

PREVISÃO DE DIFICULDADE FINANCEIRA COM XGBOOST: EVIDÊNCIAS NO SETOR DE UTILIDADE PÚBLICA DA AMÉRICA LATINA

Predicting Financial Distress with XGBoost: Evidence from the Latin American Utility Sector

JOÃO PEDRO SILVA MENDES

UNIVERSIDADE FEDERAL DE UBERLÂNDIA - UFU

DANIEL VITOR TARTARI GARRUTI

FACULDADE DE GESTÃO E NEGÓCIOS - FAGEN/UFU

FLAVIO LUIZ DE MORAES BARBOZA

UFU

Comunicação:

O XIII SINGEP foi realizado em conjunto com a 13th Conferência Internacional do CIK (CYRUS Institute of Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

PREVISÃO DE DIFICULDADE FINANCEIRA COM XGBOOST: EVIDÊNCIAS NO SETOR DE UTILIDADE PÚBLICA DA AMÉRICA LATINA

Objetivo do estudo

Avaliar o desempenho do XGBoost na previsão de dificuldade financeira em empresas latino-americanas do setor de utilidade pública, identificando variáveis contábeis e de mercado mais relevantes e comparando-o com modelos tradicionais.

Relevância/originalidade

O estudo contribui ao aplicar machine learning com foco setorial, melhorando acurácia e interpretabilidade em contextos de mercados emergentes. Analisa métricas preditivas e importância de variáveis, reforçando abordagens específicas por setor, timidamente exploradas na previsão de risco financeiro corporativo na América Latina.

Metodologia/abordagem

Utilizou-se base de 103 empresas em seis países (2000–2019), aplicando definições múltiplas de dificuldade financeira (FD1–FD4). Divisão temporal treino/teste, undersampling e implementação do XGBoost em Python. Avaliaram-se AUC, acurácia, Brier Score, erros Tipo I/II e importância das variáveis.

Principais resultados

O XGBoost superou os modelos tradicionais, especialmente em FD1 e FD4 (acurácia >94%, erro Tipo II = 0). Variáveis-chave: rentabilidade (FD1, FD4), mercado e crescimento de vendas (FD2, FD3). Percebeu-se que a especialização setorial aumentou o poder preditivo, ao menos nesse contexto.

Contribuições teóricas/metodológicas

Evidencia-se que modelos setoriais de machine learning melhoram desempenho e interpretação na previsão de risco financeiro. Integra métricas preditivas e análise de variáveis, ampliando literatura sobre aplicação de XGBoost em mercados emergentes e propondo abordagem replicável para estudos similares.

Contribuições sociais/para a gestão

O modelo auxilia analistas, investidores e reguladores na detecção antecipada de deterioração financeira, otimizando decisões de crédito, mitigação de riscos e alocação de capital. Aumenta previsibilidade e transparência, fortalecendo gestão estratégica e estabilidade no setor de utilidade pública latino-americano.

Palavras-chave: Gestão de Riscos, Risco de Crédito, Aprendizado de Máquina, Mercados Emergentes, Insolvência

Predicting Financial Distress with XGBoost: Evidence from the Latin American Utility Sector

Study purpose

To assess XGBoost performance in predicting financial distress in Latin American utility companies, identifying the most relevant accounting and market variables, and comparing it with traditional models.

Relevance / originality

The study applies machine learning with a sector-specific focus, enhancing accuracy and interpretability in emerging contexts. It analyzes predictive metrics and variable importance, reinforcing sector-specific approaches, still underexplored in corporate financial risk prediction in Latin America.

Methodology / approach

Dataset of 103 companies from six countries (2000–2019), applying multiple definitions of financial distress (FD1–FD4). Temporal train/test split, undersampling, and XGBoost implementation in Python. Evaluated AUC, accuracy, Brier Score, Type I/II errors, and variable importance.

Main results

XGBoost outperformed logistic regression and random forest, especially in FD1 and FD4 (accuracy >94%, Type II error = 0). Key variables: profitability (FD1, FD4), market valuation and sales growth (FD2, FD3). Sector specialization improved predictive consistency.

Theoretical / methodological contributions

Demonstrates that sector-specific machine learning models improve performance and interpretability in financial risk prediction. Integrates predictive metrics and variable analysis, expanding literature on XGBoost applications in emerging markets and proposing a replicable approach for future studies.

Social / management contributions

The model supports analysts, investors, and regulators in early detection of financial deterioration, optimizing credit decisions, risk mitigation, and capital allocation. Enhances predictability and transparency, strengthening strategic management and stability in the Latin American utility sector.

Keywords: Risk Management, Credit Risk, Machine Learning, Emerging Markets, Insolvency