

PREVISÃO DE ADITIVOS EM OBRAS PÚBLICAS COM ALGORITMOS DE APRENDIZADO DE MÁQUINA

Predicting Changes of Public Works with Machine Learning Algorithms

Thomas Farias Vianna

Instituto Militar de Engenharia | Rio de Janeiro, RJ | farias.thomas@ime.eb.br

Rafaela Furtado Teixeira

Instituto Militar de Engenharia | Rio de Janeiro, RJ | rafaelafurtado@ime.eb.br

Daiane Castro Dias

Instituto Militar de Engenharia | Rio de Janeiro, RJ | daiane.dias@ime.eb.br

Giuseppe Miceli Junior

Instituto Militar de Engenharia | Rio de Janeiro, RJ | giuseppe.pged@ime.eb.br

Paulo César Pellanda

Instituto Militar de Engenharia | Rio de Janeiro, RJ | pellanda@ime.eb.br

Ronaldo Ribeiro Goldschmidt

Instituto Militar de Engenharia | Rio de Janeiro, RJ | ronaldo.rgold@ime.eb.br

RESUMO

A dinâmica da execução de serviços de engenharia e obras públicas frequentemente exige alterações contratuais devido a falhas na contratação e fatos supervenientes. Na administração pública, essas mudanças ocorrem via termo aditivo, com impacto financeiro de até 50% em reformas e a 25% nos demais casos, e sem limite legal para alterações de prazo, desde que justificadas. Neste sentido, órgãos públicos que gerenciam vultosos recursos em obras devem considerar a ocorrência de aditivos no planejamento financeiro, de forma a garantir recursos necessários para conclusão dos contratos e evitar a inscrição de créditos em restos a pagar. Nesse contexto, este trabalho busca avaliar a aplicabilidade de técnicas de aprendizado de máquina na previsão da ocorrência e do impacto financeiro e temporal dos aditivos contratuais em obras públicas, visando auxiliar a tomada de decisão no nível estratégico da descentralização de recursos às unidades gestoras. Foram aplicados algoritmos de classificação e regressão, alinhadas ao conhecimento de domínio do gesto. Para avaliação dos resultados, foram utilizadas as métricas de precisão, recall e F1-score na classificação, e de erro máximo, médio quadrático e coeficiente de correlação r^2 da regressão. Os resultados indicaram melhor desempenho na previsão de aditivos de prazo em comparação aos de valor.

Palavras-chave: Obra pública; Aditivo; Regressão; Classificação; Aprendizado de Máquina.

ABSTRACT

The dynamics of the execution of engineering services and public works often require contractual modifications due to procurement failures and unforeseen events. In public administration, these changes occur through contract addendums, with financial impacts of up to 50% for renovations and 25% for other cases, and with no legal limit for changes in deadlines, as long as they are justified. In this context, public agencies managing substantial resources for construction should incorporate the occurrence of contract addendums into financial planning to ensure the necessary resources for contract completion and avoiding the use of unpaid commitments. In this context, this work seeks to evaluate the applicability of machine learning techniques in predicting the occurrence and financial and temporal impact of contractual addendums in public works, aiming to assist decision-making at the strategic level of decentralization of resources to the management units. Classification and regression algorithms were applied, aligned with the domain knowledge of the gesture. To evaluate the results, the metrics of precision, recall and F1-score were used in the classification, and maximum error, mean square and correlation coefficient r^2 in the regression. The results indicated better performance in predicting term additives compared to value addendums.

Keywords: Public Works; Addendums; Regression; Classification, Machine Learning.

1 INTRODUÇÃO

A supervisão de obras e serviços de engenharia públicos apresenta características distintas do meio privado devido à natureza dinâmica e incerta desses empreendimentos. Esses projetos frequentemente sofrem mudanças nos prazos, nas condições contratuais e nos métodos de execução ou pagamento, o que pode provocar dificuldades relacionadas aos custos ou ao prazo de conclusão da obra (Brasil, 2014).

Quanto aos custos, tanto a revogada Lei de licitações (Brasil, 1993), válida à época da maioria das contratações em estudo, quanto a Lei vigente de licitações e contratos administrativos (Brasil, 2021a), o contratado será obrigado a aceitar as alterações unilaterais de acréscimo ou supressão de até 25% do valor inicial atualizado do contrato. No caso de reforma de edifício ou de equipamento, o limite para os acréscimos é de 50%. Em casos excepcionais, pode ser realizada uma alteração com impacto ainda maior.

