



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

BRUNO ANDRADE FERNANDES

Classificação de risco de fracasso em obras públicas paraibanas

CAMPINA GRANDE - PB

2024

BRUNO ANDRADE FERNANDES

Classificação de risco de fracasso em obras públicas paraibanas

Trabalho de Conclusão Curso apresentado ao Curso Bacharelado em Ciência da Computação do Centro de Engenharia Elétrica e Informática da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Orientador: Cláudio de Souza Baptista

CAMPINA GRANDE - PB

2024

BRUNO ANDRADE FERNANDES

Classificação de risco de fracasso em obras públicas paraibanas

Trabalho de Conclusão Curso apresentado ao Curso Bacharelado em Ciência da Computação do Centro de Engenharia Elétrica e Informática da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

BANCA EXAMINADORA:

Cláudio de Souza Baptista

Orientador – UASC/CEEI/UFCG

Wilkerson de Lucena Andrade

Examinador – UASC/CEEI/UFCG

Francisco Vilar Brasileiro

Professor da Disciplina TCC – UASC/CEEI/UFCG

Trabalho aprovado em: 15 de maio de 2024.

CAMPINA GRANDE - PB

RESUMO

Diante da necessidade de administrar o capital público de forma eficiente e transparente e de uma elevada e crescente alocação de recursos no estado da Paraíba voltado às obras públicas, o trabalho sugere um facilitador à administração pública no estado e municípios que o compõem. Com o intuito de servir como um apoio às decisões de alocação do capital público, aumentando a eficiência do gasto da verba em obras públicas, esse estudo propõe treinar um modelo preditivo de fracasso de obras governamentais. Por meio da investigação dos “dados abertos do SAGRES - TCE/PB”, houve o treinamento de modelos de aprendizado de máquina via Extreme Gradient Boosting (XGBoost), com diferentes subconjuntos de *features*, tendo seus dados desbalanceados ou balanceados, capazes de realizar uma classificação binária entre sucesso ou fracasso do empreendimento. Apurou-se, também, uma melhora da acurácia dos modelos ao realizar treinamento com a agregação de algumas características.

Failure risk classification in public works in Paraíba

ABSTRACT

In face of the need to manage public capital efficiently and transparently, and the significant and growing allocation of resources in the state of Paraíba towards public works, this paper suggests a facilitator for public administration in the state and its constituent municipalities. Aimed at aiding decisions regarding the allocation of public capital and enhancing the efficiency of expenditure on public works, this study proposes training a predictive model for government project failures. By leveraging investigation of the "open data from SAGRES - TCE/PB," machine learning models were trained using Extreme Gradient Boosting (XGBoost) with different subsets of features, both with unbalanced and balanced data, capable of performing binary classification between project success or failure. Additionally, an improvement in model accuracy was observed when training with the aggregation of certain characteristics.

Bruno Andrade Fernandes
Universidade Federal de Campina
Grande
Campina Grande, Paraíba, Brasil

bruno.fernandes@ccc.ufcg.
edu.br

Cláudio de Souza Baptista
Universidade Federal de Campina
Grande
Campina Grande, Paraíba, Brasil

baptista@computacao.ufcg
.edu.br

André Luiz Alves
Universidade Federal de Campina
Grande
Campina Grande, Paraíba, Brasil

andrealthes@copin.ufcg.ed
u.br

Resumo

Diante da necessidade de administrar a despesa pública de forma eficiente e transparente e de uma elevada e crescente alocação de recursos no estado da Paraíba voltado às obras públicas, o trabalho sugere um facilitador à administração pública no estado e municípios que o compõem. Com o intuito de servir como um apoio às decisões de alocação do capital público, aumentando a eficiência do gasto da verba em obras públicas, esse estudo propõe treinar um modelo preditivo de fracasso de obras governamentais. Por meio da investigação dos “dados abertos do SAGRES - TCE/PB”, houve o treinamento de modelos de aprendizado de máquina via Extreme Gradient Boosting (XGBoost), com diferentes subconjuntos de features, tendo seus dados desbalanceados ou balanceados, capazes de realizar uma classificação binária entre sucesso ou fracasso do empreendimento. Apurou-se, também, uma melhora da acurácia dos modelos ao realizar treinamento com a agregação de algumas características.

