para tentar solucionar isso, diferentes autores sugerem a necessidade de se envolver o corpo docente não apenas na fase final de implementação, mas também no momento de formulação destas políticas [64] [66] [67].

Paulo Freire, considerado patrono da educação brasileira [68], em sua obra "Pedagogia do Oprimido", ressalta a importância da educação como uma ferramenta de transformação social. Freire argumenta que as políticas educacionais devem ser direcionadas à promoção da justiça social e da igualdade de oportunidades, visando superar as desigualdades existentes na sociedade [69].

O desenvolvimento do país, um dos objetivos que políticas públicas almejam, está relacionado com o investimento em obras públicas [70]. De acordo com definição do Tribunal de Contas da União [71], obra pública pode ser entendida como “toda construção, reforma, fabricação, recuperação ou ampliação do bem público” seja ela executada de forma direta, por meio da própria entidade da Administração, seja ela executada de forma indireta, por meio de licitação.

Entre os variados fatores que influenciam a definição de uma política pública educacional, variados autores destacam a influência positiva do ambiente escolar na aprendizagem dos alunos. No trabalho "*Do School Facilities Matter? Measuring the Effects of Capital Expenditures on Student and Neighborhood Outcomes*" [72], os autores enfatizam que uma infraestrutura adequada, incluindo salas de aula espaçosas, bibliotecas bem equipadas, laboratórios de ciências e instalações esportivas, contribui para um ambiente propício ao aprendizado.

Ademais, o relatório "*Education Policy Outlook Brasil*" [73] destaca a importância dos investimentos em infraestrutura para o crescimento econômico e social. O relatório argumenta que uma infraestrutura de qualidade é essencial para melhorar a produtividade e a competitividade de um país, além de contribuir para a redução da pobreza e o aumento da qualidade de vida. A falta de infraestrutura escolar, o que inclui a infraestrutura digital das instituições, e a desigualdade na distribuição de recursos entre as regiões do país são desafios existentes em que o governo brasileiro investe recursos para superar [73].

Ao longo dos anos, o governo tem implementado diversas medidas, como a construção de novas escolas e a reforma de prédios antigos, através de programas de

obras públicas, a exemplo dos programas Proinfância e Brasil Carinhoso [74] [75]. Essas ações visam não apenas oferecer condições adequadas de ensino, mas também incentivar a permanência dos estudantes na escola [76].

Em julho de 2023, em mais uma demonstração de esforço por meio do Estado brasileiro para aprimorar a educação brasileira, foi lançada uma portaria conjunta entre o Ministério da Educação (MEC), Ministério da Gestão e da Inovação em Serviços Públicos (MGI) e Controladoria-Geral da União (CGU) para dispor sobre repactuações entre o Fundo Nacional de Desenvolvimento da Educação (FNDE) e os entes federativos do Brasil com o intuito de concluir obras paralisadas, aquelas que possuem instrumento vigente, mas sem execução dos serviços, e inacabadas, aquelas que possuem instrumento vencido sem a conclusão do projeto [77]. Com isso, os entes federativos que se enquadrem nos critérios dispostos pela Portaria Conjunta MEC/MGI/CGU nº 82, de 10 de julho de 2023 poderão aderir ao pacto para a conclusão das obras e assim, assumir um novo compromisso com a sociedade de ampliar a oferta de uma educação básica de qualidade, com a melhoria das condições de oferta. Ao aderir ao pacto, os entes ainda se comprometem a alguns deveres, tais como progredir com a execução física em até 12 meses após aprovação do termo, concluir as obras em até 24 meses (prorrogáveis) e prestar contas sobre o instrumento repactuado entre a autoridade competente e o FNDE [78].

Nota-se, portanto, que o cenário educacional é alvo de diversas políticas públicas em âmbito nacional. O Fundo Nacional de Desenvolvimento da Educação (FNDE), por sua vez, é o órgão responsável por repassar recursos financeiros as obras públicas educacionais em execução, monitorando-as até a conclusão [76].

3.2. Proinfância

O FNDE, órgão responsável pela execução de políticas educacionais, presta assistência financeira aos estados, municípios e Distrito Federal [79]. Entre os programas geridos pelo Fundo, encontra-se o Proinfância, instituído pela Resolução

nº 6 de 24 de abril de 2007, que é uma iniciativa do Ministério da Educação para melhorar a rede de Educação Infantil [80]. O objetivo é garantir o acesso a creches e escolas com infraestrutura adequada. O programa, destinado aos municípios brasileiros e ao Distrito Federal, trabalha em duas frentes distintas. A primeira é a construção de creches e pré-escolas com assistência financeira e técnica do FNDE, e a segunda frente de atuação é a de aquisição de mobiliário e equipamentos, como mesas, cadeiras, berços, entre outros, para a rede escolar de Educação Infantil [18].

Para elucidar melhor a estrutura interna do FNDE, a diretoria responsável pelo Programa é a Diretoria de Gestão, Articulação e Projetos Educacionais (DIGAP), que possui, entre outras coordenações, a Coordenação-Geral de Infraestrutura Educacional (CGEST/FNDE), responsável pela análise de solicitações encaminhadas por meio do Sistema Integrado de Monitoramento Execução e Controle (SIMEC) e por orientações aos entes até o momento do início da execução da obra, e a Coordenação-Geral de Implementação e Monitoramento de Projetos Educacionais (CGIMP/FNDE), responsável pelo “monitoramento das ações em andamento, especialmente da execução de obras, pela aprovação técnica para a liberação de recursos e pela orientação quanto a questões técnicas, após o início da execução das ações” [18].

O ente federativo interessado em aderir ao programa deve seguir uma série de normas como realizar um diagnóstico da situação educacional e elaborar um Plano de Ações Articuladas (PAR) a ser enviado ao FNDE via sistema para homologação [18].

O Proinfância estabelece condições mínimas para a construção de escolas, uma das frentes do programa. Algumas condições são: demanda mínima a ser atendida conforme o projeto escolhido, com base em dados do Censo Escolar; o ente interessado deve ser dono do terreno onde a edificação será construída; o terreno deve possuir viabilidade técnica e legal para implantação da escola. A resolução CD/FNDE nº 4, de 4 de maio de 2020 “estabelece os critérios para o apoio técnico e financeiro às redes públicas de educação básica dos estados, municípios e do

Distrito Federal, no âmbito do quarto ciclo (2021-2024) do Plano de Ações Articuladas (PAR)” [81].

O ente que almeja ingressar ao Proinfância opta pelo tipo de projeto arquitetônico que deseja e que melhor irá atender suas necessidades. Há a opção de o órgão ingressar com um projeto próprio, onde o ente é o responsável pelo projeto. Contudo, há uma série de normas que devem ser seguidas conforme o Manual de Orientações Técnicas disponibilizado pelo FNDE [82].

Outra possibilidade que o ente federativo possui é escolher uma das propostas padronizadas para o Proinfância. Esses tipos de projetos abarcam variados ambientes, tais como, como salas de aula, berçário, sala de leitura, sala de informática, secretaria, cozinha, refeitório, pátio coberto, sanitários, entre outros, para garantir a qualidade do edifício para os alunos [83]. O FNDE fornece de maneira eletrônica todos os documentos que os entes necessitam para a execução da obra, como: memorial descritivo, planilhas orçamentárias, projeto arquitetônico, projeto elétrico, projeto estrutural e projeto hidráulico.

As opções padronizadas a disposição dos entes são:

- Projeto Tipo 1: possui capacidade de atendimento de até 376 crianças, em dois turnos, ou 188 crianças em período integral [84].



Figura 19: Fachada Frontal Tipo 1 (Fonte: Adaptado de [84]).

- Projeto Tipo 2: possui capacidade de atendimento de até 188 crianças, em dois turnos, ou 94 crianças em período integral [85].



Figura 20: Fachada Frontal Tipo 2 (Fonte: Adaptado de [85]).

- Projeto de Ampliação Módulo Infantil para Escolas: possui capacidade de atendimento é de até 96 crianças, em dois turnos, ou 48 crianças em período integral [86].



Figura 21: Fachada Frontal Ampliação Módulo Infantil (Fonte: Adaptado de [86]).

Ao se adentrar na análise das obras de educação infantil financiadas pelo FNDE, pertencentes ao programa Proinfância, na data de 24 de janeiro de 2023, nota-se que cerca de 13,2% das obras pactuadas desde 2006 ainda não foram concluídas. Esse fato é alarmante pois mais de 90% das obras presentes na base de dados foram pactuadas em 2014 ou antes disso, já havendo tempo hábil para que elas estivessem concluídas.

Excluindo-se as obras que já foram concluídas, cerca de 6% encontram-se paralisadas. Isso corresponde a R\$183.479.382,06 investidos e, por enquanto,

desperdiçados pelos cofres públicos. Pior ainda, quase cem mil crianças da primeira infância estão deixando de ir à escola. Ainda desconsiderando as obras já concluídas, as obras comprometidas (soma das obras paralisadas, inacabadas e canceladas) correspondem a 76,6% do total e representam mais de 1 bilhão e 221 milhões de reais investidos e sem retorno para a população.

Educação Infantil / Proinfância			
Status	Nº de Obras	Valores Pagos	Nº Alunos
Concluída	4.841	R\$ 5.322.796.633,54	1.497.948
Em Andamento	900	R\$ 721.813.893,89	368.550
Inacabada	917	R\$ 646.644.054,24	298.554
Não iniciada	32	R\$ 11.500.403,81	12.672
Obra Cancelada	1.896	R\$ 391.805.143,21	640.992
Paralisada	244	R\$ 183.479.382,06	97.938
Total Geral	8.830	R\$ 7.278.039.510,75	2.916.654

Tabela 6 - Obras do Proinfância (Fonte: Própria. Extraído do SIMEC em 24 de janeiro de 2023).

A tabela 6 abrange as situações das obras pactuadas desde 2006. Se elucida que, conforme já mencionado, uma obra é considerada paralisada quando o instrumento ainda se encontra vigente, mas sem execução dos serviços. O próprio ente informa essa situação no SIMEC. O status da obra passa para inacabada quando o Termo de Compromisso é vencido, sem prorrogação, e a construção não foi concluída [77]. Já obra cancelada se caracteriza como um empreendimento que teve sua execução definitivamente interrompida. Esta interrupção pode ocorrer em virtude da manifestação de desinteresse do ente federativo em prosseguir com a construção, da identificação de problemas técnicos insuperáveis nos projetos de engenharia, ou ainda pela constatação de que a obra, em sua configuração existente, não mais atende às necessidades da localidade beneficiária. O processo de cancelamento implica em desdobramentos administrativos significativos, contemplando tanto a potencial restituição dos recursos federais já desembolsados quanto a instauração de procedimentos para apuração de responsabilidades dos gestores envolvidos [77].

A busca por eficiência no monitoramento de obras por parte do FNDE

objetiva a otimização de processos e consequente diminuição do número de obras paralisadas. Para isso se faz de vital importância o gerenciamento de riscos dessas obras.

3.3. Gestão de riscos

A temática de gestão de riscos está em voga na comunidade acadêmica, conforme destacado no capítulo 2 desta pesquisa. Contudo, se faz necessário delimitar a definição de risco.

O estudo e citações sobre riscos não é algo novo na humanidade. A exemplo, a Lei das Doze Tábuas, código legal romano do século V a.C., incluía disposições relacionadas a contratos e acordos comerciais que poderiam ser vistos como precursores do gerenciamento de riscos [87]. O Talmude, coletânea de livros sagrados dos judeus datada por volta dos anos 200 d.C., também abordava, ainda que de forma indireta, o conceito de risco [88].

Na obra “*Against The Gods: The Remarkable Story of Risk*”, Peter L. Bernstein cita a importância do conceito de risco para a evolução humana e frisa que risco não é sinônimo de perigo, mas sim de não saber o que o futuro reserva [89] [90].

A ideia revolucionária que define a fronteira entre os tempos modernos e o passado é o domínio do risco: a noção de que o futuro é mais do que um capricho dos deuses e de que homens e mulheres não são passivos ante a natureza. Até os seres humanos descobrirem como transpor essa fronteira, o futuro era um espelho do passado ou o domínio obscuro de oráculos e adivinhos que detinham o monopólio sobre o conhecimento dos eventos previstos. [90]

O cientista político Aaron Wildavsky fala que risco é uma “precondição essencial para o desenvolvimento humano” e filosofa sobre o assunto citando que se o ser humano parar de assumir riscos, “inovações técnicas e sociais necessárias para solucionar muitos dos problemas mundiais desapareceriam” [91].

Stephen Hill descreve risco no “Guia sobre a gestão de riscos no serviço público” [92] como sendo “a probabilidade de que um evento, seja ele bom ou mau, ocorra no futuro”. Hill salienta que risco pode ser tanto aspectos positivos quanto negativos.

Riscos podem ser inerentes aos mais variados modelos de negócios. De acordo com a norma ISO 31000, risco pode ser definido como o “efeito da incerteza nos objetivos” [93]. Já o guia PMBOK define risco como sendo um evento ou uma condição incerta que pode gerar impacto positivo ou negativo sobre o projeto [94]. O gerenciamento de riscos, por sua vez, é o conjunto de atividades que busca mensurar, controlar e mitigar riscos identificados e que surge justamente como forma de gerir os eventos antes mesmo que eles ocorram assim como propor um plano de contingência caso ele venha a ocorrer [89] [94].

O termo “gestão de riscos” é frequentemente associado ao setor financeiro, como ferramenta de contabilidade, enquanto estudos relacionados à forma macro de estabelecer controle sobre os riscos nas organizações ainda são escassos [95].

A aplicação do controle de riscos inclui mecanismos que auxiliam na tomada de decisões, resultando em melhorias no desempenho do serviço público, contribuindo para a eficiência das estratégias governamentais em um cenário de incertezas e restrições de recursos [89].

3.4. Gestão de riscos no setor público

No setor público, o foco em pesquisa e criação de frameworks sobre o tema iniciou-se por volta dos anos 80, sob a luz da Nova Gestão Pública (*New Public Management*) que buscou aplicar práticas gerenciais do setor privado também na administração pública [31]. A diferença primordial é que no âmbito do setor público, o foco central da gestão de riscos deve ser cuidar do bem público. O interesse público deve ser o balizador das ações a serem tomadas [89] [92]. O *Privy Council Office*

canadense, equivalente à Casa Civil da Presidência da República no Brasil, saliente que a habilidade e conhecimentos dos funcionários públicos são diretamente proporcionais à capacidade do governo gerenciar riscos [96]

No Brasil, o assunto ganhou destaque com a publicação da Emenda Constitucional nº 19 de 1998 que dispõe sobre o princípio da eficiência e estabelece normas para a Administração Pública. Vários países passaram a pesquisar sobre gerenciamento de riscos no setor público com o surgimento da pandemia COVID-19. Inclusive órgãos reguladores, como a Controladoria Geral da União (CGU) no Brasil, embasada pelo artigo 17 do Decreto nº 9.203, de 2017 que estabelece e aprimora um sistema de gestão de riscos para a alta administração das organizações da administração pública federal direta, autárquica e fundacional à luz de determinados princípios, passaram a dar importância especial ao tema.

Art. 17. A alta administração das organizações da administração pública federal direta, autárquica e fundacional deverá estabelecer, manter, monitorar e aprimorar sistema de gestão de riscos e controles internos com vistas à identificação, à avaliação, ao tratamento, ao monitoramento e à análise crítica de riscos que possam impactar a implementação da estratégia e a consecução dos objetivos da organização no cumprimento da sua missão institucional, observados os seguintes princípios:

- I - implementação e aplicação de forma sistemática, estruturada, oportuna e documentada, subordinada ao interesse público;
- II - integração da gestão de riscos ao processo de planejamento estratégico e aos seus desdobramentos, às atividades, aos processos de trabalho e aos projetos em todos os níveis da organização, relevantes para a execução da estratégia e o alcance dos objetivos institucionais;
- III - estabelecimento de controles internos proporcionais aos riscos, de maneira a considerar suas causas, fontes, consequências e impactos, observada a relação custo-benefício; e
- IV - utilização dos resultados da gestão de riscos para apoio à melhoria contínua do desempenho e dos processos de gerenciamento de risco, controle e governança. [97]

A Organização para a Cooperação e Desenvolvimento Econômico (OCDE) [98] e o Banco Mundial [99] também realizaram esforços para a adoção de práticas de gerenciamento de riscos.

Entretanto, a literatura científica se debruça, majoritariamente, em estudar o assunto aplicado ao setor privado [95] [100]. Entretanto, uma mudança de tendência pôde ser observada a partir de 2020 onde o interesse em gestão de riscos voltadas para o setor público começou a crescer de forma expressiva [26].

No cenário brasileiro, em 2013, o extinto Ministério do Planejamento, Orçamento e Gestão (MPOG), atual Ministério do Planejamento e Orçamento, criou um guia de orientação para o gerenciamento de riscos no setor público baseado no modelo de gerenciamento de risco do Livro Laranja (*Risk Management Model*, presente no *Orange Book*) criado pelo governo do Reino Unido [101]. O modelo britânico foi publicado pelo governo inglês e fornece orientações para a avaliação e gestão de riscos em projetos e atividades governamentais. O modelo enfatiza a identificação e avaliação proativa de riscos, bem como a implementação de medidas para gerenciá-los eficazmente. O *Orange Book* é amplamente considerado como uma referência no setor público e é utilizado por muitos países em todo o mundo [102].

Para que determinado risco possa ser gerenciado, ele deve ser primeiramente identificado. Essa é a primeira etapa do modelo brasileiro. A identificação consiste em determinar os eventos de risco que podem afetar programas, projetos ou processos e documentar suas características [93]. Essa etapa inicial também envolve a tarefa de avaliar o tipo de risco de acordo com o contexto inserido já que, de acordo com o guia, riscos podem ser classificados como externos ou internos, dependendo da origem. Riscos externos são relacionados ao ambiente em que a organização atua, enquanto os riscos internos estão ligados à estrutura da organização, processos, governança, recursos etc. Essa etapa inicial pode ocorrer por meio de uma equipe designada para a identificação de riscos ou por meio de uma autoavaliação, onde “cada nível da organização é convocado a rever seus programas, projetos e processos finalísticos para identificar os riscos associados” [102].

Ambos os tipos de riscos podem levar a falhas na entrega de programas e projetos, impactando escopo, prazo, custo e qualidade, ou mesmo no produto/serviço em si.

Riscos Externos e Internos podem resultar em:

Falha na entrega de Programas e Projetos: Riscos que podem resultar em falha na entrega do programa ou projeto no escopo, prazo, custo e qualidade especificados

[102, p. 23]

Posteriormente a identificação, a próxima etapa consiste em realizar análise do risco, onde devem ser considerados os potenciais impactos caso o risco venha a se concretizar e qual a probabilidade de ocorrência [93] [102]. Para essa investigação, é possível que se faça uso de ferramentas como por exemplo uma matriz de probabilidade x impacto, onde os riscos identificados são elencados com base nesses fatores de acordo com a tolerância a riscos pela organização, ou outra ferramenta conveniente [103].

O próximo passo sugerido a elaboração de um planejamento de respostas aos riscos, ou seja, um plano de contingência para tratar os riscos com responsáveis e ações de controle a serem tomadas definidos caso o risco venha a se concretizar, como forma de aumentar as oportunidades e mitigar as ameaças [93] [102].

Os tipos de respostas a cada risco podem ser:

- Aceitar o risco - envolve a tolerância ao risco sem que nenhuma ação específica seja tomada, seja pela capacidade ou pelo custo-benefício;
- Mitigar os riscos - “tratá-los de forma a restringi-los a um nível aceitável reduzindo as chances de ocorrência (probabilidade) e/ou impacto do evento de riscos” [102].
- Transferir o risco para terceiros - por exemplo por meio de seguros ou cláusulas contratuais;
- Eliminação do risco – por meio de alteração do plano que deu origem ao risco. “Esta opção pode ser particularmente adotada em projetos se se tornar claro que a relação custo/benefício coloca o projeto em nível de risco inaceitável” [102].

Por fim, há a etapa de implementação, monitoramento e controle. Essa etapa consiste em implementar as ações já planejadas e monitorar o processo, de forma constante, a fim de verificar se o perfil dos riscos modificou e garantir que o gerenciamento de riscos está sendo efetivo [102].

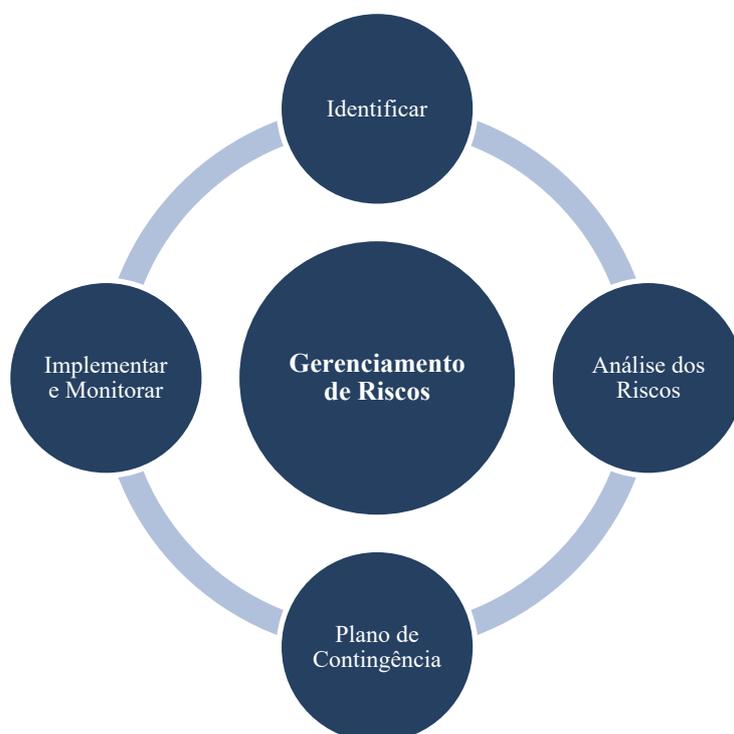


Figura 22: Modelo de Gerenciamento de Riscos (Fonte: Adaptado de [102]).

O estudo “*Risk management in the public sector: a structured literature review*” [26], já mencionado anteriormente, contribui para o entendimento da temática à medida que apresenta aspectos relevantes da gestão de riscos voltada para o setor público. Suportado por outros trabalhos, é apresentado que um sistema de controle gerencial efetivo pode suportar a implantação de um modelo de gerenciamento de riscos em determinada organização. Independentemente do contexto trabalhado, a gestão de riscos no setor público não pode ser negligenciada [26] [104].

Riscos também se fazem presente no contexto de obras públicas. De acordo com o Tribunal de Contas da União (TCU), até abril de 2023 havia mais de 8.600 obras paralisadas em todo o Brasil. Isso representa 41% das obras que deveriam estar

em andamento. Os contratos paralisados possuem valores totais superior a 32 bilhões de reais, sendo que mais de 8 bilhões de reais já foram investidos [105]. Esses valores se encontram paralisados e não podem ser realocados pois o artigo 167, inciso VI da Constituição Federal de 1988 veda “a transposição, o remanejamento ou a transferência de recursos de uma categoria de programação para outra ou de um órgão para outro, sem prévia autorização legislativa” [1]

O principal fator que acarretou obras a serem paralisadas, de acordo com auditoria realizada pelo Tribunal de Contas (TC 011.196/2018-1) [106], foi o mau planejamento dos empreendimentos que seriam construídos. O TCU frisa que “o mau planejamento é decorrente de projeto básico deficiente, falta de contrapartida e falta de capacidade técnica para execução do empreendimento” [105].

A área de educação básica é a mais alarmante de todas. De acordo com os dados de 2023, que podem ser visualizados na figura 23, a área possuía o maior número de obras paralisadas (3.580). Contrato rescindido, abandono da empresa e irregularidades são as principais causas de paralisação de obras no Brasil ligadas a educação básica [105].



Figura 23: Obras paralisadas por setor (Fonte: Adaptado de [105]).

Além do prejuízo financeiro, como custos relacionados a manutenção de obras, custos adicionais para retomar a obra, se for o caso, valor já investido e privação dos valores determinados em contrato, há também outros prejuízos sociais que obras paralisadas acarretam, como a não concretização de benefícios que o empreendimento forneceria para a sociedade e empregos que não serão gerados [106] [105]. De acordo com relatório do TCU, “apenas no tocante aos recursos destinados às creches do Programa Proinfância, 75 mil vagas deixaram de ser criadas e oferecidas à população” [106].

3.5. Gestão de riscos no FNDE

O FNDE, órgão responsável pelo financiamento de programas educacionais, tem como um de seus principais riscos o insucesso desses programas, que passa pela não conclusão de obras quando se pensa na temática do Proinfância [18] [79].

Embora o órgão possua um Plano de Integridade para gestão de riscos, instituída pela Portaria nº 208, de 22 de abril de 2019, em resposta à Instrução Conjunta nº 01, do Ministério do Planejamento e da Controladoria Geral da União (CGU) que “determina aos órgãos e entidades do Poder Executivo Federal a adoção de diversas medidas com vistas à sistematização de práticas relacionadas à Gestão de Riscos e Controles Internos” e ao Decreto Nº 9.203, de 22 de novembro de 2017, que “dispõe sobre a política de Governança da Administração Pública Federal Direta, Autarquia e Fundacional onde no art. 2º versa sobre Governança Pública, Valor Público, Alta Administração e Gestão de Riscos”, esse plano lida majoritariamente com os chamados riscos à integridade.

Art. 2º, II – Riscos para a integridade: vulnerabilidade que pode favorecer ou facilitar a ocorrência de práticas de corrupção, fraudes, irregularidades e/ou desvios éticos e de conduta, podendo comprometer os objetivos da instituição; Parágrafo único. Os riscos para a integridade podem ser causa, evento ou consequência de outros riscos, tais como financeiros, operacionais ou de imagem. [19]

Um dos pilares essenciais do Programa de Integridade do FNDE, cujas ações adotadas são de responsabilidade de todos os agentes públicos [107], é a necessidade de engajamento e respaldo da alta direção, fundamental para que o programa seja bem-sucedido. Isso envolve promover uma cultura ética, o cumprimento das leis e a implementação das políticas de integridade [108]. O Programa de Integridade do FNDE tem como objetivo “promover a prevenção, detecção, punição e remediação de fraudes e atos de corrupção, recebimento e/ou oferta de propina, desvio de verbas, abuso de poder e/ou influência, nepotismo, conflito de interesses, uso indevido e/ou vazamento de informação sigilosa e práticas antiéticas” [108]. O assunto também é alvo da Instrução Normativa 01/2016, elaborada em conjunto pelo Ministério do Planejamento, Desenvolvimento e Gestão (MP) e pelo Ministério da Transparência, Fiscalização e Controladoria Geral da União (CGU), que orienta sobre como deve ser realizada a identificação, a análise e o monitoramento de riscos [109].

Atividades de construção de escolas e monitoramento de obras envolve variados riscos, além dos abrangidos pelo Plano de Integridade do FNDE. Desde o planejamento, até início da execução e conclusão [79]. A importância da implementação do modelo de gerenciamento de riscos, apresentado na figura 18, se faz evidente dada a complexidade da temática. O registro e acompanhamento das lições aprendidas com casos anteriores é uma forma efetiva de mitigar riscos futuros. O *Orange Book* frisa que lições devem ser continuamente capturadas e estudadas como forma de se adaptar ações preventivas. O Livro cita ainda a importância da comunicação das lições aprendidas por todos os agentes envolvidos para o melhoramento contínuo do plano de gerenciamento de riscos [101]. Nesse cenário, se faz presente a relevância da gestão de conhecimento.

Gestão de conhecimento pode ser definida, segundo Dalkir, como a coordenação deliberada e sistemática de pessoas, tecnologia, de processos e da estrutura de determinada organização que tem como objetivo agregar valor, como por exemplo com a economia de tempo, por meio da reutilização do conhecimento e da inovação. Essa coordenação pode ser alcançada por meio do registro e do

compartilhamento do conhecimento, a fim de promover uma aprendizagem contínua e conseqüente melhoria contínua nas atividades envolvidas [110]. A gestão de conhecimento auxilia as organizações, inclusive públicas, a se tornarem competitivas e economizarem recursos [111]. A centralização e não formalização de determinado conhecimento gerado em um número limitado de indivíduos dentro de uma organização acarreta riscos de interrupção na continuidade dos serviços, deterioração da qualidade, sobrecarga de trabalho para determinados funcionários e perda do acervo de conhecimento ao longo do tempo [112].

Uma maneira, guiada pela gestão de conhecimento, a fim de registrar o conhecimento obtido por uma única pessoa e solidificá-lo para a organização é por meio da técnica de mapeamento de processos [112]. Processo, de acordo com a *Association of Business Process Professionals* (ABPMP), é a “agregação de atividades e comportamentos executados por humanos ou máquinas para alcançar um ou mais resultados” [113]. Mapeamento de processos, por sua vez, é uma ferramenta gerencial analítica, de fácil entendimento e comunicação, que busca esclarecer o funcionamento de determinado processo e otimizá-los, ou ainda implementar um novo processo. Processos mapeados permitem, além de entender o processo atual e propor mudanças, uma análise mais detalhada de cada atividade, o que possibilita identificar gargalos e reduzir custos e falhas [114] [115].

Se percebe que o perfeito entendimento do processo de monitoramento de obras é de suma importância para a gestão de conhecimento e conseqüente aplicação de lições aprendidas ao modelo de gerenciamento de riscos no âmbito do FNDE. Os riscos do processo de monitoramento de obras podem acarretar conseqüências indesejadas como obras inacabadas, canceladas ou paralisadas, conforme apresentado na tabela 6. Há uma lacuna referente a estudos sobre o plano de gerenciamento de riscos das obras públicas em andamento que são financiadas pelo FNDE, evidenciado pela revisão bibliográfica apresentada no capítulo 2, que pode ser justificado pela novidade e especificidade do tema. Esta pesquisa busca atacar essa oportunidade e aprofundar esse tema voltado ao Proinfância.

3.6. *Data Science e Machine Learning*

O termo *Data Science*, comumente traduzido como Ciência de Dados, pode ser entendido como uma matéria multidisciplinar que faz o uso de matemática, estatística, programação computacional e inteligência artificial, com foco em torno de dados, que almeja gerar *insights* para auxiliar tomadas de decisões de determinada organização [116] [117] [118].

A figura 24 mostra a tendência de pesquisa pelo termo no buscador Google.

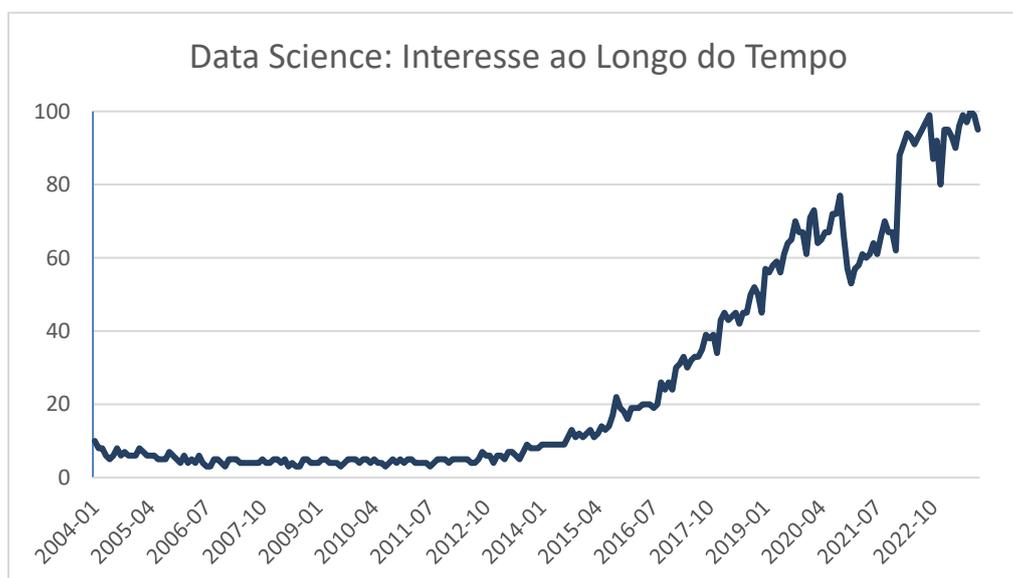


Figura 24: Tendência de pesquisa por *Data Science* (Fonte: Própria).

Na figura 24, o eixo x representa o período especificado e o eixo y representa o nível de interesse de pesquisas relativas ao tema, onde o valor 100 é o pico de popularidade do tema e o valor 0 a menor popularidade do tema. Se nota que o uso termo *Data Science* está se tornando cada vez mais comum na sociedade. Isso se justifica à medida que o volume de dados utilizados por diversas empresas cresce ano após ano [118].

Mediante o avanço tecnológico, a Ciência de Dados é capaz de gerar modelos capazes de detectar padrões e realizar previsões obtidas a partir de um conjunto de

dados (*dataset*). Modelos preditivos por meio de *machine learning*, com base em métodos estatísticos, é uma importante ferramenta para a Ciência de Dados [118].

Machine learning, por sua vez, é um subcampo da inteligência artificial (IA) e da Ciência de Dados que foca no desenvolvimento de algoritmos que permitem que sistemas aprendam a partir de dados, sem serem explicitamente programados, de modo similar a como os humanos aprendem, melhorando sua precisão ao longo do tempo [119] [120] [121].

O *machine learning* está presente numa gama de atividades cotidianas. Sistemas de recomendação de plataformas de *streaming*, detecção de fraudes bancárias, *chatbots*, mecanismos de buscas virtuais, veículos autônomos, entre outros, são exemplos de aplicação da técnica [120].

O conjunto de dados que alimenta o modelo de *machine learning* é dividido entre dados de treino, que são os dados apresentados para a criação do modelo, e dados de teste, que são apresentados para simular previsões e aferir a acurácia [120] [121].