Quanto ao prazo, segundo a cartilha de Recomendações Básicas para Contratação e Fiscalização de Obras de Edificações Públicas do TCU (Brasil, 2014), obras cuja execução ultrapasse um exercício financeiro devem estar inscritas em plano plurianual. Neste contexto, é necessário que o gestor tome medidas tempestivas no gerenciamento dos recursos empenhados, visando minimizar o volume de recursos a serem inscritos em Restos a Pagar. Assim, a ausência de previsão adequada de termos aditivos, tanto de serviços quanto de prazo, pode comprometer o cumprimento das metas financeiras nos exercícios subsequentes e impactar diretamente a eficiência da gestão contratual pública.

Outro ponto importante de motivação para essa pesquisa é a publicação da Lei do Governo Digital (Brasil, 2021b), que traz como um dos princípios e diretrizes o uso da tecnologia para otimizar processo de trabalho da administração pública. Nesse sentido, tem-se o exemplo do Tribunal de Contas da União que tem adotado o uso de inteligência artificial como ferramenta para servidores e colaboradores aprimorarem suas atividades, com orientações e respostas sobre análise de licitações e editais (Costa; Bastos, 2020). Essa prática ilustra como o aprendizado de máquina pode ser aplicado para apoiar órgãos públicos no desempenho de suas funções, especialmente no que tange à gestão de grandes volumes de informações e ao cruzamento de dados.

No âmbito legal, tanto a Lei de Responsabilidade Fiscal (LRF) (Brasil, 2000) quanto o Decreto nº 93.872/86 (Brasil, 1986) visam limitar a ocorrência de restos a pagar nos orçamentos públicos. Eles estipulam o cancelamento de restos a pagar que não atendem às disposições estabelecidas e preveem sanções para gestores responsáveis por crimes de responsabilidade. Por isso e a fim de evitar consequências, Peixoto e Peixoto (2017) afirmam que para garantir um controle mais rigoroso dos saldos de restos a pagar, as instituições públicas precisam implementar rotinas e procedimentos administrativos que assegurem o uso adequado e eficiente deste instrumento financeiro. Assim, deve ser considerada a possibilidade de aumento da eficiência na gestão de recursos financeiros através de decisões assertivas e estratégias, baseadas em informações que podem ser geradas por tarefas de aprendizado de máquina, antes da inclusão em restos a pagar.

Considerando que os problemas que envolvem restos a pagar podem ser mitigados com a sua prevenção, essa pesquisa escolheu abordar o tema por essa perspectiva. Então, neste contexto, a utilização de técnicas de *Knowledge Discovery in Databases* (KDD) pode auxiliar o processo decisório, com predição de alterações contratuais, podendo resultar na melhoria do planejamento do uso de recursos financeiros e, conseqüentemente, evitar a inscrição em restos a pagar.

O objetivo central deste trabalho é avaliar a aplicabilidade de técnicas de aprendizado de máquina na previsão da ocorrência e do impacto financeiro e temporal de aditivos contratuais em obras públicas. Os objetivos específicos incluem: (i) testar diferentes algoritmos de classificação e regressão para prever tais eventos; e (ii) analisar a viabilidade e a utilidade desses modelos como ferramenta de apoio à decisão para o gestor público durante o planejamento financeiro de obras.

2 FUNDAMENTAÇÃO TEÓRICA

Mudanças em projetos, especificações técnicas, cronograma físico-financeiro e planilhas orçamentárias devem ser justificadas por escrito e previamente aprovadas pela autoridade competente responsável pela celebração do contrato. No caso de alterações nas especificações técnicas, é essencial assegurar a manutenção da qualidade, garantia e desempenho inicialmente exigidos para os materiais a serem utilizados (Brasil, 2014).

Em um cenário em que recursos públicos são limitados e passam por constantes contingenciamentos, a gestão financeira é de suma importância no emprego de créditos pelos órgãos públicos federais. Órgãos com

vasto patrimônio imobiliário a gerir e vultosos recursos empregados em obras devem possuir uma estimativa real do valor final das obras, considerando os aditivos e reajustes.

O termo Inteligência Artificial (IA) surgiu em 1956 e desde esse momento, diversas explicações foram concebidas para tentar caracterizar o conceito. Russell e Norvig (2013) organizaram algumas dessas definições em categorias relacionadas ao processo de pensamento e ao comportamento. Dentre as explicações apresentadas, destaca-se aquelas que melhor se correspondem ao trabalho em questão: “A arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas.” (Kurzweil, 1990) e “IA...está relacionada a um desempenho inteligente de artefatos.” (Nilsson, 1998).