Keywords

Predição de risco, Obras públicas, Credit Scoring, XGBoost

1. INTRODUÇÃO

De acordo com o Tribunal de Contas da União (TCU), entre os anos de 2020 até o de 2023, a porcentagem de obras paralisadas aumentou de 29% para 41%, ao mesmo tempo, em que houve um aumento do capital investido previsto. O valor total de recursos investidos passou de R\$ 75,95 bilhões em 2020, para R\$ 113,65 bilhões em 2023. É apontada a insuficiência na coordenação, planejamento, priorização, monitoramento e avaliação das obras públicas, em que apenas na Paraíba, 406 obras encontram-se paralisadas [1].

Ao analisar-se os dados abertos do SAGRES pelo Tribunal de Contas do Estado da Paraíba (TCE-PB) [2], destaca-se como a terceira maior categoria de despesas do estado, totalizando R\$ 1.075.845.152,31 em 2023, o gasto em obras públicas, sendo um gasto crescente ao longo dos anos, acentuando-se recentemente. Com o intuito de servir como mais um parâmetro para tomada de decisões quanto a distribuição dos recursos limitados no estado da Paraíba, esse trabalho se propõe extrair dados das obras públicas paraibanas disponibilizadas pelo TCE-PB [3] para o treinamento de um modelo preditivo capaz de identificar obras com tendência a não conclusão. Desse modo, os resultados obtidos por meio do estudo poderão servir como base para identificar padrões de falhas em obras públicas, ao

mesmo tempo que previne a alocação indevida em obras que se insiram numa classificação de possível falhar, sendo arriscadas investir ou prolongar um investimento previamente realizado.

2. Trabalhos relacionados

A seção a seguir apresenta conceitos abordados ao longo do trabalho, tal como metodologia seguida na investigação e desenvolvimento do modelo e técnica de balanceamento dos dados e treinamento dos mesmos.

2.1 Credit scoring

Possuindo uma base de dados formada por informações sobre as despesas do Estado, onde, para o nicho de obras, há uma expectativa de algum retorno à sociedade, com algum risco de fracasso. Podemos definir a classificação do risco das transações realizadas entre o Estado e unidades administrativas diretas e indiretas, poderes e órgãos da estrutura governamental, um problema de avaliação de risco de crédito (*Credit Scoring*). Tendo *Credit Scoring* como a previsão de risco financeiro em empréstimos (THOMAS, 2000).

De forma simplificada, o Credit Scoring se dedica a classificar o tomador de crédito como um “bom” ou “mau” pagador, através da análise das características dessa entidade. Desse modo, estipular um risco ao empréstimo por meio do emprego de diversas técnicas estatísticas e de aprendizado de máquina em seus dados históricos.

2.2 Desbalanceamento de dados no domínio de Credit Scoring

Algo bem definido na literatura é o desbalanceamento da base de dados. Havendo, comumente, uma discrepância da quantidade de elementos da classe adimplente, quanto a classe inadimplente. Quando presente tamanho desequilíbrio entre as classes de possível classificação, há uma tendência dos modelos para a classe majoritária (BRANCO; TORGO; RIBEIRO, 2016).

2.3 Otimização de hiperparâmetros

Além do uso de técnicas de rebalanceamento das classes e seleção de *features* para o treinamento dos modelos, é importante à otimização dos hiperparâmetros dos mesmos. Dessa forma, investiga-se a calibração dos parâmetros do modelo para o objetivo proposto.

Nesse processo, avalia-se o desempenho preditivo do modelo conforme variam-se diferentes parâmetros, realizando uma otimização de caixa-preta.

2.4 Extreme Gradient Boosting

Extreme Gradient Boosting (XGBoost) é um algoritmo de aprendizado de máquina amplamente reconhecido por sua eficácia em diversos problemas de regressão e classificação. Baseado no método de Gradient Boosting, o XGBoost otimiza de forma interativa a função de perda ao adicionar modelos fracos, geralmente árvores de decisão, ao conjunto. Ajustando os modelos subsequentes de acordo com os erros dos modelos anteriores [5].

