

Universidade de Pernambuco

Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Tese de Doutorado

Área: Computação Inteligente

Título: Modelos Inteligentes na Previsão de Risco de Crédito.

Orientador(a): Roberta Andrade de A. Fagundes (roberta.fagundes@upe.br)

Descrição:

Nos últimos anos, esforços contínuos têm sido feitos na busca de eficiência na gestão de crédito [1]. A questão central é o controle de risco implementado no momento da concessão do crédito. O agente financeiro define a taxa de juros do empréstimo levando-se em consideração a possibilidade do cliente não honrar com as suas obrigações. Se a inadimplência de um credor for maior que o valor previsto, a rentabilidade do negócio provavelmente será comprometida.

É fato que toda operação de crédito está sujeita ao risco de inadimplência por parte dos devedores. Em um sistema financeiro não há a garantia de que 100% do que foi emprestado será pago nas datas acordadas. Assim, cada nova solicitação de concessão de empréstimo demanda avaliações criteriosas de risco por parte das instituições credoras. Essas avaliações levam em consideração à análise sobre as mais diversas características do solicitante, necessita de tempo e envolvem custos elevados para sua análise e conclusão. Uma classificação errada suscita em perdas financeiras para as instituições envolvidas [2].

O volume de dados e a incorporação de variáveis preditivas cresceram a um ponto de que técnicas apenas estatísticas, que pressupõem comportamentos específicos dos dados, deixassem de ser tão eficientes. É neste momento que começam a ser incorporadas técnicas de *Machine Learning* (ML) na atividade de avaliação de risco de crédito. Algumas das vantagens de aplicar métodos de ML é que eles trazem mais rapidez nas análises de crédito, como também, maior assertividade [3].

Vários estudos na literatura demonstram o benefício na aplicação de métodos de *machine learning* para construção de modelos de risco de crédito [4]. Estes estudos incluem desde o uso de Rede Neurais [5], passando por *Random Forest* (RF) [6], *Support Vector Machine* (SVM)[7] e incluem até métodos de *ensemble learning* (*boosting* e *bagging*)[8].

Assim, o principal objetivo deste projeto é a proposição de modelos inteligentes baseado em técnicas de ML aplicados ao problema de risco de crédito. Aplicação de algumas técnicas de otimização de hiperparâmetros poderão ser executadas, de forma a melhorar a desempenho dos modelos preditivos, com intuito de melhorar a aplicação de crédito.

Referências Bibliográficas:

- [1] Alexandre Jorge Chaia. Modelos de Gestão do Risco de Crédito e sua Aplicabilidade ao Mercado Brasileiro. USP, 1 ed. edition, 2023.
- [2] Grmanova, E.; Ivanova, E. Efficiency of banks in Slovakia: Measuring by DEA models. Journal of International Studies Vol, 11(1), 2018.
- [3] S. Lessmann et al. "Benchmarking state-of-art classification algorithms for credit scoring: an update of research." European Journal of Operational Research, 247, 124-136, 2015.
- [4] Louzada, F., Ara, A., & Fernandes, G. B. "Classification methods applied to credit scoring: Systematic review and overall comparison." Surveys in Operations Research and Management Science, 21(2), 117-134, 2016.
- [5] C. F. Tsai and J.-W. Wu, "Using neural network ensembles for bankruptcy prediction and credit scoring," Expert systems with applications, vol. 34, no. 4, pp. 2639–2649, 2008.
- [6] Malekipirbazari M, Aksakalli V. Risk assessment in social lending via random forests. Expert Systems with Applications, 2015, 42(10): 4621-4631.
- [7] C.L. Huang, H. Chen, C.-J. Hsu, W.-H. Chen, S. Wu, Credit rating analysis with support vector machines and neural networks: a market comparative study, Decision Support Systems 37 (2004) 543–558.
- [8] Xia, Y., Liu, C., Li, Y., & Liu, N. "A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring." Expert Systems with Applications, 78, 225-241, 2017.