

Identificação e Categorização de Reclamações em Comentários sobre Empresas do Ramo de Apostas Esportivas

Tobias de Abreu Kuse¹, Helena Graziottin Ribeiro¹

¹EXATAS - Universidade de Caxias do Sul (UCS)
Caxias do Sul – RS – Brasil

tobias.abreu.kuse@gmail.com, hgrib@ucs.br

Abstract. *A significant part of the comments on sports betting company profiles refer to complaints and problems reported by customers. The present work tested supervised learning methods to classify comments as complains in data collected from Instagram, using the SVM model. Topic modeling techniques were applied to comments classified as complaints, and the GSDMM algorithm was selected, making it possible to obtain the main problems reported by users. The selected models were implemented in an online prototype that allows the insertion and analysis of new comments.*

Resumo. *Uma parte significativa dos comentários em perfis de empresas de apostas esportivas referem-se a reclamações e problemas reportados pelos clientes. O presente trabalho testou métodos de aprendizado supervisionado para classificar comentários como reclamações em dados coletados do Instagram, sendo escolhido o modelo SVM. Técnicas de modelagem de tópicos foram aplicadas nos comentários classificados como reclamações, e foi selecionado o algoritmo GSDMM, tornando possível obter os principais problemas relatados pelos usuários. Os modelos selecionados foram implementados em um protótipo online que permite a inserção e análise de novos comentários.*

1. Introdução

Empresas do ramo de apostas esportivas estão presentes nas redes sociais, especialmente no Instagram. É comum haver várias postagens por dia que podem gerar muitas interações nos comentários. O grande volume de mensagens torna inviável a análise manual. Como uma parte significativa desses comentários são reclamações sobre os produtos e serviços ofertados, o não atendimento dessas insatisfações gera um descontentamento por parte dos clientes. A possibilidade de identificar e categorizar essas reclamações pode trazer benefícios às empresas nos seguintes aspectos: gestão de reputação e marca, melhoria na comunicação com usuários insatisfeitos, identificação de problemas emergentes, análise da concorrência, redução de riscos legais e regulatórios, entre outros.

Trabalhos semelhantes podem ser vistos em [İLHAN OMURCA et al. 2021] com categorização não-supervisionada, e em [Ohata et al. 2022] e [Parmar et al. 2018] com categorização supervisionada. Neles, as mensagens analisadas vieram de sistemas de suporte ao consumidor em que o conteúdo geralmente são reclamações.

A abordagem aqui realizada possui duas etapas. Primeiro, utiliza-se métodos de classificação de textos para identificar reclamações. A seguir, aplica-se métodos de modelagem de tópicos para distinguir os tipos diferentes de reclamações dos consumidores. Os

métodos com melhor desempenho foram implementados em um protótipo online usando o *framework* de aplicação *streamlit*. Esse protótipo permite que novas mensagens sejam submetidas e analisadas, e os resultados são mostrados por gráficos e tabelas apresentando as principais estatísticas. Nas Seções 2, 3, 4 e 5 são apresentados os experimentos aplicados, e na Seção 6 tem-se os principais resultados do trabalho.

2. Coleta e Anotação dos Dados

A coleta dos comentários foi realizada por *web-scraping* com a biblioteca *Selenium* do *Python*. O código de coleta simula a interação de um usuário com o navegador de internet e coleta os comentários em postagens do *Instagram*. Os dados foram salvos em arquivos no formato *csv*. A coleta de dados foi realizada no perfil de quatro empresas no período de 18 de junho de 2023 a 6 de setembro de 2023, resultando em 146596 registros.

A criação do atributo alvo para a classificação foi feita com auxílio do *ChatGPT* (*API* da *OpenAI*, *gpt-3.5-turbo-16k*). Foram feitas requisições à *API* usando um *prompt* que continha como instrução que o modelo classificasse as mensagens que configurassem uma reclamação contra as empresas ou de seus produtos e serviços, retornando a classificação em um formato *JSON* fornecido. Também foi realizada uma validação manual das anotações para corrigir eventuais erros de interpretação do *ChatGPT*. A maior parte dos equívocos cometidos ocorreram nos comentários em que uma reclamação era feita sobre outro assunto: um evento esportivo, jogadores, arbitragem, técnicos, etc e não contra as empresas e seus serviços. Todos esses casos foram corrigidos.