Segundo Hao e Ho (2019), o aprendizado de máquina (*machine learning*, ML) é um dos campos da IA que utiliza algoritmos treinados em conjuntos de dados para criar modelos capazes de realizar tarefas que normalmente seriam executadas por seres humanos. De modo geral, os algoritmos de ML podem ser agrupados em diferentes categorias, como árvores de decisão, máquinas de vetor de suporte (SVM) e redes neurais artificiais, cada uma com suas vantagens e limitações (Géron, 2019).

Os métodos baseados em árvores de decisão, como Random Forest, AdaBoost, XGBoost e LGBM, destacam-se por sua robustez, capacidade de lidar com dados desbalanceados e facilidade de interpretação, permitindo identificar as variáveis com maior influência nos resultados (Hao e Ho, 2019). As SVM são conhecidas por sua capacidade de encontrar margens ótimas de separação entre classes — ou seja, categorias ou rótulos distintos nos dados de saída a serem previstos, sendo eficazes mesmo com um número reduzido de amostras e alta dimensionalidade (Berrar, 2019). Por outro lado, redes neurais artificiais, como o *Multilayer Perceptron* (MLP), são indicadas para capturar relações não lineares complexas, mas apresentam maior custo computacional e menor interpretabilidade dos resultados (Russell e Norvig, 2013; Hao e Ho, 2019).

Por sua vez, o KDD é um processo metodológico estruturado que inclui etapas como pré-processamento, mineração de dados e interpretação de resultados, dentre as tarefas utilizadas ML no processo de KDD, destacam-se a classificação e a regressão, utilizadas neste trabalho.

Na linguagem de programação *Python*, o *Scikit-Learn* é a biblioteca de código aberto mais abrangente na área de aprendizado de máquina, em que os algoritmos são otimizados para eficiência computacional, além de possuir um suporte ativo da comunidade. Uma de suas principais características é a padronização das interfaces de entrada e saída, o que permite um procedimento único para ajuste de modelos, facilitando a implementação e a comparação entre diferentes técnicas (Scikit-Learn, 2025).

No processo de configuração desses modelos, destaca-se a definição dos hiperparâmetros, que são variáveis externas ao treinamento que controlam o comportamento dos algoritmos, como a profundidade máxima das árvores de decisão (Berrar, 2019). A escolha inadequada desses hiperparâmetros pode resultar em problemas de *overfitting* ou *underfitting*, comprometendo a capacidade preditiva dos modelos. Ademais, a busca por combinações ótimas demanda elevado custo computacional. Assim, é comum o uso dos hiperparâmetros padrão fornecidos pelas bibliotecas, considerados adequados como ponto de partida para avaliações comparativas (Scikit-Learn, 2025).

3 METODOLOGIA

Esta seção detalha o processo de KDD realizado visando à utilização de ferramentas de inteligência artificial na predição de ocorrência de aditivos contratuais nas obras geridas pelo Sistema de Obras Militares (SOM), do Exército Brasileiro. Com o objetivo de gerir todas as informações relacionadas às edificações militares foi desenvolvido, em 2008, um sistema web denominado Sistema Unificado do Processo de Obras (OPUS) (Fernandes, Scheer e Miceli Junior, 2020). O SOM utiliza o OPUS como ferramenta de controle de aproximadamente 88 mil benfeitorias, vinculadas a mais de 650 Organizações Militares espalhadas pelo território nacional (Miceli Junior, 2019). No ano de 2023, de acordo com os dados extraídos do OPUS, o Exército geriu 1,5 bilhão de reais; desse valor, aproximadamente 150 milhões foram oriundos de modificações contratuais. Portanto, não considerar os termos aditivos de serviços e de prazo no planejamento financeiro pode ser prejudicial ao cumprimento das metas financeiras dos anos subsequentes. Além dos aditivos, devem ser considerados no planejamento financeiro das obras o custo dos reajustes anuais, que são a atualização monetária do saldo de obra passado um ano da data do orçamento base do contrato.

O conjunto de dados foi gerado a partir do relatório gerencial de contratos no formato .csv, com informações do código da obra, valores contratados, data de contratação e demais dados gerenciais do contrato, como medições, reajustamentos e termos aditivos, fornecido pelo OPUS. Um exemplo de relatório é apresentado na Figura 1.