Além disso, o XGBoost incorpora técnicas de regularização para mitigar a *overfitting* e oferece suporte a reamostragem de linhas e colunas. Essa combinação de técnicas confere ao XGBoost flexibilidade e eficiência, destacando-o como uma ferramenta de grande valia na análise de dados e modelagem preditiva em diversos domínios de aplicação, tendo um bom desempenho para dados desbalanceados.

3. Metodologia

Devido à dispersão das informações sobre obras em diferentes tabelas e relacionamento e a complexidade das regras de negócio, esse trabalho foi realizado seguindo a metodologia Cross Industry Standard Process for Data Mining (CRISP-DM) (CHAPMAN et al., 2000). Dessa forma é exposto, de forma empírica, à base de dados, trazendo maior compreensão das informações e possibilitando *insights* sobre seus relacionamentos e dados, tal como ilustrado na Figura 1.

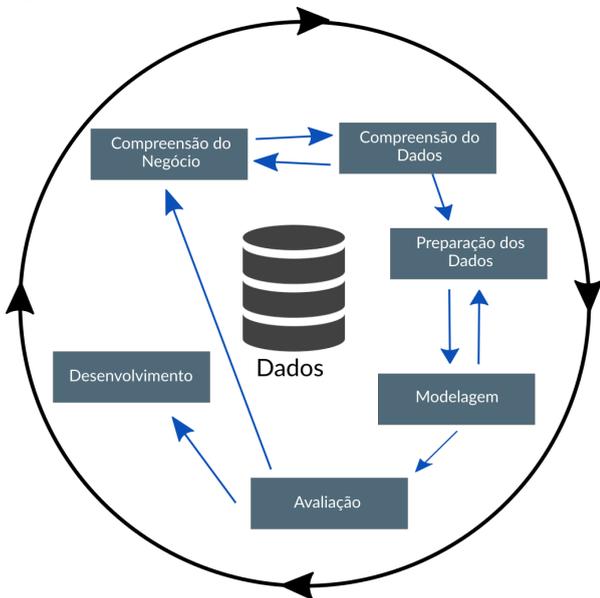


Figura 1. Visão geral da metodologia CRISP-DM.

3.1 Extração de dados e Compreensão de Dados

Os dados foram provenientes de algumas tabelas do banco de dados do SAGRES, na forma de dados abertos. As tabelas disponíveis para download estão no formato texto, UTF-8, compactado com GZip e foram importados para uma base de dados SQL, replicando a base de origem, com o intuito de

compreender o relacionamento entre entidades do banco e seus dados.

Através de *scripts* em Python, foi realizada a desnormalização da base de dados formada pelas 20 tabelas originais, modelada na terceira Forma Normal (3NF). Dessas, se destacaram as tabelas “t_evolucao” e “t_obra”, onde foram extraídas as principais características, dentre as 191 que compõem a base. Ao final, formou-se o modelo conceitual de entidades ilustrado na Figura 2.

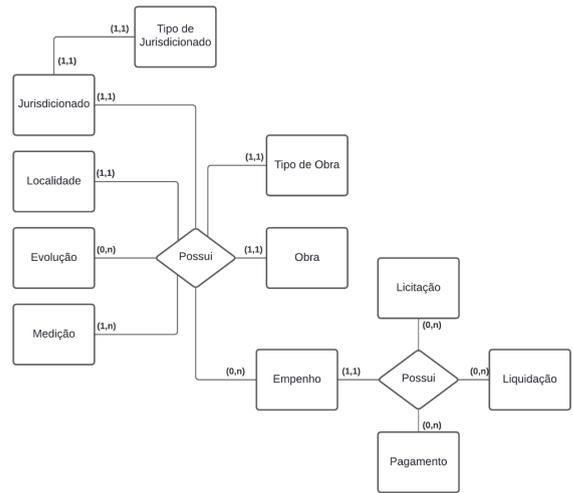


Figura 2. Diagrama Entidade-Relacionamento das principais tabelas da base

Houve informações em que não foi possível agregá-las ao modelo de dados, tal como os dados provenientes da tabela “t_licitacao” que, apesar de possuir uma relação com outras entidades não havia correspondência entre as chaves das tabelas, se tornando uma tabela não aproveitada para a formação da base de dados.