3. Pré-processamento

Textos de comentários em redes sociais costumam ser muito curtos e não apresentam contexto suficiente para uma boa análise do conteúdo. Por isso foram considerados somente textos com pelo menos dez palavras. Os textos foram processados com bibliotecas de processamento de linguagem natural como *Spacy* e *nlTK* e com a biblioteca de manipulação de dados *Pandas*. Foram realizadas operações de: remoção de duplicatas, remoção de URLs, tradução de emojis para texto, remoção de acentos, remoção de pontuação, conversão dos textos para letra minúscula, remoção de quebras de linha, remoção de menções, remoção de *hashtags*, manutenção de *stopwords* negativas (não, nem, nunca, etc), remoção das demais *stopwords*, substituição de abreviações por palavras correspondentes, correção ortográfica, redução de palavras flexionadas à sua forma base, manutenção somente de substantivos, verbos, adjetivos e advérbios. Após esses procedimentos, o conjunto de dados resultante para o treinamento dos modelos ficou com 11550 exemplos, dentre estes 3663 classificados como reclamações.

4. Classificação de Texto

Como havia desbalanceamento entre as classes 'reclamação' e 'não-reclamação', fez-se uma redução aleatória da classe majoritária (não-reclamação) nos dados de treinamento com a biblioteca *imblearn*. Os dados para validação ficaram na proporção original.

Os textos foram transformados em representações vetoriais para servir como entrada em modelos de aprendizado de máquina. Foram utilizados três métodos de vetorização para extração de atributos: Engenharia de Atributos, *Term Frequency–Inverse Document Frequency* e *Word Embedding*. O primeiro método, Engenharia de Atributos,

TABELA I: Resultados da Classificação de Texto

Vetorização	Modelo	Acurácia	Precisão	Recall	F1
Eng. de Atributos	Linear Regression	0.65	0.44	0.66	0.53
	Random Forest	0.64	0.44	0.66	0.53
	SVM	0.65	0.44	0.62	0.52
	XGB	0.65	0.44	0.64	0.52
	Naive Bayes	0.64	0.43	0.54	0.48
TF-IDF	Linear Regression	0.76	0.60	0.76	0.67
	Random Forest	0.74	0.61	0.53	0.57
	SVM	0.78	0.62	0.77	0.69
	XGB	0.74	0.60	0.58	0.59
	Naive Bayes	0.75	0.57	0.81	0.67
Word Embedding	Linear Regression	0.66	0.48	0.68	0.56
	Random Forest	0.68	0.50	0.70	0.59
	SVM	0.61	0.44	0.71	0.54
	XGB	0.68	0.50	0.69	0.58
	Naive Bayes	0.69	0.52	0.55	0.54

TABELA II: Resultados da Modelagem de Tópicos

Modelo	Quant. Tópicos	Coherence Score
LDA	10	0.35
	11	0.34
	12	0.36
	13	0.35
	14	0.37
	15	0.37
	16	0.36
	17	0.35
	18	0.37
	19	0.36
	20	0.38
GSDMM	18	0.54

Figura 1. Resultados da classificação de texto e da modelagem de tópicos.

foi aplicado nos textos no formato original extraídos do *Instagram*. Os outros dois foram aplicados nos textos pré-processados conforme descrito na Seção 3. Cada método de vetorização foi combinado com cinco algoritmos de aprendizado distintos (Figura 1): *Logistic Regression* (LR), *Random Forest* (RF), *Support Vector Machine* (SVM), *Extreme Gradient Boosting* (XGB) e *Naive Bayes* (NB). A biblioteca usada para a aplicação dos modelos foi a *scikit-learn*. A discussão dos resultados está na Seção 6.

5. Modelagem de Tópicos

Dois algoritmos foram testados para a modelagem de tópicos das reclamações: o tradicional *Latent Dirichlet Allocation* (LDA) e *Gibbs Sampling Dirichlet Multinomial Mixture* (GSDMM). Essas duas técnicas foram aplicadas somente nos dados de treinamento classificados como reclamação.

O LDA é um modelo generativo probabilístico que considera cada documento como uma mistura de vários tópicos [Qiang et al. 2022]. Entretanto, textos de redes sociais são geralmente curtos, o que resulta em uma falta de co-ocorrência de termos e gera uma degradação do desempenho desse modelo. Mesmo assim essa hipótese foi testada neste trabalho para comparar com o GSDMM. A aplicação do LDA exige a indicação da quantidade de tópicos (K), e ele foi executado com valores de K variando de 10 a 20. Métricas de coerência de tópicos (*coherence score*) foram calculadas para cada iteração (Figura 1). Já o GSDMM é um modelo que considera um único tópico por documento, e foi criado para ter um bom desempenho em textos curtos como os das redes sociais. Ele consegue inferir a quantidade ótima de tópicos, é preciso apenas definir um valor de limite superior [Yin and Wang 2014]: ele foi definido em 30 e realizadas 100 iterações. A convergência do modelo ocorreu para 18 tópicos de reclamações, os quais foram reduzidos manualmente para 9 de acordo com a semelhança semântica entre eles. A Tabela 1 mostra as reclamações categorizadas (tópicos) e as respectivas palavras-chave.

