

Predição de Customer LifeTime Value: Uma Abordagem de Aprendizado de Máquina

Gabriel Luiz Magalhães Amorim
João Marcos Alves Modesto Ramos
Fabrício Aguiar Silva

Pesquisa

ODS: Indústria, Inovação e Infraestrutura

Introdução

No cenário atual dos negócios, conquistar novos clientes pode custar até 5 vezes mais que manter aqueles que já estão ativos. Esse pensamento fez com que empresas mudassem o foco de uma abordagem centrada apenas no produto para estratégias voltadas ao cliente. Nesse contexto, o Customer Lifetime Value ou simplesmente LTV se mostra como medida extremamente necessária para estimar a rentabilidade de cada cliente. Apesar de sua importância, o cálculo é um grande desafio uma vez que possui diversos parâmetros que variam para cada modelo de negócio. Por consequência, métodos tradicionais se mostram limitados e não aplicáveis em um contexto realista.

Objetivos

A partir desse desafio, a pesquisa buscou desenvolver soluções para a previsão do LTV usando técnicas de aprendizado de máquina, comparando-as com os métodos clássicos utilizados até então na literatura. Apesar de ser o principal foco da pesquisa, ela não se limita a estimar o valor em um cenário controlado, mas também a desenvolver abordagens genéricas que possam ser aplicadas a diversos contextos de mercados. Ademais, a intenção é evidenciar que a aplicação dos modelos de aprendizado de máquina nesse contexto pode tornar o LTV uma ferramenta de fácil acesso para orientar a tomada de decisão interna de empresas.

Material e Métodos

Para validar a abordagem proposta, foram analisadas bases de dados reais que, juntas, representam aproximadamente 200.000 clientes em contextos que incluem e-commerce, varejo e bancos. Foram comparados o desempenho de modelos probabilísticos tradicionais com abordagens de aprendizagem de máquina. Essa abordagem se mostra necessária uma vez que a precisão dos modelos pode ser alterada em diferentes contextos. Portanto, a medida que se usam dados de contextos distintos, pode-se ter uma melhor validação do desempenho dos modelos e garantir, também, uma versatilidade da solução proposta.

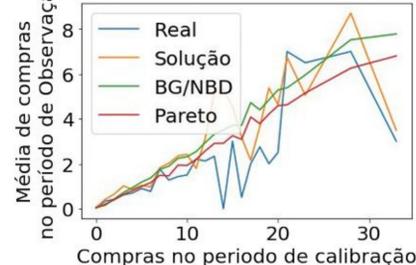
Apoio Financeiro



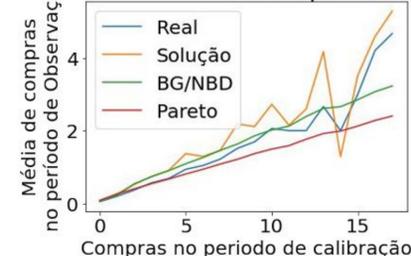
Resultados

Os testes evidenciaram que os modelos baseados em aprendizado de máquina superaram em consistente os métodos tradicionais, as novas abordagens trouxeram uma redução de até 34% no erro da previsão. Além disso, quando aplicadas técnicas mais robustas na engenharia de dados, a melhora consegue alcançar os 80% de redução no erro. Os avanços citados evidenciam o potencial do uso de dados transacionais para previsões mais robusta, mesmo em cenários com grande distinção entre perfis de clientes.

Compras no período de Observação vs Previsto na Base CDNOW



Compras no período de Observação vs Previsto na Base OpenCDP



Conclusões

Os resultados alcançados reforçam que a abordagem de aprendizado de máquina oferece uma alternativa para tornar viável o uso do LTV para contextos reais. Ou seja, o LTV pode se tornar uma métrica importante para a análise de perfil de clientes, o que, por sua vez, facilita a elaboração de estratégias de marketing, por exemplo. De forma distinta aos métodos clássicos, a nova abordagem traz uma agilidade e precisão desse cálculo nunca antes vista.

Bibliografia

Desirena, G., Diaz, A., Desirena, J., Moreno, I., and Garcia, D. (2019). Maximizing customer lifetime value using stacked neural networks: An insurance industry application. Proceedings of the 2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA), pp. 541–544.

Mendez-Suárez, M. and Crespo-Tejero, N. (2021). Why do banks retain unprofitable customers? A customer lifetime value real options approach. Journal of Business Research, 122:621–626.

Sun, Y., Liu, H., and Gao, Y. (2023). Research on customer lifetime value based on machine learning algorithms and customer relationship management analysis model. Heliyon, 9(2):e13384.