Figura 1: extrato do relatório gerencial fornecido pelo OPUS

Descrição da Obra	Região Militar	Valor Inicial	% aditada valor	Valor Atual	% Medido	Ano	Prazo Contratado	Prazo Aditivo	%aditada	Prazo Total
Construção / Pavilhão Rancho / 9º B COM GE	9ª RM	6.16	0.07	5.75	95.21	18	20	33.23	1.66167	53
Construção / Pista de Combate a Localidade Ord...	11ª RM	2.92	0.13	3.30	99.76	18	30	26.07	0.86889	56
Construção / EsIMEEx / C I E	11ª RM	14.29	0.14	16.34	100.00	19	15	8.00	0.53333	23
Construção / Estacionamento / Ba Av T	2ª RM	6.06	0.11	6.71	100.00	19	21	0.00	0.00000	21
Construção / Infraestrutura Complementar do FS...	11ª RM	14.82	0.11	16.47	68.61	19	18	24.67	1.37037	43

Fonte: Os autores.

Foram extraídos 4.914 casos de obras e serviços de engenharia distribuídos em todo o país, com dados entre 2012 e maio de 2024. Em seguida, iniciaram-se as etapas de pré-processamento:

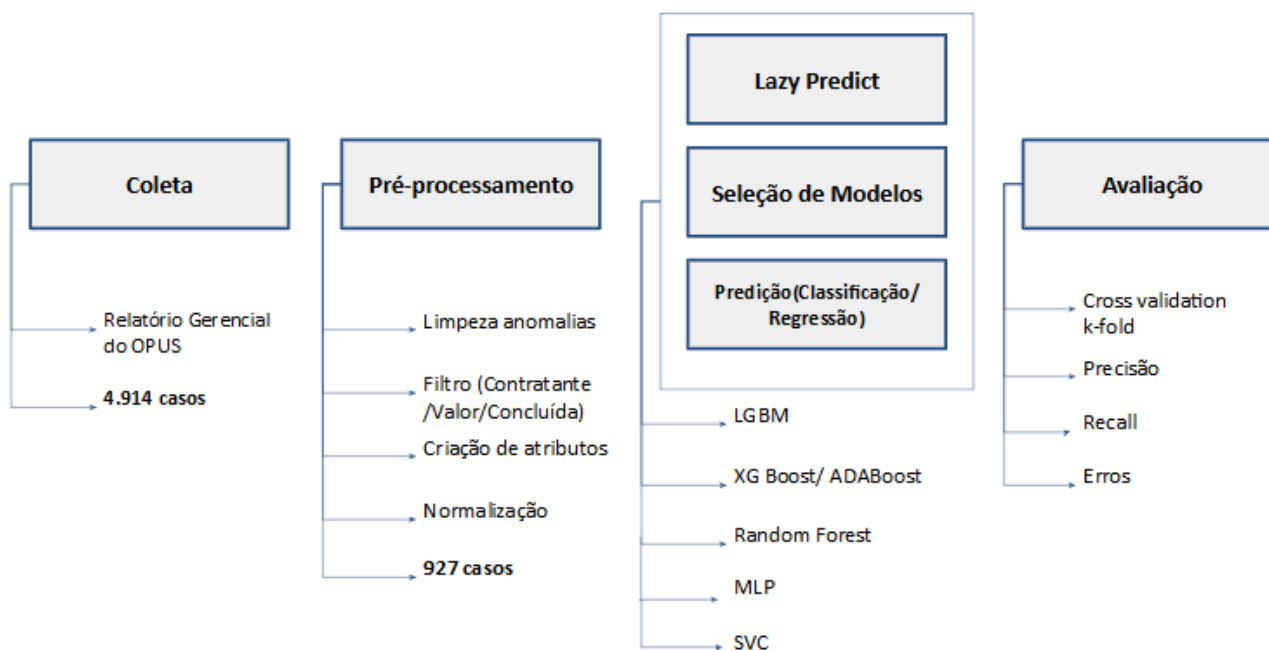
- Limpeza de anomalias: com exclusão de registros incompletos, uma vez que não há informações suficientes para completar todos os dados e qualquer imputação fictícia poderia comprometer a análise;
- Filtro de obras contratadas pelos setores especializados de engenharia: para se ter maior confiabilidade nos dados lançados;
- Filtro de obras pelo valor: foram considerados apenas contratos com valor inicial superior a R\$ 500.000,00, pois obras de menor vulto não possuem impacto relevante no planejamento financeiro;
- Filtro de obras pelo andamento do contrato: não foram considerados os contratos em andamento, uma vez que ainda podem ocorrer aditivos para esses casos, alterando os dados de análise;

