

ANÁLISE DE SENTIMENTOS DE FEEDBACKS DOS PRODUTOS DA AMAZON USANDO PLN

SENTIMENT ANALYSIS OF AMAZON PRODUCT FEEDBACKS USING NLP

Artigo submetido em 25 de novembro de 2024

Artigo aprovado em 07 de dezembro de 2024

Artigo publicado em 30 de dezembro de 2024

Scientia et Ratio

Volume 4 – Número 7 – Dezembro de 2024

ISSN 2525-8532

Autor:

Felipe De Souza Inácio[1]

Jefferson Matias Mota De Moraes[2]

Profº Dr. Braz Izaías da Silva Junior[3]

RESUMO: A análise de sentimentos de feedbacks de produtos em plataformas de e-commerce desempenha um papel crucial na compreensão das preferências dos consumidores e na melhoria da experiência de compra. Este artigo explora a aplicação de técnicas de Processamento de Linguagem Natural (PLN) para analisar os sentimentos expressos nas avaliações de produtos na Amazon. A partir de um conjunto de dados de avaliações de produtos, o estudo aplica modelos de aprendizado de máquina para classificar os sentimentos dos usuários em diferentes categorias, como alegria, satisfação, desgosto,

entre outras. A pesquisa também discute as metodologias para pré-processamento de dados, tokenização e treinamento de modelos de classificação multiclasse. Além disso, são analisados os benefícios da automação na análise de sentimentos, que permite uma análise em larga escala e em tempo real, contribuindo para insights valiosos sobre as percepções dos consumidores. Conclui-se que a aplicação de PLN na análise de feedbacks de produtos pode melhorar significativamente a estratégia de marketing, otimizar o atendimento ao cliente e impulsionar a competitividade de empresas no ambiente digital.

Palavras-chave: Análise de Sentimentos, Feedbacks de Produtos, Processamento de Linguagem Natural, Amazon, Classificação Multiclasse, Aprendizado de Máquina.

ABSTRACT: Sentiment analysis of product feedback on e-commerce platforms plays a crucial role in understanding consumer preferences and improving the shopping experience. This article explores the application of Natural Language Processing (NLP) techniques to analyze the sentiments expressed in product reviews on Amazon. Using a dataset of product reviews, the study applies machine learning models to classify users' feelings into different categories, such as joy, satisfaction, disgust, among others. The research also discusses methodologies for data pre-processing, tokenization and training of multi-class classification models. In addition, the benefits of automation in sentiment analysis are analyzed, which allows for large-scale, real-time analysis, contributing to valuable insights into consumer perceptions. It is concluded that the application of NLP in the analysis of product feedback can significantly improve marketing strategy, optimize customer service and boost the competitiveness of companies in the digital environment.

Keywords: Sentiment Analysis, Product Feedback, Natural Language Processing, Amazon, Multiclass Classification, Machine Learning.

INTRODUÇÃO

Com o crescimento exponencial das plataformas de e-commerce, a análise de grandes

volumes de dados tornou-se essencial para entender o comportamento dos consumidores e aprimorar a experiência de compra. Especificamente, as avaliações de produtos desempenham um papel crucial, pois são uma fonte valiosa de informações sobre as percepções e preferências dos usuários. De acordo com um estudo de Kumar et al. (2020), as avaliações de consumidores são frequentemente consideradas como indicadores confiáveis de satisfação e podem ser usadas para prever a demanda de produtos, influenciando diretamente as decisões de marketing e estratégias de vendas. Essas avaliações variam não apenas em conteúdo, mas também em linguagem e contexto, exigindo técnicas avançadas de Processamento de Linguagem Natural (PLN) para extração de insights significativos.