Machine learning utiliza diversos algoritmos para resolver problemas complexos com dados. A depender de como os dados são fornecidos, os algoritmos podem ser classificados em categorias, onde destaca-se as principais:

- Aprendizagem supervisionada: o conjunto de dados relaciona *inputs* e *outputs*. Para cada saída, um rótulo, numérico ou textual, é atribuído. “O algoritmo determina uma forma de prever qual o rótulo de saída com base em uma entrada informada” [122].
- Aprendizagem não-supervisionada: não são atribuídos rótulos para as saídas. “Com base em um número grande de dados, o algoritmo busca padrões e similaridades entre os dados, permitindo identificar grupos de itens similares ou similaridade de itens novos com grupos já definidos” [122].

- Aprendizagem semi-supervisionada: junta características das duas classificações anteriores. É aplicado quando há um conjunto de dados com algumas amostras rotuladas e outras amostras não rotuladas [120].
- Aprendizagem por reforço: o agente que está sendo treinado se relaciona com o ambiente para aprender por meio de tentativa e erro. Os feedbacks colhidos pelo agente servem como aprendizado [120] [122].

Na temática desta pesquisa, mediante os dados que serão obtidos junto ao FNDE, o tipo de *machine learning* que será empregado se classifica como aprendizado supervisionado, pois os dados fornecidos são atribuídos a um rótulo de saída. No caso, o *output* é status de cada obra (concluída, em andamento, inacabada, não iniciada, cancelada e paralisada).

O fluxograma do aprendizado supervisionado é apresentado na figura 25.

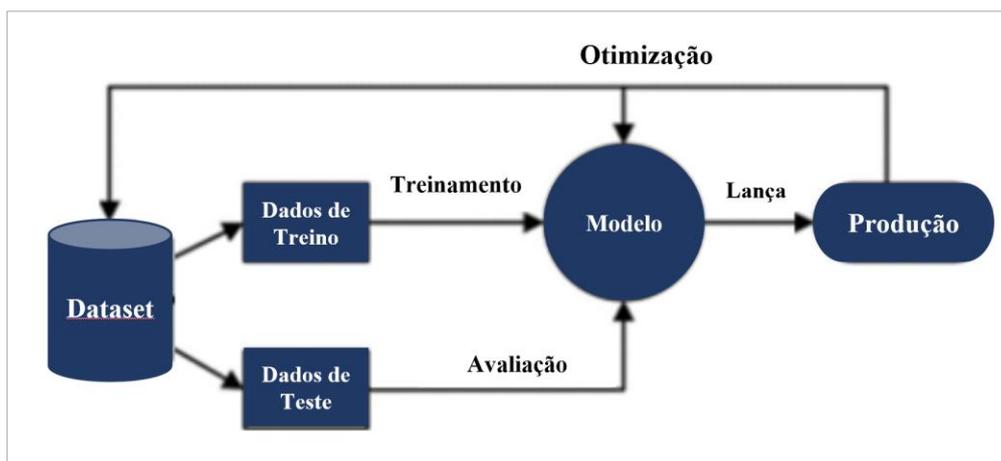


Figura 25: Fluxograma de aprendizado supervisionado (Fonte: Adaptado de [121]).

Algoritmos de aprendizagem supervisionada podem ser divididos, por sua vez, em dois grupos principais: algoritmos de regressão e algoritmos de classificação [122] [123].

Algoritmos de regressão são aqueles cujos rótulos de saídas podem assumir qualquer valor real, isto é, não há rótulos pré-definidos. Essas variáveis podem ser contínuas ou discretas [122] [123]. Exemplos de saídas são valores monetários ou temperatura de determinado ambiente.

Algoritmos de classificação, por outro lado, são aqueles cujos rótulos de saídas possíveis são pré-definidos pelo conjunto de dados [122] [123]. Exemplos de saídas são alto/médio/baixo (multiclasse) ou possuem determinada característica/não possuem determinada característica (binária).

O contexto trabalhado no FNDE fornece uma lista pré-definida de possíveis *outputs*, que é o status de cada obra. Portanto, na pesquisa será utilizado algoritmos de classificação, que são “algoritmos de aprendizagem supervisionada onde o objetivo é prever uma classe ou rótulo associado com uma variável de entrada contendo determinados atributos” [122]. Esse tipo de algoritmo pode ser entendido como uma função matemática, representada na figura 26 que busca associar um conjunto de dados (*inputs*) a um conjunto de classes (*outputs*).

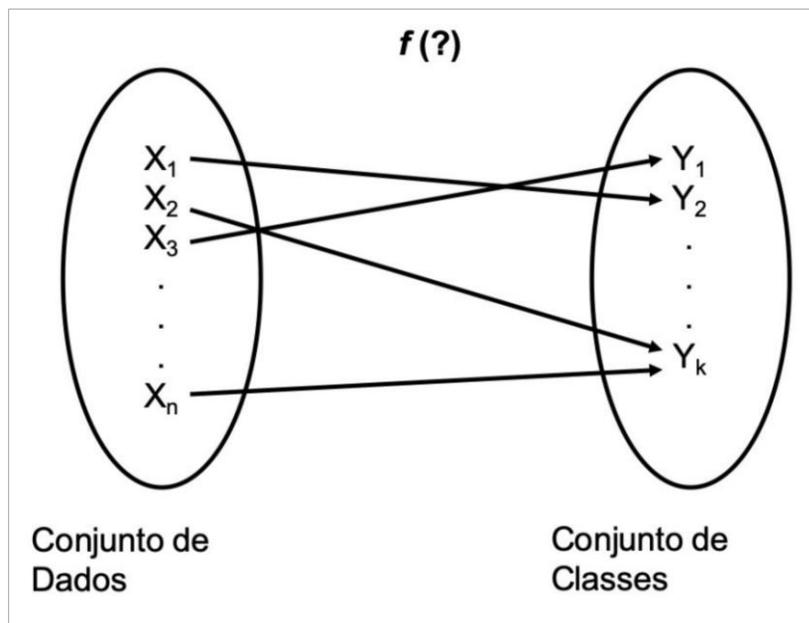


Figura 26: Função matemática de problema de classificação (Fonte: [123]).

Para cada tipo de problema de *machine learning*, há diversos algoritmos que podem ser utilizados. Alguns algoritmos supervisionados ligados a modelos de classificação são:

- **Árvore de Decisão:** utiliza amostras de características dos dados para criar regras de decisão e representa em forma de gráfico de árvore suas escolhas e os

resultados, onde os nós representam os atributos que o grupo pode assumir e os ramos representam os valores que os nós podem assumir [121] [123].

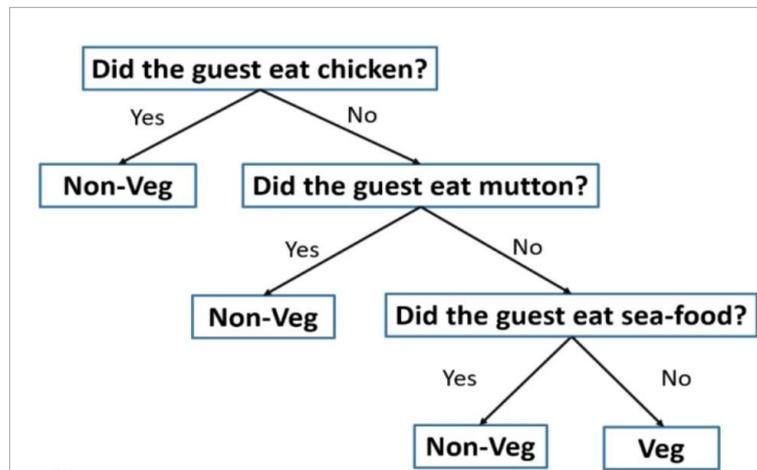


Figura 27: Exemplo de Árvore de Decisão (Fonte: [121]).

- *K-Nearest Neighbors* (KNN): o classificador do vizinho mais próximo é baseado na distância geométrica entre o ponto avaliado e os k vizinhos do grupo de treinamento, onde o valor de k é determinado pelo usuário. O modelo armazena as posições espaciais do grupo de treinamento e compara os atributos com esse grupo [122] [123].

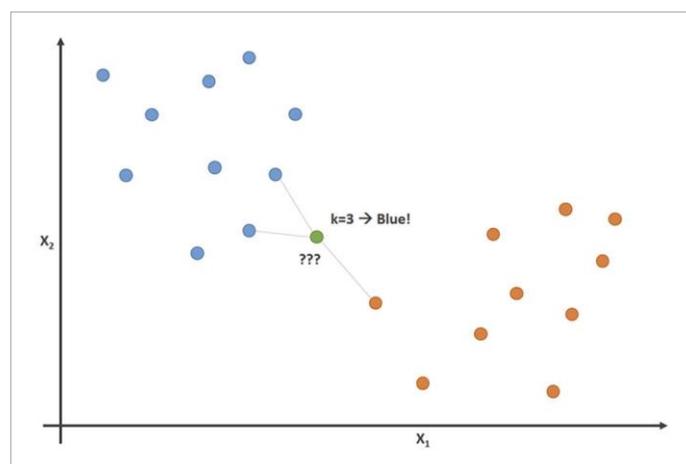


Figura 28: Exemplo de gráfico de KNN (Fonte: [124]).

- *Naive Bayes*: essa técnica, baseada no Teorema de Bayes, determina a probabilidade de um atributo pertencer a determinada classe. Esse método não

considera a correlação existente entre os atributos do conjunto de dados e possui como uma de suas principais aplicações o ramo de classificação textual [121] [123].

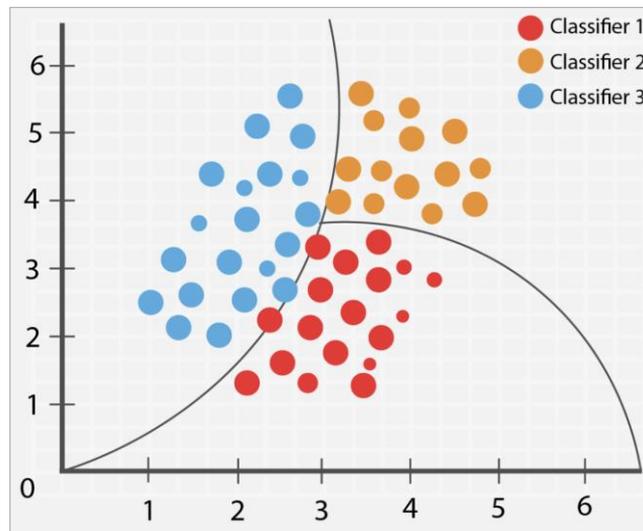


Figura 29: Exemplo de gráfico de *Naive Bayes* (Fonte: [125]).

- **Regressão Logística:** semelhante à regressão linear (utilizada para problemas de regressão), a regressão logística é utilizada para problemas de classificação, onde uma função calcula a probabilidade determinado evento ocorrer e fornece como saída um valor entre 0 e 1 [123] [126].

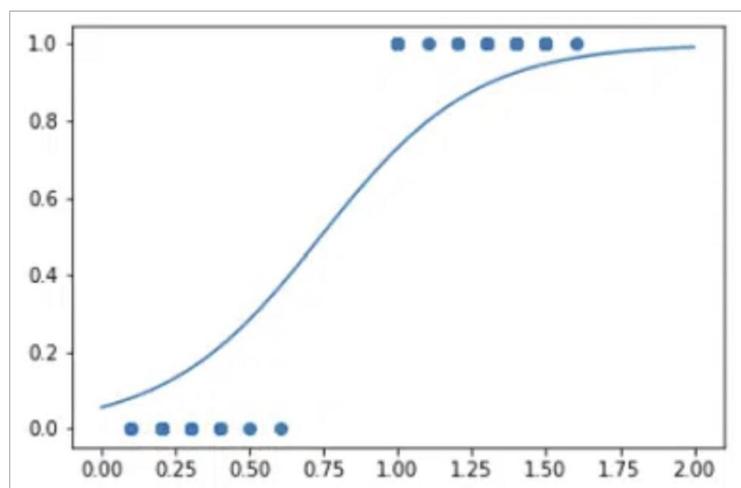


Figura 30: Exemplo de gráfico de Regressão Logística (Fonte: [127]).

- **Support Vector Machine (SVM):** além de realizar classificações lineares, essa técnica executa classificações não-lineares dos atributos, por meio de funções

kernel, para expandir os dados de treinos originais em um plano de dimensão maior. Dessa maneira, é possível traçar uma margem de forma a maximizar a distância entre as classes e, conseqüentemente, minimizar os erros de classificação [121] [123].

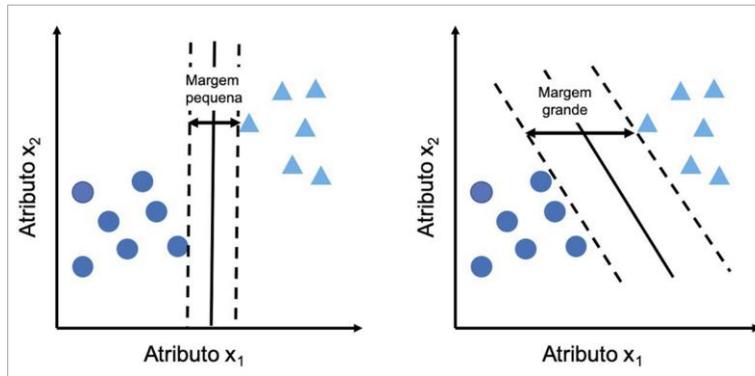


Figura 31: Exemplo de gráfico de SVM (Fonte: [123]).

- Redes Neurais: reconhece relações entre o conjunto de dados de maneira similar o funcionamento do cérebro humano. É formada por uma camada oculta, que possui peso estabelecido, entre os dados de entrada e os dados de saída. Dessa maneira, a função é processada de forma que cada *input* é multiplicado pelo peso para fornecer o dado de saída [122] [128].

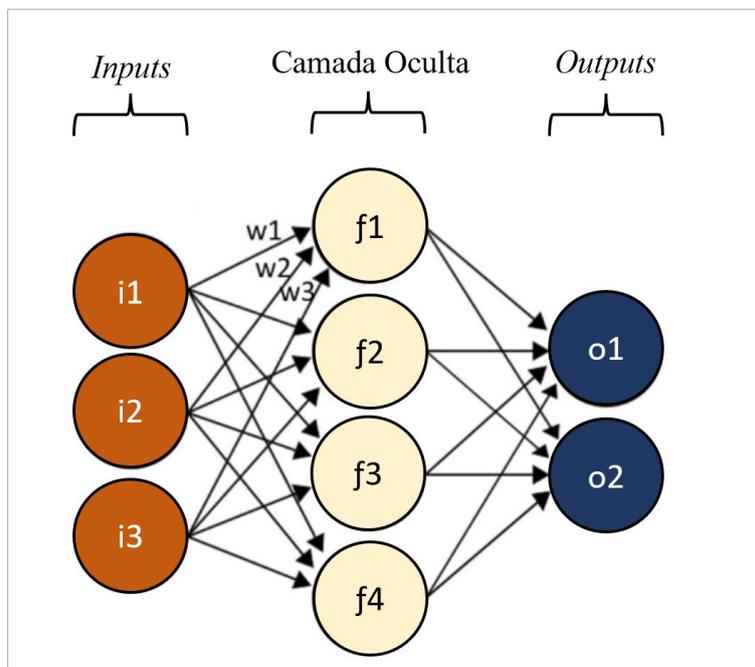


Figura 32: Exemplo de Rede Neural (Fonte: Própria).

- *Deep learning*: são redes neurais com várias camadas ocultas. Pode processar um grande volume de dados e determinar pesos para cada “neurônio” [120] [128].

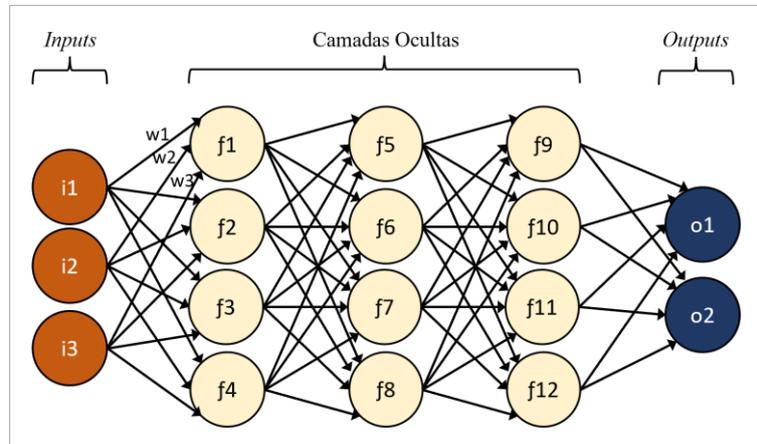


Figura 33: Exemplo de *Deep Neural Network* (Fonte: Própria).

Se ressalta que não há algoritmo melhor ou pior, ou um único que sirva para todos os casos. A escolha do algoritmo depende de fatores como o tipo de problema a ser trabalhado e os dados fornecidos [121]. O capítulo 4 desta pesquisa irá apresentar, na seção de procedimento metodológico, o software que será utilizado para realizar o processamento do conjunto de dados e a criação do modelo preditivo.

Capítulo 4

Método De Pesquisa

O quarto capítulo deste trabalho detalha as etapas necessárias para atingir os objetivos da pesquisa propostos. A metodologia científica avalia as técnicas disponíveis que possibilitam o processamento das informações para solucionar os problemas investigados e gerar valor para a sociedade [129].

A pesquisa científica pode ser classificada de maneiras variadas a depender do “problema a ser investigado, da sua natureza e situação espaço-temporal em que se encontra” é [130]. As formas clássicas que esta pesquisa é classificada estão destacadas na figura 34:

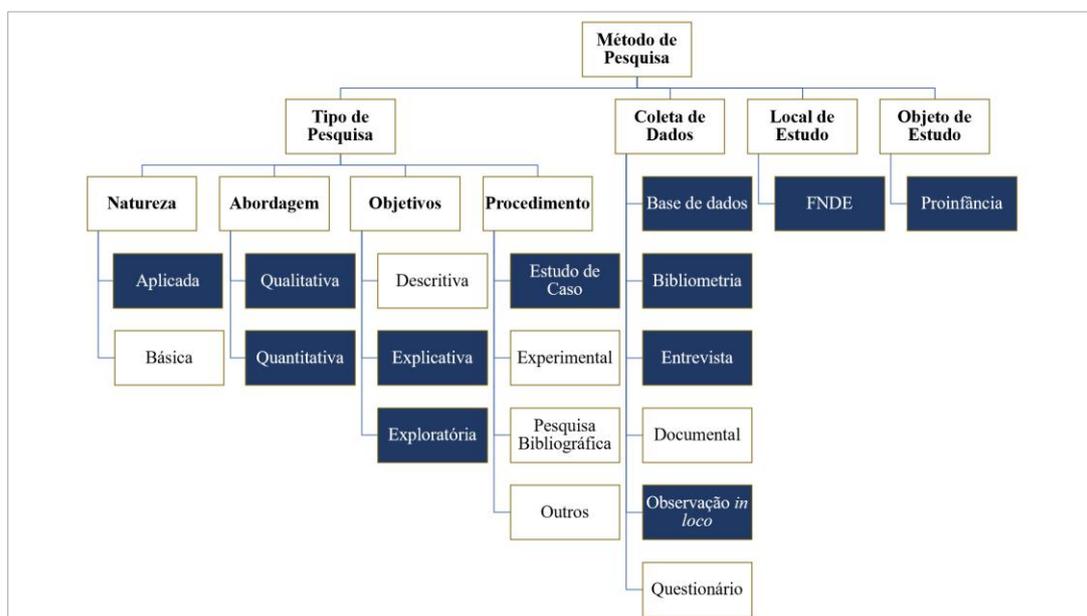


Figura 34: Método de Pesquisa (Fonte: Própria).

As próximas seções deste capítulo irão detalhar as classificações apresentadas acima.

4.1. Tipo de pesquisa

Alguns métodos de classificação permitem identificar os tipos de pesquisas científicas quanto à sua natureza, sua abordagem, seus objetivos e seus procedimentos.

- Quanto à natureza: a pesquisa pode ser básica, caso “objetiva gerar conhecimentos novos, úteis para o avanço da Ciência, sem aplicação prática prevista”, ou aplicada, caso “objetiva gerar conhecimentos para aplicação prática, dirigidos à solução de problemas específicos” [131]. Esta pesquisa se enquadra como aplicada, pois busca contribuir de forma prática com o problema de obras paralisadas do Proinfância.

- Quanto à abordagem: a pesquisa pode ser qualitativa, caso não se preocupe “com representatividade numérica, mas, sim, com o aprofundamento da compreensão de um grupo social” [131] ou quantitativa, caso os resultados da pesquisa possam ser quantificados. Há ainda a opção de a pesquisa científica adotar as duas abordagens, que é o caso deste estudo, sendo classificada como qualitativa e quantitativa.

- Quanto aos objetivos: a pesquisa pode ser classificada em exploratória, caso busque proporcionar uma maior familiaridade com o problema, para torná-lo mais explícito; descritiva, caso busque registrar e descrever os fatos observados sem interferir; e explicativa, caso busque identificar os fatores que contribuem para a ocorrência dos fenômenos [132]. Esta pesquisa pode ser classificada como exploratória, tendo em vista o caráter bibliográfico e de estudo de caso, características desse tipo, e como explicativa, pois busca identificar fatores que contribuem para o problema em questão.

- Quanto ao procedimento: essa classificação se refere à maneira pela qual são obtidos os dados necessários para o desenvolvimento da pesquisa. A pesquisa pode ser classificada, principalmente, entre experimental, bibliográfica, documental, de campo, *ex-post-facto*, de levantamento (*survey*), de estudo de caso, participante, pesquisa-ação. Embora possua um extensivo levantamento bibliográfico, característica ideal de qualquer trabalho científico [133], este trabalho não se baseia unicamente na pesquisa bibliográfica e, portanto, pode ser classificada como estudo de caso, pois, além de ser uma pesquisa aplicada, está voltada para a aplicação imediata dos conhecimentos na realidade estudada [132].

4.2. Local de estudo

O estudo foi realizado no Fundo Nacional de Desenvolvimento da Educação (FNDE), autarquia vinculada ao Ministério da Educação, com atuação nacional.

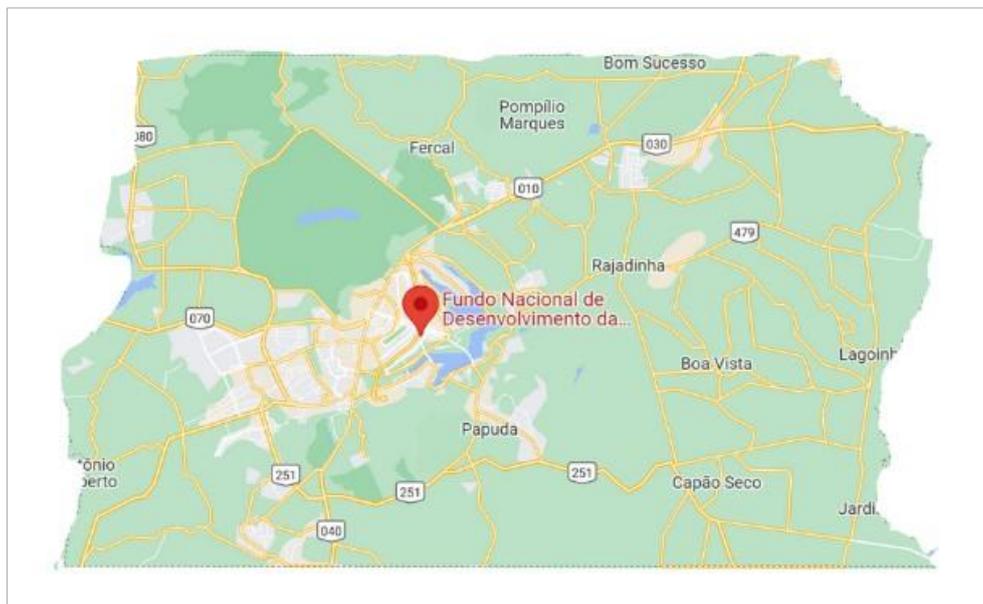


Figura 35: Mapa do Distrito Federal (Fonte: *Google Maps*).

A figura 35 apresenta o mapa do Distrito Federal destacado a sede do FNDE, localizada no Setor Bancário Sul, Quadra 2, Asa Sul, situado em Brasília (DF), capital do Brasil.

4.3. Objeto de estudo

A pesquisa possui como objeto as obras realizadas pelo Proinfância, os estudos dos riscos envolvidos nas construções e aplicação de técnicas computacionais com o intuito de criar um modelo preditivo de obras paralisadas.

4.4. Procedimento metodológico

Para a estruturação do processamento e análise dos dados, será adotado o CRISP-DM, uma metodologia estruturada para projetos de mineração de dados que orienta as etapas do ciclo de vida dos dados.

A coleta de dados será realizada a partir de bases institucionais do Fundo Nacional de Desenvolvimento da Educação (FNDE). Primeiramente, serão identificadas, junto à equipe da Coordenação-Geral de Implementação e Monitoramento de Projetos Educacionais (CGIMP), as bases de dados existentes no FNDE que contêm informações sobre os motivos de paralisação de obras relacionadas ao Proinfância. Após a obtenção, os dados passarão por um processo de limpeza, transformação e seleção de variáveis, visando garantir a qualidade e relevância para o estudo.

A ferramenta escolhida para se realizar a modelagem do conjunto de dados foi o software *Altair® AI Studio*, plataforma de ciência de dados onde é possível realizar o *input* dos dados para processamento, visualização, e criação de um modelo.

Serão utilizados aproximadamente 70% dos dados disponíveis para o treinamento do modelo e 30% para testes, seguindo práticas recomendadas em mineração de dados. A base completa contém informações de todas as obras do Proinfância gerenciadas pelo FNDE entre 2007 e 2023, totalizando mais de 8.500 registros com múltiplas variáveis, incluindo dados de execução física e financeira, informações geográficas, características do terreno, tipo de projeto, dados demográficos dos municípios e histórico de fiscalizações.

Técnicas estatísticas e de mineração de dados serão aplicadas para identificar padrões e fatores de risco associados à paralisação de obras. Serão realizadas análises de correlação entre variáveis, testes de significância estatística e validação cruzada para garantir a robustez do modelo preditivo desenvolvido.

Após a criação e validação do modelo, será criada uma estratégia para implantar o modelo na rotina de trabalho dos funcionários do FNDE, garantindo a utilidade prática na prevenção de obras paralisadas.

4.5. Software utilizado

O *Altair® AI Studio*, antes chamado de *RapidMiner Studio*, é uma plataforma de análise de dados e machine learning voltada para a criação e automação de processos de análise preditiva. O foco do software está em fornecer ferramentas que facilitem a análise e a exploração de grandes volumes de dados de forma eficiente e escalável. O *Altair® AI Studio* integra técnicas avançadas de machine learning e inteligência artificial (IA), permitindo que cientistas de dados e analistas desenvolvam modelos preditivos.

A escolha do software se deu pela possibilidade de criação de fluxos de trabalho que vão desde a preparação e limpeza de dados até a construção, validação e implementação de modelos de machine learning e por possuir uma interface visual intuitiva. Além disso, a plataforma se destaca por sua capacidade de processamento paralelo, visualização de dados e integração com diferentes fontes de dados. O software é capaz de processar os dados em variados modelos como *Naive Bayes*, modelo linear generalizado, regressão logística, árvore de decisão, *random forest*, *deep learning*, entre outros [134] [135]. Dessa maneira, é possível escolher o modelo que possua maior performance mediante os *inputs* fornecidos.

Em junho de 2024, a plataforma foi reconhecida pelo *Magic Quadrant*, coleção de relatórios de pesquisa de mercado publicados periodicamente pela empresa de

consultoria de TI *Gartner*, como uma das plataformas líderes para *Data Science* e *machine learning* [136] [137].

Neste trabalho, será utilizada a versão 2025.5.0 em conjunto com a *engine* 11.0.0. Essa versão, em relação ao antigo *RapidMiner Studio*, inclui melhorias na integração de fluxos de trabalho de análise de dados e aprendizado de máquina, além de suporte expandido para novas técnicas e algoritmos de IA [138].

Capítulo 5

Resultados

5.1. CRISP-DM

O grande volume de processamento de dados para auxiliar tomadas de decisões atrai atenção de equipes de TI de indústrias de diversos ramos [139]. Nesse sentido, gerenciar projetos de *Data Science* pode ser desafiador. Uma pesquisa conduzida em 2018 com um grupo de cientistas de dados reportou que 82% dos pesquisados não utilizam nenhuma metodologia explícita para modelar os processos [140]. Ademais, 87% de projetos de Data Science não chegam à fase de implantação [141].

O CRISP-DM, acrônimo para *Cross Industry Standard Process for Data Mining*, criado na década de 90, apresenta etapas para se gerenciar projetos de Data Science e pode ser aplicado independentemente do setor industrial em estudo [142] [143] [144].

O framework do CRISP-DM, composto por seis fases, é apresentado na figura 36.

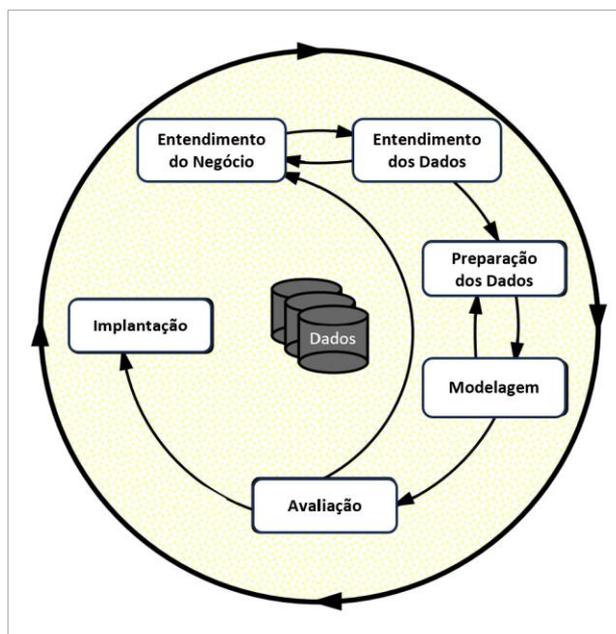


Figura 36: Framework CRISP-DM (Fonte: Adaptado de [142]).

A primeira fase do CRISP-DM é entender o negócio que será trabalhado. Nessa etapa é analisada qual a situação atual do negócio e onde se almeja chegar por meio da definição dos objetivos do projeto [139] [143] [144]. Essa primeira etapa foi abordada neste trabalho por meio da realização da pesquisa bibliográfica, com o auxílio da metodologia TEMAC, detalhada no Capítulo 2. Durante esse processo, foram utilizadas as bases de dados do *Web of Science* e *Scopus* e foram utilizados os softwares *VOSViewer*, Microsoft Excel, além do website “Tagcrowd.com” para elaborar as figuras e tabelas apresentadas.

De maneira paralela, foram realizadas observações *in loco* no local de estudo. O acompanhamento junto aos gestores da Coordenação-Geral de Implementação e Monitoramento de Projetos Educacionais (CGIMP), pertencente ao FNDE, possibilitou a elaboração da Tabela 5, dentro da seção 3.2, com a identificação do cenário das obras geridas pelo FNDE.

O próximo passo deste projeto, ainda no âmbito de entendimento do negócio, é a compreensão plena do contexto. Para isso, foram realizadas entrevistas junto aos gestores com o intuito de compreender o fluxo de monitoramento de obras no FNDE.

Após o processo ser estudado, se adentra na fase de entendimento dos dados, previsto na metodologia CRISP-DM. Nessa etapa ocorre a identificação do local de onde os dados necessários para o projeto serão extraídos, a coleta de dados, a exploração e análise da qualidade dos dados obtidos [139] [143] [144]. São identificadas, junto ao time da CGIMP, bases de dados existentes no FNDE que apresentam os motivos que levaram obras relacionadas ao Proinfância a serem paralisadas.

Posteriormente, acontece a etapa de preparação dos dados. Essa etapa, também conhecida como pré-processamento ou *data munging*, precede a execução do modelo. Nessa fase é realizada a normalização dos dados, formatação de dados, por exemplo de possíveis datas que constam na base de dados, combinação de dados de variadas fontes, limpeza de dados desnecessários, construção de possíveis novos atributos, entre outras ações necessárias para se alcançar o conjunto de dados (*dataset*) final [143] [145]. Se estima que essa etapa, vital para o sucesso do projeto, é a que demanda maior tempo do cientista de dados [145] [146].

O tratamento da base de dados obtida junto ao FNDE possibilita o início da próxima etapa do CRISP-DM, a de modelagem. A fase de modelagem engloba a seleção da técnica mais adequada para o modelo, de acordo com a necessidade do negócio, dados disponíveis e tipo de variável a ser analisada. São estabelecidos critérios específicos para selecionar a técnica mais adequada. Nessa fase, o conjunto de dados é processado para criar um ou mais modelos [139] [143] [144].

A próxima etapa do CRISP-DM é a de avaliação. Nessa fase os resultados são interpretados, de acordo com a expectativa inicial, para mensurar o sucesso do modelo. Caso seja necessário, otimizações podem ser realizadas para que se aumente o desempenho do modelo. [139] [143] [144].

Por fim, há a etapa de implantação (*deployment*). Esse é o momento em que o projeto é apresentado aos stakeholders e é sugerida a implementação do modelo a

fim de gerar valor para o negócio. O monitoramento contínuo do modelo e possíveis adaptações são realizadas ao longo do tempo [139] [143] [144].

5.2. Etapas 2 e 3 do CRISP-DM - Entendimento e preparação dos dados

Após a etapa de entendimento do negócio, a metodologia CRISP-DM estabelece a necessidade de entendimento dos dados que serão utilizados. De acordo com [147], as tarefas dessa fase englobam diversas etapas como:

- Acesso aos dados:

Essa etapa se refere a necessidade de identificar fontes de dados existentes, determinar possíveis problemas de privacidade de dados, determinar problemas práticos com a extração de dados, identificar quaisquer problemas de latência de dados, definir de quais fontes os dados serão extraídos, consolidar diversas fontes de dados (arquivos, tabelas, planilhas etc.), decisão *Go-vs-NoGo* (decidir se a natureza dos dados disponíveis é adequada para a análise pretendida).