Após a etapa de extração dos dados, prosseguiu-se para o pré-processamento e seleção, descritos na próxima seção.

3.2 Preparação dos Dados

Como ilustrado na Figura 3, estão presentes na base de dados importada 36.997 obras cadastradas, onde grande parte dessas ainda estavam em execução, sendo desconsideradas pelo nosso estudo, por não possuírem a concretude de seu sucesso ou fracasso. Desse modo, foram removidos mais de 32.000 registros de obras.

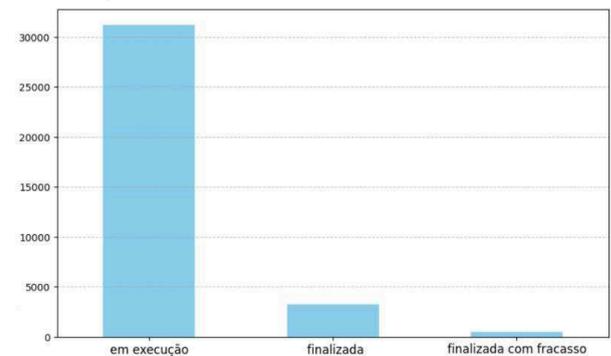


Figura 3. Distribuição de andamento de obras na base de dados importada do SAGRES TCE-PB.

Destas, foram consideradas apenas aquelas que possuíam um “número de protocolo tramita”, de forma a ser possível rastrear e acompanhar processos relacionados à obra.

Assim, durante o pré-processamento do modelo de dados, foi realizada a remoção de entidades em que possuísem sua data de início posterior à data de término ou possuídas de valores vazios, para limpeza da base.

Considerando as principais features extraídas para modelagem em problemas de *credit scoring*, foram extraídas informações quanto ao município da obra, modalidade da obra, seu andamento, datas de início, término e previsão de término, valores compactuados à mesma e tipo de jurisdicionado associado à obra.

Tendo como objetivo a previsão do sucesso de uma obra, foram definidas obras falhas aquelas que foram finalizadas com um *status* de “Inacabado”, “Finalizado Judicialmente” ou “Abandonado”, tendo a correta concretude aquelas com *status* “conclusao”. Conseqüentemente, foram desprezadas as obras não finalizadas, por serem exteriores ao escopo do estudo.

Ao final, a primeira versão da base (v1) possuiu 3.701 entidades, sendo 3.258 concluídas corretamente, contra 443 de forma falha. Após a filtragem das entidades, houve um processo de agregação de seus valores e relações com o intuito de gerar novas informações valiosas. Sendo discriminado o total de dias de execução da obra e a quantidade de dias previstos inicialmente.

Ao agregar dados da tabela de medições em uma nova versão do modelo de dados (v2), possibilitou-se visualizar a quantidade de medições de empenho que uma obra teve ao longo de sua execução, tal como quantos e quais estados de execução se encontrou, a quantidade média de dias que levou de uma medição à outra e o total e média dos valores agregados à medição. A proporção da classe *target* “andamento” se manteve constante.

Devido à presença de colunas com valores monetários com grande variância, aplicou-se a normalização desses dados com o intuito de evitar um possível viés do modelo. Desse modo, os dados correspondentes à gravação de alguma transação passaram por uma transformação utilizando-se a técnica de normalização Min-Max (SINGH; VERMA; THOKE, 2015), com $\min = 0$ e $\max = 1$.

Para as colunas categóricas extraídas, aplicou-se a codificação *onehot encoding*, transformando uma coluna em um vetor esparsos de dimensão d , sendo esta dimensão a quantidade de valores distintos que a coluna pode assumir. Dessa forma, tornando a base de dados legível ao modelo a ser treinado. Em uma nova versão do conjunto de dados (v3), foram removidas as identificações do local da obra, devido ao grande aumento do número de colunas atreladas a essa informação após aplicar o *onehot encoding*, havendo 223 municípios no estado da Paraíba. Nesta versão, foram filtradas as obras que não possuíam medições associadas, de modo a validar se a porção de dados com valores *defaults* nas colunas de medição interferiu no aprendizado do modelo. Assim, finalizando com 1.079 obras finalizadas com sucesso contra 261 falhas, totalizando 1.340. Ao final, houve um

aumento da proporção de obras falhas na base final, como ilustrado na Figura 4.