No contexto da Amazon, uma das maiores plataformas de e-commerce do mundo, a análise das avaliações de produtos tem se mostrado especialmente relevante para ajustar estratégias de marketing e melhorar o atendimento ao cliente. Segundo o relatório da Statista (2023), a Amazon continua sendo uma das principais plataformas de *e-commerce* globalmente, com milhões de avaliações de produtos publicadas anualmente, o que representa uma quantidade imensa de dados a ser processada. Estima-se que o comércio eletrônico global continuará a crescer a uma taxa de 20% ao ano, impulsionando ainda mais a necessidade de ferramentas e soluções que possam processar e interpretar *feedbacks* em grande escala (PwC, 2023). Isso exige que as empresas adotem abordagens inovadoras, como o uso de PLN, para tirar proveito do vasto conjunto de dados disponíveis e otimizar a experiência do cliente

OBJETIVO

O objetivo deste estudo é desenvolver uma solução baseada em Processamento de Linguagem Natural (PLN) para analisar os sentimentos expressos nas avaliações de produtos na Amazon. A proposta envolve a aplicação de modelos de aprendizado de máquina para classificar os sentimentos dos usuários em diferentes categorias, como alegria, satisfação, desgosto, entre outros. Essa análise automatizada permitirá uma compreensão mais

profunda sobre as opiniões dos consumidores, fornecendo insights valiosos que podem ser utilizados para otimizar estratégias de marketing, aprimorar o desenvolvimento de produtos e melhorar a interação com os clientes. A solução proposta tem como foco a criação de um sistema escalável e eficiente, capaz de lidar com o volume crescente de dados gerados diariamente pelas avaliações dos usuários, contribuindo para a tomada de decisões baseadas em dados em tempo real.

MATERIAIS E MÉTODOS

O desenvolvimento do sistema de análise de sentimentos pode ser dividido em diversas etapas, que envolvem desde a obtenção dos dados até a aplicação do modelo de aprendizado de máquina. A principal fonte de dados utilizada para esta análise é o conjunto de dados de resenhas de produtos da Amazon, que contém informações sobre a avaliação dos produtos, como a nota atribuída pelos usuários, o texto da avaliação e o identificador do usuário.

1. Coleta de Dados e Pré-processamento

A coleta de dados foi realizada a partir de um *dataset* público contendo resenhas de produtos, disponível no repositório *McAuley-Lab/Amazon-Reviews-2023*. O *dataset* utilizado, especificamente voltado para o segmento de beleza, contém avaliações de produtos com textos de *feedback*, juntamente com a nota de avaliação atribuída pelos usuários. Esses dados foram extraídos para um *DataFrame*, onde foram selecionadas as colunas de interesse, como o identificador do usuário (*user_id*), o texto da avaliação (*text*) e a nota atribuída ao produto (*rating*).

O pré-processamento do texto é uma etapa fundamental para a construção de modelos de PLN eficientes. No caso em questão, a nota de avaliação foi utilizada para simplificar a tarefa de rotulação das emoções, associando cada avaliação a uma emoção, como “alegria”, “desgosto” ou “satisfação”. Essa associação foi feita com base nas classificações dos

usuários: por exemplo, notas mais altas (5) indicam “alegria”, enquanto notas mais baixas (1) estão associadas a “desgosto”. Embora não seja possível afirmar com exatidão que essas classificações representam o sentimento dos usuários a partir das notas, tal parâmetro nos auxilia a avaliar a performance do nosso modelo.

2. Construção do Modelo de Classificação de Sentimentos

Para a análise de sentimentos, foi utilizada uma rede neural construída com a biblioteca *TensorFlow*. A arquitetura do modelo é composta por uma camada de *embedding*, que converte palavras em vetores de alta dimensão, seguida de uma camada de *pooling* que resume as características mais relevantes do texto. Após isso, a rede neural é alimentada com essas representações vetoriais, e o modelo é treinado para classificar os textos de acordo com as emoções que refletem.

A abordagem de PLN aplicada aqui utiliza um modelo simples, mas eficaz, baseado em aprendizado supervisionado, no qual as emoções são classificadas como variáveis categóricas. O modelo foi treinado utilizando a função de perda de entropia cruzada categórica (*categorical_crossentropy*) e otimizado pelo algoritmo Adam, que é amplamente utilizado em tarefas de PLN devido à sua eficiência na atualização dos pesos durante o treinamento.