Nesta dissertação, os dados foram obtidos a partir do SIMEC (Sistema Integrado de Monitoramento Execução e Controle), uma plataforma pertencente ao Ministério da Educação (MEC), que oferece uma ampla gama de informações relacionadas à execução e monitoramento de obras públicas, com destaque para obras educacionais vinculadas ao programa Proinfância.

Os dados foram extraídos do SIMEC, no dia 25 de janeiro de 2023 e resultaram em nove planilhas distintas, cada uma representando diferentes aspectos do monitoramento de obras. Essas planilhas continham dados sobre o status das obras, prazos, localização, tipo de obra e outras informações relevantes para o monitoramento e execução de obras de infraestrutura educacional. Esse volumoso conjunto de dados bruto apresentava algumas inconsistências, como duplicação de informações, que devem ser tratadas na fase de preparação dos dados.

- Enriquecimento dos dados:

Além dos dados obtidos diretamente pela extração, é possível incorporar dados externos (demográficos, psicográficos etc.) que agregam valor à análise ou criação de novos parâmetros.

Na base trabalhada foi necessária com a criação de um número identificador de obra único, formado pela junção do ID da obra e do número do processo. Foi realizada também a formatação de algumas informações, como datas, para o formato padrão que o software *Altair® AI Studio* aceita como *input* (yyyy/mm/dd).

- Caracterização e descrição dos dados:

Antes de utilizar os dados para executar o modelo, é necessário investigar as variáveis e identificar variáveis-alvo. Operações como transformação de variáveis também podem ser planejadas se for identificada a necessidade.

Após a definição de que a variável-alvo do modelo será a coluna “Situação”, uma das colunas presente na base de dados, o software *Altair® AI Studio* requer a caracterização dos dados que serão inseridos, crucial para garantir que os algoritmos de machine learning tratem corretamente as informações. Cada tipo de dado tem um propósito específico e influencia como os cálculos são realizados e como os modelos são treinados. A classificação dos dados disponível no software, são as seguintes:

- Polinomial:

O tipo polinomial é usado para variáveis que têm múltiplas categorias não ordenadas. Essas categorias são representações simbólicas, como nomes ou rótulos, e não há uma relação de ordem entre elas. Esse tipo de dado é ideal para variáveis que descrevem atributos qualitativos. Exemplo: coluna "Situação" com vários valores possíveis: “concluída”, “em andamento”, “inacabada”, “não iniciada” “obra cancelada” e “paralisada”.

- Binominal:

O tipo binominal é uma subcategoria dos dados polinomiais, mas com apenas duas categorias possíveis. Normalmente, é utilizado para variáveis que representam resultados binários ou sim/não. Exemplo: coluna "Restrições" com dois valores possíveis: Sim ou Não.

- Real:

O tipo real (ou numérico contínuo) representa variáveis que podem assumir qualquer valor em um intervalo contínuo. Essas variáveis geralmente possuem casas decimais e são usadas para medir quantidades ou proporções. Exemplo: coluna "Valores pagos" com vários valores possíveis: R\$1.971.633,1 R\$1.279.557,9 R\$923.263,7 etc.

- Inteiro:

O tipo *integer* (ou numérico discreto) é utilizado para variáveis que representam números inteiros, sem casas decimais. Ele é frequentemente usado para contar objetos ou eventos. Exemplo: Coluna "Número de alunos (integral)" com valores possíveis: 60, 94, 112, 188.

- *Date_time*:

O tipo *date_time* é usado para armazenar valores que representam uma data e um horário completos. Esse formato combina informações de data e hora em um único valor, sendo ideal para variáveis temporais precisas.

- *Date*:

O tipo *date* é utilizado para representar exclusivamente datas, sem informações sobre horas ou minutos. É ideal para variáveis que acompanham eventos diários, mas sem a necessidade de precisão temporal. Exemplo: coluna "Última Vistoria Instituição" com valores possíveis: 2018-05-21, 2019-12-13 etc.

- *Time:*

O tipo *time* é utilizado para armazenar apenas o horário (hora, minuto, segundo), sem a inclusão de uma data associada. Esse tipo de dado é útil em situações em que apenas o tempo do dia é relevante.

A preparação dos dados, próxima etapa prevista na metodologia CRISP-DM, é uma das mais críticas para o desenvolvimento de modelos preditivos. De acordo com [147], essa fase pode consumir de 60% a 90% do tempo do projeto.

Essa etapa envolve diversas tarefas complexas para garantir a qualidade e eficiência do modelo preditivo, como: limpeza de dados (excluir valores inválidos ou sensíveis e garantir a adequação dos dados para a modelagem); redução de dados (diminuir a dimensionalidade dos dados para simplificar a análise, agregando variáveis similares ou agrupando registros); normalização (se refere ao ajuste dos dados para algoritmos paramétricos); padronização e recodificação (padronizar variáveis semelhantes a fim de evitar possíveis erros e substituir campos de erro por campos vazios); tratamento de valores ausentes (verificar impacto dos valores ausentes e substituí-los com constantes ou fórmulas); derivação de variáveis (se refere a criação de variáveis derivadas, como somas, médias e desvios padrão de dados transacionais); tratamento de outliers (tarefa na qual se decide se mantém, exclui ou recodifica os outliers, dependendo do impacto desejado no modelo).

A etapa de limpeza dos dados envolveu a remoção de registros duplicados, que foram identificados após a combinação das diversas planilhas. Dados repetidos podem distorcer as análises e influenciar negativamente a performance dos modelos de machine learning.

Após a remoção dos duplicados, o próximo passo foi a consolidação das colunas relevantes e de redução de dados, já que algumas colunas estavam presentes em múltiplas planilhas e continham informações semelhantes, mas com pequenas variações de nomenclatura ou formato. Essas colunas foram unificadas e padronizadas para garantir consistência nos dados. As colunas que não apresentavam

relevância para o objetivo do estudo, como detalhes administrativos internos, também foram eliminadas.

Também foi realizada a exclusão das linhas que continham valores insignificantes na coluna dos valores do contrato de obra, o que significa erro no momento do preenchimento.

Ao final desse processo, foi gerada uma única planilha consolidada, contendo 34 colunas e 8.821 linhas. Essa quantidade de registros presentes na base de dados oferece uma amostra representativa e diversificada, o que aumenta a confiabilidade dos resultados preditivos. Essa base de dados final foi a principal fonte de informações para os modelos preditivos de paralisação de obras.

5.2.1. Tratamento de outliers

Para tratar os outliers da base de dados em questão, será utilizada a técnica de detecção de outliers baseada na distância euclidiana. Este método consiste em calcular a distância entre cada ponto de dados e seus vizinhos mais próximos (KNN). Além de capturar valores extremos que podem distorcer a modelagem, esse procedimento também auxilia na identificação de problemas de digitalização dos dados. A identificação de outliers com base na distância euclidiana é uma técnica amplamente utilizada, especialmente no contexto de dados multivariados, onde a distribuição dos dados pode ser complexa e difícil de visualizar [148].

A técnica de *k-nearest neighbors* (KNN) é uma abordagem que permite a detecção de anomalias sobre a distribuição dos dados. O uso de métodos baseados na técnica KNN é eficaz para identificar outliers em cenários com grandes quantidades de dados, já que os pontos mais afastados tendem a ser discrepantes [149].

Primeiramente, para o cálculo da distância euclidiana, é medido a distância entre cada ponto observado e seus vizinhos mais próximos no espaço de múltiplas

dimensões. A distância euclidiana (d) entre dois pontos $A(x_1, y_1)$ $B(x_2, y_2)$ é calculada pela fórmula:

$$d(A, B) = \sqrt{\{(x_2 - x_1)^2 + (y_2 - y_1)^2\}}$$

Equação 1: Distância euclidiana entre dois pontos

Depois, para cada ponto de dados, será considerado o valor de $k = 10$, adequado para bases de dados de tamanho moderado/grande, balanceando a sensibilidade à detecção de outliers.

Por fim, após calcular as distâncias euclidianas para todos os pontos, será selecionado um percentual de 3% das observações como outliers. Isso significa que os 3% dos pontos que tiverem as maiores distâncias em relação aos seus 10 vizinhos mais próximos serão classificados como outliers. Essa técnica assume que a maioria dos dados segue um padrão de proximidade razoável, enquanto os outliers estarão mais distantes do padrão observado.

Após realizar tais operações, a base de dados resultou em 8.555 linhas que serão utilizadas como *dataset* para rodar os modelos propostos.

O código XML executado, composto por 1781 linhas, pode ser visualizado graficamente por meio do processo apresentado no apêndice I.

5.2.2. Estrutura da Base Inicial

A base de dados inicialmente utilizada contém informações estruturadas em colunas que são essenciais para a modelagem preditiva. As 30 variáveis (colunas) presentes no *dataset* são as seguintes:

- **Identificador:** Um código único que identifica cada obra.
- **Ciclo:** Período ou fase em que a obra está inserida, podendo ser “convênio” que se refere a obras financiadas por convênios formais, ou “PAR2”, que se refere ao Plano de Ações Articuladas, versão 2.

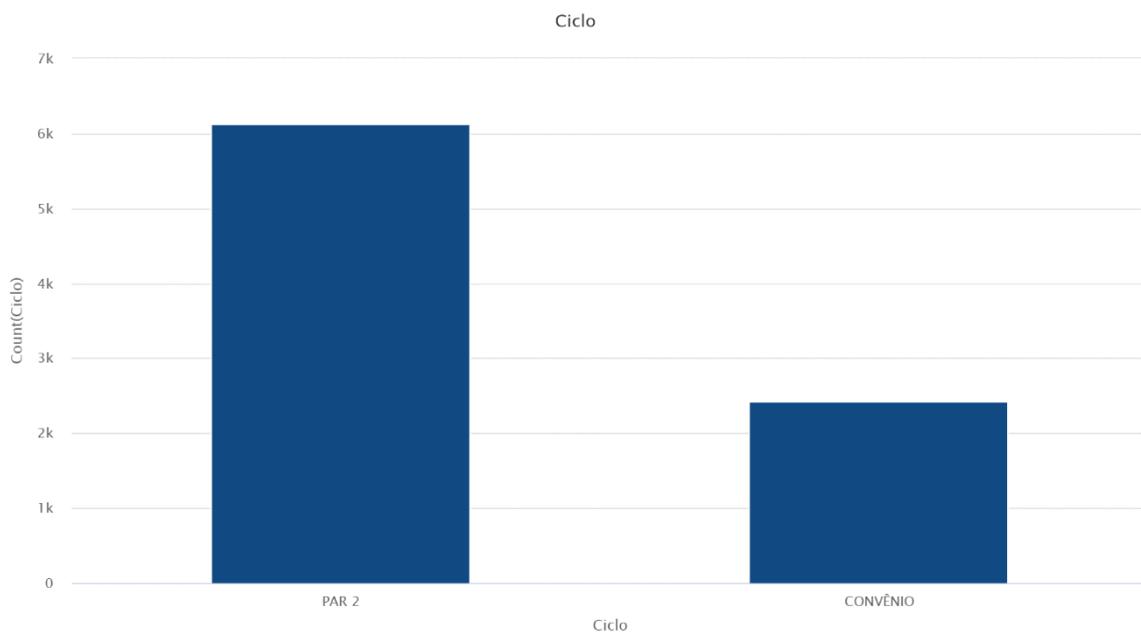


Figura 37: Base inicial – Ciclo (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
PAR 2	6,123	71.57%
CONVÊNIO	2,432	28.43%

Tabela 7: Base inicial – Ciclo (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Ano Termo/Convênio:** Ano em que o termo ou convênio foi assinado.

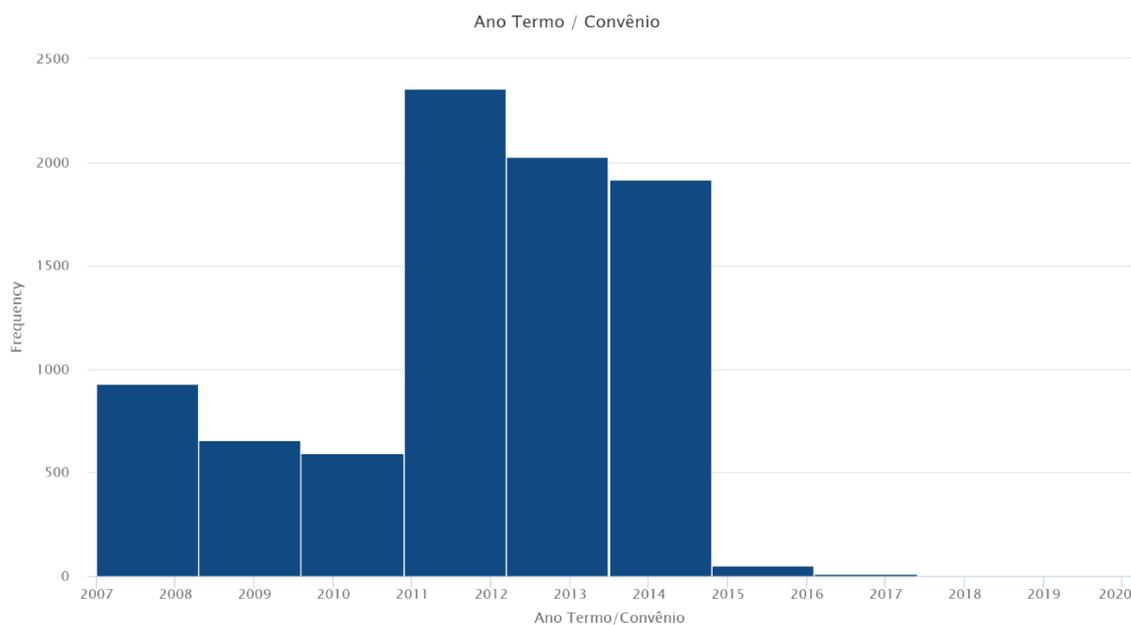


Figura 38: Base inicial - Ano Termo/Convênio (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	2007
Maximum	2020
Average	2011.697
Standard Deviation	2.144

Tabela 8: Base inicial - Ano Termo/Convênio (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Quantidade de Obras:** Número total de obras relacionadas ao convênio ou termo.

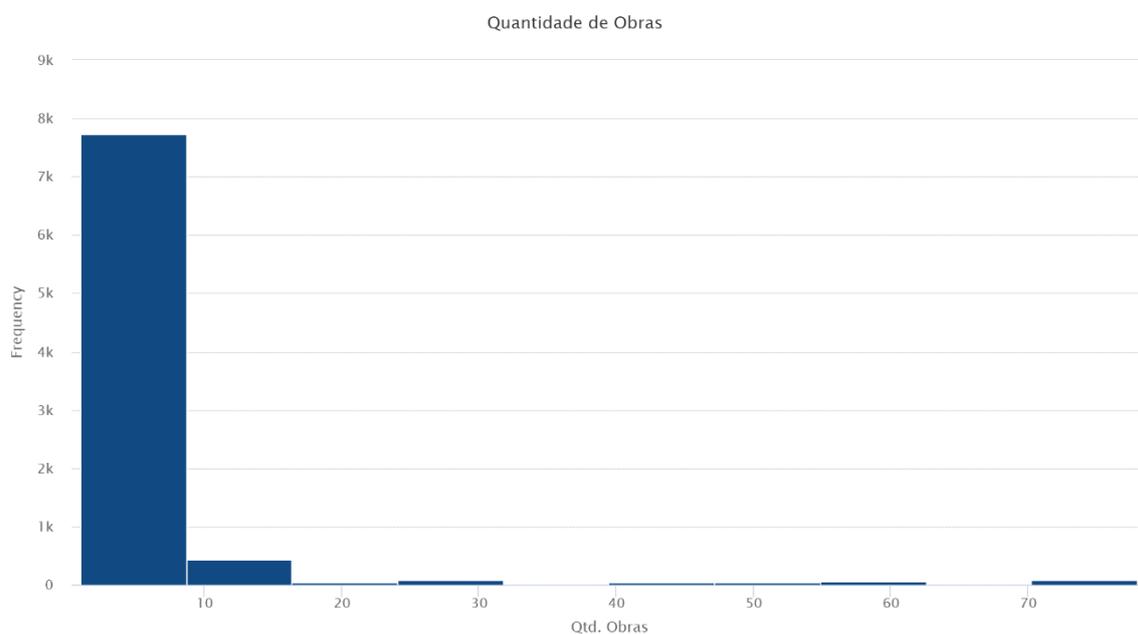


Figura 39: Base inicial - Quantidade de Obras (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	1
Maximum	78
Average	4.265
Standard Deviation	10.407

Tabela 9: Base inicial - Quantidade de Obras (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Município:** Cidade onde a obra está sendo realizada. Os municípios com maiores números de obras são apresentados na tabela 10.

Value	Count	Percentage
Fortaleza	110	1.29%
Brasília	104	1.22%
São Paulo	78	0.91%
Belo Horizonte	63	0.74%
Manaus	62	0.72%

Tabela 10: Base inicial – Municípios (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **UF:** Unidade Federativa, ou seja, o estado onde a obra está localizada.

As UFs com maiores números de obras são apresentadas na tabela 11.

Value	Count	Percentage
MG	1,039	12.14%
SP	889	10.39%
BA	665	7.77%
RS	637	7.45%
PR	607	7.10%

Tabela 11: Base inicial – UF (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Situação:** Estado atual da obra, podendo incluir categorias como “concluída”, “em andamento”, “inacabada”, “não iniciada” “obra cancelada” e “paralisada”.

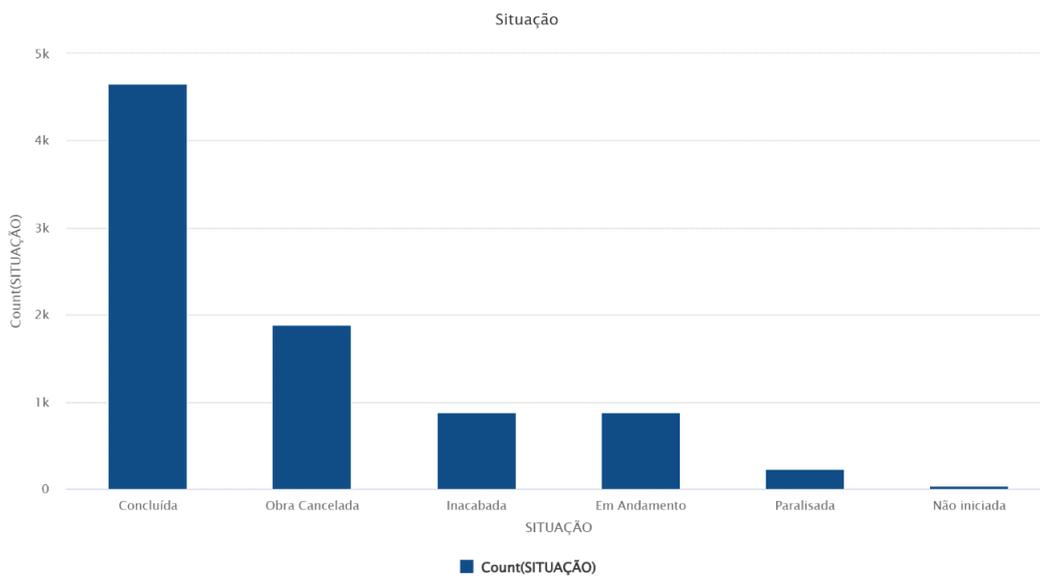


Figura 40: Base inicial – Situação (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
Concluída	4,654	54.40%
Obra Cancelada	1,886	22.05%
Em Andamento	877	10.25%
Inacabada	874	10.22%
Paralisada	232	2.71%
Não iniciada	32	0.37%

Tabela 12: Base inicial – Situação (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **% Executado Instituição Acumulado:** Percentual da obra que já foi executado pela instituição até a data da análise.

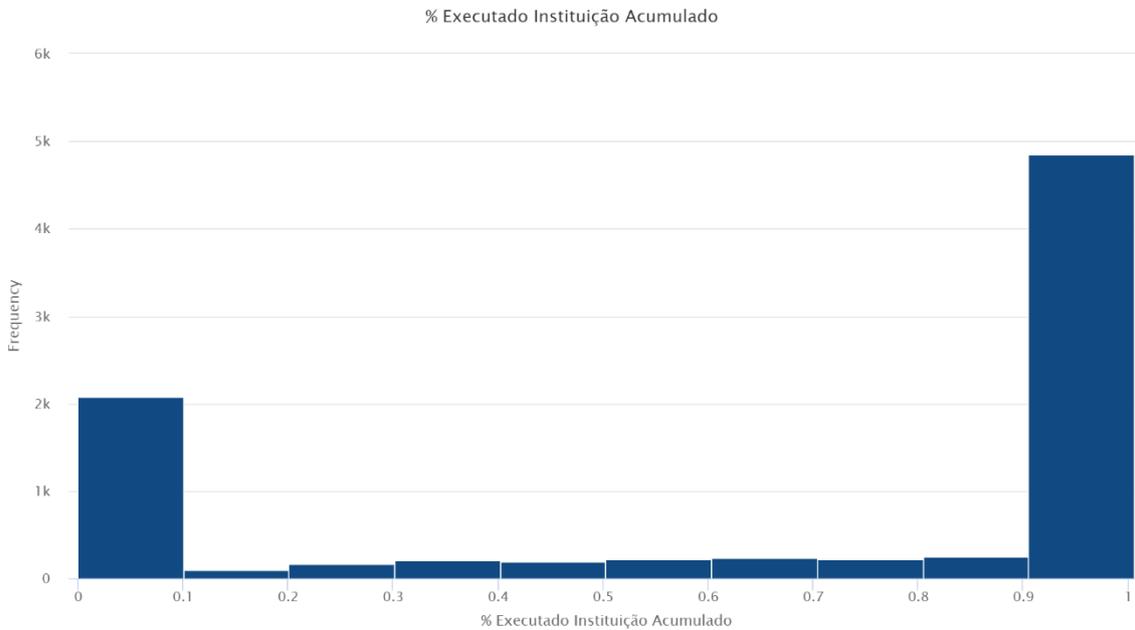


Figura 41: Base inicial - % Executado Instituição Acumulado (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	0
Maximum	1.006
Average	0.669
Standard Deviation	0.424

Tabela 13: Base inicial - % Executado Instituição Acumulado (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Última Vistoria Instituição:** Data da última vistoria realizada pela instituição responsável.



Figura 42: Base inicial - Última Vistoria Instituição (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Fonte:** Indica a origem dos recursos financeiros para a obra.

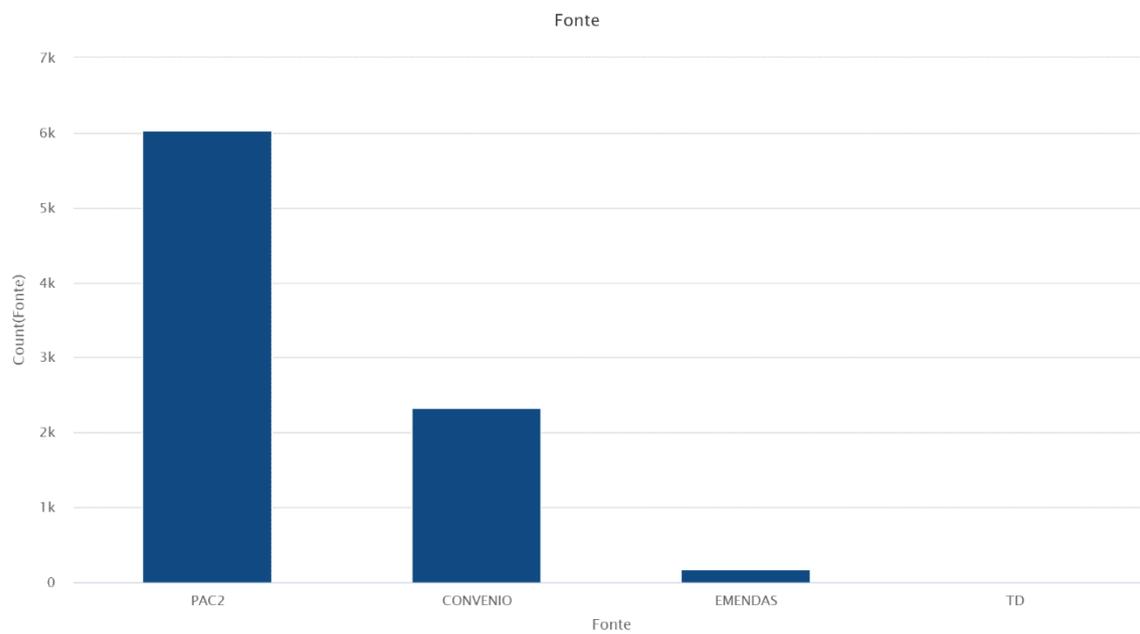


Figura 43: Base inicial – Fonte (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
PAC2	6,028	70.46%
CONVENIO	2,331	27.25%
EMENDAS	185	2.16%
TD	11	0.13%

Tabela 14: Base inicial – Fonte (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Esfera:** Refere-se à esfera de governo envolvida.

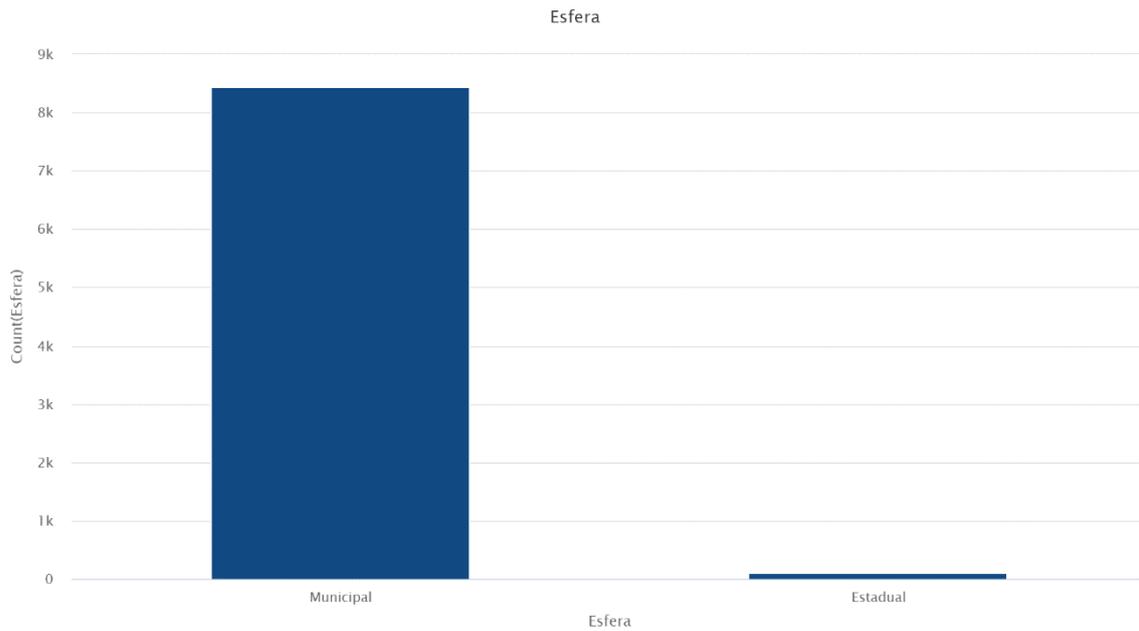


Figura 44: Base inicial – Esfera (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
Municipal	8,446	98.73%
Estadual	109	1.27%

Tabela 15: Base inicial – Esfera (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Tipologia:** Classificação da obra.

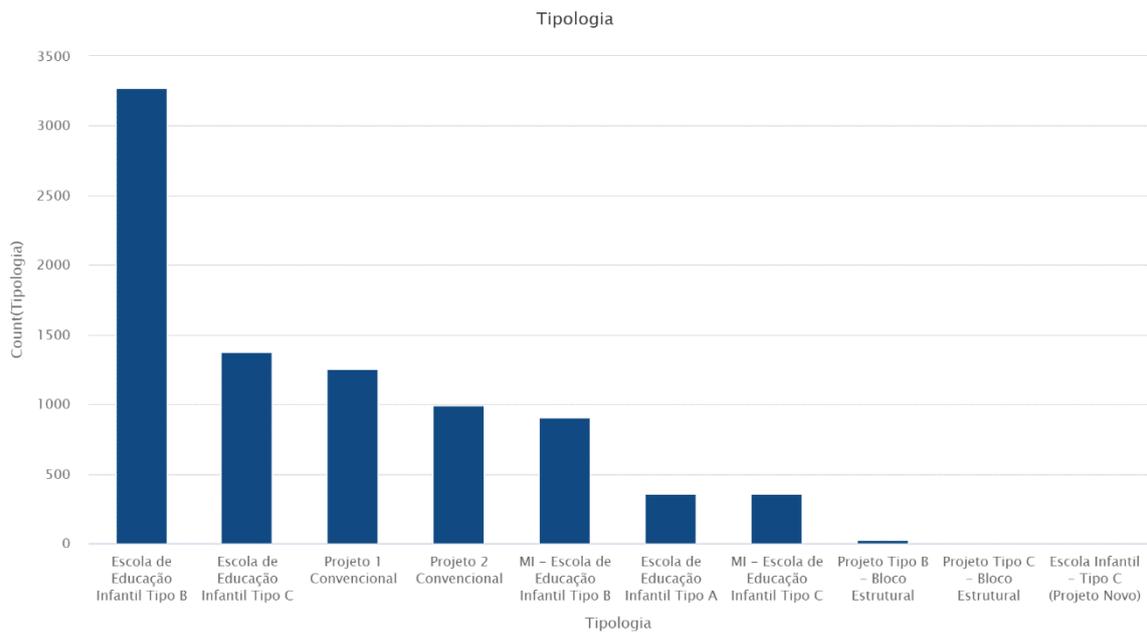


Figura 45: Base inicial – Tipologia (Fonte: Própria. Extraída de Altair® AI Studio).

Value	Count	Percentage
Escola de Educação Infantil Tipo B	3,275	38.28%
Escola de Educação Infantil Tipo C	1,377	16.10%
Projeto 1 Convencional	1,253	14.65%
Projeto 2 Convencional	993	11.61%
MI - Escola de Educação Infantil Tipo B	907	10.60%
Escola de Educação Infantil Tipo A	360	4.21%

Tabela 16: Base inicial – Tipologia (Fonte: Própria. Extraída de Altair® AI Studio).

- **Valores FNDE:** Valores relacionados ao Fundo Nacional de Desenvolvimento da Educação (FNDE) que foram alocados para a obra.

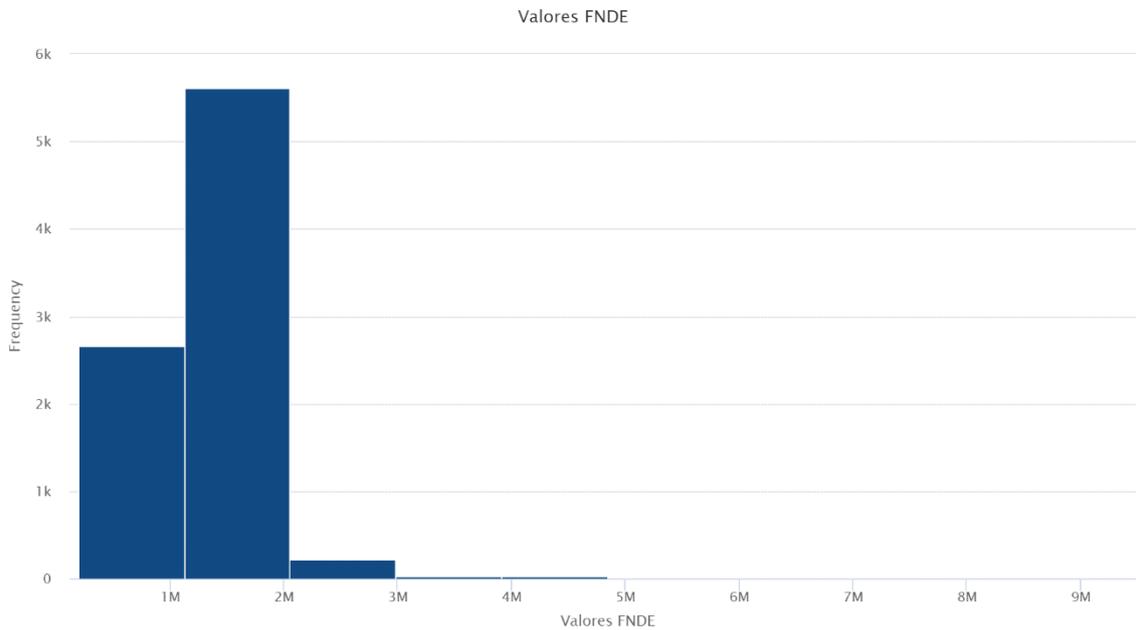


Figura 46: Base inicial - Valores FNDE (Fonte: Própria. Extraída de Altair® AI Studio).

Name	Value
Minimum	200000
Maximum	9486012.770
Average	1291587.584
Standard Deviation	504389.919

Tabela 17: Base inicial - Valores FNDE (Fonte: Própria. Extraída de Altair® AI Studio).

- **Valores Pagos:** Total de valores já pagos até o momento para a execução da obra.