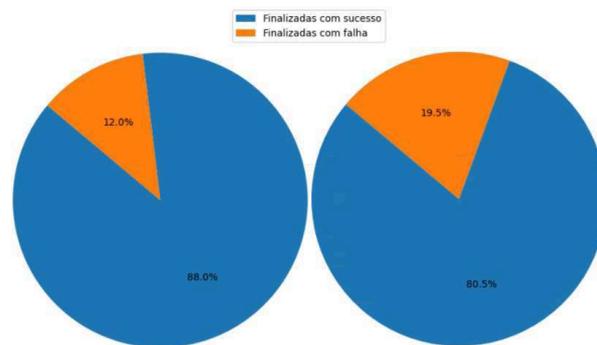


Figura 4. Distribuição de andamento de obras, v1 à esquerda e v3 à direita.

3.2.1 Balanceamento

Como esperado de problemas de *credit scoring*, houve um grande desbalanceamento quanto às classes majoritárias, adimplemento. Com o intuito de reduzir esse viés, foi aplicada a técnica de rebalanceamento de undersampling aleatório (no inglês, Random Sub-Sampling - RUS). Desse modo, entidades são selecionadas aleatoriamente da classe majoritária e são removidas do conjunto de treino para que se iguale da quantidade de obras presentes nas classes de estudo ao fim do processo.

3.3 Modelagem

Por meio do uso da linguagem Python, associado ao módulo Scikit-Learn (PEDREGOSA et al., 2011) e a biblioteca XGBoost, que implementa o algoritmo de tree boosting e de posse de três diferentes subconjuntos da base de dados definidos anteriormente, foram realizados os experimentos. Através do método de validação cruzada *k-fold*, foi segmentado igualmente os dados das bases em 10 segmentos ou *folds*, de maneira a ser mantida a proporção inicial da classe *target*.

Nesses segmentos, são realizadas 10 interações, nas quais, em cada fase, há o treinamento com 9 segmentos e teste com o *fold* restante (YADAV; SHUKLA, 2016). Assim, são calculadas, em cada interação, a precisão, *recall* e F1-score, para o cálculo da média dessas métricas.

Após recolhido os resultados dos treinamentos anteriores, é iniciado o processo de otimização dos hiperparâmetros com o intuito de melhorar as métricas alcançadas. Foi usado o Optuna, uma biblioteca de otimização automatizada dos hiperparâmetros que utiliza algoritmos de busca eficientes para explorar o espaço de hiperparâmetros em busca das melhores configurações. Definiu-se a função objetivo da otimização como maximização do *F1 score* do modelo no conjunto de validação, garantimos que o modelo seja capaz de alcançar bons valores de precisão e *recall*, de forma equilibrada. Sendo também necessário o ajuste do espaço de busca dos hiperparâmetros, descritos a seguir:

- *eta*: Representa a taxa de aprendizado, controlando a magnitude das atualizações de peso durante o treinamento;
- *max_depth*: Profundidade máxima das árvores de decisão;

- *gamma*: Parâmetro de regularização que controla a complexidade do modelo;
- *alpha*: Regularização L1, responsável por controlar os pesos das características;
- *lambda*: Regularização L2, controlando os pesos das características;

Ao realizar o treinamento, com o intuito de averiguar o quanto o desbalanceamento da classe alvo afetaria o resultado, foram treinadas versões desbalanceadas e balanceadas das bases, através do uso do RUS.

3.4 Validação do modelo

Ao abordar a base de dados desbalanceada, como a do cenário, nota-se um problema quanto ao uso apenas da acurácia, posto que bastaria catalogar todas obras para a classe majoritária (obras com sucesso) que resultaria em um valor de 88,0% a 80,5%, por se tratar de uma classificação binária.