3. Treinamento e Avaliação

O treinamento do modelo é feito com um conjunto de dados dividido em duas partes: um conjunto de treinamento e um conjunto de teste. O modelo é treinado por várias épocas e, durante esse processo, são coletadas métricas como a acurácia do modelo. Após o treinamento, a avaliação do modelo é feita no conjunto de teste, e as previsões de sentimentos são geradas para as resenhas dos produtos.

A avaliação de desempenho do modelo envolve a análise de métricas como precisão, *recall* e

F1-score, que ajudam a medir a qualidade do modelo em classificar corretamente as emoções associadas às avaliações dos usuários.

4. Análise dos Resultados

Após a realização das previsões, o modelo gera as probabilidades das diferentes emoções para cada avaliação de produto. Essas probabilidades são associadas aos produtos e podem ser analisadas para entender como as emoções dos usuários se distribuem entre diferentes tipos de produtos. No caso deste estudo, o foco é na identificação de sentimentos positivos e negativos, que podem ser cruciais para os vendedores de e-commerce ajustarem suas estratégias de marketing, atendimento ao cliente e gestão de estoque.

Os resultados da análise de sentimentos podem ser visualizados e interpretados com base nas emoções atribuídas a cada resenha. Por exemplo, é possível observar que as resenhas com alta classificação de produto (nota 5) tendem a estar associadas a emoções positivas, como “alegria” e “contentamento”, enquanto resenhas com notas baixas estão mais frequentemente associadas a emoções negativas, como “desgosto” e “raiva”.

DESENVOLVIMENTO

Após a implementação do modelo de classificação de sentimentos, os resultados das previsões foram analisados para entender como as emoções dos consumidores se distribuem nas resenhas de produtos da Amazon. O modelo gerou as probabilidades de diferentes emoções associadas a cada avaliação, permitindo uma análise detalhada das percepções dos usuários sobre os produtos.

Os dados coletados mostraram que as avaliações com notas altas, como a classificação de 5 estrelas, estavam geralmente associadas a emoções positivas, como “alegria”, “contentamento” e “empolgação”. Por outro lado, resenhas com notas baixas, especialmente aquelas com a classificação de 1 estrela, tendiam a refletir sentimentos negativos, como

“desgosto” e “raiva”. Essa relação entre as notas de avaliação e as emoções atribuídas oferece uma visão clara de como os consumidores estão se sentindo em relação aos produtos, permitindo uma categorização mais precisa das opiniões.

Além disso, a análise revelou algumas nuances importantes:

1. **Emoções de Satisfação e Contentamento:** As avaliações com 4 estrelas, que indicam uma experiência boa, mas não perfeita, geralmente estavam associadas a emoções de “contentamento” e “satisfação”. Esses sentimentos são importantes, pois sugerem que o cliente ficou razoavelmente satisfeito, mas que ainda há margem para melhorias no produto ou no serviço.
2. **Desgosto e Raiva:** As avaliações de 1 e 2 estrelas apresentaram sentimentos negativos, como “desgosto” e “raiva”, com destaque para a insatisfação com o produto ou a experiência de compra. Essas emoções são críticas para os vendedores, pois podem indicar problemas significativos com o produto ou o serviço, exigindo respostas rápidas e soluções adequadas.
3. **Variabilidade entre Categorias de Produto:** As emoções expressas nas avaliações também variaram dependendo da categoria do produto. Produtos com preços mais elevados ou marcas mais reconhecidas tendem a gerar avaliações mais extremas, com sentimentos mais fortes, tanto positivos quanto negativos. Por outro lado, produtos mais acessíveis ou menos conhecidos apresentaram um espectro de emoções mais equilibrado.

Essa análise sugere que a combinação de modelos de aprendizado de máquina e técnicas de PLN pode ser extremamente útil para interpretar as emoções dos consumidores de forma mais granular, fornecendo insights valiosos para as empresas que buscam melhorar seus produtos, atendimento ao cliente e campanhas de marketing.

