

COMPARAÇÃO DE ALGORITMOS DE APRENDIZADO SUPERVISIONADO NA DETECÇÃO DE FRAUDES ONLINE ODS (9)

Alan Alves de Sales (Universidade de Taubaté)
Gabriel Peixoto Fialho Costa (Universidade de Taubaté)
Luiz Eduardo Souza Evangelista (Universidade de Taubaté)
Luis Fernando de Almeida (Universidade de Taubaté)

O crescimento acelerado das fraudes em transações bancárias e com cartões de crédito tem colocado em evidência a necessidade de soluções tecnológicas eficazes para proteção do sistema financeiro. Este trabalho tem como objetivo avaliar o desempenho de algoritmos supervisionados de aprendizado de máquina na identificação automática de transações fraudulentas. Para isso, foi desenvolvido um fluxo metodológico composto por etapas de análise exploratória, pré-processamento e balanceamento do conjunto de dados por meio da técnica *Synthetic Minority Over-sampling Technique* (SMOTE), aplicada antes da divisão do conjunto em treino e teste. Após o balanceamento, os dados foram divididos em aproximadamente 70% para treino e 30% para teste, resultando em cerca de 85.500 registros para avaliação, incluindo aproximadamente 150 casos de fraude, com as classes já balanceadas para melhor desempenho dos modelos. Foram utilizados algoritmos reconhecidos por sua eficiência em problemas de classificação complexos, como Random Forest, AdaBoost, CatBoost, XGBoost e LightGBM, implementados em linguagem Python com o uso de bibliotecas especializadas em aprendizado de máquina. A avaliação dos modelos foi realizada com base em métricas adequadas para bases desbalanceadas e para problemas os quais falsos negativos são críticos, incluindo precisão, recall e F1-score. Os resultados mostraram que Random Forest, XGBoost, CatBoost e LightGBM apresentaram desempenhos bons e relativamente semelhantes. O Random Forest atingiu precisão de 0,88, recall de 0,79 e F1-score de 0,83 para a classe fraude. O XGBoost apresentou precisão de 0,42, recall de 0,84 e F1-score de 0,56. O LightGBM obteve precisão de 0,69, recall de 0,78 e F1-score de 0,73. Já o CatBoost alcançou precisão de 0,72, recall de 0,82 e F1-score de 0,77. Em contraste, o AdaBoost apresentou recall relativamente alto de 0,86, mas com precisão extremamente baixa com 0,10 e F1-score de apenas 0,19, resultando em muito mais falsos positivos em relação aos demais. Além disso, enquanto a média de tempo de execução dos outros modelos ficou entre 1 e 2 minutos, o AdaBoost levou quase 5 minutos para completar os testes. Conclui-se então que a combinação de boas práticas de tratamento de dados com algoritmos supervisionados de aprendizado de máquina oferece uma solução promissora para fortalecer os mecanismos de segurança no setor bancário, auxiliando instituições na tomada de decisões

estratégicas, na mitigação de riscos e na redução de prejuízos causados por atividades ilícitas.

Palavras-chave: Detecção de fraudes; Aprendizado de máquina; Classificação supervisionada; Transações bancárias; SMOTE.