6. Resultados

Comparação dos Modelos de Classificação: quatro métricas foram calculadas e comparadas para a seleção do modelo a ser utilizado: Acurácia, Precisão, *Recall* e *F1-Score*. A principal métrica avaliada foi o *F1-Score* seguida do *Recall*. O objetivo do classificador é identificar a maior parte das reclamações dos clientes, mas mantendo um bom balanço com a precisão a fim de evitar muitos falsos positivos, *i.e* retornar como reclamação o que não for (o desbalanço entre as classes pode fazer com que depender apenas da acurácia gere uma interpretação errada, pois o modelo pode classificar a maior parte dos comentários como não sendo reclamação e ainda assim ter pontuação alta nessa métrica).

Comparação dos Modelos de Tópicos: a métrica *coherence score* foi calculada para o LDA e GSDMM. Essa métrica considera palavras que são semanticamente relacionadas e frequentemente co-ocorrem nos documentos. Quanto maior o valor dessa métrica melhor é a coerência entre os tópicos [İLHAN OMURCA et al. 2021].

A Figura 1 mostra os resultados dos testes realizados. O modelo SVM combinado com o *tf-idf* apresentou o melhor desempenho com *F1-Score* de 0.69 e *recall* de 0.77. O modelo GSDMM apresentou maior *coherence score* (0.54) comparado aos testes de LDA.

Tabela 1. Tópicos e palavras-chave

Tópicos	Palavras-chaves
Problemas relacionados a bônus, saques e erros técnicos.	esperar, bonus, entrar, quebrar, jogo, campo, perna, cliente, plataforma, conta, ganhar, fogo, sacanagem, cano, depender
Problemas persistentes e dificuldade em obter solução.	possível, resolver, brilhar, contar, prejudicar, liberar, apostar, trabalhar, rápido, banca, voltar, perceber, errar, compreensão, programa
Problemas relacionados a perdas contínuas.	saco, dinheiro, id, ingresso, prometer, cade, postar, convite, banda, comprometimento, público, enrolar, gerar, agonia, culpa
Problemas técnicos, instabilidade no site e orientações não fornecidas.	instabilidade, resolver, cliente, entender, preocupar, conversar, trabalhar, provedora, ocorrer, orientar, aguardar, acompanhar, tratativa, dúvida, disposição
Problemas de privacidade, espera, e experiências negativas após perder.	esperar, entender, ajudar, contato, pessoa, verificar, ver, chamar, ficar, conferir, falar, contar, confirmar, resolver, instante
Reclamações sobre apostas não creditadas.	novamente, ganhar, rodada, roleta, dinheiro, giro, bônus, centavo, rodar, ficar, pagar, grátis, cliente, chance, acertar
Problemas com o atendimento ao cliente.	comentário, chat, pessoa, banir, mensagem, tirar, bloquear, solução, reportar, permanente, mandar, enviar, responder, conteúdo, chamar.
Problemas com depósitos e pagamentos não recebidos	cair, saque, dinheiro, entrar, aposta, conta, suporte, problema, deposito, clicar, pagar, liberar, palhaco, ruim, acessar
Comentários sobre jogar na roleta, esperar por vitórias e perdas nas apostas.	ganhar, banca, sorte, nunca, novamente, nada, perder, acertar, decepcionar, banquinha, continuar, ressarcimento, resolver, solucionar, resumir

Um protótipo online foi implementado usando essas técnicas de aprendizado supervisionado e modelagem de tópicos, permitindo inserção e análise de novos comentários coletados: <https://complaints-classifier.streamlit.app/>.

Referências

- Ohata, E. F., Mattos, C. L. C., Gomes, S. L., Rebouças, E. D. S., and Rego, P. A. L. (2022). A text classification methodology to assist a large technical support system. *IEEE Access*, 10:108413–108421.
- Parmar, P. S., Biju, P. K., Shankar, M., and Kadiresan, N. (2018). Multiclass text classification and analytics for improving customer support response through different classifiers. In *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pages 538–542.
- Qiang, J., Qian, Z., Li, Y., Yuan, Y., and Wu, X. (2022). Short text topic modeling techniques, applications, and performance: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 34(03):1427–1445.
- Yin, J. and Wang, J. (2014). A dirichlet multinomial mixture model-based approach for short text clustering. In *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '14, page 233–242, New York, NY, USA. Association for Computing Machinery.
- İLHAN OMURCA, S., EKİNCİ, E., YAKUPOĞLU, E., ARSLAN, E., and ÇAPAR, B. (2021). Automatic detection of the topics in customer complaints with artificial intelligence. *Balkan Journal of Electrical and Computer Engineering*, 9(3):268–277.