Durante o pré-processamento de dados, observou-se que um desbalanceamento entre os contratos com e sem aditivos, com predominância da classe com aditivos. Essa distribuição assimétrica pode induzir os algoritmos classificadores a um viés em favor da classe majoritária, dificultando a identificação correta dos casos da classe minoritária (Berrar, 2019). No entanto, optou-se por manter esse desequilíbrio tendo em vista que é o que ocorre nos casos reais. No caso de contratações por empreitada por preço unitário, a ocorrência de aditivos é maior devido ao grau de maturidade do projeto licitado, em que não é possível prever as quantidades exatas que serão executadas no contrato (CROCE *et al.*, 2008).

Com essa redução de dados restaram 927 registros. Como os contratos em estudo são de obras dos diversos estados brasileiros a anos distintos, foi necessário regionalizar os valores por meio do CUB (Custo Unitário Básico da Construção) (CUB, 2024) de Goiás, como referência, e a atualização monetária, referenciada a Mar/24 pelo INCC (Índice Nacional da Construção Civil) (FGV-IBRE, 2024). Em seguida, os dados numéricos foram normalizados linearmente para o intervalo entre 0 (zero) e 1 (um), a fim de reduzir a influência de escalas distintas entre as variáveis e melhorar o desempenho dos algoritmos de aprendizado de máquina.

Concluída a etapa de pré-processamento de dados, iniciaram-se as tarefas de aprendizado de máquina, com seleção de ferramentas de Classificação, para verificar a ocorrência ou não de termos aditivos, e Regressão, para quantificar o impacto dos termos aditivos, com a utilização do pacote *Lazy Predict* disponível na biblioteca *scikit-learn*. Os que apresentaram melhores performances foram selecionados e terão seus resultados apresentados na próxima seção deste trabalho. Para verificar o problema de *overfitting*, comum em aplicações de aprendizado de máquina, também se utilizou a validação cruzada (Berrar, 2019). O *pipeline* de KDD utilizado é ilustrado na Figura 2. Na avaliação dos resultados, foram utilizadas as métricas de acurácia, precisão, revocação e f1-score para classificação, e raiz do erro quadrático médio (RMSE), o erro médio absoluto (MAE) e o coeficiente de determinação (r^2) para regressão.

Figura 2: Processo KDD.



Fonte: Os autores

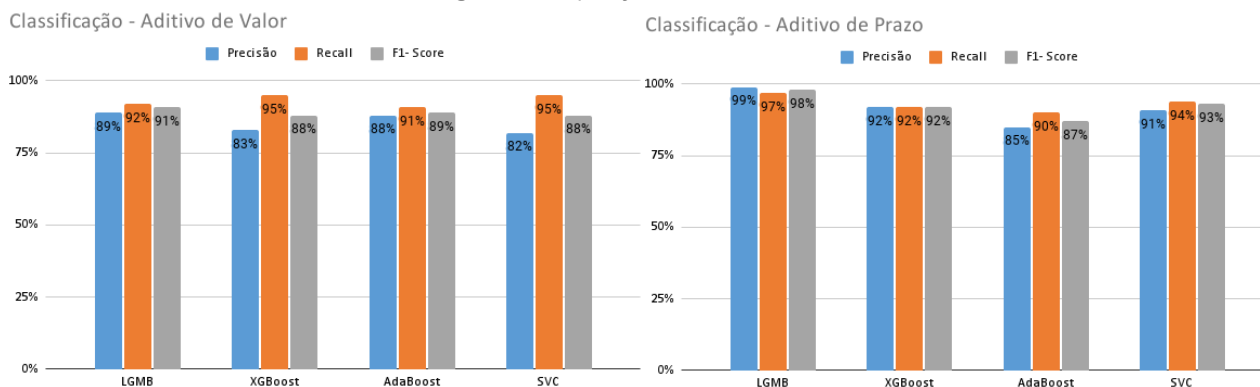
Devido à alta dimensionalidade dos dados de entrada, caracterizada pelo grande número de colunas (atributos), a tentativa de otimização dos hiperparâmetros resultou em um elevado custo computacional, com tempo de processamento significativamente prolongado. Diante dessa limitação, optou-se por utilizar os algoritmos com hiperparâmetros padrão disponibilizados pela biblioteca *Scikit-Learn*.