Então, para a avaliação dos resultados de classificação dos modelos, foram calculadas dos diferentes casos de treino, com os diferentes subconjuntos de dados, as métricas de precisão, *recall* e *F1-score*. Busca-se identificar um método assertivo ao classificar uma obra como possível fracasso (alta precisão), ao mesmo tempo que não deixe de classificar obras falhas serem classificadas como de execução normal (um bom *recall*). Tendo o *F1-score* como norte da nossa avaliação, por se tratar de uma média harmônica entre o *precision* e o *recall* e resultado entre as métricas anteriores. Dessa forma, pode-se realizar uma comparação entre os desempenhos alcançados e induzir os motivos dos resultados e oscilações.

De forma complementar, para melhor visualizar e comparar os modelos, foi visualizada a matriz de confusão, onde:

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Tabela 1. Exemplificação da estrutura de uma matriz de confusão.

- TP: Obras com êxito, previstas corretamente;
- FN: Obras falhas, previstas erroneamente;
- FP: Obras com êxito, previstas erroneamente;
- TN: Obras falhas, previstas corretamente;

Ao realizar-se a validação do treinamento do modelo, para cada variação de base utilizada, retornou-se à seção de 3.2 para reformulação da base e validação desta.

4. Resultados

Como descrito na metodologia, após a extração das features que formam a base de dados do treinamento, houve retornos ao processo de seleção de características, conforme foram criadas hipóteses no processo de modelagem. Desse modo, foram formados três subconjuntos distintos de dados,

definidas anteriormente e cada uma delas passou pelo processo de treinamento de forma semelhante.

Cada base alimentou o treino de um modelo, através do método *k-fold* de *cross-validation*, com $k = 10$, sendo 9 *folds* de treinamento e 1 para validação. Ao final, extraíram-se as médias das métricas a fim de validar a generalização e capacidade preditiva do modelo. Em seguida, foi feito o mesmo treinamento com os dados balanceados e, por fim, foram calculados os hiperparâmetros otimizados pelo Optuna. Assim, chegamos aos seguintes resultados na classificação de obras falhas:

Estado da Base	Precisão	Recall	F1-score	Acurácia
v1 Desbalanceada	62%	24%	34%	89%
v1 Balanceada	73%	25%	37%	90%
v1 com Hiperparâmetros otimizados	59%	30%	39%	89%
v2 Desbalanceada	68%	29%	41%	90%
v2 Balanceada	68%	30%	41%	90%
v2 com Hiperparâmetros otimizados	61%	32%	42%	89%
v3 Desbalanceada	63%	42%	51%	84%
v3 Balanceada	60%	46%	52%	84%
v3 com Hiperparâmetros otimizados	82%	35%	49%	86%

Tabela 2. Métricas colhidas da classificação da falha de obras através dos treinamentos com diferentes configurações e bases

De início, foi possível visualizar que o treino do modelo com dados balanceados possuiu um melhor resultado, mas suas métricas ainda não haviam sido satisfatórias. Por esse motivo, buscou-se treinar diferentes versões do subconjunto dos dados. Como esperado, houve um aumento dos nossos critérios de validação ao treinarmos com o subconjunto v2. O intuito dessa base de treino consistia no aumento das características as quais o modelo poderia aprender sobre.

Tendo em vista que esse modelo trouxe novos dados e que houve ganhos associados a essa mudança, foi elaborado o modelo v3, que superou novamente os resultados alcançados anteriormente. A necessidade dessa base partiu da dúvida sobre o quanto um número elevado de colunas, pela codificação da informação de localidade da obra, e campos vazios sobre suas medições impactam o aprendizado do modelo.

Devido ao aumento considerável do F1-score comparada às demais, é evidenciado o impacto premeditado no aprendizado do classificador. Desse modo, definiu-se que o melhor modelo de base para treino foi aquele que conseguiu agregar informações não apenas da obra em si, mas também das medições periodicamente realizadas nela, assim possuindo

maior quantidade de parâmetros ao analisar o comportamento de uma obra ao longo da sua evolução.