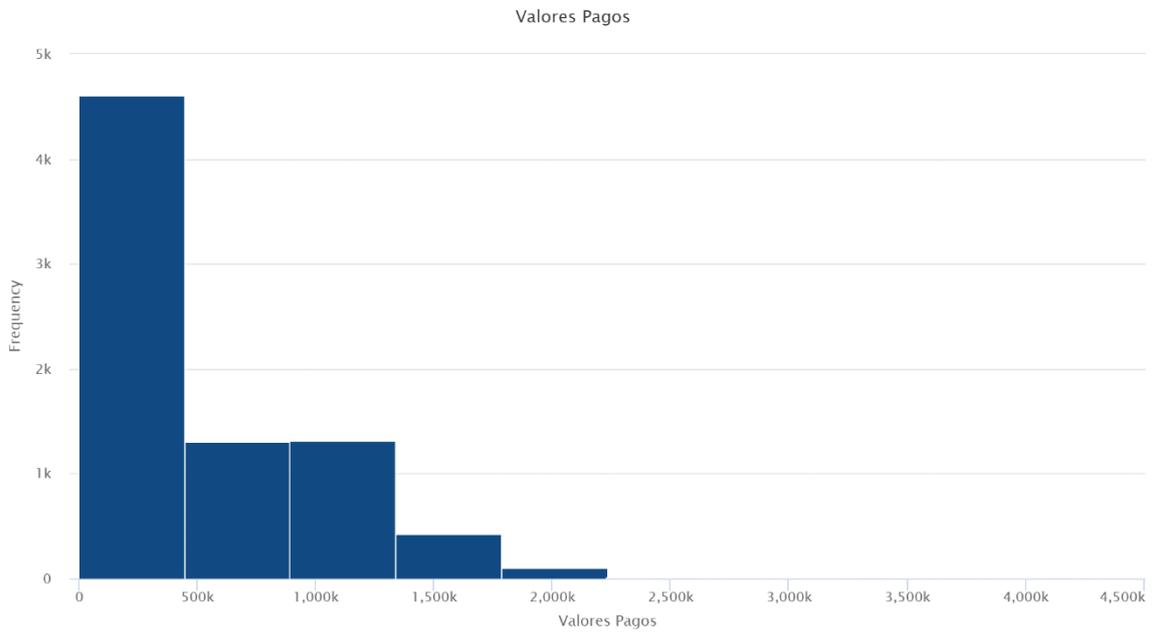


Figura 47: Base inicial - Valores Pagos (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	3
Maximum	4465843.520
Average	481914.287
Standard Deviation	531360.793

Tabela 18: Base inicial - Valores Pagos (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Vigência:** Período durante o qual o convênio é válido.

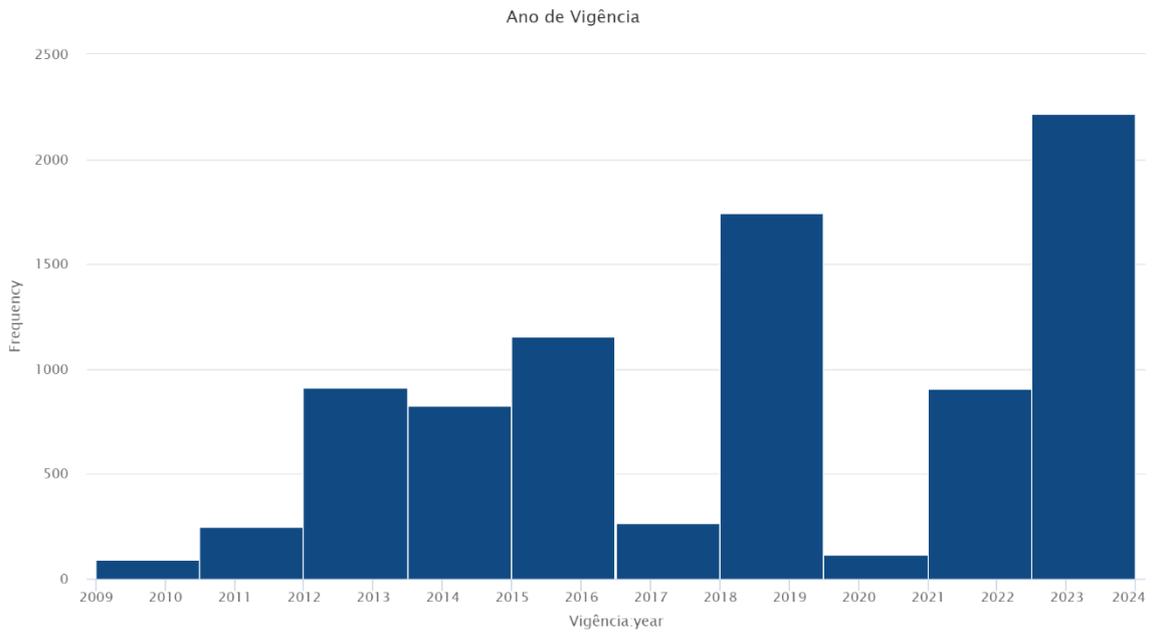


Figura 48: Base inicial – Vigência (Fonte: Própria. Extraída de Altair® AI Studio).

Name	Value
Minimum	2009
Maximum	2024
Average	2018.157
Standard Deviation	3.974

Tabela 19: Base inicial – Vigência (Fonte: Própria. Extraída de Altair® AI Studio).

- **Nº alunos (2 turnos):** Número de alunos que serão atendidos pela obra em dois turnos.

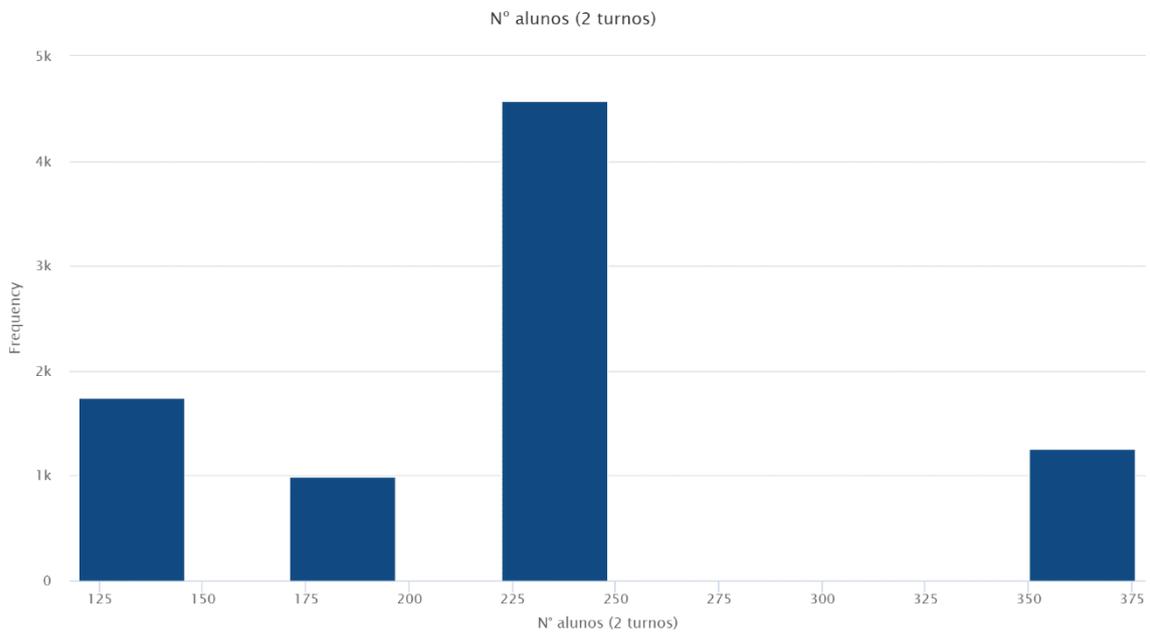


Figura 49: Base inicial - Nº alunos (2 turnos) (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Nº Alunos (integral):** Número de alunos atendidos em turno integral.

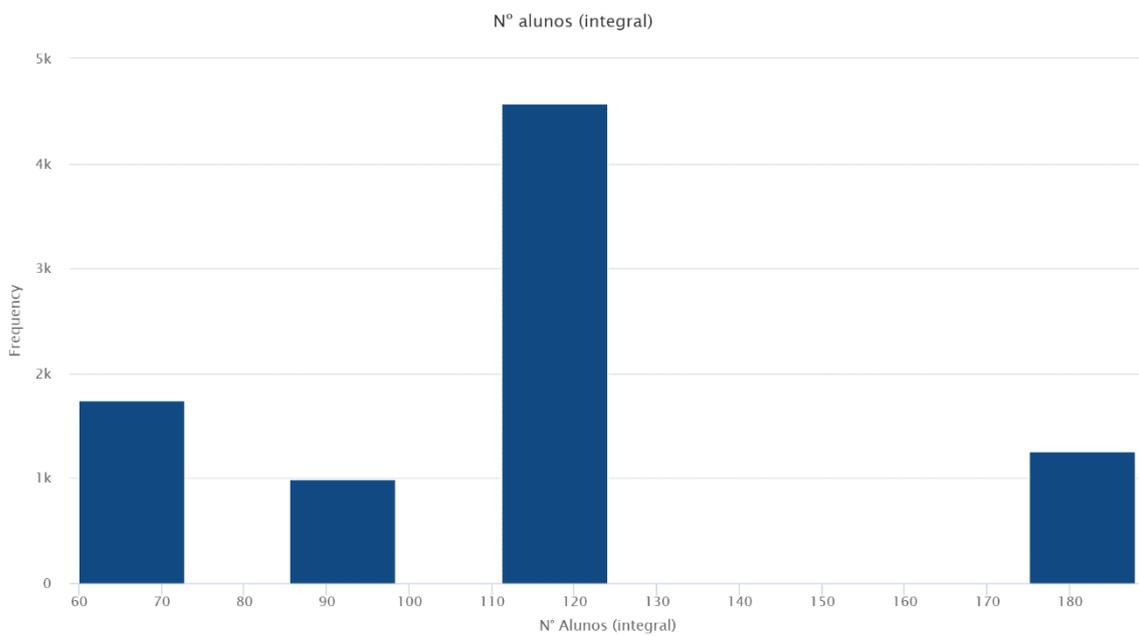


Figura 50: Base inicial - Nº alunos (integral) (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Restrições:** Restrições que podem estar impedindo a execução da obra.

Restrições geram suspensão do pagamento até que sejam solucionadas [150].

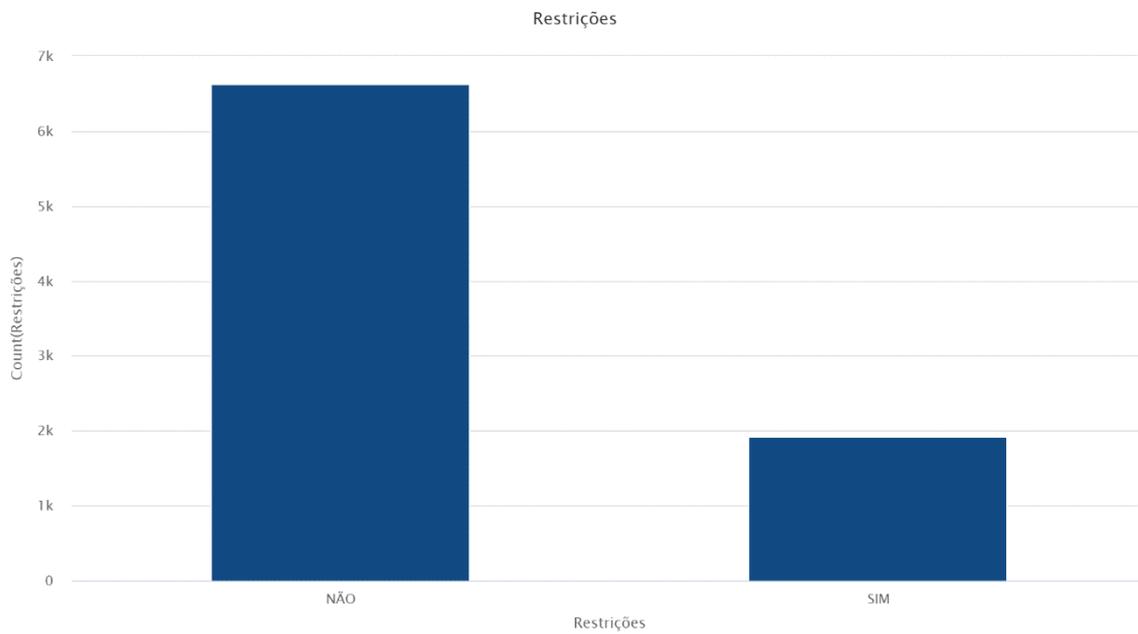


Figura 51: Base inicial – Restrições (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
NÃO	6,625	77.52%
SIM	1,921	22.48%

Tabela 20: Base inicial – Restrições (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Inconformidades:** Divergências ou problemas identificados nas vistorias ou relatórios técnicos.

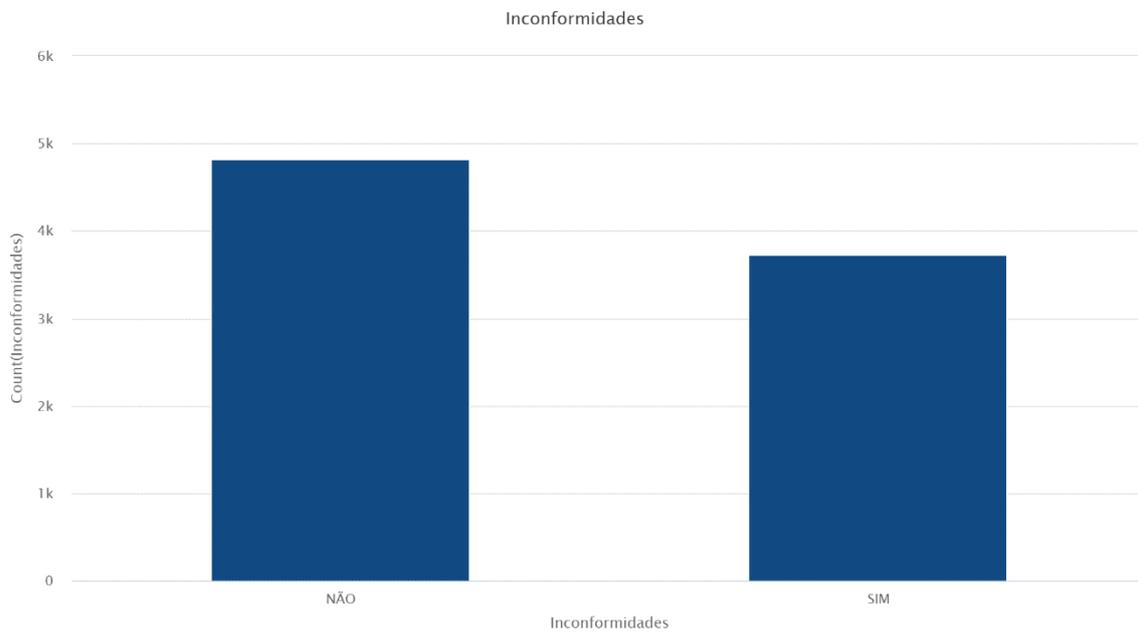


Figura 52: Base inicial – Inconformidades (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
NÃO	4,824	56.45%
SIM	3,722	43.55%

Tabela 21: Base inicial – Inconformidades (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Vinculada:** Ocorre quando, após o abandono ou paralisação de uma obra pela construtora original, uma nova empresa é contratada por meio de um novo processo licitatório para continuar o projeto. Nesse caso, a nova obra é classificada como vinculada [150].

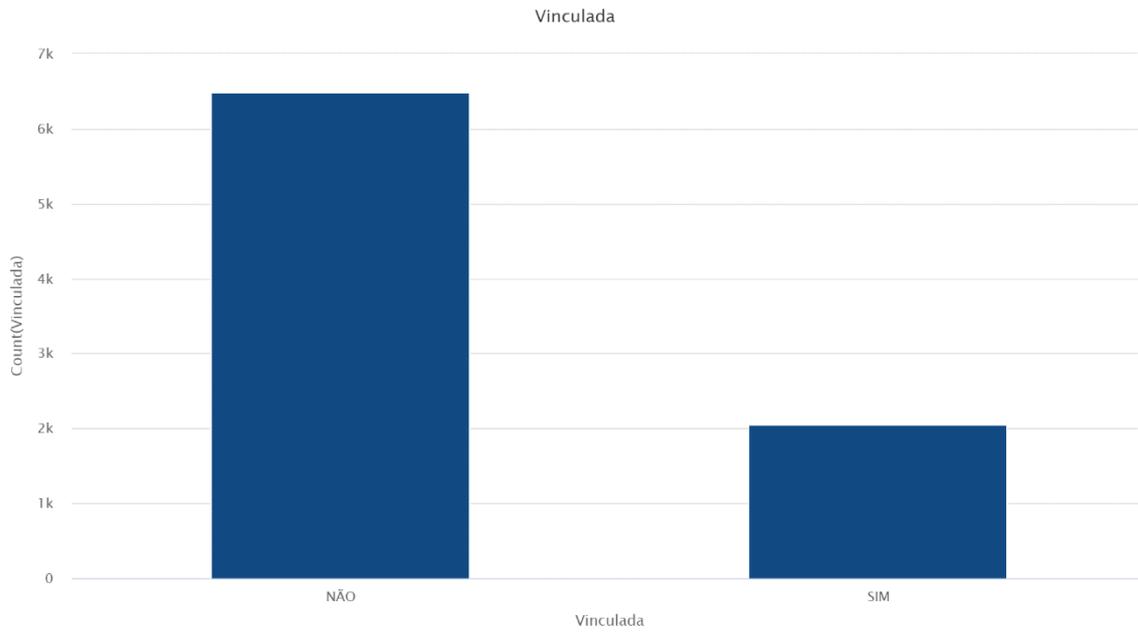


Figura 53: Base inicial – Vinculada (Fonte: Própria. Extraída de *Altair® AI Studio*).

Value	Count	Percentage
NÃO	6,490	75.94%
SIM	2,056	24.06%

Tabela 22: Base inicial – Vinculada (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Tipo de Paralisação:** Classificação do motivo da paralisação da obra, como questões climáticas, problemas técnicos etc.

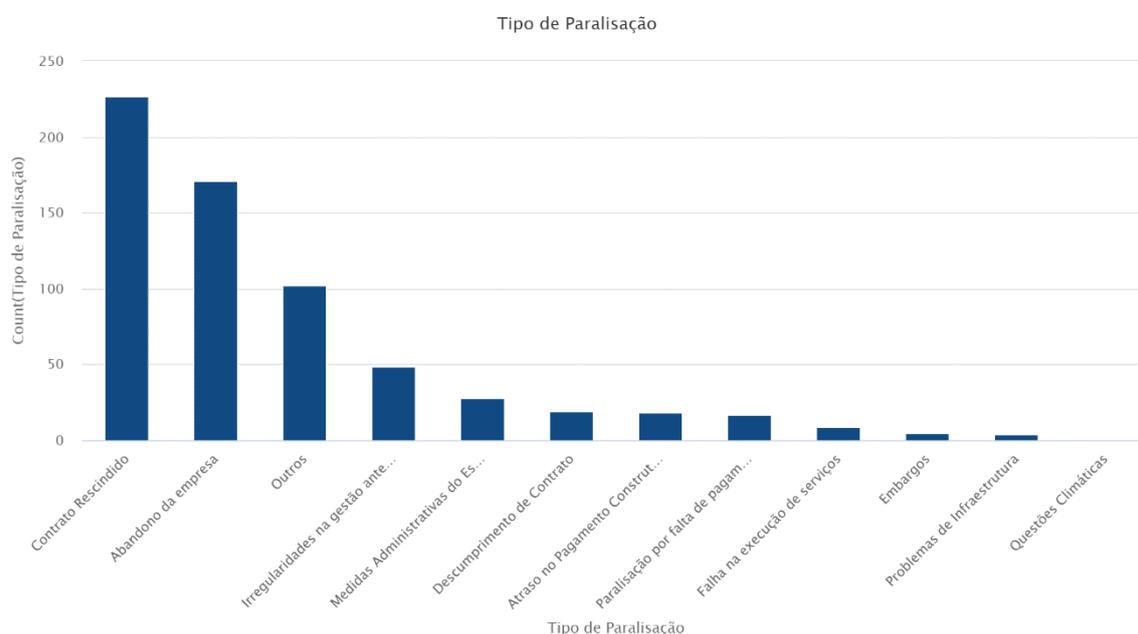


Figura 54: Base inicial - Tipo de Paralisação (Fonte: Própria. Extraída de Altair® AI Studio).

Value	Count	Percentage
Contrato Rescindido	227	34.92%
Abandono da empresa	171	26.31%
Outros	102	15.69%
Irregularidades na gestão anterior	49	7.54%
Medidas Administrativas do Estado/Município	28	4.31%
Descumprimento de Contrato	19	2.92%

Tabela 23: Base inicial - Tipo de Paralisação (Fonte: Própria. Extraída de Altair® AI Studio).

- **Quantidade Dias Última Vistoria:** Número de dias desde a última vistoria realizada.

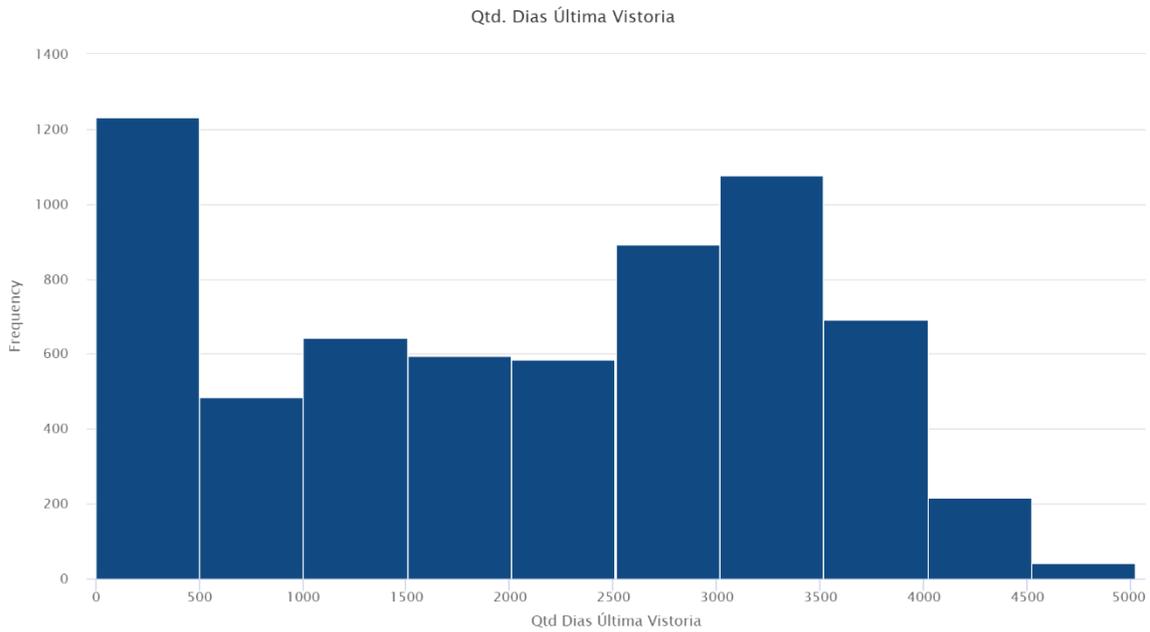


Figura 55: Base inicial - Quantidade Dias Última Vistoria (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	0
Maximum	5026
Average	2070.089
Standard Deviation	1320.417

Tabela 24: Base inicial - Quantidade Dias Última Vistoria (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Valor Contrato:** Valor total do contrato firmado para a execução da obra.

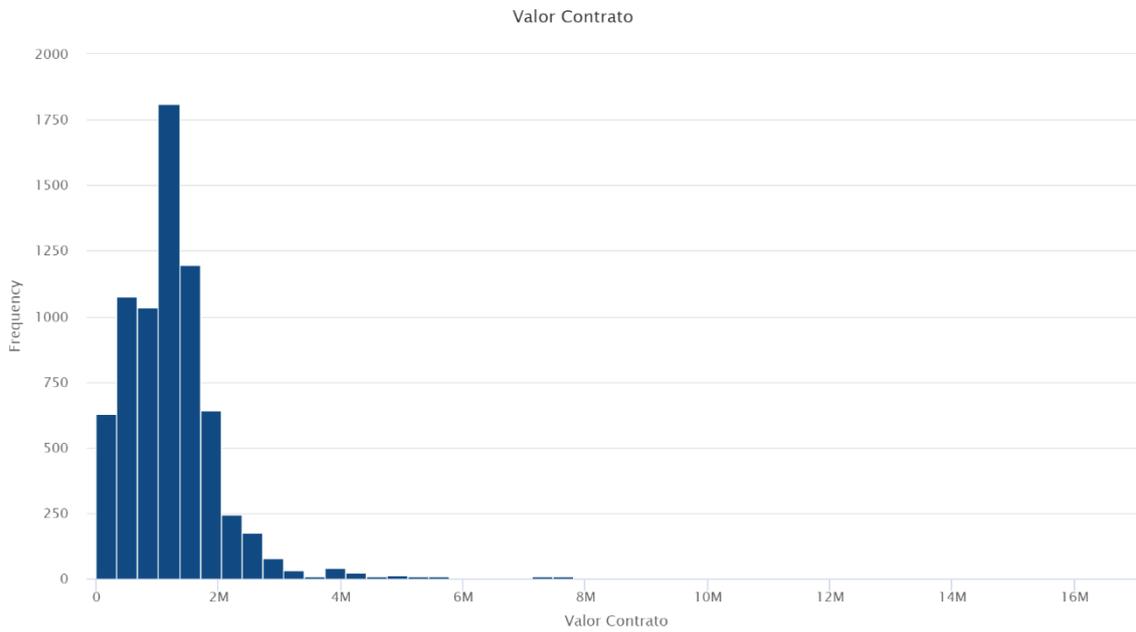


Figura 56: Base inicial - Valor Contrato (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	6600
Maximum	16996599.580
Average	1265983.912
Standard Deviation	895473.488

Tabela 25: Base inicial - Valor Contrato (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Valores Pactuados:** Valores acordados no convênio ou contrato, podendo incluir ajustes ou modificações.

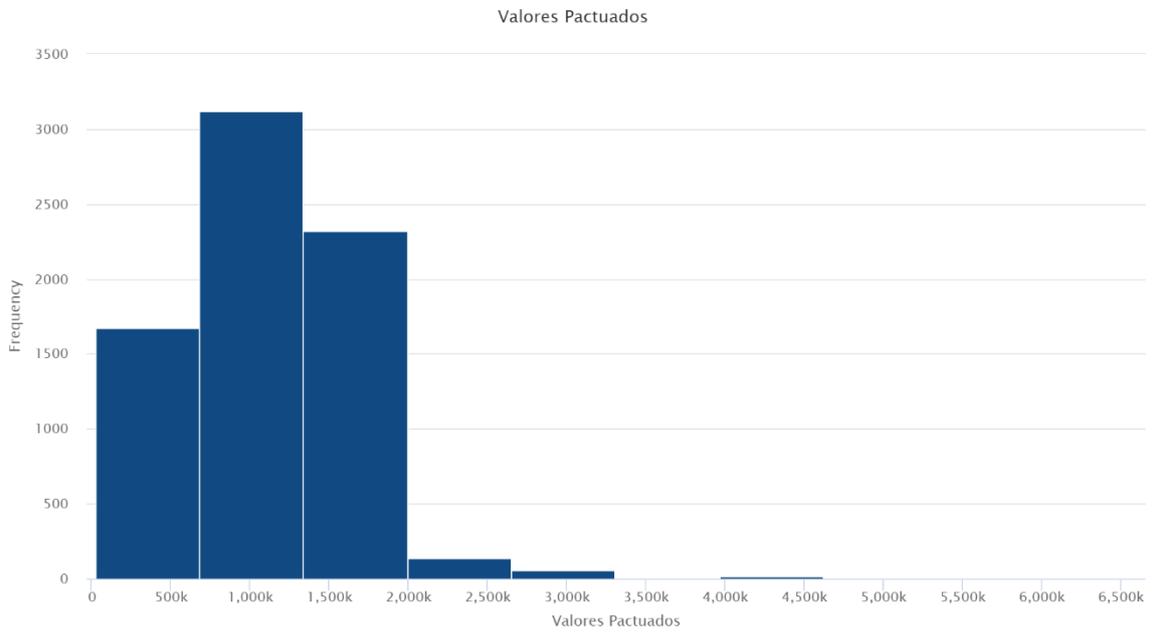


Figura 57: Base inicial - Valores Pactuados (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	25000
Maximum	6595945.020
Average	1216081.102
Standard Deviation	558426.532

Tabela 26: Base inicial - Valores Pactuados (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Valores Empenhados:** Total de valores que foram comprometidos para a obra, mas ainda não pagos.

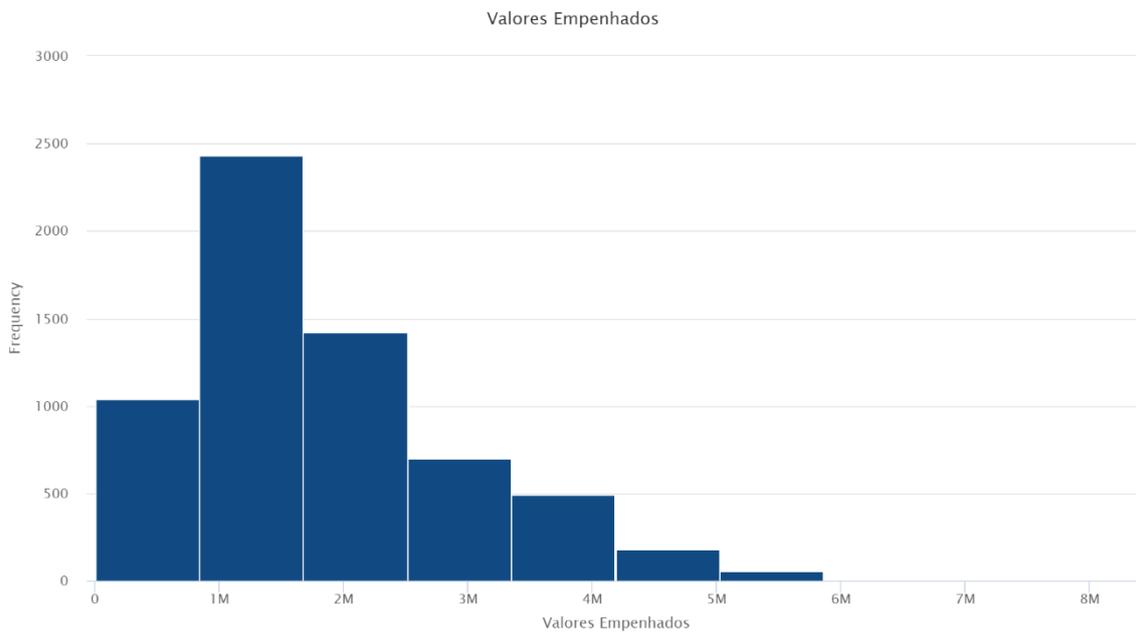


Figura 58: Base inicial - Valores Empenhados (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	10002.390
Maximum	8375190.230
Average	1884404.487
Standard Deviation	1089866.241

Tabela 27: Base inicial - Valores Empenhados (Fonte: Própria. Extraída de *Altair® AI Studio*).

- **Tipo de RI:** Tipo de restrição ou inconformidade.

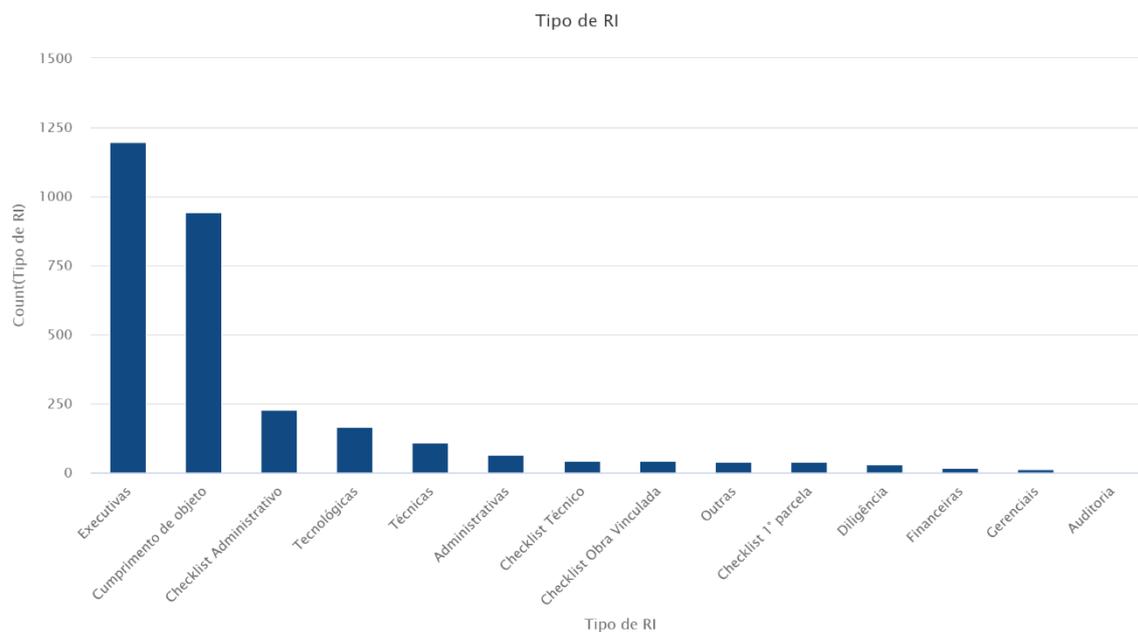


Figura 59: Base inicial - Tipo de RI (Fonte: Própria. Extraída de Altair® AI Studio).

Value	Count	Percentage
Executivas	1,199	40.87%
Cumprimento de objeto	941	32.07%
Checklist Administrativo	227	7.74%
Tecnológicas	165	5.62%
Técnicas	111	3.78%
Administrativas	67	2.28%

Tabela 28: Base inicial - Tipo de RI (Fonte: Própria. Extraída de Altair® AI Studio).

- **Divisão RI:** Divisão das restrições ou inconformidades.