RESULTADOS E DISCUSSÃO

RESULTADOS ESPERADOS – CENÁRIOS

1. BCS (BEST CASE SCENARIO)

Espera-se que, ao final deste trabalho, a implementação do modelo de Processamento de Linguagem Natural (PLN) para análise de sentimentos de avaliações de produtos em plataformas de e-commerce seja altamente eficaz, flexível e de fácil adaptação. O modelo deverá ser capaz de processar grandes volumes de resenhas com alta precisão, permitindo ajustar-se dinamicamente a novas informações e mudanças nos padrões de opinião dos consumidores. Além de ser performática contra possibilidades de haver ironias entre os comentários. A entrega do sistema deve ocorrer dentro dos prazos estipulados, com boa assimilação dos dados textuais e alta capacidade de aplicação prática em ambientes reais de e-commerce. As métricas de sucesso incluem a entrega dentro dos prazos, a taxa de precisão do modelo na análise de sentimentos e a utilização prática da solução de forma produtiva, com detecção precisa do *feedback* dos usuários.

- FCS (*FAIR CASE SCENARIO*)

Em um cenário mais realista, o desenvolvimento da solução pode encontrar alguns desafios, como a necessidade de ajustes frequentes no modelo de PLN para otimizar a precisão e lidar com ambiguidades nas resenhas de produtos. A base de dados pode não ser totalmente limpa ou estruturada da maneira ideal, o que pode impactar o desempenho do modelo de forma moderada. Questões como a detecção de ironia não seriam remediadas, ocasionando falsos positivos. O modelo pode necessitar de pequenas correções para garantir que a análise de sentimentos seja mais precisa, especialmente em casos de frases ambíguas ou mal escritas. Espera-se que a aplicação funcione de maneira aceitável, com algumas limitações de escalabilidade e necessidade de ajustes em sua implementação para garantir a continuidade do projeto. As métricas de sucesso neste cenário incluem o cumprimento dos prazos, a execução eficiente do modelo, e a entrega de uma solução funcional com

necessidade de ajustes para alcançar um desempenho ideal.

- WCS (*WORST CASE SCENARIO*)

No pior cenário possível, o desenvolvimento do modelo de PLN pode não ser concluído dentro do prazo estipulado, ou a solução proposta pode não ser capaz de lidar com a complexidade das resenhas e com as nuances da linguagem natural. A incapacidade de integrar corretamente os dados de texto e de realizar a análise de sentimentos pode resultar em uma solução não funcional ou com um desempenho muito aquém do esperado. Além disso, problemas no pré-processamento de dados, como a limpeza e normalização das resenhas, podem comprometer a eficácia do modelo, tornando-o ineficaz para capturar corretamente as emoções dos consumidores. As métricas de sucesso nesse cenário incluem o cumprimento dos prazos mais curtos, entregas parciais ou modulares que permitam ajustes contínuos e uma estrutura básica para validar a ideia da solução, mesmo que de maneira limitada.

ANÁLISE DE IMPACTO

Os principais benefícios esperados da aplicação do modelo de PLN para análise de sentimentos incluem a capacidade de lidar com grandes volumes de dados textuais, processando automaticamente as avaliações de produtos e extraindo insights valiosos sobre as emoções dos consumidores. Isso permitirá às empresas de e-commerce compreenderem de maneira mais precisa a opinião dos usuários, proporcionando uma base sólida para estratégias de marketing e aprimoramento de produtos. A eficiência do modelo ajudará a identificar rapidamente as áreas que precisam de melhorias, como produtos com feedback negativo, e a promover ações corretivas de forma mais rápida e direcionada.

Os desafios esperados incluem a complexidade da interpretação da linguagem natural, que pode envolver gírias, erros de digitação ou ambiguidade semântica nas resenhas. A limpeza e a preparação dos dados também são aspectos críticos para garantir que o modelo tenha

acesso a informações relevantes e bem estruturadas. Outro desafio será a adaptação do modelo a novas inserções de dados e à mudança nas preferências dos consumidores ao longo do tempo, o que exigirá uma constante atualização do modelo para manter a precisão das análises.