Conclusão da Obra	Precisão	Recall	F1-score
Sucesso	88%	93%	90%
Falha	60%	46%	52%

Tabela 3. Métricas colhidas da classificação de obras na base v3 desbalanceada

Ao obter-se métricas elevadas na classificação de obras com sucesso, fato que mostrou-se presente em outros experimentos, houve o treinamento de um modelo Máquina de vetores de suporte (Support Vector Machine, ou SVM) *one class* para verificar a hipótese de não tratar-se de uma questão de identificação de anomalias. Após alguns testes, o modelo treinado com a base v3 desbalanceada, aquela que demonstrou melhor *F1-score*, com seu limite superior para a fração de erro configurado para 0.4, verificou-se a inferioridade dos resultados alcançados Tabela 4 em comparação com os resultados ilustrados Tabela 4.

Conclusão da Obra	Precisão	Recall	F1-score
Sucesso	83%	29%	43%
Falha	21%	76%	32%

Tabela 4. Métricas colhidas durante o treinamento do SVM

Dessa forma, prova-se a não trivialidade da classificação, tal como a indicativa de que o treino de um SVM não adaptou-se tão bem ao objetivo do estudo.

5. Conclusão

O trabalho desenvolvido buscou desenvolver um modelo preditivo de fracasso de obras públicas com a confecção de uma base de dados na qual seja reproduzível e utilizável com os dados públicos do SAGRES - TCE/PB. Considerando a concretude desses objetivos, apesar da acentuada redução de dados úteis, notou-se que a consideração de dados que replicam a obra no decorrer do tempo, trouxeram melhores resultados.

Assim, tendo em vista trabalhos futuros, sugere-se a incapacidade de realizar os vínculos dos dados da base aos dados de suas licitações tenha trazido impactos aos resultados obtidos. Isso ocorre devido ao fato da tabela de licitações evoluir desde a licitação que originou a obra, até as licitações provenientes de aditivos contratuais, apontadas como pontos importantes para identificar obras com orçamentos subestimados e de maior risco de paralisação.

6. Referências

- [1] Brasil tem 8,6 mil obras paralisadas, financiadas com recursos federais. <https://portal.tcu.gov.br/imprensa/noticias/brasil-tem-8-6-mil-obras-paralisadas-financiadas-com-recursos-federais.htm>
- [2] Despesas detalhadas do SAGRES. Disponível em: <https://sagresonline.tce.pb.gov.br/#/municipal/inicio>
- [3] DADOS ABERTOS DO SAGRES - TCE/PB. Disponível em: <https://tce.pb.gov.br/servicos/dados-abertos-do-sagres-tce-pb>
- [4] THOMAS, L. C. A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. *International Journal of Forecasting*, v. 16, n. 2, p. 149 – 172, 2000.
- [5] [XGBoost: A Scalable Tree Boosting System](#) greedy function Approximation: A Gradient boosting Machine - Jerome H. Friedman IMS 1999 Reitz Lecture
- [6] CHAPMAN, P.; CLINTON, J.; KERBER, R.; KHABAZA, T.; REINARTZ, T.; SHEARER, C.; WIRTH, R. CRISP-DM 1.0. Step-by-step data mining guide. Edited by CRISP-DM Consortium. 2000. Acesso em 28/04/2024. Disponível em: <https://www.kde.cs.uni-kassel.de/wp-content/uploads/lehre/ws2012-13/kdd/files/CRISPWP-0800.pdf>.
- [7] PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. et al. Scikit-learn: Machine learning in python. *Journal of machine learning research*, v. 12, n. Oct, p. 2825-2830, 2011
- [8] Yadav, S.; Shukla, S. Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In: 2016 IEEE 6th International Conference on Advanced Computing (IACC). [S.l.: s.n.], 2016. p. 78-83
- [9] GUILHON, Daniel Moreira. Classificação de risco em transferências voluntárias federais utilizando XGBoost. 2020. 84 f. Dissertação (Programa de Pós-Graduação em Ciência da Computação/CCET) - Universidade Federal do Maranhão, São Luís, 2020. Disponível em: <https://tede.ufma.br/jspui/handle/tede/3207#preview-1ink0>.
- [10] Falta de planejamento e corrupção: especialistas apontam causas para as milhares de obras paradas no país. <https://brasil61.com/n/falta-de-planejamento-e-corrupcao-especialistas-apontam-causas-para-as-milhares-de-obras-paradas-no-pais-pind223078>

Sobre o autor:

Bruno Andrade Fernandes é aluno do curso de Ciência da Computação na Universidade Federal de Campina Grande.