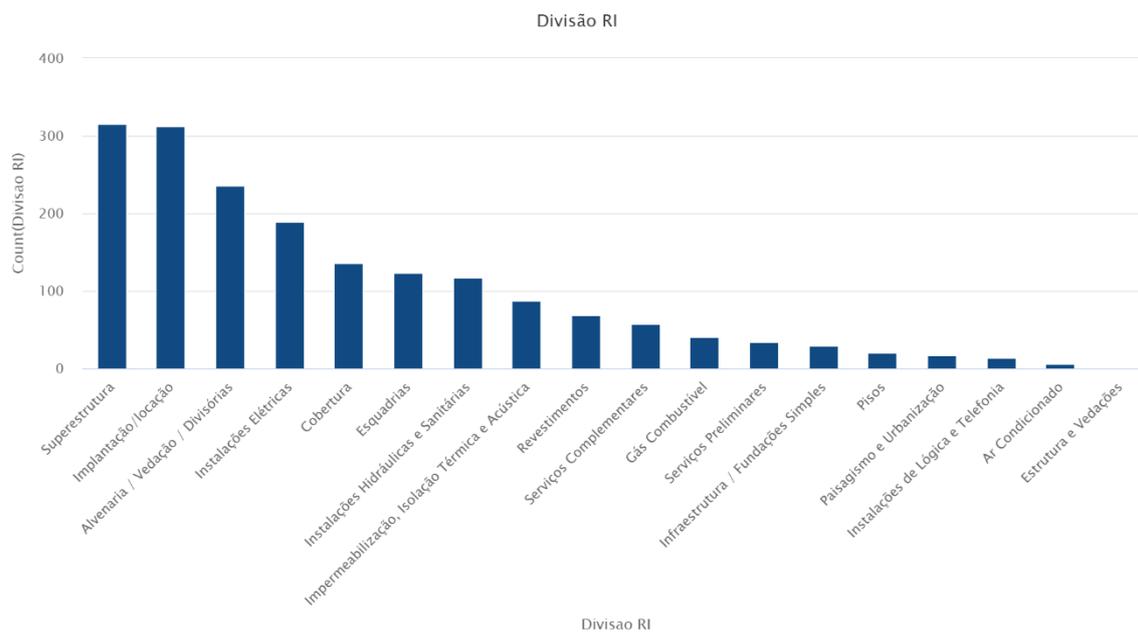


Figura 60: Base inicial - Divisão RI (Fonte: Própria. Extraída de Altair® AI Studio).

Value	Count	Percentage
Superestrutura	316	17.50%
Implantação/locação	312	17.28%
Alvenaria / Vedação / Divisórias	236	13.07%
Instalações Elétricas	189	10.47%
Cobertura	136	7.53%
Esquadrias	124	6.87%

Tabela 29: Base inicial - Divisão RI (Fonte: Própria. Extraída de Altair® AI Studio).

- **Modalidade de Licitação:** Tipo de processo licitatório utilizado para contratar a obra, como concorrência, pregão etc.

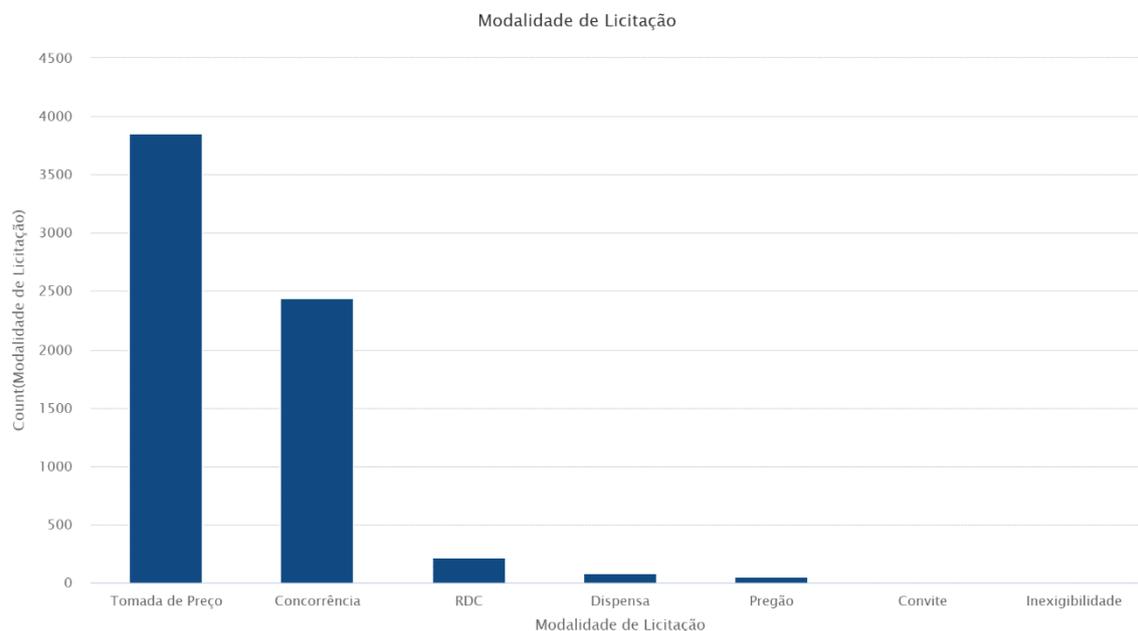


Figura 61: Base inicial - Modalidade de Licitação (Fonte: Própria. Extraída de Altair® AI Studio).

Value	Count	Percentage
Tomada de Preço	3,859	57.90%
Concorrência	2,443	36.65%
RDC	222	3.33%
Dispensa	86	1.29%
Pregão	48	0.72%
Convite	5	0.08%

Tabela 30: Base inicial - Modalidade de Licitação (Fonte: Própria. Extraída de Altair® AI Studio).

- **Empresa Contratada:** Nome da empresa responsável pela execução da obra. Essa variável possui 3.909 valores (empresas) possíveis.

Value	Count	Percentage
(1654319411) SPE INOVA BH S/A	44	0.67%
(8142496217) MVC COMPONENTES PLASTICOS...	41	0.63%
(1312341156) CONSORCIO PRO-INFANCIA BRA...	33	0.50%
(1997111) J R A CONSTRUTORA LTDA	30	0.46%

Tabela 31: Base inicial - Empresa Contratada (Fonte: Própria. Extraída de Altair® AI Studio).

- **Prazo de Vigência:** Duração restante para a execução do contrato ou convênio.

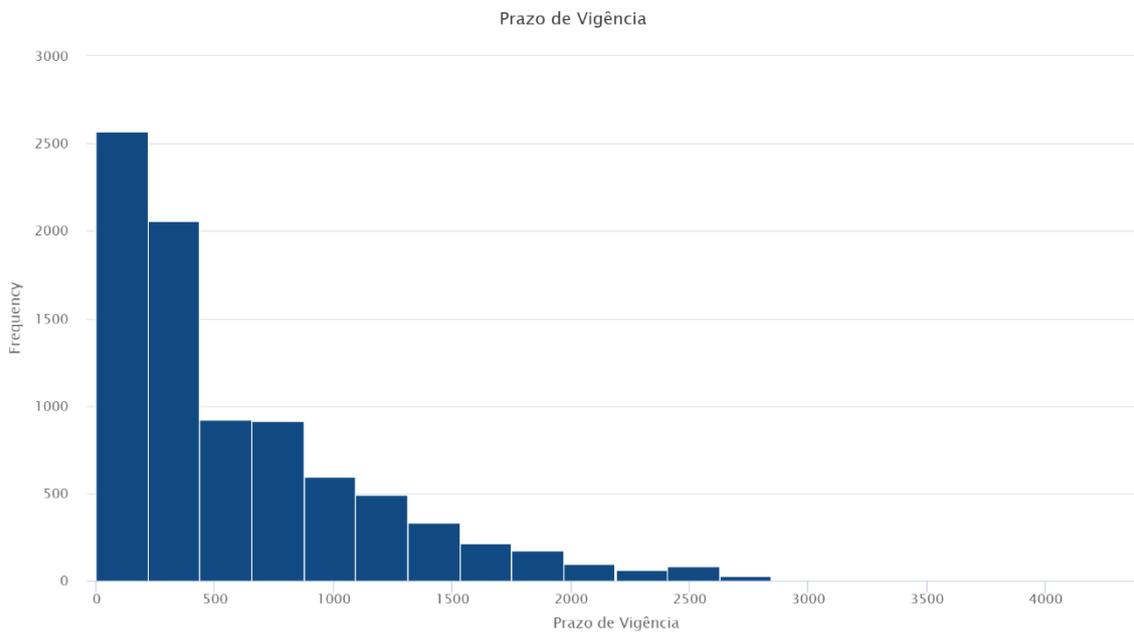


Figura 62: Base inicial - Prazo de Vigência (Fonte: Própria. Extraída de *Altair® AI Studio*).

Name	Value
Minimum	0
Maximum	4380
Average	579.225
Standard Deviation	589.710

Tabela 32: Base inicial - Prazo de Vigência (Fonte: Própria. Extraída de *Altair® AI Studio*).

Esses dados são cruciais para análises que visam identificar os fatores associados à paralisação de obras, possibilitando a criação de um modelo robusto de previsão de risco. Com mais de 8.500 registros, a base de dados oferece uma amostra representativa e diversificada, o que aumenta a confiabilidade dos resultados preditivos. final

Algumas variáveis (colunas) foram excluídas durante a fase de preparação dos dados. Se enquadram nesse caso:

- **Classificação da Obra:** Indica se a obra é em área urbana ou rural. Essa variável foi retirada pois, na base original, apenas 11 obras eram rurais, enquanto mais de 8.000 obras são classificadas como urbanas. Todas as obras rurais foram consideradas outliers e retiradas do *dataset*.

- **% Última Vistoria:** Percentual de execução da obra observado na última vistoria. Essa variável foi retirada pois apresentava 97,23% de valores ausentes.

- **Laudo Técnico:** Relatório técnico que avalia as condições da obra e pode indicar se há problemas a serem resolvidos. Essa variável textual foi retirada pois, além de apresentar mais de 97% de valores ausentes, não havia padronização na forma de escrita, acarretando vieses.

A preparação dos dados é uma etapa fundamental para garantir a qualidade das informações que serão utilizadas nos modelos de machine learning. A limpeza e consolidação permitiram gerar uma base confiável e robusta, que é indispensável para previsões eficazes no contexto de paralisação de obras públicas educacionais.

5.3. Etapa 4 do CRISP-DM - Modelagem

A etapa de modelagem, prevista no CRISP-DM envolve a criação de modelos de aprendizado de máquina do conjunto de dados previamente preparados. Nessa fase, diferentes técnicas de modelagem são aplicadas para encontrar padrões e fazer previsões.

Os modelos selecionados para serem testados pelo software *Altair® AI Studio* são: Naive Bayes, Modelo Linear Generalizado, Regressão Logística, *Fast Large Margin* (FLM), *Deep Learning*, Árvore de Decisão, *Random Forest*, *Gradient Boosted Trees* e *Support Vector Machine* (SVM).

Após a aplicação de todos os modelos mencionados, o próximo passo é avaliar o desempenho de cada um deles. A seleção do modelo preditivo mais adequado será

feita com base em métricas de desempenho específicas, com destaque para a acurácia e o número de erros de classificação.

A acurácia de um modelo se refere à proporção de previsões corretas feitas pelo modelo em relação ao total de previsões. Embora a acurácia seja uma métrica importante, é necessário analisar em conjuntos com outras métricas visto que, em casos em que uma classe é mais prevalente que as outras, o foco apenas na acurácia pode ocultar problemas no desempenho do modelo, pois ele pode acertar predominantemente a classe majoritária, enquanto falha em prever corretamente as classes menos frequentes [151].

O critério de erros de classificação avalia a quantidade de previsões incorretas realizadas. Um modelo com alto número de erros de classificação pode não ser confiável para tarefas que requerem alta precisão [152].

Cada uma dessas métricas oferece uma perspectiva diferente sobre a performance do modelo, contribuindo para uma escolha embasada.

Após executar os modelos propostos, a avaliação de cada um será realizada utilizando técnicas de validação para garantir que os resultados não estão sujeitos ao fenômeno de *overfitting* ao conjunto de dados de treino [153].

É comum que os modelos gerados não apresentem o desempenho esperado na primeira tentativa. Nesse cenário, o próximo passo envolve a recalibração dos hiperparâmetros de cada modelo, ajustando-os para maximizar o desempenho. Essa etapa é conhecida como otimização de hiperparâmetros (*hyperparameters tuning*). A otimização de hiperparâmetros pode resultar em ganhos de desempenho significativos, potencializando a capacidade preditiva [154].

A partir das avaliações e ajustes descritos, será selecionado o modelo que apresentar o melhor desempenho em diferentes métricas de avaliação como *Under the Curve* (AUC), *Precision*, *Recall*, *F-measure* e Especificidade, além da Acurácia e Erro de Classificação.

5.3.1. Dataset I

Continuando a análise da etapa de modelagem prevista no CRISP-DM, os modelos propostos foram treinados utilizando o software *Altair® AI Studio*, gerando resultados que permitem uma análise comparativa detalhada de desempenho.

De acordo com os resultados obtidos, que podem ser observados na figura 63, todos os modelos, exceto a Regressão Logística e o *Fast Large Margin*, apresentaram acurácia superior a 85%. O modelo de Árvore de Decisão destacou-se com o melhor desempenho geral, alcançando uma acurácia de 92,27% e apresentando a menor taxa de erro de classificação (7,73%). Além do excelente desempenho preditivo, a Árvore de Decisão também demonstrou eficiência computacional significativa, com o menor tempo de treinamento entre todos os modelos testados (21,4 segundos por 1.000 linhas).

Modelo	Acurácia	Erro de Classificação	Desvio Padrão	Tempo de Treinamento (1,000 linhas)	Tempo Total
Árvore de Decisão	92,27%	7,73%	± 0,90%	21 ms	1 min 49 s
Gradient Boosted Trees	92,11%	7,89%	± 0,62%	399 ms	7 min 57 s
Deep Learning	91,25%	8,75%	± 0,75%	710 ms	2 min 43 s
Modelo Linear Generalizado	90,02%	9,98%	± 0,63%	1 s 79 ms	2 min 32 s
Random Forest	89,33%	10,67%	± 1,54%	445 ms	17 min 27 s
Naive Bayes	85,60%	14,40%	± 0,70%	32 ms	2 min 09 s
Fast Large Margin	57,59%	42,41%	± 0,81%	2 s 08 ms	13 min 59 s
Regressão Logística	0,37%	99,63%	± 0,17%	838 ms	7 min 53 s

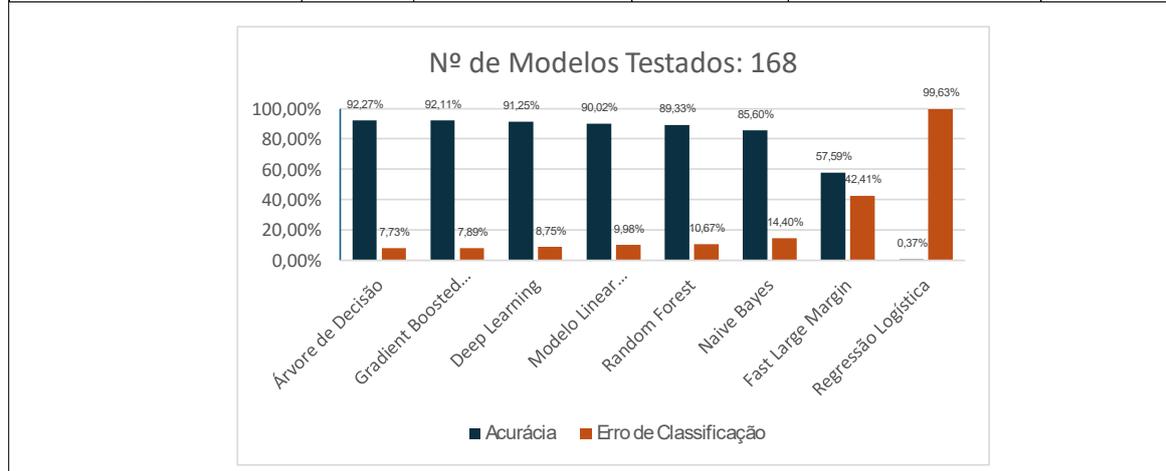


Figura 63: Resultados *dataset I* (Fonte: Própria).

O segundo melhor desempenho foi obtido pelo modelo *Gradient Boosted Trees*, com acurácia de 92,11% e erro de classificação de 7,89%, seguido pelo *Deep*

Learning, com acurácia de 91,25% e erro de classificação de 8,71%. Entretanto, esses modelos demandaram tempos de processamento consideravelmente maiores em comparação com a Árvore de Decisão.

A escolha da Árvore de Decisão como modelo mais adequado fundamenta-se não apenas em sua superior acurácia e baixo índice de erros de classificação, mas também em sua eficiência computacional e grau de interpretabilidade, características essenciais para a aplicação prática no contexto do FNDE.

5.3.2. *Dataset II*

O CRISP-DM preconiza um processo iterativo de refinamento do conjunto de dados, ou seja, prevê ciclos repetidos de desenvolvimento e refinamento do modelo de mineração de dados, com cada ciclo implementando os aprendizados dos ciclos anteriores. O próximo passo será otimizar o modelo através do ajuste do conjunto de dados para atender às necessidades específicas da rotina operacional do FNDE. Uma modificação importante será a remoção das obras já concluídas do *dataset*, visto que o objetivo principal da rotina do FNDE é identificar obras com potencial risco de serem paralisadas e as obras concluídas não são mais passíveis de paralisação. A inclusão de obras já concluídas no conjunto de treinamento não contribui diretamente para o objetivo do órgão e pode introduzir ruído desnecessário ao modelo

Após esta adequação no *dataset*, os modelos serão retreinados para avaliar se essa alteração impacta a performance preditiva, buscando um desempenho ainda mais preciso e focado na identificação precoce de obras com risco de paralisação.

Após a exclusão das obras concluídas, o novo *dataset* foi refinado para atender ao objetivo principal do estudo: prever obras passíveis de paralisação. O novo *dataset*, resultante da seleção de obras em andamento, paralisadas, canceladas, inacabadas e não iniciadas, inicialmente composto por 3.980 linhas, passou por um processo de tratamento de outliers. Utilizando o método de distância euclidiana,

foram removidos 3% dos registros considerados atípicos, resultando em um conjunto refinado de 3.861 linhas.

No processo de preparação dos dados, identificou-se alta taxa de valores faltantes nas colunas "Divisão RI" (93,5% de dados ausentes) e "Tipo de RI" (89,46% de dados ausentes). Conseqüentemente, essas colunas foram removidas do conjunto de dados para evitar possíveis distorções no modelo preditivo.

Após o tratamento, o *dataset* final permaneceu robusto, composto por 25 colunas que abrangem as informações de: porcentagem executada acumuladamente pela instituição, ano do termo ou convênio, ciclo do projeto, empresa contratada, esfera de atuação, fonte de recursos, inconformidades identificadas, modalidade de licitação, município, número de alunos em dois turnos, número de alunos em turno integral; prazo de vigência, quantidade de obras, dias desde a última vistoria, restrições existentes, situação atual, tipo de paralisação, tipologia do projeto, unidade federativa, valor do contrato, valores empenhados, valores destinados pelo FNDE, valores pactuados, valores pagos e instituição vinculada.

Este conjunto de dados preparado representa uma base refinada para a continuidade da modelagem preditiva, com foco específico na identificação de obras com potencial risco de paralisação, permitindo uma análise mais precisa e direcionada das variáveis que podem influenciar a interrupção de projetos educacionais.

Com o conjunto de dados otimizado, os modelos de aprendizado de máquina foram aplicados novamente para verificar o impacto das alterações no desempenho preditivo. As 25 variáveis remanescentes foram testadas para avaliar sua contribuição na previsão de obras passíveis de paralisação, com destaque para a identificação de variáveis mais relevantes no processo preditivo.

Durante a fase de modelagem com o *dataset* refinado, foram submetidos a teste 205 modelos preditivos, visando identificar o modelo mais eficaz na predição de riscos de paralisação de obras do FNDE. Essa abordagem permitiu uma análise comparativa robusta dos diferentes algoritmos de aprendizado de máquina.

Os resultados obtidos, apresentados na figura 64, revelaram diferenças significativas no desempenho dos modelos. O *Deep Learning* foi o algoritmo de melhor performance, alcançando uma acurácia de 90,93% e um baixo erro de classificação de 9,07%, com um desvio padrão de $\pm 1,17\%$.

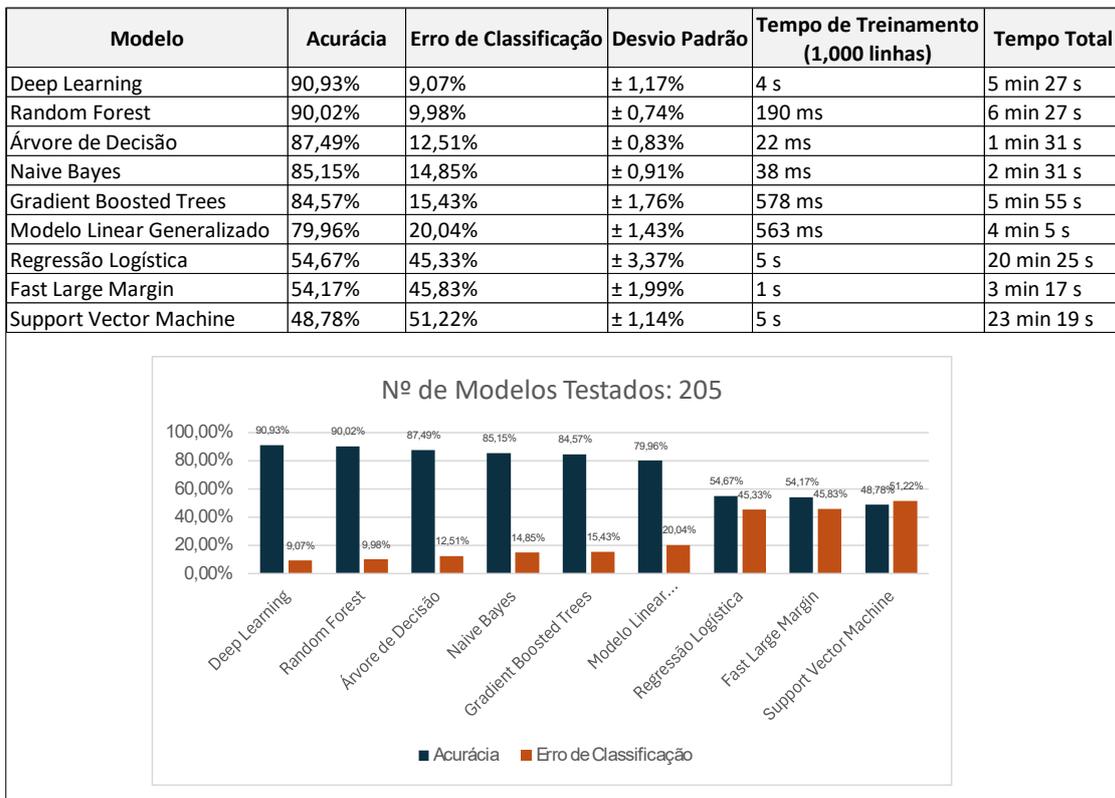


Figura 64: Resultados *dataset II* (Fonte: Própria).

Para o conjunto de dados trabalhado, o *Deep Learning* é o modelo mais adequado por suas características intrínsecas. Esse algoritmo de inteligência artificial se destaca pela capacidade de aprender representações complexas e hierárquicas dos dados, permitindo identificar padrões não lineares e interações sutis entre as variáveis que outros modelos podem não detectar. No contexto específico das obras do FNDE, essa capacidade de identificar padrões ocultos é crucial, considerando a multiplicidade de fatores que podem influenciar a paralisação de um projeto.

O segundo melhor modelo, Random Forest, apresentou desempenho próximo, com acurácia de 90,02% e erro de classificação de 9,98%. A Árvore de Decisão também se mostrou uma boa alternativa, com 87,49% de acurácia. Em contraste,

modelos como *Support Vector Machine*, *Regressão Logística* e *Fast Large Margin* foram menos eficazes, com acurácias inferiores a 55%, indicando a limitação de aplicação desses modelos para o problema em análise.

O desvio padrão das métricas fornece informações sobre a consistência dos modelos. O *Random Forest* apresentou o menor desvio padrão ($\pm 0,74\%$), sugerindo maior estabilidade em suas predições, enquanto a *Regressão Logística* mostrou o maior desvio ($\pm 3,37\%$), indicando maior variabilidade nos resultados.

Esses resultados evidenciam a natureza complexa do problema de predição de riscos em obras educacionais, ressaltando a importância de uma abordagem metodológica rigorosa na seleção e avaliação de modelos de machine learning.

5.3.3. Dataset III

Seguindo o processo iterativo preconizado pelo CRISP-DM, procedeu-se com um novo refinamento do conjunto de dados, visando a transformação do problema de classificação multiclasse em um problema de classificação binária.

A adaptação para um modelo de classificação binária possibilita a utilização de métricas de avaliação mais específicas, incluindo *Area Under the Curve* (AUC), *Precision*, *Recall*, *F-measure* e Especificidade, além das métricas já utilizadas de Acurácia e Erro de Classificação. Tal abordagem permite uma avaliação mais precisa e multifacetada do desempenho dos modelos preditivos, especialmente relevante no contexto de identificação precoce de obras com potencial risco de comprometimento.

Nesta iteração, o *dataset* foi reestruturado através da exclusão das obras não iniciadas e do agrupamento das categorias "paralisadas", "inacabadas" e "canceladas" em uma única classe, denominada "obras comprometidas". Esta nomenclatura foi escolhida por refletir o estado crítico dessas obras que apresentam significativos impedimentos em sua execução regular. Assim, a variável alvo

"Situação" passou a contemplar apenas duas classes: "Em andamento" e "Obras comprometidas".

O novo conjunto de dados resultante é composto por 3.829 registros, já excluídos os 3% outliers de acordo com o método de distância euclidiana. Similarmente às iterações anteriores, as colunas "Divisão RI" e "Tipo de RI" foram excluídas devido à alta proporção de valores ausentes. O *dataset* preservou sua estrutura com 25 variáveis preditoras, abrangendo aspectos financeiros, administrativos, estruturais e temporais das obras.

Após a transformação do problema para classificação binária, foram testados 404 modelos preditivos, cujos resultados permitiram uma análise mais abrangente através de múltiplas métricas de desempenho. Os resultados são apresentados nas tabelas 33 e 34.

Modelo	Acurácia	Erro de Classificação	<i>F Measure</i>	<i>Precision</i>	Especificidade
<i>Deep Learning</i>	93,51%	6,49%	95,95%	92,63%	73,05%
<i>Gradient Boosted Trees</i>	93,05%	6,95%	95,69%	92,04%	70,47%
<i>Random Forest</i>	92,41%	7,59%	95,30%	91,52%	68,51%
Modelo Linear Generalizado	89,95%	10,05%	93,61%	92,76%	74,14%
Árvore de Decisão	89,85%	10,15%	93,52%	91,34%	70,54%
<i>Naive Bayes</i>	85,28%	14,72%	91,21%	84,70%	39,44%
Regressão Logística	77,24%	22,76%	87,15%	77,24%	0%
<i>Fast Large Margin</i>	77,24%	22,76%	87,15%	77,24%	0%
<i>Support Vector Machine</i>	77,24%	22,76%	87,15%	77,24%	0%

Tabela 33: Resultados *dataset* III (Acurácia, Erro de Classificação, F Measure, Precision) (Fonte: Própria).

Modelo	Recall	Desvio Padrão	Tempo de Treinamento (1,000 linhas)	Tempo Total
<i>Deep Learning</i>	99,52%	± 0,93%	8 s	10 min 34 s
<i>Gradient Boosted Trees</i>	99,64%	± 0,98%	699 ms	5 min 12 s
<i>Random Forest</i>	99,41%	± 0,68%	104 ms	5 min 52 s
Modelo Linear Generalizado	94,49%	± 1,33%	95 ms	3 min 8 s
Árvore de Decisão	95,81%	± 0,59%	8 ms	1 min 43 s
<i>Naive Bayes</i>	98,82%	± 1,16%	9 ms	1 min 52 s
Regressão Logística	100%	± 1,14%	1 s	3 min 47 s
<i>Fast Large Margin</i>	100%	± 1,14%	248 ms	52 s
<i>Support Vector Machine</i>	100%	± 1,14%	3 s	16 min 13 s

Tabela 34: Resultados *dataset* III (Recall, Desvio Padrão, Tempo de Treinamento, Tempo Total) (Fonte: Própria).

5.4. Etapa 5 do CRISP-DM - Avaliação

A próxima etapa prevista pelo CRISP-DM é a de avaliação, que envolve a realização da interpretação dos resultados e possíveis otimizações.

A análise de diferentes métricas, conforme previamente apresentadas nas tabelas 33 e 34, fornece diferentes perspectivas sobre a capacidade preditiva dos modelos.

A acurácia, que representa a proporção total de previsões corretas em relação ao total de casos, variou entre 77,24% e 93,51% entre os modelos testados. Essa métrica, embora importante, deve ser analisada em conjunto com outras medidas. A acurácia pode ser calculada como [151]:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

Equação 2: Acurácia

Onde VP são verdadeiros positivos, VN são verdadeiros negativos, FP são falsos positivos e FN são falsos negativos. Essas siglas também serão utilizadas nas equações das demais métricas de desempenho.

O erro de classificação, complementar à acurácia, mensura a proporção de previsões incorretas, apresentando variação entre 6,49% e 22,76% nos modelos avaliados. Quanto menor o valor desta métrica, melhor o desempenho do modelo, indicando menor quantidade de classificações errôneas [152].

$$\text{Erro de Classificação} = \frac{FP + FN}{VP + VN + FP + FN}$$

Equação 3: Erro de Classificação

A precisão (*precision*) indica a proporção de verdadeiros positivos entre todos os casos classificados como positivos, variando de 77,24% a 92,76% nos modelos testados. Essa métrica é particularmente relevante quando o custo de falsos positivos é alto [155].

$$\text{Precision} = \frac{VP}{VP + FP}$$

Equação 4: *Precision*

O *recall*, também conhecido como sensibilidade, mede a proporção de casos positivos corretamente identificados, com valores entre 94,49% e 100% nos modelos avaliados. Essa métrica é crucial quando é importante não deixar de identificar casos positivos [155].

$$\text{Recall} = \frac{VP}{VP + FN}$$

Equação 5: *Recall*

O *F-measure*, também chamado de *F1 Score*, representa a média harmônica entre precisão e recall, ou seja, fornece um equilíbrio entre estas duas métricas [155]. Os modelos testados variaram essa métrica entre 87,15% e 95,95%.

$$F \text{ measure} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Equação 6: *F-measure*

A especificidade, que avalia a proporção de verdadeiros negativos corretamente identificados, foi a métrica que apresentou maior variabilidade entre os modelos, com valores entre 0% e 74,14%. Essa métrica é importante para avaliar a capacidade do modelo em identificar corretamente os casos negativos [156].

$$Especificidade = \frac{VN}{VN + FP}$$

Equação 7: Especificidade

Quanto à eficiência computacional, os tempos de treinamento por 1.000 linhas variaram desde 8 milissegundos até 8 segundos, com tempos totais de processamento entre 52 segundos e 16 minutos e 13 segundos.

O desvio padrão das métricas, variando entre $\pm 0,59\%$ e $\pm 1,33\%$, indica a estabilidade e consistência dos modelos em suas previsões.

A análise multifacetada das métricas de desempenho permite uma avaliação robusta dos modelos, considerando diferentes aspectos de sua capacidade preditiva e eficiência computacional.

5.4.1. Curvas ROC e AUC

Para determinar qual modelo apresenta o melhor desempenho geral, será realizada uma análise através da comparação das curvas ROC (*Receiver Operating Characteristic*). Este método é particularmente adequado para problemas de classificação binária, pois permite visualizar graficamente o desempenho de cada modelo através da relação entre a taxa de verdadeiros positivos (sensibilidade) e a taxa de falsos positivos (1 - especificidade).

Na curva ROC, o eixo Y representa a taxa de verdadeiros positivos (sensibilidade), enquanto o eixo X representa a taxa de falsos positivos (1 - especificidade). Um modelo perfeito teria sua curva passando pelo ponto (0,1), que representa 100% de sensibilidade e 100% de especificidade. Portanto, quanto mais

próxima a curva estiver do canto superior esquerdo do gráfico, melhor será o desempenho do modelo.

A área sob a curva ROC (AUC) fornece uma medida numérica deste desempenho, onde valores mais próximos de 1 indicam melhor capacidade de discriminação entre as classes. A análise comparativa das curvas ROC, que representa o equilíbrio entre sensibilidade e especificidade para a tarefa de predição de obras comprometidas, auxiliará na decisão do modelo mais adequado para o caso.

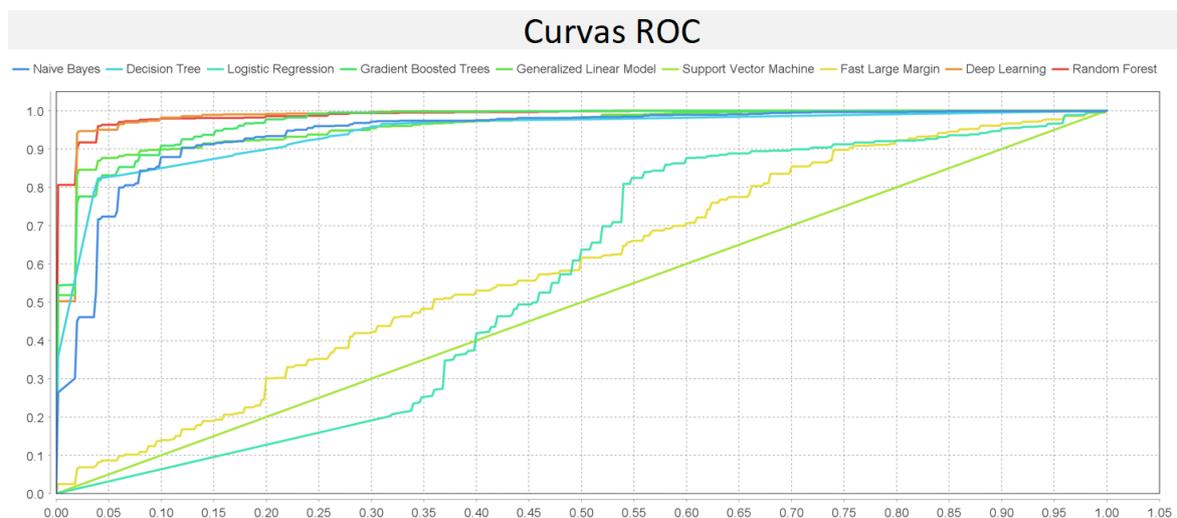


Figura 65: Curvas ROC (Fonte: Própria).