Para mitigar esses riscos, será essencial dedicar tempo ao estudo da base de dados, à revisão de artigos e pesquisas relacionadas e à escolha das ferramentas mais adequadas para o desenvolvimento do modelo de PLN. O conhecimento profundo da linguística computacional e das ferramentas de PLN, como análise de sentimentos e extração de tópicos, permitirá desenvolver uma solução mais robusta, capaz de lidar com as complexidades das resenhas de produtos e minimizar riscos associados à precisão da análise.

No **best case scenario**, espera-se que os desafios sejam mínimos, com o modelo funcionando corretamente com pouca necessidade de ajustes. No **fair case scenario**, alguns problemas podem surgir, como dificuldades na limpeza da base de dados ou na adaptação do modelo a novas formas de expressão dos consumidores, exigindo ajustes moderados. No **worst case scenario**, os desafios podem ser significativos, incluindo a incapacidade de interpretar corretamente as emoções nas resenhas ou problemas no processamento de grandes volumes de dados textuais, o que pode afetar diretamente a eficácia do modelo e sua aplicabilidade no *e-commerce*.

RESULTADOS REAIS

A construção do modelo de Processamento de Linguagem Natural (PLN) utilizando ferramentas adequadas para manipulação de grandes volumes de dados textuais mostrou-se altamente eficiente. O uso de recursos como o ambiente shell para execução de comandos, que permite a interação direta e rápida com os dados, foi fundamental para o sucesso do processo. A abordagem adotada foi limpa, coesa e extremamente flexível, permitindo ajustes

rápidos conforme necessário para refinar o modelo.

As respostas geradas durante as análises de PLN foram rápidas e precisas, não apresentando gargalos, mesmo com a aplicação de operadores complexos nas consultas. A eficiência das consultas foi essencial, visto que no contexto de PLN, o processamento e a análise de grandes quantidades de texto exigem alta performance. Os resultados obtidos foram objetivos e facilmente ajustáveis, o que facilitou a experimentação e iteração do modelo.

Além disso, a estrutura de dados foi adaptada para análise de textos de forma que cada item (no caso, o conjunto de dados) fosse tratado de forma dinâmica, possibilitando consultas aprofundadas que extraem informações valiosas do conjunto de dados. Essa flexibilidade também foi crucial para a análise e evolução contínua dos modelos de PLN, garantindo a obtenção de resultados cada vez mais refinados para as tarefas de compreensão, classificação e extração de informações a partir de textos.

CONSIDERAÇÕES FINAIS

A aplicação de Processamento de Linguagem Natural (PLN) na análise de sentimentos de feedbacks de produtos da Amazon se mostrou uma estratégia eficaz para entender as opiniões dos consumidores em larga escala. O modelo desenvolvido foi capaz de classificar as emoções dos usuários de maneira robusta, considerando tanto sentimentos positivos quanto negativos, e oferecendo uma visão detalhada sobre as percepções dos consumidores.

Os resultados obtidos demonstram que a análise de sentimentos não apenas auxilia na otimização da experiência do usuário, mas também oferece uma base sólida para a tomada de decisões estratégicas. Empresas podem usar essas informações para ajustar suas campanhas publicitárias, melhorar a qualidade dos produtos, personalizar ofertas e até mesmo otimizar a logística e o atendimento ao cliente, com base nas emoções identificadas nas resenhas.

Além disso, a automação da análise de sentimentos permite que as empresas monitorem em tempo real a percepção dos consumidores sobre seus produtos, respondendo de maneira ágil às críticas e promovendo uma interação mais eficiente com o cliente. A escalabilidade dos modelos de PLN torna possível processar grandes volumes de dados de forma eficiente, o que é essencial para plataformas de e-commerce com uma quantidade imensa de avaliações, como a Amazon.