4 RESULTADOS E DISCUSSÃO

A partir do resultado apresentado pelo pacote *Lazy Predict*, para a etapa de classificação foram escolhidos os algoritmos *LGBM Classifier*, *XGBoost Classifier*, *AdaBoost Classifier*, *Random Forest Classifier*, todos baseados em árvore de decisão, e um algoritmo do tipo *Support Vector Machine*, o SVC. Os algoritmos foram empregados com hiperparâmetros padrões disponíveis na biblioteca *Scikit-Learn*. Além disso, os 927 casos utilizados apresentavam desbalanceamento de classes, em virtude de a maioria de casos disponíveis no OPUS serem da classe com aditivo. Ademais, não foi realizado balanceamento com enriquecimento (criação de casos), pois não seriam criados com informações reais, podendo ocasionar “casos perfeitos”.

Conforme pode ser observado na Figura 2, os resultados apresentados foram comparados com os valores obtidos por meio da validação cruzada, realizada utilizando a técnica de *k-fold cross-validation* com cinco subconjuntos (ou *folds*) da base de dados (Tabela 1) Nesse procedimento, o conjunto total foi dividido em cinco partes aproximadamente iguais: em cada iteração, quatro partes foram usadas para o treinamento do modelo e a parte restante foi utilizada para o teste. Esse processo foi repetido cinco vezes, alternando o subconjunto destinado ao teste, o que proporciona uma avaliação mais robusta e menos sensível a variações específicas de uma única divisão dos dados (Berrar, 2019). Para a classificação da previsão de aditivo de valor na classe positiva (ocorrência de aditivos), o conjunto de teste obteve métricas de acurácia, precisão, revocação e F1-score superiores a 80%. Já no caso da classificação da previsão de aditivo de prazo, utilizando as mesmas métricas, os resultados para a classe positiva foram superiores a 85%, com os algoritmos baseados em árvore de decisão com as métricas acima de 90%, conforme Figura 2 e Tabela 2.

Figura 2: Comparação dos classificadores.



Fonte: Os autores

Tabela 1: Comparação dos classificadores para aditivo de valor

MODELO	ACURÁCIA MÉDIA	DESVIO PADRÃO
LGBM	88,27%	3,23%
XGBoost	94,42%	4,4%
AdaBoost	87,48%	1,93%
Random Forest	92,27%	4,39%
SVC	97,84%	2,15%

Fonte: Os autores

Tabela 2: Comparação dos classificadores para aditivo de prazo

MODELO	ACURÁCIA MÉDIA	DESVIO PADRÃO
LGBM	93,55%	5,20%
XGBoost	97,42%	2,82%
AdaBoost	92,67%	1,17%
Random Forest	91,78%	4,22%
SVC	85,35%	4,09%

Fonte: Os autores

Em seguida, o pacote *Lazy Predict* foi utilizado novamente, na tarefa de regressão para quantificação do impacto dos aditivos de prazo e valor nos contratos, o qual foi implementado com os mesmos dados da classificação. Os algoritmos *LGBM Regressor*, *Random Forest Regressor* e *MLP Regressor* apresentaram os melhores resultados na análise estatística dos conjuntos apresentados, com métricas comparativas do conjunto de teste e previstos pelos algoritmos, apresentados nas Tabelas 3 e 4.

Tabela 3: Comparação dos regressores para aditivo de valor

INDICADOR	TESTE	RANDOM FOREST	LGBM	MLP
Amostras	186	186	186	186
Média	0,15240	0,16882	0,16339	0,35473
Desvio Padrão	0,17967	0,08676	0,10353	0,15239
Mínimo	0,00000	0,00004	-0,03247	0,00952
1º Quartil	0,00000	0,10955	0,09008	0,24896
2º Quartil	0,09041	0,17701	0,16142	0,33268
3º Quartil	0,26558	0,22828	0,23394	0,43114
Máximo	0,93166	0,39382	0,59142	0,84195

Fonte: Os autores

Tabela 4: Comparação dos regressores para aditivo de prazo

INDICADOR	TESTE	RANDOM FOREST	LGBM	MLP
Amostras	186	186	186	186
Média	0,06707	0,06781	0,06729	0,06271
Desvio Padrão	0,08784	0,08687	0,08376	0,14044
Mínimo	0,00000	0,0008	-0,01018	-0,41567
1º Quartil	0,00000	0,00672	0,00818	-0,00919
2º Quartil	0,03766	0,03786	0,03769	0,06467
3º Quartil	0,08717	0,08898	0,08821	0,13645
Máximo	0,49467	0,54001	0,41439	0,56809

Fonte: Os autores

Observa-se que para os modelos gerados pelos algoritmos *LGBM* e *MLP (Multilayer Perceptron)* há valores negativos, o que representaria no caso do aditivo de prazo que um contrato seria executado em prazo inferior ao contratado, diferentemente do que se observa no conjunto de teste. Tais resultados reforçam a necessidade da análise do especialista nos resultados previstos pelos algoritmos de aprendizado de máquina. Adicionalmente, foram calculadas as métricas de erros nos resultados previstos, apresentados nas Tabelas 3 e 4.