Modelo	AUC
<i>Random Forest</i>	98,89%
<i>Deep Learning</i>	98,46%
<i>Gradient Boosted Trees</i>	97,03%
Modelo Linear Generalizado	95,82%
Árvore de Decisão	94,25%
<i>Naive Bayes</i>	94,13%
<i>Fast Large Margin</i>	59,11%
Regressão Logística	55,36%
<i>Support Vector Machine</i>	50%

Tabela 35: AUC (Fonte: Própria).

A *Area Under the Curve* (AUC) avalia a capacidade do modelo de distinguir as classes, medindo a área sob a curva ROC (*Receiver Operating Characteristic*). Os

valores observados variaram entre 50% e 98,89%, onde valores próximos a 100% indicam melhor capacidade discriminativa do modelo.

O *Random Forest* apresentou a maior área sob a curva ROC (AUC = 98,89%), seguido muito proximamente pelo *Deep Learning* (AUC = 98,46%) e pelo *Gradient Boosted Trees* (AUC = 97,03%). Estes valores expressivamente altos de AUC indicam excelente capacidade de discriminação entre obras em andamento e obras comprometidas. A curva ROC destes três modelos demonstra uma inflexão acentuada em direção ao canto superior esquerdo do gráfico, confirmando visualmente o superior desempenho indicado pelos valores de AUC.

O Modelo Linear Generalizado e a Árvore de Decisão apresentaram desempenho intermediário, com AUC de 95,82% e 94,25% respectivamente. Suas curvas ROC, embora ainda demonstrando boa capacidade preditiva, apresentam uma curvatura menos acentuada em direção ao ponto ideal (0,1) quando comparadas aos três primeiros modelos.

O *Naive Bayes*, com AUC de 94,13%, apresentou desempenho similar à Árvore de Decisão, porém com menor especificidade (39,44%), o que é evidenciado pela maior distância de sua curva ROC em relação ao eixo vertical esquerdo do gráfico.

Os modelos de Regressão Logística (AUC = 55,36%), *Fast Large Margin* (AUC = 59,11%) e *Support Vector Machine* (AUC = 50%) apresentaram curvas ROC significativamente mais próximas à diagonal do gráfico, indicando capacidade preditiva marginalmente superior a uma classificação aleatória. Este comportamento é consistente com a especificidade nula observada nestes modelos.

A correlação entre as curvas ROC e os valores de AUC é direta e pode ser observada na forma das curvas: quanto maior a área sob a curva, mais próxima ela estará do canto superior esquerdo do gráfico. O *Random Forest*, com o maior AUC, apresenta a curva mais próxima deste ponto ideal, com o *Deep Learning* muito próximo.

Com base na análise das curvas ROC e valores de AUC, associada às demais métricas de desempenho previamente apresentadas, o *Deep Learning* emerge como o modelo mais adequado para a tarefa de predição de obras comprometidas. Embora o *Random Forest* tenha apresentado AUC ligeiramente superior, o *Deep Learning* demonstrou melhor equilíbrio geral entre todas as métricas avaliadas, com acurácia de 93,51%, precisão de 92,63%, alta sensibilidade (99,52%) e especificidade satisfatória (73,05%).

A escolha é fundamentada não apenas no desempenho superior das métricas individuais, mas também na robustez e consistência demonstradas pelo modelo *Deep Learning* ao longo de todas as avaliações realizadas, tornando-o a escolha mais adequada para implementação no contexto do FNDE.

5.4.2. *Deep Learning* como modelo preditivo

O *Deep Learning*, ou Aprendizado Profundo, representa uma evolução no campo da inteligência artificial, sendo um subconjunto específico do *machine learning* [157]. Essa abordagem é baseada em redes neurais artificiais com múltiplas camadas (*deep neural networks*), inspiradas no funcionamento do cérebro humano [158].

O conceito inicial de redes neurais artificiais surgiu em 1943 com o modelo matemático de McCulloch e Pitts [159]. Contudo, sua aplicação prática em larga escala só se tornou viável a partir dos anos 2000, impulsionada pelo aumento expressivo da capacidade computacional e pela disponibilidade de grandes volumes de dados [160]. Um marco significativo ocorreu em 2012, quando uma rede neural profunda denominada AlexNet revolucionou o campo da visão computacional na competição “ImageNet” [161].

A arquitetura do *Deep Learning* é estruturada em camadas múltiplas de neurônios artificiais interconectados. A primeira camada, denominada camada de entrada, recebe os dados brutos. As camadas intermediárias, conhecidas como

camadas ocultas, processam progressivamente informações mais abstratas e complexas. A camada final, ou camada de saída, produz a predição ou classificação desejada. Cada conexão entre neurônios possui um peso associado, que é ajustado durante o processo de treinamento através de algoritmos de otimização, como o gradiente descendente.

Matematicamente, o *Deep Learning* opera através de transformações não lineares sucessivas dos dados de entrada. Cada neurônio artificial realiza uma combinação linear de suas entradas, seguida por uma função de ativação não linear:

$$y = f(\sum(wi \times xi) + b)$$

Equação 8: Ativação do Neurônio Artificial

Onde y é a saída do neurônio, wi são os pesos das conexões, xi são as entradas, b é o viés (bias) e f é a função de ativação, que pode ser ReLU (*Rectified Linear Unit* - retorna zero para valores negativos e mantém os valores positivos), sigmoide (mapeia valores de entrada para um intervalo entre 0 e 1), tangente hiperbólica (também chamada de *tanh*. Mapeia valores de entrada entre -1 e 1.), entre outras [162]. O treinamento da rede ocorre através do algoritmo de retropropagação (*backpropagation*), que utiliza a regra da cadeia do cálculo para computar gradientes e atualizar os pesos através do gradiente descendente estocástico [163].

Existem diversos tipos de arquiteturas de *Deep Learning*, cada uma adaptada a diferentes tipos de problemas, entre elas:

- Redes Neurais *Feedforward* (FNN): A arquitetura mais básica, onde a informação flui de forma unidirecional da entrada para a saída [164].
- Redes Neurais Convolucionais (CNN): Eficazes no processamento de dados com estrutura em grade, como imagens [165].
- Redes Neurais Recorrentes (RNN) e *Long Short-Term Memory* (LSTM): Projetadas para processar sequências de dados, sendo aplicadas em análise temporal e processamento de linguagem natural [166].

- *Autoencoders*: Utilizados para aprendizado não supervisionado e redução de dimensionalidade [167].

As aplicações *do Deep Learning* são vastas, incluindo visão computacional, processamento de linguagem natural, sistemas de recomendação e diagnóstico médico [157]. No contexto da previsão de obras comprometidas do FNDE, o modelo demonstrou excepcional capacidade preditiva, alcançando acurácia de 93,51% e AUC de 98,46%, o que evidencia a capacidade de discriminar efetivamente entre obras em andamento regular e obras com potencial de comprometimento, fornecendo uma ferramenta valiosa para a gestão preventiva de recursos públicos na área educacional. Esse desempenho pode ser atribuído à capacidade do *Deep Learning* de identificar padrões complexos e não lineares em dados multidimensionais [168]. O modelo consegue processar simultaneamente múltiplas variáveis e suas interações, capturando nuances sutis que podem indicar potenciais problemas em obras educacionais

A robustez do modelo para o caso em análise deriva da capacidade de aprendizado hierárquico, onde cada camada da rede neural extrai características progressivamente mais complexas dos dados [169]. Essa característica é particularmente relevante na análise de obras públicas, onde múltiplos fatores interagem de forma complexa para determinar o sucesso ou comprometimento dos projetos.

5.4.2.1. Processo de implementação do *Deep Learning*

O processo de implementação do modelo de *Deep Learning* foi estruturado em cinco etapas principais, seguindo uma abordagem sistemática para garantir a qualidade e do modelo preditivo. A figura 66 representa o processo criado por código XML composto por 4079 linhas que especificam detalhadamente cada módulo, suas interconexões e parâmetros utilizados no fluxo de trabalho.

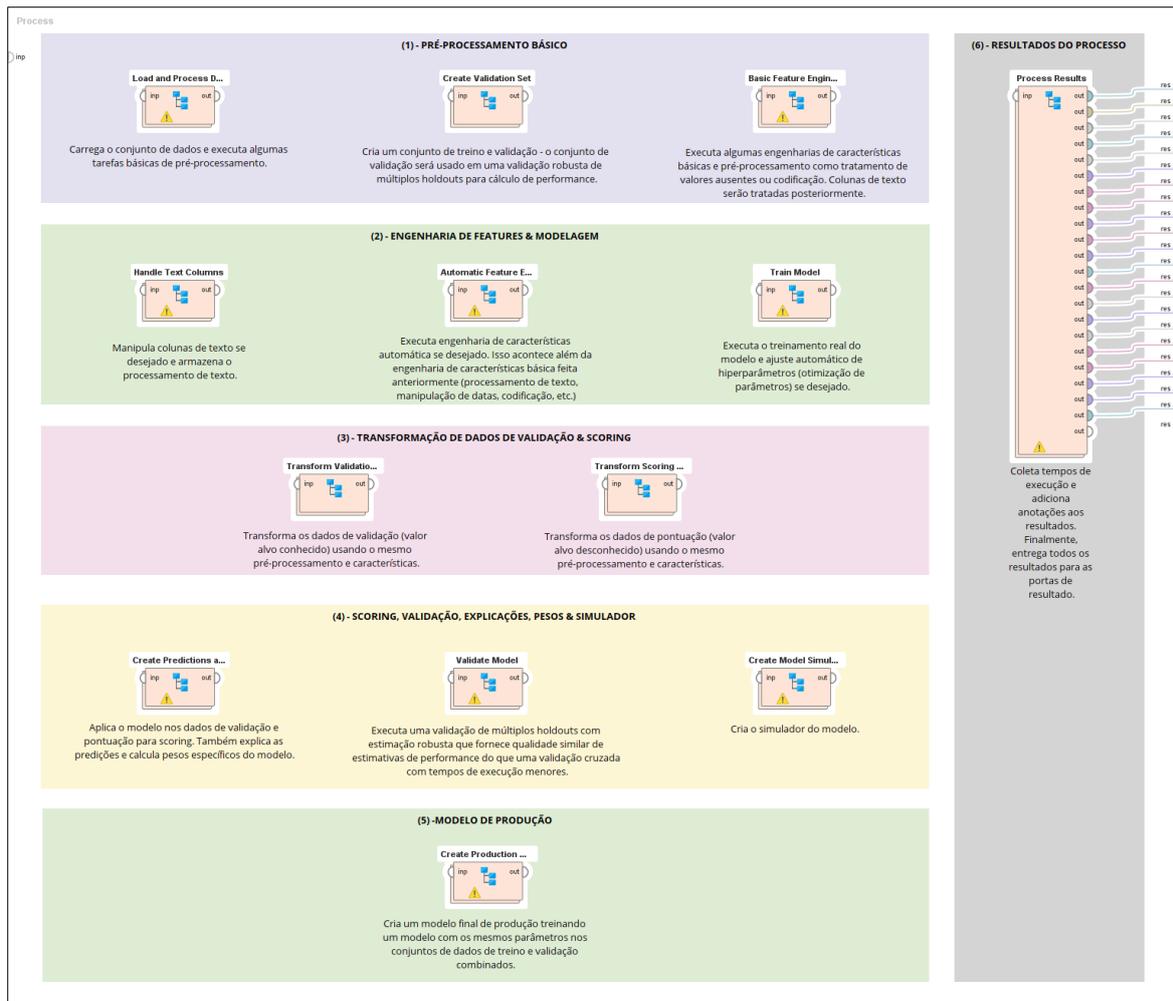


Figura 66: Processo de *Deep Learning* (Fonte: Própria).

A figura 67 apresenta um diagrama de fluxo numerado de 1 a 13, que ilustra a sequência dos macroprocessos descritos na figura 66. Este fluxograma demonstra visualmente a ordem de execução e as interconexões entre as diferentes etapas do processo de implementação do modelo de *Deep Learning*.

A representação visual permite uma melhor compreensão do fluxo de trabalho e das dependências entre cada etapa do processo, evidenciando como cada componente se conecta aos demais para formar um pipeline completo e coerente de machine learning.

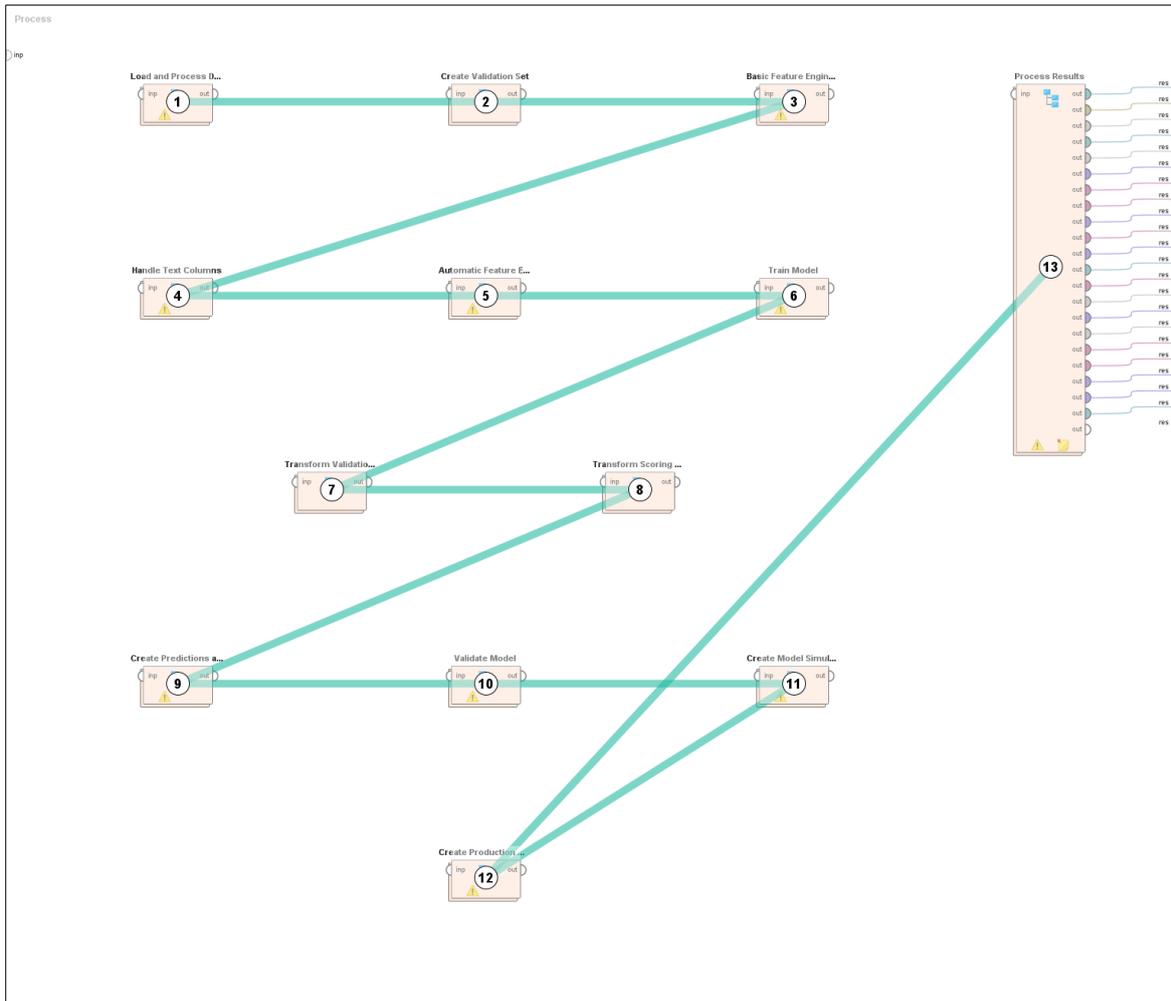


Figura 67: Fluxograma do processo de *Deep Learning* (Fonte: Própria).

Os números indicados na imagem correspondem à sequência lógica das operações, começando pelo pré-processamento básico (1-3), passando pela engenharia de features e modelagem (4-6), transformação dos dados (7-8), validação e predições (9-11), criação do modelo de produção (12) e finalizando com o processamento dos resultados (13).

As etapas do processo implementação do modelo de aprendizagem profunda são:

1. **Pré-processamento básico** - etapa inicial. Fundamental para preparar os dados para o treinamento do modelo e é dividida em três componentes principais:

- **Carregamento e Processamento de Dados:** Responsável por carregar o conjunto de dados e realizar o processamento básico inicial, incluindo a identificação de dados rotulados e não rotulados que serão utilizados posteriormente pelo modelo.

- **Criação do Conjunto de Validação:** Realiza a divisão dos dados em conjuntos de treinamento e validação. Essa divisão é necessária para avaliar o desempenho do modelo em dados não vistos durante o treinamento, evitando problemas de *overfitting*.

- **Engenharia de Features Básica:** Executa operações fundamentais de pré-processamento, como o tratamento de valores ausentes e codificação de variáveis categóricas. Nesta fase, as colunas textuais são identificadas para processamento posterior.

2. **Engenharia de Features e Modelagem** - esta etapa é composta por três componentes críticos:

- **Processamento de Colunas Textuais:** Realiza o tratamento específico das colunas que contêm dados textuais, armazenando o modelo de processamento textual para uso posterior.

- **Engenharia Automática de Features:** Executa um processo automatizado de engenharia de features, complementando o processamento básico realizado anteriormente. Este componente trabalha em conjunto com os processos de tratamento textual, manipulação de datas e codificação.

- **Treinamento do Modelo:** Responsável pelo treinamento efetivo do modelo de *Deep Learning*, utilizando técnicas de otimização de hiperparâmetros para maximizar sua performance. Parâmetros como taxa de aprendizado, quantidade de neurônios por camada e funções de ativação são ajustados automaticamente.

3. **Transformação dos Dados de Validação e *Scoring*** - esta etapa garante a consistência no processamento dos dados:

- **Transformação dos Dados de Validação:** Aplica as mesmas transformações e pré-processamentos utilizados nos dados de treinamento ao conjunto de validação.

- **Transformação dos Dados de *Scoring*:** Realiza o mesmo processo para os dados de *scoring* (sem valores conhecidos), garantindo uniformidade no tratamento dos dados.

4. **Scoring, Validação, Explicações, Pesos e Simulador** - etapa crucial para a avaliação e interpretação do modelo:

- **Criação de Predições:** Aplica o modelo treinado aos conjuntos de validação e *scoring*, gerando predições e calculando pesos específicos do modelo.

- **Validação do Modelo:** Implementa uma validação robusta através de múltiplos *hold-outs*, que reduz o viés e melhora a qualidade das estimativas de desempenho.

- **Criação do Simulador do Modelo:** Desenvolve um simulador que permite testar diferentes cenários e entender o comportamento do modelo.

5. **Modelo de Produção** - etapa que consiste na criação do modelo definitivo:

- **Criação do Modelo de Produção:** Treina o modelo final utilizando os mesmos parâmetros otimizados, mas agora aplicados ao conjunto completo de dados (treinamento + validação).

Os resultados de cada etapa do processo são coletados e organizados em portas de saída. Esses resultados incluem anotações, métricas de desempenho, explicações e predições geradas pelo modelo. O pipeline estruturado garante não apenas o treinamento eficiente do modelo de *Deep Learning*, mas também sua rigorosa validação e preparação para implementação em ambiente de produção. A abordagem sistemática adotada contribui para a alta performance alcançada pelo modelo.

5.4.2.2. Modelo de Produção do Algoritmo de *Deep Learning*

Conforme apresentado no pipeline, a última etapa, denominada "Modelo de Produção", realiza a criação de um modelo final de produção. Durante o processo de criação do modelo de produção, os parâmetros e configurações definidos nas etapas anteriores são reutilizados. Isso inclui tanto os ajustes realizados no pré-processamento quanto os métodos de engenharia de características e otimização aplicados no modelo de treinamento.

O modelo implementado utiliza uma arquitetura do tipo redes neurais *feedforward* (FNN) com a seguinte arquitetura:

- Camada de entrada: 3348 unidades
- Primeira camada oculta: 50 unidades com função de ativação ReLU
- Segunda camada oculta: 50 unidades com função de ativação ReLU
- Camada de saída: 2 unidades com função softmax

A arquitetura do modelo pode ser visualizada na figura 68:

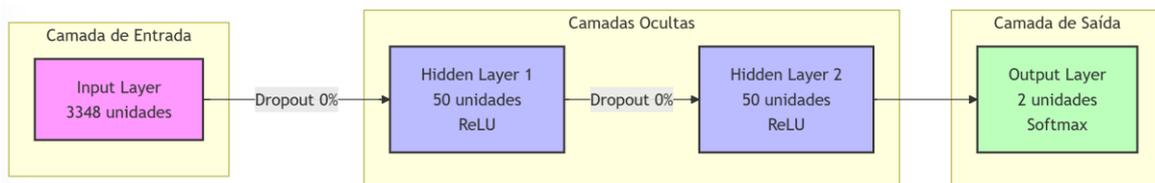


Figura 68: Arquitetura do modelo I (Fonte: Própria).

O modelo apresentou os seguintes resultados de performance:

Métrica	Valor
Erro Quadrático Médio (MSE)	0,0183
Raiz do Erro Quadrático Médio (RMSE)	0,1354
R^2	0,8961
AUC	0,9963
PR AUC	0,9989
<i>Log Loss</i>	0,0677
Erro Médio por Classe	0,0307

Tabela 36: Resultados modelo I (Fonte: Própria).

O Erro Quadrático Médio (*Mean Squared Error*, MSE) é uma métrica de desempenho que calcula a média das diferenças ao quadrado entre os valores reais e os previstos, penalizando mais os erros grandes [158]. A Raiz do Erro Quadrático Médio (*Root Mean Squared Error*, RMSE) é a raiz quadrada do MSE, representando os erros na mesma escala dos dados originais [170]. O R^2 (Coeficiente de Determinação) avalia a proporção da variância explicada pelo modelo em relação aos dados reais, indicando a qualidade do ajuste do modelo [171]. A AUC (Área sob a Curva ROC) mede a capacidade de um modelo de classificar corretamente as classes [156]. PR AUC (*Precision-Recall Area Under the Curve*) foca na avaliação de modelos em conjuntos de dados desbalanceados, destacando a relação entre precisão e *recall* [172]. O *Log Loss* mede a perda logarítmica em classificações, penalizando previsões confiantes, mas incorretas, tornando-se essencial para modelos probabilísticos [152]. Por fim, o Erro Médio por Classe calcula o erro separadamente para cada classe e depois faz a média, sendo especialmente relevante para problemas com classes desbalanceadas [173].

5.4.3. Otimização de hiperparâmetros

A otimização de hiperparâmetros, ou *Hyperparameter Tuning*, é o processo de ajuste dos parâmetros que não são aprendidos diretamente durante o treinamento do modelo, mas que influenciam de forma significativa o desempenho do mesmo [158]. Esses hiperparâmetros incluem, entre outros, a taxa de aprendizado (*learning rate*), o número de camadas ocultas, o número de neurônios em cada camada e a função de ativação utilizada.

Escolhas inadequadas de hiperparâmetros podem resultar em redes neurais que não convergem ou que apresentam desempenho subótimo [174]. A otimização de hiperparâmetros, portanto, é crucial para maximizar o desempenho do modelo e evitar problemas como *overfitting* ou *underfitting*.

Inicialmente, no caso em voga, os hiperparâmetros foram automatizados pelo software *Altair® AI Studio*. Com base nos resultados preliminares e visando aprimorar o desempenho do modelo, foi proposta uma nova arquitetura com modificações estruturais significativas. O modelo de produção otimizado é apresentado no apêndice II e representado graficamente na figura 69:

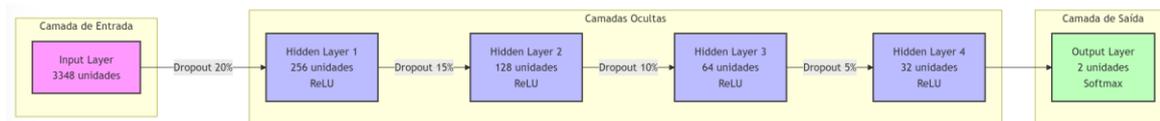


Figura 69: Arquitetura do modelo otimizado (Fonte: Própria).

O modelo original apresenta uma arquitetura mais simples com duas camadas ocultas de 50 unidades cada, seguindo o princípio de simplicidade arquitetural [157]. A versão otimizada implementa uma estrutura mais profunda com quatro camadas ocultas. A configuração de neurônios por camada oculta (256→128→64→32) foi projetada seguindo o princípio de redução progressiva, onde cada camada subsequente possui metade dos neurônios da camada anterior. Essa abordagem de dimensionamento permite que a rede aprenda representações mais complexas nas camadas iniciais e gradualmente as refine em representações mais abstratas [175]. A primeira camada com 256 neurônios permite uma rica extração de características iniciais, enquanto as reduções subsequentes para 128, 64 e 32 neurônios permitem o refinamento progressivo dessas características em representações mais compactas e significativas [176]. Essa proporção ajuda a manter um equilíbrio entre a capacidade de representação do modelo e o risco de *overfitting*.

Outro aspecto do modelo otimizado é a implementação do *dropout*, uma técnica de regularização que consiste em desativar aleatoriamente uma proporção específica de neurônios durante o treinamento [177]. No modelo otimizado, as taxas de *dropout* foram configuradas de forma decrescente (20%, 15%, 10%, 5%) ao longo das camadas, uma estratégia que visa reduzir a dependência entre os neurônios e melhorar a capacidade de generalização da rede [167].

O *dropout* funciona como uma técnica que simula o treinamento simultâneo de várias versões diferentes da rede neural [178], onde cada iteração de treinamento treina uma sub-rede diferente, melhorando a robustez do modelo e reduzindo o *overfitting*. A redução gradual nas taxas de *dropout* (de 20% na primeira camada até 5% na última) se alinha com a intuição de que as características de alto nível nas camadas mais profundas são mais especializadas e, portanto, requerem menos regularização [179].

Característica	Modelo 1	Modelo 2 (Otimizado)
Camadas Ocultas	2	4
Unidades por Camada	[50, 50]	[256, 128, 64, 32]
Função de Ativação	ReLU	ReLU com <i>Dropout</i>
<i>Dropout</i>	Não utiliza	[20%, 15%, 10%, 5%]
Total de Parâmetros	170.102	900.642

Tabela 37: Comparação entre modelos (Fonte: Própria).

O modelo otimizado, apesar de sua maior complexidade, manteve métricas muito próximas ao modelo base, como pode ser observado na tabela 38.

Métrica	Valor	Δ em relação ao modelo I
Erro Quadrático Médio (MSE)	0,0189	0,00059
Raiz do Erro Quadrático Médio (RMSE)	0,1375	0,00218
R^2	0,8927	-0,00337
AUC	0,9953	-0,00101
PR AUC	0,9985	-0,00031
<i>Log Loss</i>	0,0708	0,00313
Erro Médio por Classe	0,0364	0,0057

Tabela 38: Resultados modelo II (Fonte: Própria).

Ao se comparar as métricas de desempenho, apresentadas na tabela 39, o modelo otimizado demonstrou melhorias em grandes partes das métricas avaliadas, com destaque para o aumento na especificidade. Este ganho é particularmente relevante em aplicações onde falsos positivos têm um alto custo [180].

	Modelo 1	Modelo 2 (Otimizado)
Acurácia	93,51%	94,79%
Erro de Classificação	6,49%	5,21%
AUC	98,46%	98,90%
<i>Precision</i>	92,63%	94,47%
<i>Recall</i>	99,52%	99,05%
<i>F Measure</i>	95,95%	96,70%
Especificidade	73,05%	80,34%

Tabela 39: Comparação entre métricas de desempenho (Fonte: Própria).

Entretanto, o modelo otimizado apresentou maior complexidade computacional (900.642 parâmetros versus 170.102 do modelo base), o que resultou em um maior tempo de treinamento (1min 12s versus 30s), uma menor velocidade de processamento (678 obs/s versus 1577 obs/s) e um tamanho de modelo maior (10.3 MB versus 2.0 MB)

De acordo com [169], a arquitetura mais profunda do modelo otimizado permite aprender hierarquias mais complexas de features, embora com custo computacional mais elevado. A escolha entre eles deve considerar o trade-off entre performance e recursos computacionais disponíveis [157]. Este trabalho irá considerar o modelo otimizado.

5.4.4. Matriz de confusão

	true Em Andamento	true Obra Comprometida	class precision
pred. Em Andamento	200	8	96.15%
pred. Obra Comprometida	49	837	94.47%
class recall	80.32%	99.05%	

Figura 70: Matriz de confusão (Fonte: Própria).

A matriz de confusão é uma importante ferramenta para avaliar o desempenho de modelos de classificação, apresentando uma tabulação cruzada entre as classes

previstas e as classes reais [156]. No contexto deste estudo, a matriz de confusão apresentada na figura 70 demonstra:

- Verdadeiros Positivos (VP): 837 obras foram corretamente classificadas como comprometidas, o que representa o sucesso do modelo em identificar obras problemáticas.
- Falsos Positivos (FP): 49 obras em andamento foram incorretamente classificadas como comprometidas, também conhecido como Erro Tipo I.
- Verdadeiros Negativos (VN): 200 obras foram corretamente classificadas como em andamento, o que indica a capacidade do modelo em reconhecer obras saudáveis.
- Falsos Negativos (FN): 8 obras comprometidas foram incorretamente classificadas como em andamento, também conhecido como Erro Tipo II.

A matriz demonstra um excelente desempenho do modelo na identificação de obras comprometidas, com uma precisão de 94,47% para esta classe. Esse resultado é particularmente relevante considerando que, no contexto de gestão pública, falsos positivos (obras em andamento classificadas erroneamente como comprometidas) são preferíveis a falsos negativos, pois permitem ações preventivas.

5.4.5. Peso das variáveis

A análise dos pesos das variáveis, apresentada na figura 71, revela a importância relativa de cada atributo no processo decisório do modelo. Essa análise é crucial para entender quais fatores têm maior influência nas previsões do modelo [181].

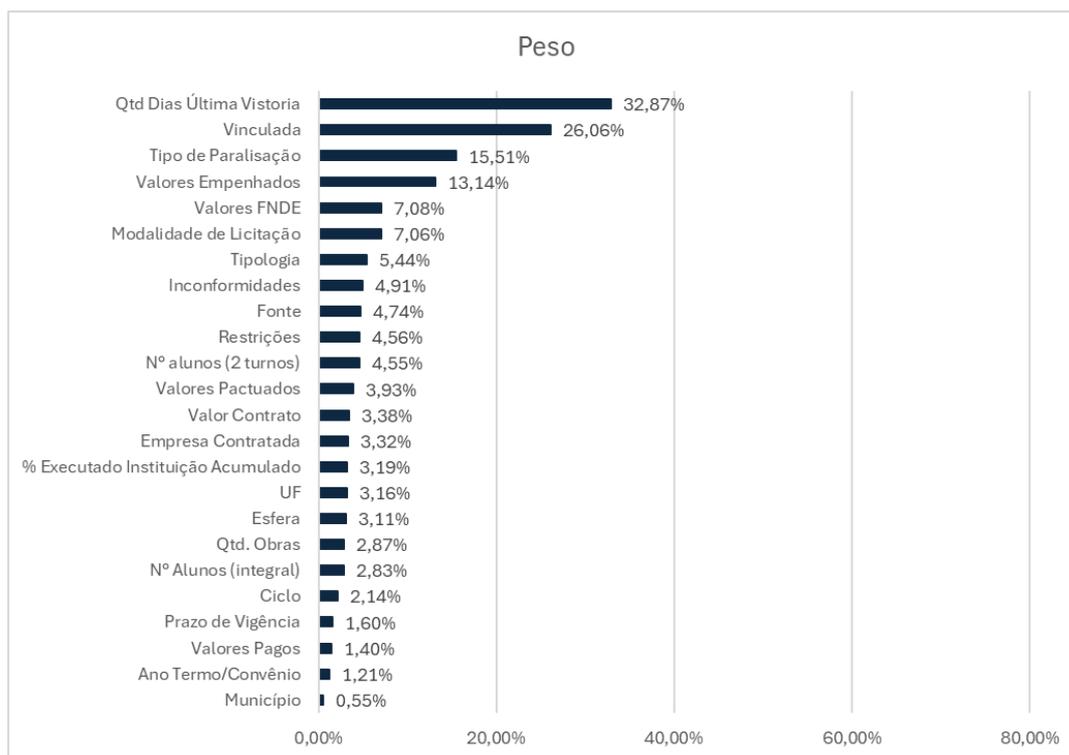


Figura 71: Peso das variáveis (Fonte: Própria).

Os cinco atributos com maior peso são: “Quantidade de Dias desde a Última Vistoria” (32,87%), “Vinculada” (26,06%), “Tipo de Paralisação” (15,51%), “Valores Empenhados” (13,14%) e “Valores FNDE” (7,08%).