Com o crescimento contínuo do comércio eletrônico, as técnicas de PLN serão cada vez mais essenciais para empresas que buscam se destacar em um mercado competitivo. A implementação de sistemas de análise de sentimentos baseados em PLN, como demonstrado neste estudo, pode fornecer um diferencial competitivo significativo, ajudando as empresas a compreenderem melhor as necessidades e desejos de seus consumidores e a aprimorar suas estratégias de marketing e atendimento.

Referências

1. **Jurafsky, D., & Martin, J. H.** (2021). *Speech and Language Processing* (3rd ed.). Prentice Hall.
2. **Manning, C. D., & Schütze, H.** (1999). *Foundations of Statistical Natural Language Processing*. MIT Press.
3. **Pang, B., & Lee, L.** (2008). *Opinion Mining and Sentiment Analysis*. Foundations and Trends® in Information Retrieval, 2(1-2), 1-135.
4. **Liu, B.** (2012). *Sentiment Analysis and Opinion Mining*. Synthesis Lectures on Human Language Technologies.
5. **Goldberg, Y.** (2017). *Neural Network Methods for Natural Language Processing*. Morgan & Claypool Publishers.
6. **Kim, Y.** (2014). *Convolutional Neural Networks for Sentence Classification*. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP 2014), 1746-1751.

7. **Hu, M., & Liu, B.** (2004). *Mining and summarizing customer reviews*. In Proceedings of the 2004 ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 168-177.
 8. **Zhang, Y., & Wu, S.** (2016). *Sentiment analysis of product reviews for e-commerce platforms*. In Proceedings of the 2016 International Conference on Artificial Intelligence and Machine Learning (AI & ML 2016), 44-53.
 9. **Kumar, A., & Garg, N.** (2020). *E-commerce product reviews analysis: A sentiment analysis perspective*. Journal of Retailing and Consumer Services, 55, 102-111.
 10. **Wang, Y., & Yu, C.** (2017). *The impact of online consumer reviews on the e-commerce industry*. International Journal of Information Management, 37(5), 323-329.
 11. **Vilares, D., & García, D.** (2019). *Sentiment analysis in social media: Challenges, trends, and applications*. Journal of Computational Science, 29, 87-102.
 12. **Chowdhury, G. G.** (2003). *Natural Language Processing*. ACM Computing Surveys (CSUR), 36(3), 110-115.
 13. **Hugging Face Documentation.** (2023). *Transformers: State-of-the-art Natural Language Processing for Pytorch and TensorFlow 2.0*. Hugging Face.
 14. **TensorFlow Documentation.** (2023). *TensorFlow for Machine Learning*. TensorFlow.
-

[1] Estudante do curso superior de ciência de dados.

[2] Estudante do curso superior de ciência de dados.

[3] Sou um engenheiro eletricitista pela Universidade Federal de Pernambuco, com mestrado pela UNICAMP e doutorado pela Carnegie-Mellon University (USA). Também tenho um MBA em Enterprise management pela Fundação Getúlio Vargas. Tenho extensa experiência profissional como desenvolvedor de Software (Philps, ESCA), gerente de projetos (Controlmatic e HelthBit) e diretor comercial e de novos negócios (ST Microelectronics, TOTVS, BROADCOM, UNITEC, SILVACO e Newland). Também trabalhei em vários institutos de

pesquisa, tais como Instituto Genius de Tecnologia, Instituto Atlantico, Instituto Venturus e Centro Tecnológico para Informática. Academicamente falando, trabalhei como professor universitário nas seguintes instituições Universidade São Francisco, Centro Universitário UNISAL, Faculdade Lusofona de São paulo e FATEC (Santana de Parnaíba e Cotia). Atualmente, eu sou professor das seguintes disciplinas: (a) Banco de Dados e Data Warehouse; (b) Engenharia de Software II; (c) Processamento de Linguagem Natural; (d) Economia da informação, inovação e negócios disruptivos e Paradigmas e tecnologias emergentes em Ciência de dados.