Para regressores, é importante analisar métricas adicionais como a raiz do erro quadrático médio (RMSE), o erro médio absoluto (MAE) e o coeficiente de determinação (r^2) no conjunto predito (Gneiting; Raftery, 2007). Por isso, utilizando validação cruzada com 5 conjuntos de dados, apresentam-se estas medidas na Tabela 5, para aditivo de valor e na Tabela 6, para prazo.

Tabela 5: Erro dos algoritmos regressores para aditivo de valor

MODELO	RMSE Médio	RMSE Desvio Padrão	MAE Médio	MAE Desvio Padrão	r2 Médio	r2 Desvio Padrão
<i>Random Forest</i>	0,16158	0,00634	0,11567	0,01001	0,20567	0,03831
<i>LGBM</i>	0,15262	0,00462	0,10900	0,00654	0,28485	0,02442
<i>MLP</i>	0,26188	0,02336	0,19216	0,02937	-1,277826	1,24810

Fonte: Os autores

Tabela 6: Erro dos algoritmos regressores para aditivo de prazo

MODELO	RMSE Médio	RMSE Desvio Padrão	MAE Médio	MAE Desvio Padrão	r2 Médio	r2 Desvio Padrão
<i>Random Forest</i>	0,02953	0,00088	0,00955	0,00241	0,92128	0,04686
<i>LGBM</i>	0,03611	0,00137	0,01283	0,00357	0,88578	0,07574
<i>MLP</i>	0,16289	0,01771	0,10819	0,03025	-1,99814	1,14001

Fonte: Os autores

É possível observar que o modelo *MLP* apresenta um coeficiente de determinação (r^2) negativo, impactado por previsões discrepantes, o que indica que o modelo teve desempenho inferior ao de uma simples média dos valores observados. Além disso, os valores das métricas de erro, como o RMSE e o MAE, demonstram desvios acentuados entre os valores previstos e os reais, reforçando a inadequação do MLP para o conjunto de dados utilizado. Esses resultados indicam que o modelo não conseguiu capturar a relação entre as variáveis de entrada e a variável de saída, possivelmente devido à combinação entre a alta dimensionalidade dos dados e o tamanho relativamente reduzido da amostra disponível para treinamento. Por essas razões, as previsões geradas pelo MLP foram descartadas na análise comparativa de desempenho.

5 CONSIDERAÇÕES FINAIS

Comparando-se os resultados apresentados na regressão para aditivo de valor e prazo, verifica-se que os modelos apresentam melhor previsão do impacto de tempo nos contratos do que os valores que serão aditivados. Porém, com uma estimativa precisa da duração total do objeto, é possível realizar uma boa programação de descentralização de recursos. Além disso, na predição do aditivo de prazo o modelo *Random Forest* se mostra conservador, o que pode impactar no planejamento da descentralização de recursos. Outrossim, os erros discrepantes apresentados pelo modelo MLP, reforçam a necessidade de um especialista do domínio analisar os resultados preditos.

Dessa forma, com o presente trabalho, pode-se concluir que as ferramentas de inteligência artificial podem ser utilizadas no suporte à decisão em nível estratégico do planejamento de recursos para execução de obras públicas. Assim, o gestor alinha o conhecimento do domínio com os resultados apresentados na classificação e regressão, embasando as tomadas de decisão.

Como trabalhos futuros, é possível propor o emprego dos modelos utilizados em dados do Portal da Transparência do governo federal, de modo a auxiliar outros órgãos da administração pública na gestão de recursos financeiros. Sugere-se, ainda, a otimização dos hiperparâmetros dos modelos, especialmente do *MLP*, visando à redução da discrepância dos resultados preditos por este modelo e melhorar o desempenho geral do algoritmo. Outro ponto relevante seria a aplicação de métodos de seleção de atributos (*feature selection*), com o objetivo de reduzir a dimensionalidade e aumentar a capacidade de generalização dos modelos.