A predominância da variável "Quantidade de Dias desde a Última Vistoria" (32,87%) indica que o monitoramento regular das obras é um fator crítico para seu sucesso. O resultado corrobora com a literatura que enfatiza a importância do acompanhamento contínuo em obras públicas como meio de acelerar as entregas dos projetos de infraestruturas [182].

O expressivo peso desta variável pode ser atribuído a diversos fatores. Primeiramente, longos períodos sem vistoria podem mascarar problemas emergentes que, se identificados precocemente, seriam mais facilmente solucionáveis [183]. Adicionalmente, a ausência de vistorias regulares pode indicar falhas nos processos de gestão e fiscalização, frequentemente associadas a desvios de cronograma e qualidade.

A variável "Vinculada" (26,06%), que emerge como o segundo fator mais influente no modelo, representa situações em que uma nova empresa é contratada para dar continuidade a uma obra anteriormente abandonada ou paralisada. O alto peso dessa variável sugere que obras retomadas por novas construtoras apresentam maior probabilidade de enfrentar dificuldades adicionais.

A significativa influência desta variável pode ser explicada por múltiplos fatores. Primeiro, obras vinculadas podem herdar problemas técnicos e estruturais da execução anterior, o que pode gerar complexidades não previstas no novo contrato. Além disso, a necessidade de realizar um novo processo licitatório e a transição entre empresas frequentemente resulta em atrasos significativos e possíveis divergências na interpretação dos projetos originais [184].

5.4.6. *Lift chart*

Com o intuito de fornecer uma representação clara e intuitiva da eficácia do modelo em termos práticos e operacionais, foi criado um *lift chart*, ou gráfico de elevação, apresentado na figura 72. Essa é uma ferramenta visual que demonstra a eficácia do modelo em identificar casos positivos em comparação com uma seleção aleatória [185]. O gráfico apresenta duas métricas principais: “*Cumulative Coverage of Obra Comprometida*” (linha), que representa a porcentagem acumulada de obras comprometidas identificadas corretamente, e “*Correct in Confidence Segment*” (barras), que indica a precisão do modelo em cada segmento da população.

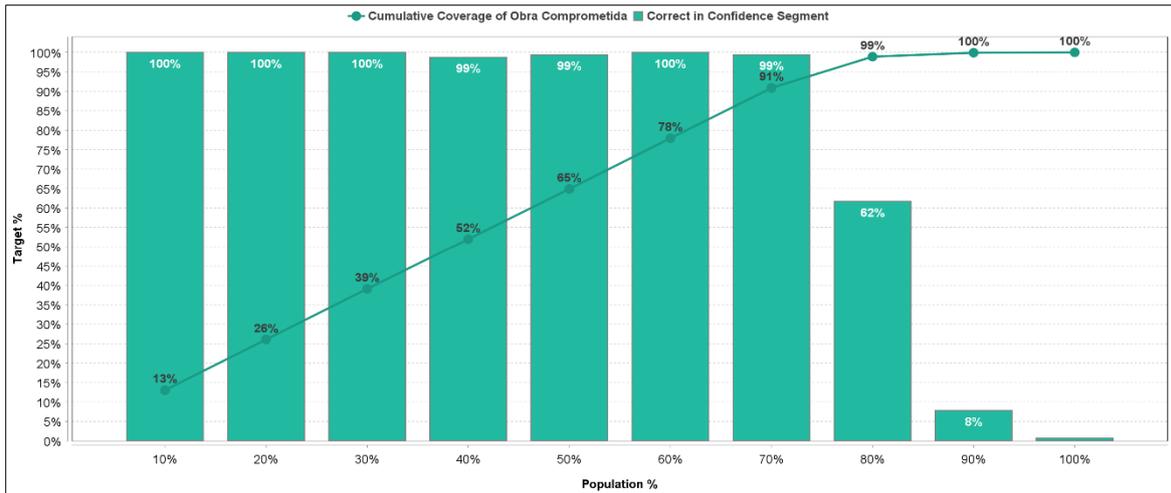


Figura 72: *Lift Chart* (Fonte: Própria).

Um *lift chart* ideal apresenta uma curva fortemente ascendente no início, indicando que o modelo é capaz de identificar uma grande proporção de casos positivos analisando uma pequena fração da população [186]. O gráfico apresentado demonstra exatamente esse comportamento, com uma curva acentuada nos primeiros segmentos.

A análise do *lift chart* revela que, nos primeiros 10% da população, o modelo é capaz de identificar 13% das obras comprometidas com 100% de precisão. Ao expandir a avaliação para 50% da população, o modelo captura 65% das obras comprometidas, mantendo uma precisão de 99%. Já ao considerar 80% da população, o modelo identifica 99% das obras comprometidas, demonstrando sua eficácia na classificação desses casos.

O excelente desempenho indica que o modelo é altamente eficiente em priorizar a inspeção de obras com maior probabilidade de comprometimento. A capacidade de identificar precocemente 65% das obras comprometidas analisando apenas metade da população representa uma significativa otimização dos recursos de fiscalização.

5.5. Etapa 6 do CRISP-DM - Implantação

A etapa de implantação (*Deployment*) constitui a fase final do modelo CRISP-DM, representando o momento crucial em que os conhecimentos e modelos desenvolvidos são efetivamente integrados ao ambiente operacional da organização.

Nesta fase, o objetivo principal é criar uma solução que seja não apenas tecnicamente validada, mas também utilizável, garantindo que os insights extraídos durante as etapas anteriores de análise sejam transformados em ações concretas que agreguem valor real para o negócio.

5.5.1. Simulador preditivo de obras

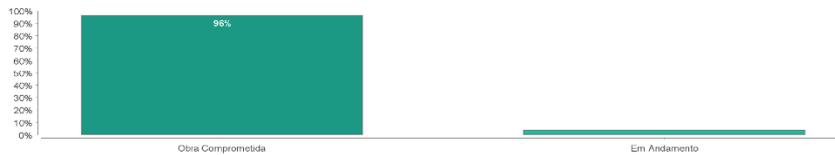
A criação de um simulador permite que os gestores realizem análises preditivas em tempo real para avaliar o risco de comprometimento de obras com base nas variáveis mais significativas identificadas pelo modelo de *Deep Learning*. O simulador, desenvolvido com o auxílio do software *Altair® AI Studio*, é uma ferramenta interativa que permite ao usuário explorar e compreender como diferentes variáveis influenciam a probabilidade de uma obra ser classificada como comprometida. Essa funcionalidade é especialmente relevante no contexto do FNDE, onde a previsão de riscos e a alocação eficiente de recursos são fatores determinantes para a continuidade das obras educacionais. A ferramenta incorpora os pesos das variáveis mais relevantes, como identificado na análise anterior, possibilitando uma avaliação dinâmica do risco.

A figura 73 apresenta um exemplo de uso do simulador.

Deep Learning - Simulator

% Executado Instituição Acumulado:	<input type="text" value="0.286"/>	<input type="text" value="0.286"/>	<input type="text" value="0.286"/>
Ano Termo/Convênio:	<input type="text" value="2012.882"/>	<input type="text" value="2012.882"/>	<input type="text" value="2012.882"/>
Ciclo:	PAR 2		
Empresa Contratada:	(111228198) CONSTRUMOREIRA LTDA		
Esfera:	Municipal		
Fonte:	PAC2		
Inconformidades:	NÃO		
Modalidade do Licitação:	Concorrência		
Município:	Fortaleza		
Nº Alunos (integral):	<input type="text" value="119.154"/>	<input type="text" value="119.154"/>	<input type="text" value="119.154"/>
Nº alunos (2 turnos):	<input type="text" value="238.307"/>	<input type="text" value="238.307"/>	<input type="text" value="238.307"/>
Prazo de Vigência:	<input type="text" value="480.539"/>	<input type="text" value="480.539"/>	<input type="text" value="480.539"/>
Qtd Dias Última Vistoria:	<input type="text" value="948.150"/>	<input type="text" value="948.150"/>	<input type="text" value="948.150"/>
Qtd. Obras:	<input type="text" value="4.859"/>	<input type="text" value="4.859"/>	<input type="text" value="4.859"/>
Restrições:	NÃO		
Tipo de Paralisação:	Abandono da empresa		
Tipologia:	Projeto 1 Convencional		
UF:	MG		
Valor Contrato:	<input type="text" value="1430788.723"/>	<input type="text" value="1430788.723"/>	<input type="text" value="1430788.723"/>
Valores Empenhados:	<input type="text" value="2021028.818"/>	<input type="text" value="2021028.818"/>	<input type="text" value="2021028.818"/>
Valores FNDE:	<input type="text" value="1461687.203"/>	<input type="text" value="1461687.203"/>	<input type="text" value="1461687.203"/>
Valores Pactuados:	<input type="text" value="1407831.569"/>	<input type="text" value="1407831.569"/>	<input type="text" value="1407831.569"/>
Valores Pagos:	<input type="text" value="332172.895"/>	<input type="text" value="332172.895"/>	<input type="text" value="332172.895"/>
Vinculada:	NÃO		

Most Likely: Obra Comprometida



Important Factors for Obra Comprometida

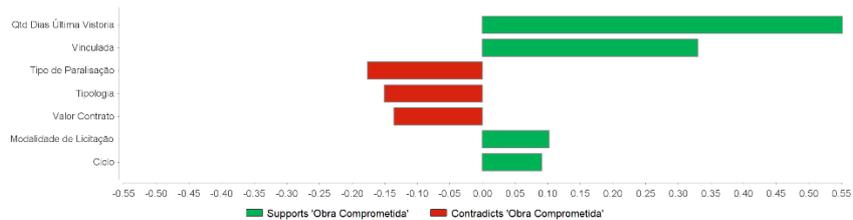


Figura 73: Simulador (Fonte: Própria. Extraída de Altair® AI Studio).

A implementação do simulador na rotina de monitoramento do Fundo Nacional de Desenvolvimento da Educação (FNDE) pode trazer benefícios significativos para a gestão preventiva de obras como a realização de avaliações preliminares de risco antes das vistorias in loco, a identificação precoce de obras que necessitam de atenção especial, a otimização da alocação de recursos de fiscalização, a possibilidade de se realizar testes em diferentes cenários e verificar as implicações.

A arquitetura do simulador foi projetada para proporcionar uma experiência interativa e dinâmica de análise de riscos. Sua concepção permite ao usuário manipular variáveis preditivas com grande flexibilidade, gerando estimativas instantâneas sobre potenciais comprometimentos de projetos educacionais.

A entrada paramétrica do simulador possibilita ajustes precisos em variáveis críticas, como quantidade de dias desde a última vistoria, valores empenhados e tipologia de paralisação. Cada modificação nos parâmetros aciona imediatamente o modelo preditivo, gerando projeções de risco em tempo real com alta granularidade.

Um aspecto importante do simulador é a capacidade de visualização probabilística. Diferentemente de ferramentas tradicionais que apresentam resultados binários, esta solução fornece representações gráficas detalhadas das estimativas de risco, permitindo a compreensão das potenciais vulnerabilidades de cada projeto.

A análise de sensibilidade constitui outro recurso diferencial. O simulador demonstra matematicamente como modificações em parâmetros específicos impactam a probabilidade de paralisação, oferecendo aos gestores uma compreensão profunda da influência de cada variável no modelo preditivo.

5.5.2. Implementação do simulador no processo de monitoramento de obras

Após análise do mapeamento do processo de monitoramento de obras (Anexo I), se sugere implementar o uso do simulador na etapa de "Acompanhar Evolução da Obra". Essa abordagem estratégica permitirá uma avaliação antecipada de potenciais riscos, possibilitando a simulação de múltiplos cenários antes da tomada de decisões críticas.

A utilização da ferramenta possibilitará o direcionamento mais eficiente de recursos de fiscalização e permitirá uma alocação inteligente e baseada em dados, direcionando esforços para projetos com maior probabilidade de apresentarem irregularidades. Os gestores poderão antecipar problemas potenciais, estabelecer estratégias preventivas e mitigar riscos antes que estes se concretizem.

A utilização sistemática do simulador, que pode contribuir significativamente para a redução do número de obras paralisadas, através da identificação precoce de riscos e da implementação tempestiva de medidas preventivas, deve ser utilizado como uma ferramenta de suporte à decisão, não como substituto do julgamento técnico dos profissionais envolvidos.

5.6. Síntese dos principais resultados e implicações

Conclui-se que os resultados obtidos demonstraram a utilidade e viabilidade do uso de modelos de Machine Learning para prever a paralisação de obras. Os modelos testados apresentaram performances elevadas, destacando-se o modelo baseado em *Deep Learning*, que alcançou uma acurácia superior a 94% e um erro de classificação inferior a 6%. Outras métricas como AUC, precisão, *recall*, *F Measure* e especificidade também apresentaram alto desempenho.

A análise possibilitou identificar variáveis-chave que exercem influência direta na paralisação das obras, destacando a importância de determinados atributos na

previsão dos riscos. Entre essas variáveis, os cinco atributos que apresentaram maior peso no modelo preditivo foram a quantidade de dias desde a última vistoria, a condição de a obra ser ou não vinculada, o tipo de paralisação identificado, os valores empenhados no projeto e os valores disponibilizados pelo FNDE, com pesos relativos de 32,87%, 26,06%, 15,51%, 13,14% e 7,08%, respectivamente. Esses resultados indicam que a regularidade das vistorias, o histórico operacional da obra, a classificação da paralisação e o volume de recursos empenhados e repassados desempenham papéis centrais na dinâmica das paralisações.

O elevado peso atribuído à variável “Quantidade de Dias desde a Última Vistoria”, que corresponde a 32,87%, reforça a necessidade de estabelecer cronogramas rigorosos de vistoria, implementar protocolos padronizados de inspeção, desenvolver sistemas de alerta para identificar obras que não passaram por vistorias recentes e promover a capacitação contínua das equipes de fiscalização. Tais medidas estão em consonância com as diretrizes do Instituto Brasileiro de Auditoria de Obras Públicas [187], que estabelece a regularidade das vistorias como elemento fundamental para garantir a execução adequada de obras públicas e prevenir problemas futuros.

Ademais, o peso expressivo da variável "Vinculada", que representa 26,06% do modelo, indica que para obras nessa situação é necessário realizar uma avaliação criteriosa das condições da obra antes da realização de novas contratações, documentar detalhadamente o estado atual da construção, revisar os projetos e estabelecer protocolos específicos de acompanhamento. A importância de controles mais rigorosos em obras vinculadas se dá em virtude da maior complexidade de gestão associada a elas.

A criação do simulador preditivo demonstrou potencial significativo para otimizar o monitoramento de obras educacionais. Por meio dessa ferramenta, é possível a realização de simulações de cenários de risco com o intuito de alocar de maneira mais eficiente recursos destinados à fiscalização e acompanhamento das construções, possibilitando uma abordagem mais proativa por parte dos órgãos

competentes. O simulador é uma aplicação prática desta pesquisa, permitindo que gestores tomem decisões fundamentadas e adotem medidas preventivas antes que as obras alcancem um estado crítico de paralisação.

Capítulo 6

Considerações Finais

O presente estudo teve como foco a problemática da paralisação de obras públicas educacionais no Brasil, com ênfase nas construções do programa Proinfância. A alta taxa de paralisação dessas obras compromete o acesso à educação infantil e gera desperdício de recursos públicos. O objetivo central foi desenvolver um modelo preditivo baseado em *machine learning*, utilizando a metodologia CRISP-DM, para antecipar riscos de paralisação e auxiliar gestores na tomada de decisões preventivas.

Ao longo da pesquisa, buscou-se compreender os principais fatores que influenciam a paralisação das obras educacionais, analisando as bases de dados do FNDE e suas correlações com os fatores de risco identificados. Para isso, foi desenvolvido um modelo preditivo capaz de classificar obras com alta probabilidade de paralisação. A pesquisa também se dedicou à proposição de estratégias voltadas à implementação do modelo elaborado, de modo a contribuir para um processo decisório mais eficaz por parte dos gestores públicos responsáveis pela infraestrutura educacional no país.

Para atingir o objetivo geral do estudo, foi necessário realizar a identificação dos riscos associados a obras públicas, compreender o processo de monitoramento de obras do FNDE, determinar os fatores que implicam na paralisação de obras do programa Proinfância, elaboração de uma estratégia sugerida para implementação

do modelo preditivo na rotina do FNDE. Com isso, todos os objetivos específicos propostos inicialmente foram alcançados.

A pesquisa trouxe contribuições inovadoras para o campo das políticas públicas educacionais, ao integrar metodologias avançadas de análise preditiva na gestão de infraestrutura escolar. A utilização do framework CRISP-DM estruturou a aplicação de técnicas de *machine learning*, garantindo reprodutibilidade e padronização na análise de riscos.

6.1. Limitações da pesquisa

Apesar das contribuições significativas deste estudo, algumas limitações devem ser mencionadas. A qualidade e disponibilidade dos dados constituíram desafios relevantes ao longo da pesquisa, pois algumas informações essenciais para a previsão dos riscos de paralisação não estavam devidamente padronizadas nas bases de dados do FNDE.

Além disso, a implementação do modelo preditivo desenvolvido ainda necessita de testes em ambientes operacionais reais, de modo que sua efetividade possa ser validada ao longo do tempo, considerando diferentes contextos administrativos e financeiros. Outra limitação observada diz respeito ao escopo da pesquisa, que se concentrou em um conjunto específico de obras educacionais vinculadas ao programa Proinfância. Estudos futuros podem expandir essa abordagem para incluir outras tipologias de infraestrutura pública, permitindo uma avaliação mais ampla do impacto do modelo proposto.

6.2. Recomendações

A partir dos resultados obtidos, algumas recomendações práticas podem ser delineadas para aprimorar a gestão de obras educacionais pelo FNDE. A implementação do simulador preditivo desenvolvido ao longo deste estudo representa

uma medida importante para otimizar o monitoramento das construções, permitindo a identificação precoce de riscos e a adoção de estratégias de mitigação eficazes.

É importante ressaltar que a interpretação criteriosa dos resultados por parte dos gestores permanece indispensável. O simulador deve ser compreendido como uma ferramenta de suporte, não como um substituto da expertise de profissionais especializados. Apesar de seu potencial transformador, o simulador requer atenção contínua. A alimentação permanente com dados atualizados é fundamental para manter sua precisão preditiva. Se recomenda uma manutenção periódica do modelo, incorporando novas informações e refinando os algoritmos.

A convergência entre inteligência artificial, análise de dados e conhecimento especializado se materializa nesta solução, simbolizando um avanço na administração pública brasileira. Os achados do estudo oferecem subsídios para os gestores públicos e tomadores de decisão, tornando possível a adoção de medidas preventivas voltadas à redução da incidência de paralisações em obras educacionais. A pesquisa também reforça a relevância da digitalização e do uso de dados na administração pública, ampliando as perspectivas para o aprimoramento contínuo dos processos de monitoramento e gestão da infraestrutura educacional no país.

Outra iniciativa que pode contribuir para o aperfeiçoamento da gestão das obras educacionais é a padronização dos dados registrados pelo FNDE, garantindo maior uniformidade e confiabilidade nas informações disponíveis. A adoção de mecanismos de aprimoramento contínuo para a base de dados permitirá que modelos preditivos sejam constantemente refinados, aumentando sua precisão e utilidade para os gestores públicos.

Além disso, a capacitação dos gestores e profissionais envolvidos na administração das obras se apresenta como um fator essencial para potencializar os benefícios das soluções tecnológicas desenvolvidas. A formação de equipes especializadas na interpretação e utilização de modelos preditivos pode ampliar a

eficiência da gestão pública, tornando os processos decisórios mais ágeis e embasados em dados.

Mediante o peso encontrado da variável “Vinculada”, sugere-se aprofundar estudos acerca dos desafios na retomada de obras públicas paralisadas.

Por fim, este estudo abre espaço para a realização de pesquisas futuras que explorem a utilização de técnicas de explicabilidade de modelos (XAI) e o emprego de modelos híbridos de previsão de riscos, que combinem duas ou mais técnicas analíticas para aprimorar a capacidade de identificar, quantificar e antecipar riscos em determinados contextos. Essas abordagens podem contribuir para a compreensão mais detalhada dos fatores que levam à paralisação das obras, fazendo com que a adoção de medidas de intervenção seja ainda mais assertiva e fundamentada.

Diante da relevância do tema e do impacto que paralisação de obras possuem na educação básica, esta pesquisa contribui de maneira significativa para o aprimoramento das políticas públicas na área. O uso de *Machine Learning* se mostrou promissor para a gestão proativa dos riscos, abrindo caminho para futuras inovações no monitoramento de projetos educacionais.

Portanto, espera-se que os resultados deste estudo incentivem gestores públicos a adotarem estratégias baseadas em evidências, promovendo maior eficácia na execução de obras e garantindo que os investimentos na educação se traduzam em infraestrutura adequada para as futuras gerações.

Capítulo 7

Referências Bibliográficas

- [1] Brasil, *Constituição (1988)*, Brasília, DF: Presidência da República, [2016], 1988.
- [2] Brasil, “LEI Nº 13.005, DE 25 DE JUNHO DE 2014,” 25 Junho 2014. [Online]. Available: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2014/lei/113005.htm.
- [3] OECD, “Relatórios Econômicos OCDE: Brasil 2018,” 2018.
- [4] OECD, “PISA 2015 Results (Volume I): Excellence and Equity in Education,” OECD Publishing, Paris, 2015.
- [5] OECD, “Low-Performing Students: Why They Fall Behind and How To Help Them Succeed,” OECD Publishing, Paris, 2016.
- [6] L. G. P. Oliveira, “A Inclusão na educação infantil – Unidades do Proinfância,” *Revista Contemporânea de Educação*, vol. 12, nº 25, Dezembro 2017.
- [7] Agência Senado, “Educação busca superar estragos da pandemia,” 08 Abril 2022. [Online]. Available: <https://www12.senado.leg.br/noticias/infomaterias/2022/03/educacao-busca-superar-estragos-da-pandemia>.
- [8] OECD, “Learning Our Lesson: Review of Quality Teaching in Higher Education.,” 2010. [Online]. Available: <https://www.oecd.org/education/imhe/44058352.pdf>.
- [9] K. M. Muqimjonovna, “FACTORS AFFECTING THE QUALITY OF EDUCATION,” em *International Conference on Humanity, Education and Science*, London, 2021.
- [10] C. & C. D. & S. S. & R. F. Pramana, “Strategies to Improved Education Quality in Indonesia: A Review.,” *Turkish Online Journal of Educational Technology*, 2021.
- [11] A. Muthanna e G. Sang, “A Conceptual Model of the Factors Affecting Education Policy Implementation,” *Education Sciences*, 01 Março 2023.
- [12] R. Habeeb e N. Kiazai, “Factors Affecting the Quality Education in Rural Areas of District Kech, Balochistan,” *Pakistan Social Sciences Review*, 22 Maio 2022.
- [13] B. S. Widodo, “The Factors Which Influence the Quality of Education in Undeveloped Area (Multi-Cases Study in 10 Districts in Indonesia),” em *PROSIDING ICTTE FKIP UNS*, 2016.
- [14] J. Teixeira, J. Amoroso e J. Gresham, “Why education infrastructure matters for

- learning,” 03 Outubro 2017. [Online]. Available:
<https://blogs.worldbank.org/education/why-education-infrastructure-matters-learning>.
- [15] P. Barrett, F. Davies, Y. Zhang e L. Barrett, “The Holistic Impact of Classroom Spaces on Learning in Specific Subjects,” *Environment and Behavior*, p. 425–451, 2017.
- [16] P. Barrett, A. Treves, T. Shmis, D. Ambasz e M. Ustinova, *The Impact of School Infrastructure on Learning: A Synthesis of the Evidence*, Washington: International Development in Focus, 2019.
- [17] Brasil, “Ministério da Educação,” 2017. [Online]. Available:
<https://www.gov.br/fnde/pt-br>.
- [18] Brasil, “Ministerio da Educação,” 2017. [Online]. Available:
<https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/proinfancia>.
- [19] Brasil. Controladoria-Geral da União (CGU)., *Portaria n. 57, de 4 de janeiro de 2019*, Brasília, 2019.
- [20] A. M. Mariano e M. S. Rocha, “Revisão da literatura: apresentação de uma abordagem integradora.,” em *Anais XXVI Congresso Internacional AEDEM| 2017 AEDEM International Conference-Economy, Business and Uncertainty: ideas for a European and Mediterranean industrial policy.*, 2017.
- [21] G. Stam, P. Bottelberghs, J. Post e H. Bos, “PROTEUS, a technical and management model for aquatic risk assessment of industrial spills,” *Journal of hazardous materials*, pp. 439-448, 07 Janeiro 2000.
- [22] A. P. Chan, J. F. Yeung, C. C. Yu, S. Q. Wang e Y. Ke, “Empirical study of risk assessment and allocation of public-private partnership projects in China.,” *Journal of management in engineering*, vol. 27, nº 3, pp. 136-148, 2011.
- [23] Y. Ke, S. Wang, A. P. Chan e P. T. Lam, “Preferred risk allocation in China’s public-private partnership (PPP) projects.,” *International Journal of Project Management*, vol. 28, nº 5, pp. 482-492, 2010.
- [24] Y. Ke, S. Wang e A. P. Chan, “Risk allocation in public-private partnership infrastructure projects: comparative study.,” *Journal of infrastructure systems*, vol. 16, nº 4, pp. 343-351, 2010.
- [25] J. Liu, P. E. Love, P. R. Davis, J. Smith e M. Regan, “Conceptual framework for the performance measurement of public-private partnerships.,” *Journal of Infrastructure systems*, vol. 21, nº 1, 2015.
- [26] E. Bracci, M. Tallaki, G. Gobbo e L. Papi, “Risk management in the public sector: a structured literature review,” *International Journal of Public Sector Management*, 2021.
- [27] A. Ansar, B. Flyvbjerg, A. Budzier e D. Lunn, “Should we build more large dams? The actual costs of hydropower megaproject development.,” *Energy policy*, vol. 69, pp. 43-56, 2014.
- [28] A. Ng e M. Loosemore, “Risk allocation in the private provision of public infrastructure.,” *International journal of project management*, vol. 25, nº 1, pp. 66-76, 2007.
- [29] M. C. Wolbers, “Application of risk management in Public Works organisations in Chile.,” *Bachelor's thesis, University of Twente*, 2009.

- [30] L. Bing, A. Akintoye, P. J. Edwards e C. Hardcastle, “The allocation of risk in PPP/PFI construction projects in the UK,” *International Journal of project management*, vol. 23, pp. 25-35, 2005.
- [31] I. Lapsley, “New public management: The cruellest invention of the human spirit?,” *Abacus*, vol. 45, n^o 1, pp. 1-21, 2009.
- [32] N. T. S. Nune, S. C. Mota, A. C. d. A. Cabral e S. M. d. Santos, “The Brazilian scientific production on risk management in the public sector: a bibliometric analysis,” *Revista do Serviço Público*, vol. 71, n^o 4, pp. 887-920, 24 Dezembro 2020.
- [33] H. Mahama, M. Elbashir, S. Sutto e V. Arnold, “Enabling enterprise risk management maturity in public sector organizations,” *Public Money & Management*, pp. 403-407, 2022.
- [34] I. Marshakova, “Citation networks in information science,” *Scientometrics*, vol. 3, n^o 1, pp. 13-25, 1981.
- [35] T. Palermo, “Accountability and expertise in public sector risk management: a case study,” *Financial Accountability & Management*, vol. 30, n^o 3, pp. 322-341, 2014.
- [36] E. Vinnari e P. Skærbæk, “The uncertainties of risk management: A field study on risk management internal audit practices in a Finnish municipality,” *Accounting, Auditing & Accountability Journal*, pp. 489-526, 2014.
- [37] M. Woods, “A contingency theory perspective on the risk management control system within Birmingham City Council,” *Management Accounting Research*, pp. 69-81, 2009.
- [38] M. Power, “The risk management of nothing,” *Accounting, organizations and society*, vol. 34, pp. 849-855, 2009.
- [39] A. Mikes, “From counting risk to making risk count: Boundary-work in risk management,” *Accounting, organizations and society*, pp. 226-245, 2011.
- [40] B. Li e Z. Ren, “Bayesian technique framework for allocating demand risk between the public and private sector in PPP projects,” em *6th International Conference on Service Systems and Service Management*, 2009.
- [41] B. Adam, J. Van Loon e U. Beck, *The risk society and beyond.*, 2000.
- [42] C. Hood, “A public management for all seasons?,” *Public administration*, pp. 3-19, 1991.
- [43] M. M. Kessler, “Bibliographic coupling between scientific papers. American documentation,” *American documentation*, vol. 14, n^o 1, pp. 10-25, 1963.
- [44] F. S. Schäfer, B. Hirsch e C. Nitzl, “Stakeholder pressure as a driver of risk management practices in public administrations,” *Journal of Accounting & Organizational Change*, pp. 33-56, 2022.
- [45] B. Scala e C. F. Lindsay, “Supply chain resilience during pandemic disruption: evidence from healthcare,” *Supply Chain Management: An International Journal*, pp. 672-688, 2021.
- [46] D. Rehak, “Assessing and strengthening organisational resilience in a critical infrastructure system: Case study of the Slovak Republic,” *Safety Science*, vol. 123, 2020.
- [47] A. Räsänen, H. Lein, D. Bird e G. Setten, “Conceptualizing community in disaster risk management,” *International Journal of Disaster Risk Reduction*, vol. 45, 2020.

- [48] P. Murr e N. Carrera, “Institutional logics and risk management practices in government entities: evidence from Saudi Arabia,” *Journal of Accounting & Organizational Chang*, pp. 12-32, 2022.
- [49] IFC World Bank Group, “Who Cares Wins, 2004–08,” 2004.
- [50] United Nations Global Compact, “Who Cares Wins,” Genebra, 2004.
- [51] Pacto Global e Stilingue, “A evolução do ESG no Brasil,” Abril 2021. [Online]. Available:
https://d335luupugsy2.cloudfront.net/cms%2Ffiles%2F150560%2F1619627473Estudo_A_Evoluo_do_ESG_no_Brasil.pdf. [Acesso em 13 Setembro 2023].
- [52] M. Khan, G. Serafeim e A. Yoon, “Corporate Sustainability: First Evidence on Materiality.,” *The Accounting Review*, vol. 91, n^o 6, pp. 1697-1724, 2016.
- [53] PwC, “Asset and wealth management revolution: The power to shape the future.,” 2020.
- [54] Morgan Stanley, “Sustainable Signals: Asset owners see sustainability as core to the future of investing.,” New York, 2020.
- [55] N. Viri e V. Adachi, “Fundos ESG captaram ao menos R\$ 2,5 bi em 2020 no Brasil. O que está por trás do número?,” 29 Janeiro 2021. [Online]. Available:
<https://capitalreset.uol.com.br/financas/investimentos/fundos-esg-captaram-ao-menos-r-25-bi-em-2020-no-brasil-o-que-esta-por-tras-do-numero/>. [Acesso em 23 Setembro 2023].
- [56] M. Noland, T. Moran e B. R. Kotschwar, “Is gender diversity profitable? Evidence from a global survey.,” *Peterson Institute for International Economics Working Paper*, 2016.
- [57] T. D. e. a. Akinosho, “Deep learning in the construction industry: A review of present status and future innovations,” *Journal of Building Engineering*, vol. 32, Novembro 2020.
- [58] S. O. e. a. Abioye, “Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges,” *Journal of Building Engineering*, vol. 44, Dezembro 2021.
- [59] J. Hegde e B. Rokseth, “Applications of machine learning methods for engineering risk assessment – A review,” *Safety Science*, vol. 122, Fevereiro 2020.
- [60] A. Gondia, A. Siam, W. El-Dakhakhni e A. H. Nassar, “Machine learning algorithms for construction projects delay risk prediction,” *Journal of Construction Engineering and Management*, vol. 146, 2020.
- [61] ONG Todos Pela Educação, “O que é uma política pública e como ela afeta sua vida?,” 02 Maio 2020. [Online]. Available:
<https://todospelaeducacao.org.br/noticias/o-que-e-uma-politica-publica-e-como-ela-afeta-sua-vida/>.
- [62] B. L. C. Nascimento, *A Reforma Universitária de 1968: origens, processo e resultados de uma política para o ensino superior*, Rio de Janeiro, 1991.
- [63] J. A. d. Castro e M. G. d. Oliveira, “Políticas públicas e desenvolvimento,” em *MADEIRA, L. M. (Org.). Avaliação de Políticas Públicas.*, Porto Alegre, 2014.
- [64] C. Moro, “Avaliação de contexto e políticas públicas para a educação infantil,” *Laplage em Revista*, vol. 3, Abril 2017.