REFERÊNCIAS

- BERRAR, D. Cross-validation. **Encyclopedia of Bioinformatics and Computational Biology**, v. 1, p. 542–545, 2019.
- BRASIL. **Lei nº 8.666, de 21 de junho de 1993**. Regulamenta o art. 37, inciso XXI, da Constituição Federal, institui normas para licitações e contratos da Administração Pública e dá outras providências. Brasília, DF: [s.n.], 1993.
- BRASIL. **Lei complementar nº 101, de 4 de maio de 2000**. Estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências. Brasília, DF: [s.n.], 2000.
- BRASIL. Tribunal de Contas da União. **Recomendações básicas para a contratação e fiscalização de obras de edificações públicas**. Brasília, DF: TCU, 2014.
- BRASIL. **Lei nº 14.133, de 1º de abril de 2021**. Lei de Licitações e Contratos Administrativos. Brasília, DF: [s.n.], 2021a.
- BRASIL. **Lei nº 14.129, de 29 de março de 2021**. Dispõe sobre princípios, regras e instrumentos para o Governo Digital e para o aumento da eficiência pública e altera a Lei nº 7.116, de 29 de agosto de 1983, a Lei nº 12.527, de 18 de novembro de 2011 (Lei de Acesso à Informação), a Lei nº 12.682, de 9 de julho de 2012, e a Lei nº 13.460, de 26 de junho de 2017. Brasília, DF: [s.n.], 2021b.
- COSTA, M. B.; BASTOS, P. R. L. Alice, Monica, Adele, Sofia, Carina e Ágata: o uso da inteligência artificial pelo Tribunal de Contas da União. **Controle Externo: Revista do Tribunal de Contas do Estado de Goiás**, Goiânia, v. 3, p. 11–34, jan./jun. 2020.
- CROCE, J. C. B.; MELLO, S. M. C. C.; AZEVEDO, W. A. **Decisão por empreitada global ou unitária em obras públicas de reformas de edificações**. Rio de Janeiro: Pontifícia Universidade Católica/ Tribunal de Contas do Estado do Rio de Janeiro, 2008.
- CUB. **Custo unitário básico: indicador de custos do setor da construção civil**. Disponível em: <<http://www.cub.org.br/>>. Acesso em: 04 jul. 2024.
- FERNANDES, Fernanda Louize Monteiro Brocardo; SCHEER, Sérgio; MICELI JUNIOR, Giuseppe. O uso da Modelagem da Informação da Construção (BIM) no ciclo de vida de edificações militares. **Revista Militar de Ciência e Tecnologia**, Rio de Janeiro, RJ, v. 37, n. 4, outubro, 2020. Disponível em: <<https://ebrevistas.eb.mil.br/CT/article/view/8568/7421>>. Acesso em: 02 fev. 2025.
- FGV-IBRE. **Índice Nacional de Custo da Construção**. Disponível em: <<https://portalibre.fgv.br/incc>>. Acesso em: 04 jul. 2024.
- GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2 ed. O'Reilly Media, 2019.
- GNEITING, Tilmann; RAFTERY, Adrian E. Strictly proper scoring rules, prediction, and estimation. **Journal of the American Statistical Association**, v. 102, n. 477, p. 359-378, 2007.
- HAO, J.; HO, T. K. Machine learning made easy: a review of scikit-learn package in Python programming language. **Journal of Educational and Behavioral Statistics**, v. 44, n. 3, p. 348–361, 2019.
- KURZWEIL, Ray et al. **The age of intelligent machines**. Cambridge: MIT press, 1990.
- MICELI JUNIOR, G. **Modelagem de Informação da Construção para Gestão de Projetos de Obras de Infraestrutura de Defesa**. 2019. Tese (Doutorado em Engenharia) – Instituto Militar de Engenharia, Rio de Janeiro.
- NILSON, Nils J. **Introduction to machine learning**. Robotics Laboratory. Department of Computer Science Stanford University. Stanford. USA, 1998.
- PEIXOTO, A. A. A.; PEIXOTO, A. G. Restos a pagar: um procedimento contábil legalmente instituído com severas implicações no equilíbrio orçamentário. In: **I Congresso Internacional de Desempenho do Setor Público**, 2017.
- RUSSELL, S. J.; NORVIG, P. **Inteligência artificial**. Tradução de Regina Célia Simille. Rio de Janeiro: Elsevier, 2013.
- SCIKIT-LEARN. Scikit-learn: machine learning in Python. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 19 jun. 2025.