- [65] J. Mainardes, “Abordagem do ciclo de políticas: uma contribuição para a análise de políticas educacionais,” *Educação & Sociedade*, vol. 27, n^o 94, pp. 47-69, 2006.
- [66] B. Charlot, “A pesquisa educacional entre conhecimentos, políticas e práticas: especificidades e desafios de uma área de saber,” *Revista Brasileira de Educação*, vol. 11, n^o 31, pp. 7-18, 2006.
- [67] C. A. Gomes, “Desserialização escolar: alternativa para o sucesso?,” *Ensaio: Avaliação e Políticas Públicas em Educação*, vol. 13, n^o 46, pp. 11-38, 2005.
- [68] Brasil, “LEI N^o 12.612, DE 13 DE ABRIL DE 2012,” 13 Abril 2012. [Online]. Available: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12612.htm. [Acesso em 13 Março 2024].
- [69] P. Freire, *Pedagogia do oprimido*, Paz & Terra, 1971.
- [70] P. E. A. Salomão, D. P. Pêgo, A. R. Rhis e S. S. F. Coelho, “O impacto econômico e social da paralisação das obras públicas de infraestrutura,” *Research, Society and Development*, vol. 8, n^o 5, pp. 01-13, 2019.
- [71] TCU, “Recomendações Básicas para a Contratação e Fiscalização de Obras de Edificações Públicas,” Brasília, 2014.
- [72] J. Lafortune e D. Schonholzer, “Do school facilities matter? Measuring the effects of capital expenditures on student and neighborhood outcomes,” *Public Policy Institute of California.*, 2018.
- [73] OECD, “Education Policy Outlook Brasil,” Itaú Social, 2021.
- [74] C. Martins e M. M. Barreto, “Public policy early childhood education in Brazil: the implementation of Proinfância,” *Revista Sapiência: Sociedade, Saberes e Práticas Educacionais.*, 2017.
- [75] ONG Todos pela Educação, “Brasil Carinhoso,” 2016. [Online]. Available: https://www.todospelaeducacao.org.br/primeirainfancia/pais_brasil.html. [Acesso em 23 Abril 2023].
- [76] Brasil, “Fundo Nacional de Desenvolvimento da Educação (FNDE),” 2017. [Online]. Available: <https://www.gov.br/fnde/pt-br>. [Acesso em 23 Abril 2023].
- [77] Brasil, “Pacto Nacional pela Retomada de Obras da Educação Básica,” 24 Agosto 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/par/pacto-nacional-pela-retomada-de-obras-da-educacao-basica/pacto-nacional-pela-retomada-de-obras-da-educacao-basica>. [Acesso em 4 Setembro 2023].
- [78] Brasil, *Portaria Conjunta MEC/MGI/CGU n^o 82, de 10 de julho de 2023.*, 2023.
- [79] C. Milhomem, “A gestão de riscos do Programa Nacional de Reestruturação e Aquisição de Equipamentos para a Rede Escolar Pública de Educação Infantil–Proinfância,” *UnB*, 2020.
- [80] Brasil, “RESOLUÇÃO/CD/FNDE N^o 006 DE 24 DE ABRIL DE 2007,” 24 Abril 2007. [Online]. Available: http://portal.mec.gov.br/arquivos/pdf/resolucao_n6_240407_proinfancia_medida18.pdf. [Acesso em 23 Abril 2023].
- [81] Brasil, “Resolução n^o 4, de 04 de maio de 2020,” 22 Março 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/legislacao/resolucoes/2020/resolucao-ndeg-4-de-04-de-maio-de>

- 2020/view#:~:text=Estabelece%20os%20crit%C3%A9rios%20para%20o,Plano%20de%20A%C3%A7%C3%B5es%20Articuladas%20%E2%80%93%20PAR.. [Acesso em 4 Setembro 2023].
- [82] FNDE/DIGAP, “Manual de Orientações Técnicas Volume 02 - Elaboração de Projetos de Edificações Escolares: Educação Infantil,” Brasília - DF, 2017.
- [83] FNDE/CGEST, “Memorial Descritivo - Projeto Proinfância I,” 2017.
- [84] Brasil, “Creche Pré-Escola – Tipo 1,” 3 Abril 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/proinfancia/projetos-arquiteticos-para-construcao/projeto-tipo-1>. [Acesso em 4 Setembro 2023].
- [85] Brasil, “Creche Pré-Escola – Tipo 2,” 3 Abril 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/proinfancia/projetos-arquiteticos-para-construcao/projeto-tipo-2>. [Acesso em 4 Setembro 2023].
- [86] Brasil, “Ampliação Módulo Infantil em Escolas,” 3 Abril 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/proinfancia/projetos-arquiteticos-para-construcao/modulo-de-educacao-infantil-1>. [Acesso em 4 Setembro 2023].
- [87] J. Bezerra, “Lei das Doze Tábuas,” [Online]. Available: <https://www.todamateria.com.br/lei-das-doze-tabuas/#:~:text=Determinava%20a%20proibi%C3%A7%C3%A3o%20do%20casamento,Lei%20Canuleia%2C%20em%20445%20a.C.> [Acesso em 4 Setembro 2023].
- [88] J. R. Goldim, “Risco,” 21 Setembro 2001. [Online]. Available: <https://www.ufrgs.br/bioetica/risco.htm#Bernstein>. [Acesso em 4 Setembro 2023].
- [89] M. D. G. Ávila, “Gestão de Riscos no Setor Público,” *Revista controle: doutrina e artigos*, vol. 12, n^o 2, pp. 179-198, Julho/Dezembro 2014.
- [90] P. L. Bernstein, “Bernstein, P. L., & Bernstein, P. L. (1996). Against the gods: The remarkable story of risk (p. 400). New York: Wiley.,” New York, Wiley, 1996, p. 1.
- [91] A. Wildavsky, “No Risk Is the Highest Risk of All: A leading political scientist postulates that an overcautious attitude toward new technological developments may paralyze scientific endeavor and end up leaving us less safe than we were before,” *American Scientist*, vol. 67, n^o 1, pp. 32-37, Janeiro-Fevereiro 1979.
- [92] S. Hill, Guia sobre a Gestão de Riscos no Serviço Público., vol. 30, Brasília: Escola Nacional de Administração Pública (ENAP), 2006.
- [93] Associação Brasileira de Normas Técnicas, “NBR 31000: Gestão de riscos - Princípios e diretrizes,” Rio de Janeiro, 2009.
- [94] Project Management Institute, PMBOK®️, Guia, 6a. ed, 2017.
- [95] P. Bromiley, “Enterprise risk management: Review, critique, and research directions,” *Long range planning*, pp. 265-276, 2015.
- [96] Privy Council Office (PCO), “Risk management for Canada and Canadians: Re-port of the Adm Working Group on Risk Management,” Government of Canada, Ottawa, 2000.
- [97] Brasil, *DECRETO Nº 9.203, DE 22 DE NOVEMBRO DE 2017*, Brasília, 2017.
- [98] A. Boin e M. Lodge, “Designing resilient institutions for transboundary crisis

management: A time for public administration.,” *Public administration*, vol. 94, nº 2, pp. 289-298, 2016.

- [99] D. Osgood, M. McLaurin, M. Carriquiry, A. Mishra, F. Fiondella, J. Hansen, N. Peterson e N. Ward, “Designing Weather Insurance Contracts for Farmers in Malawi, Tanzania and Kenya: Final Report to the Commodity Risk Management Group, ARD, World Bank.,” *International Research Institute for Climate and Society (IRI), Columbia University*, Junho 2007.
- [100] D. Olson e D. Dash Wu, “A review of enterprise risk management in supply chain,” *Emerald.com*, vol. 39, pp. 694-706, 2010.
- [101] Reino Unido (UK). HM Treasury, *Management of Risk - Principles and Concepts - The Orange Book*, 2004.
- [102] Ministério do Planejamento, Orçamento e Gestão - MPOG, “Guia de orientação para o gerenciamento de riscos,” Secretaria de Gestão Pública, Brasília, 2013.
- [103] Tribunal de Contas da União - TCU, “Referencial básico de gestão de riscos,” Secretaria Geral de Controle Externo (Segecex), Brasília, 2018.
- [104] T. H. Z. Rana e K. Jacobs, “Public sector reform implications for performance measurement and risk management practice: insights from Australia,” *Public Money and Management*, pp. 37-45, 2019.
- [105] TCU, “Acompanhamento de Obras Paralisadas,” 2023. [Online]. Available: <https://paineis.tcu.gov.br/pub/?workspaceId=8bfbd0cc-f2cd-4e1c-8cde-6abfdffea6a8&reportId=013930b6-b989-41c3-bf00-085dc65109de>. [Acesso em 5 Setembro 2023].
- [106] TCU, “Auditoria Operacional Sobre Obras Paralisadas,” 2019.
- [107] Brasil, “Programa de Integridade,” 26 Junho 2023. [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/estrategia-governanca>. [Acesso em 11 Setembro 2023].
- [108] Brasil. Fundo Nacional de Desenvolvimento da Educação (FNDE), “Plano de Integridade do Fundo Nacional de Desenvolvimento da Educação (FNDE),” Brasília, 2018.
- [109] MP e CGU, “INSTRUÇÃO NORMATIVA CONJUNTA MP/CGU Nº 1/2016,” 2016. [Online]. Available: <https://repositorio.cgu.gov.br/bitstream/1/33947/8/Instrucao%20Normativa%20Conjunta%20MP-CGU%2001-2016.pdf>.
- [110] K. Dalkir, *Knowledge management in theory and practice.*, Routledge, 2013.
- [111] C. S. C. Jannuzzi, O. M. Falsarella e C. R. Sugahara, “Gestão do conhecimento: um estudo de modelos e sua relação com a inovação nas organizações.,” *Perspectivas em Ciência da Informação*, vol. 21, pp. 97-118, 2016.
- [112] P. V. Campos, I. B. V. I. Coelho, G. A. P. Nepomuceno e M. M. Silva, “Gestão do conhecimento como ferramenta de mapeamento de processo e modernização institucional.,” em *Congresso Consad de Gestão Pública XI*, Brasília, 2016.
- [113] BPM CBOK, *Guia para o Gerenciamento de Processos de Negócio Corpo Comum de Conhecimento*, 1 ed., vol. 3, Association of Business Process Management Professionals (ABPMP), 2013.
- [114] V. D. Hunt, *Process mapping: how to reengineer your business processes.*, New York:

John Wiley & Sons, Inc., 1996.

- [115] C. D. S. S. Villela, “Mapeamento de processos como ferramenta de reestruturação e aprendizado organizacional,” 2000.
- [116] IBM, “What is data science?,” IBM, [Online]. Available: <https://www.ibm.com/topics/data-science>. [Acesso em 24 Outubro 2023].
- [117] D. Donoho, “50 Years of Data Science,” *Journal of Computational and Graphical Statistics*, vol. 26, n^o 4, pp. 745-766, 2017.
- [118] V. Dhar, “Data science and prediction,” *Communications of the ACM*, vol. 56, n^o 12, pp. 64-73, 2013.
- [119] IBM, “What is machine learning?,” IBM, [Online]. Available: <https://www.ibm.com/topics/machine-learning>. [Acesso em 24 outubro 2023].
- [120] S. Brown, “Machine learning, explained,” MIT Sloan School of Management, 21 Abril 2021. [Online]. Available: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>. [Acesso em 24 Outubro 2023].
- [121] B. Mahesh, “Machine learning algorithms-a review,” *International Journal of Science and Research (IJSR)*, vol. 9, n^o 1, pp. 381-386, Janeiro 2020.
- [122] É. Fontana, “Introdução aos algoritmos de aprendizagem supervisionada,” *Departamento de Engenharia Química, Universidade Federal do Paraná.*, 2020.
- [123] T. Escovedo e A. S. Koshiyama, *Introdução a Data Science - Algoritmos de Machine Learning e métodos de análise*, São Paulo: Casa do Código, 2020.
- [124] I. Mierswa, “K-Nearest Neighbors: A Simple Machine Learning Algorithm,” RapidMiner, Maio 2017. [Online]. Available: <https://rapidminer.com/blog/k-nearest-neighbors-laziest-machine-learning-technique/>. [Acesso em 26 Outubro 2023].
- [125] Thatware, “Naive Bayes,” Thatware, [Online]. Available: <https://thatware.co/wp-content/uploads/2020/04/naive-bayes.png>. [Acesso em 26 Outubro 2023].
- [126] S. Dreiseitl e L. Ohno-Machado, “Logistic regression and artificial neural network classification models: a methodology review,” *Journal of biomedical informatics*, vol. 35, pp. 352-359, 2002.
- [127] “Regressão Logística - Algoritmos de Aprendizado de Máquinas,” Hashtag Treinamentos, Dezembro 2022. [Online]. Available: <https://www.hashtagtreinamentos.com/regressao-logistica-ciencias-dados>. [Acesso em 26 Outubro 2023].
- [128] C. A. R. Pacheco e N. S. Pereira, “Deep learning conceitos e utilização nas diversas Áreas do conhecimento,” *Revista Ada Lovelace*, vol. 2, pp. 34-49, 2018.
- [129] C. C. Prodanov e E. C. De Freitas, *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico*, 2^a ed., Feevale, 2013.
- [130] J. C. Köche, *Fundamentos de metodologia científica: teoria da ciência e iniciação à pesquisa.*, Petrópolis, RJ: Vozes, 2011.
- [131] T. E. Gerhardt e D. T. Silveira, *Métodos de pesquisa.*, Porto Alegre: UFRGS, 2009.
- [132] A. C. Gil, *Métodos e técnicas de pesquisa social.*, 6^a ed., São Paulo: Atlas, 2008.
- [133] J. J. S. da Fonseca, *Metodologia da pesquisa científica.*, Fortaleza: Apostila, 2002.
- [134] RapidMiner, “RapidMiner,” [Online]. Available: <https://rapidminer.com/>. [Acesso em 24 Outubro 2023].

- [135] M. Hofmann e R. Klinkenberg, *RapidMiner: Data mining use cases and business analytics applications.*, CRC Press, 2013.
- [136] Altair Engineering Inc., “Altair was Named A Leader in the June 2024 Gartner® Magic Quadrant™ for Data Science and Machine Learning Platforms,” Altair Engineering Inc., 2024. [Online]. Available: https://web.altair.com/gartner-magic-quadrant-for-data-science-and-machine-learning-platforms-2024?utm_source=&utm_medium=&utm_campaign=&utm_content=&utm_term=&_gl=1*b56uy5*_gcl_au*MTY3MDA5MTU5MC4xNzI2ODU3Njc0LjE0NzgzNDYwODUuMTcyNjg2MDE1NC4xNzI2ODYwMTkz. [Acesso em 20 Setembro 2024].
- [137] Gartner, Inc., “Gartner Magic Quadrant for Data Science and Machine Learning Platforms,” 2024.
- [138] Altair Engineering Inc., “Altair® AI Studio,” Altair Engineering Inc., 2024. [Online]. Available: <https://altair.com/altair-ai-studio>. [Acesso em 20 Setembro 2024].
- [139] C. Schröer, F. Kruse e J. M. Gómez, “A systematic literature review on applying CRISP-DM process model,” *Procedia Computer Science*, vol. 181, pp. 526-534, 2021.
- [140] J. H. N. W. D. Saltz e K. Stirling, “Exploring project management methodologies used within data science teams,” em *24th Americas Conference on Information Systems: Digital Disruption, AMCIS 2018.*, New Orleans, LA, USA, 2018.
- [141] S. Lahiri e J. Saltz, “Evaluating Data Science Project Agility by Exploring Process Frameworks Used by Data Science Teams,” em *56th Hawaii International Conference on System Sciences*, Hawaii , 2023.
- [142] R. Wirth e J. Hipp, “CRISP-DM: Towards a standard process model for data mining,” em *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining.*, Manchester, UK., 2000.
- [143] P. Chapman, J. Clinton, R. Kerber, T. Khabaza, T. Reinartz, C. Shearer e R. Wirth, *CRISP-DM 1.0*, SPSS, 1999.
- [144] C. Shearer, “The CRISP-DM Model: The New Blueprint for Data Mining,” *Journal of Data Warehousing*, vol. 5, n^o 4, pp. 13-22, 2000.
- [145] N. Hotz, “What is CRISP DM?,” Data Science Process Alliance, 19 Janeiro 2023. [Online]. Available: <https://www.datascience-pm.com/crisp-dm-2/>. [Acesso em 24 Outubro 2023].
- [146] Escola DNC, “CRISP-DM: A metodologia ideal para Ciência de Dados,” Escola DNC, 28 Outubro 2020. [Online]. Available: <https://www.escoladnc.com.br/blog/data-science/metodologia-crisp-dm/>. [Acesso em 24 Outubro 2023].
- [147] R. Nisbet, G. Miner e K. Yale, “Chapter 18 - A Data Preparation Cookbook,” em *Handbook of Statistical Analysis and Data Mining Applications*, Elsevier, 2018, pp. 727-740.
- [148] D. Hawkins, *Identification of Outliers*, Chapman and Hall, 1980.
- [149] M. Goldstein e A. Dengel, “Histogram-based outlier score (hbos): A fast unsupervised anomaly detection algorithm,” *KI-2012: poster and demo track*, pp. 59-63, 2012.
- [150] FNDE, “Obras Convencionais: Orientações ao Gestor Público na execução de obras de infraestrutura para educação básica,” [Online]. Available: https://www.fnde.gov.br/phocadownload/programas/pro_infancia/Manuais/cartilha_de_orientacoes_ao_gestor_publico_obras_convencionais_2-0.pdf. [Acesso em 2 Outubro 2024].

- [151] F. Provost e T. Fawcett, *Data Science for Business: What you need to know about data mining and data-analytic thinking*, O'Reilly Media, Inc., 2013.
- [152] C. M. Bishop e N. M. Nasrabadi, *Pattern recognition and machine learning*, New York: springer, 2006.
- [153] O. A. M. López, A. M. López e J. Crossa, “Overfitting, Model Tuning, and Evaluation of Prediction Performance.,” em *Multivariate Statistical Machine Learning Methods for Genomic Prediction*, Springer, Cham, 2022.
- [154] C. Arnold, L. Biedebach, A. Küpfer e M. Neunhoeffer, “The role of hyperparameters in machine learning models and how to tune them,” *Political Science Research and Methods*, pp. 1-8, 2024.
- [155] D. M. Powers, “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation,” *International Journal of Machine Learning Technology*, 2020.
- [156] T. Fawcett, “An introduction to ROC analysis,” *Pattern recognition letters*, vol. 27, n^o 8, pp. 861-874, 2006.
- [157] Y. LeCun, Y. Bengio e G. Hinton, “Deep learning,” *Nature*, p. 436–444, 2015.
- [158] I. Goodfellow, Y. Bengio e A. Courville, *Deep Learning book*, MIT Press, 2016.
- [159] W. S. McCulloch e W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” em *The bulletin of mathematical biophysics*, vol. 5, 1943, pp. 115-133.
- [160] J. Schmidhuber, “Deep learning in neural networks: An overview,” *Neural networks*, vol. 61, pp. 85-117, 2015.
- [161] A. Krizhevsky, I. Sutskever e G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Advances in neural information processing systems*, vol. 25, 2012.
- [162] M. Nielsen, *Neural networks and deep learning*, Determination Press, 2015.
- [163] D. E. Rumelhart, G. E. Hinton e R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, pp. 533-536, 1986.
- [164] F. Rosenblatt, “The perceptron: a probabilistic model for information storage and organization in the brain,” *Psychological review*, 1958.
- [165] Y. e. a. LeCun, “Gradient-Based Learning Applied to Document Recognition,” *Proceedings of the IEEE*, vol. 86, pp. 2278-2324, 1998.
- [166] J. Schmidhuber e S. Hochreiter, “Long Short-Term Memory,” *Neural Comput*, vol. 9, pp. 1735-1780, 1997.
- [167] G. E. Hinton e R. R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Networks,” *Science*, vol. 313, pp. 504-507, 2006.
- [168] Q. Zhang, L. T. Yang, Z. Chen e P. Li, “A Survey on Deep Learning for Big Data,” *Information Fusion*, vol. 42, pp. 146-157, 2018.
- [169] Y. Bengio, A. Courville e P. Vincent, “Representation Learning: A Review and New Perspectives,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, pp. 1798-1828, 2013.
- [170] R. J. Hyndman e G. Athanasopoulos, “Forecasting,” *Principles and practice*, vol. 2, 2018.
- [171] M. H. Kutner, C. J. Nachtsheim, J. Neter e W. Li, *Applied linear statistical models*, McGraw-hill, 2005.

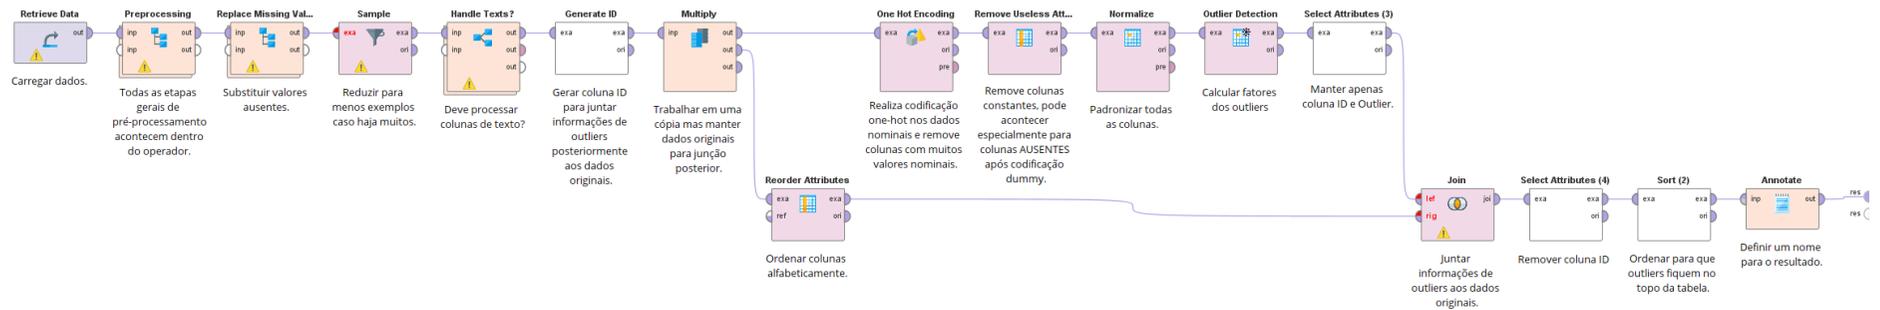
- [172] T. Saito e M. Rehmsmeier, “The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets,” *PloS one*, vol. 10, n^o 3, p. e0118432, 2015.
- [173] H. He e E. A. Garcia, “Learning from imbalanced data,” *IEEE Transactions on knowledge and data engineering*, vol. 21, n^o 9, pp. 1263-1284, 2009.
- [174] F. Hutter, L. Kotthoff e J. Vanschoren, *Automated machine learning: methods, systems, challenges*, Springer Nature, 2019.
- [175] M. Z. Alom e e. al., “The history began from alexnet: A comprehensive survey on deep learning approaches,” *arXiv preprint arXiv:1803.01164*, 2018.
- [176] C. Liu e e. al., “Progressive neural architecture search,” *Proceedings of the European conference on computer vision (ECCV)*, pp. 19-34, 2018.
- [177] N. Srivastava e e. al., “Dropout: a simple way to prevent neural networks from overfitting,” *The journal of machine learning research*, vol. 15, n^o 1, pp. 1929-1958, 2014.
- [178] Y. Gal e Z. Ghahramani, “A theoretically grounded application of dropout in recurrent neural networks,” *Advances in neural information processing systems*, vol. 29, 2016.
- [179] P. Baldi e P. Sadowski, “The dropout learning algorithm,” *Artificial intelligence*, vol. 210, pp. 78-122, 2014.
- [180] J. Davis e M. Goadrich, “The relationship between Precision-Recall and ROC curves,” *Proceedings of the 23rd international conference on Machine learning*, pp. 233-240, 2006.
- [181] M. Kuhn e K. Johnson, *Applied Predictive Modeling*, Springer, 2013.
- [182] G. F. Gori e e. al., “The expediting effect of monitoring on infrastructural works. A regression-discontinuity approach with multiple assignment variables,” *Italian Economic Journal*, vol. 10, n^o 1, pp. 197-224, 2024.
- [183] H. K. Doloi, “Understanding stakeholders' perspective of cost estimation in project management,” *International journal of project management*, vol. 29, n^o 5, pp. 622-636, 2011.
- [184] F. A. S. H. F. B. K. & d. M. M. I. Santos, “Análise dos problemas e conflitos nas obras públicas em Sergipe a partir da teoria da agência,” *Revista Gestão e Organizações*, vol. 6, n^o 1, pp. 82-102, 2021.
- [185] Microsoft Corporation, “Gráfico de comparação de precisão (Analysis Services - Mineração de Dados),” Microsoft, 2023. [Online]. Available: <https://learn.microsoft.com/pt-br/analysis-services/data-mining/lift-chart-analysis-services-data-mining?view=asallproducts-allversions>. [Acesso em 25 Janeiro 2025].
- [186] W. A. G. N. E. R. Meira Jr e M. J. Zaki, *Data mining and analysis, Fundamental Concepts and Algorithms*, 2014.
- [187] Instituto Brasileiro de Auditoria de Obras Públicas, “Manual de auditoria de obras públicas e serviços de engenharia,” Outubro 2018. [Online]. Available: <https://www.ibraop.org.br/wp-content/uploads/2019/03/Manual-de-Auditoria-de-Obras-P%C3%BAblicas-e-Servi%C3%A7os-de-Engenharia.pdf>. [Acesso em 30 Janeiro 2025].
- [188] ERNST & YOUNG GLOBAL LIMITED, “2021 EY Global Wealth Research Report,”

2021. [Online]. Available: https://assets.ey.com/content/dam/ey-sites/ey-com/en_gl/topics/wealth-and-asset-management/ey-2021-global-wealth-research-report-optimized-for-web-v2.pdf.
- [189] URBE.LAB, “A relação entre risco e retorno,” [Online]. Available: <https://urbe.me/lab/risco-e-investimento/>. [Acesso em 20 Fevereiro 2023].
- [190] NORMA BRASILEIRA, “ABNT NBR ISO 31000. Gestão de riscos - Princípios e diretrizes,” 30 Novembro 2009. [Online]. Available: https://edisciplinas.usp.br/pluginfile.php/4656830/mod_resource/content/1/ISO31000.pdf. [Acesso em 24 Fevereiro 2020].
- [191] FNDE, [Online]. Available: <https://www.fnde.gov.br/1ccr/pnae.html>.
- [192] H. Mahama, T. Rana, T. Marjoribanks e M. Z. Elbashir, “Principles-based risk regulatory reforms and management control practices: a field study,” *Accounting, Auditing & Accountability Journal*, pp. 773-800, 2023.
- [193] FNDE, 2017. [Online]. Available: <https://www.fnde.gov.br/1ccr/pdde.html>.
- [194] Brasil, “Portal do FNDE,” 2017. [Online]. Available: <https://www.gov.br/fnde/pt-br>. [Acesso em 30 Janeiro 2019].
- [195] Brasil, “Ministerio da Educação,” [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/programas-do-livro>.
- [196] Brasil, “Ministerio da Educação,” [Online]. Available: <https://www.gov.br/fnde/pt-br/aceso-a-informacao/acoes-e-programas/programas/pnate>.
- [197] FNDE, “Projetos Arquitetônicos - Proinfância,” [Online]. Available: https://www.fnde.gov.br/phocadownload/programas/pro_infancia/projetos_arquiteticos/tipo_1/perspectivas.rar. [Acesso em 10 Dezembro 2024].

Apêndice I

Process

Drp



Apêndice II

Deep Learning Model

Model Metrics Type: Binomial
 Description: Metrics reported on full training frame
 model id: rm-h2o-model-production_model-39
 frame id: rm-h2o-frame-production_model-39
 MSE: 0.018916098
 RMSE: 0.13753581
 R²: 0.89273214
 AUC: 0.99530756
 pr_auc: 0.9985575
 logloss: 0.0708135
 mean_per_class_error: 0.036474153
 default threshold: 0.540285587310791
 CM: Confusion Matrix (Row labels: Actual class; Column labels: Predicted class)

	Em Andamento	Obra	Error	Rate
Em Andamento	740	48	0.0609	48 / 788
Obra Comprometida	32	2627	0.0120 32 /	2,659
Totals	772	0.0232 80 /		3,447

Gains/Lift Table (Avg response rate: 77.14 %, avg score: 78.02 %):

Group	Cumulative Data Fraction	Lower Threshold	Lift	Cumulative Lift	Response Rate	Score	Cumulative Response Rate	Cumulative Score	Capture Rate	Cumulative Capture Rate	Gain	Cumulative Gain	Kolmogorov Smirnov
1	0.01073397	0.999999	1.296.352	1.296.352	1.296.352	1.000.000	0.999999	1.000.000	0.999999	0.013915	0.013915	29.635.201	0.013915
2	0.0201741	0.999999	1.296.352	1.296.352	1.296.352	1.000.000	0.999999	1.000.000	0.999999	0.012035	0.025950	29.635.201	0.025950
3	0.03017116	0.999997	1.296.352	1.296.352	1.296.352	1.000.000	0.999998	1.000.000	0.999999	0.013163	0.039112	29.635.201	0.039112
4	0.04003481	0.999996	1.296.352	1.296.352	1.296.352	1.000.000	0.999996	1.000.000	0.999998	0.012787	0.051899	29.635.201	0.051899
5	0.05018857	0.999994	1.296.352	1.296.352	1.296.352	1.000.000	0.999995	1.000.000	0.999998	0.013163	0.065062	29.635.201	0.065062
6	0.10008703	0.999990	1.296.352	1.296.352	1.296.352	1.000.000	0.999992	1.000.000	0.999995	0.064696	0.129748	29.635.201	0.129748
7	0.14998549	0.999982	1.296.352	1.296.352	1.296.352	1.000.000	0.999986	1.000.000	0.999992	0.064696	0.194434	29.635.201	0.194434
8	0.20017406	0.999973	1.296.352	1.296.352	1.296.352	1.000.000	0.999978	1.000.000	0.999988	0.065062	0.259496	29.635.201	0.259496
9	0.29997099	0.999950	1.296.352	1.296.352	1.296.352	1.000.000	0.999963	1.000.000	0.999980	0.129372	0.388868	29.635.201	0.388868
10	0.40005802	0.999883	1.296.352	1.296.352	1.296.352	1.000.000	0.999923	1.000.000	0.999965	0.129748	0.518616	29.635.201	0.518616
11	0.50014505	0.999262	1.296.352	1.296.352	1.296.352	1.000.000	0.999697	1.000.000	0.999912	0.129748	0.648364	29.635.201	0.648364
12	0.59994198	0.996966	1.285.047	1.294.471	1.294.471	0.991279	0.998322	0.998549	0.999647	0.128244	0.776608	28.504.662	0.772801
13	0.70002901	0.987947	1.270.049	1.290.980	1.290.980	0.979710	0.993536	0.995856	0.998774	0.127115	0.903723	27.004.922	0.9097.965
14	0.79982594	0.193750	0.911969	1.243.689	1.243.689	0.703488	0.755314	0.959376	0.968396	0.091012	0.994735	-8.803.143	24.368.918
15	0.89991297	0.010984	0.052606	1.111.219	1.111.219	0.040580	0.056687	0.857189	0.866330	0.005265	1.000.000	-94.739.441	11.121.857
16	1.00000000	0.000501	0.000000	1.000.000	1.000.000	0.000000	0.005478	0.771395	0.780170	0.000000	1.000.000	-100.000.000	0.000000

Status of Neuron Layers (predicting SITUAÇÃO, 2-class classification, bernoulli distribution, CrossEntropy loss, 900,642 weights/biases, 10.3 MB, 34,470 training samples, mini-batch size 1):

Layer Units	Type	Dropout	L1	L2	Mean Rate	Rate	RMS	Momentum	Mean Weight	Weight	RMS	Mean Bias	Bias	RMS
1 3348	Input	0.00 %												
2 256	RectifierDropout	20.00 %	0.000010	0.0000	0.5434546	0.438673	0.000000	0	-0.0009	0.0219	0.299171	0.128155		
3 128	RectifierDropout	15.00 %	0.000010	0.00000	0.028731	0.026818	0.000000	0	-0.0112	0.0718	0.945661	0.039580		
4 64	RectifierDropout	10.00 %	0.000010	0.00000	0.011689	0.016341	0.000000	0	-0.0067	0.1010	0.975364	0.025581		
5 32	RectifierDropout	5.00 %	0.000010	0.00000	0.018118	0.052132	0.000000	0	-0.0093	0.1418	0.967769	0.019271		
6 2	Softmax		0.000010	0.00000	0.001986	0.000963	0.000000	0	0.0345	0.5113	-0.000000	0.005853		

Scoring History:

Timestamp	Duration	Training Speed	Epochs	Iterations	Samples	Training RMSE	Training LogLoss	Training r2	Training AUC	Training pr_auc	Training Lift	Training Classification Error	
2025-01-30 18:47:26	0.000 sec		0.00000	0	0.00	0.0000	NaN	NaN	NaN	NaN	NaN	NaN	
2025-01-30 18:47:32	7.385 sec	624 o/sec	1.00000	1	3447.00	0.0000	0.19871	0.15137	0.7761	0	0.976650.98689	129.635.0.0	4845
2025-01-30 18:47:39	14.537 sec	639 o/sec	2.00000	2	6894.00	0.0000	0.19312	0.14326	0.7885	1	0.980290.98840	129.635.0.0	4120
2025-01-30 18:47:46	21.508 sec	653 o/sec	3.00000	3	10341.00	0.0000	0.16971	0.10864	0.8366	7	0.983370.99147	129.635.0.0	3684
2025-01-30 18:47:53	28.383 sec	660 o/sec	4.00000	4	13788.00	0.0000	0.16884	0.10605	0.8383	4	0.989910.99679	129.635.0.0	3481
2025-01-30 18:48:00	35.291 sec	667 o/sec	5.00000	5	17235.00	0.0000	0.16282	0.09288	0.8496	7	0.991940.99746	129.635.0.0	3394
2025-01-30 18:48:07	42.476 sec	670 o/sec	6.00000	6	20682.00	0.0000	0.16080	0.10849	0.8533	8	0.992210.99752	129.635.0.0	3104
2025-01-30 18:48:15	50.306 sec	656 o/sec	7.00000	7	24129.00	0.0000	0.16839	0.10005	0.8392	1	0.993490.99795	129.635.0.0	2872
2025-01-30 18:48:21	56.891 sec	665 o/sec	8.00000	8	27576.00	0.0000	0.15542	0.08927	0.8630	2	0.994170.99818	129.635.0.0	2814
2025-01-30 18:48:28	1 min 3.458 sec	672 o/sec	9.00000	9	31023.00	0.0000	0.13754	0.07081	0.8927	3	0.995310.99856	129.635.0.0	2321
2025-01-30 18:48:35	1 min 10.041 sec	678 o/sec	10.00000	10	34470.00	0.0000	0.16131	0.09052	0.8524	4	0.995840.99873	129.635.0.0	2263
2025-01-30 18:48:36	1 min 12.025 sec	678 o/sec	10.00000	10	34470.00	0.0000	0.13754	0.07081	0.8927	3	0.995310.99856	129.635.0.0	2321

H2O version: 3.42.0.1-rm10.4.0

Anexo I

