Análise de sentimentos em mensagens de avaliação de clientes sobre o setor de comércio do Rio de Janeiro

Yasmin Silva Amaro de Lima
Departamento de Engenharia Industrial, PUC-Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro (RJ), Brasil
yasminamaro.lima@aluno.puc-rio.br, yasminamaro.lima@outlook.com

Paula Medina Maçaira
Departamento de Engenharia Industrial, PUC-Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro (RJ), Brasil
paulamacaira@puc-rio.br

Fernanda Araujo Baião
Departamento de Engenharia Industrial, PUC-Rio
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro (RJ), Brasil
fbaiao@puc-rio.br

RESUMO

A Análise de Sentimentos é uma área de estudo que engloba conhecimentos da Ciência da Computação, Linguística e Inteligência Artificial e possui como objetivo a extração automática de opiniões expressas nos meios eletrônicos em relação a diversos contextos. O destaque dessa área ocorreu devido à ampliação do uso da web como ferramenta para expressar sentimentos sobre determinado evento e, baseado na revisão bibliográfica, a sua utilização é benéfica e cada vez mais importante para as Organizações. Neste contexto, um dos setores mais importantes é o de Varejo, porém, a análise da qualidade dos estabelecimentos a partir da visão do cliente é extremamente escassa. Desta forma, a utilização de técnicas de Análise de Sentimentos para análise de mercado neste setor é um diferencial importante. Este artigo tem como objetivo captar a percepção dos clientes sobre aproximadamente 12.000 lojas do setor de Varejo do Rio de Janeiro e extrair os assuntos mais comentados.

PALAVRAS-CHAVE. Análise de Sentimentos, Varejo, Processamento de Linguagem Natural.
Tópicos: Big Data e Analytics (BDA)

ABSTRACT

Sentiment Analysis is an area of study that encompasses knowledge of Computer Science, Linguistics and Artificial Intelligence and aims to extract automatically opinions expressed in electronic media in relation to different contexts. The highlight of this area was due to the expansion of the use of the web as a tool to express feelings about a certain event and, based on the literature review, its use is beneficial and increasingly important for Organizations. In this context, one of the most important sectors is Retail, although, the analysis of the quality of establishments from the customer's point of view is extremely scarce. Thus, the use of Sentiment Analysis techniques for market analysis in this sector is an important differential. This article aims to capture the perception of customers about approximately 12,000 stores in the retail sector in Rio

de Janeiro and extract the most talked about issues.

KEYWORDS. Sentiment Analysis, Retail, Natural Language Processing.

Paper topics: Big Data and Analytics (BDA)

1. Introdução

Os aplicativos de análise de sentimentos se espalharam para quase todos os domínios possíveis, de produtos de consumo, serviços e saúde a eventos sociais e eleições políticas [Liu 2012]. Sun et al. [2017] afirmam que a mineração de opinião atrai a comunidade industrial devido à ampla diversidade de aplicações práticas, como precificação de produtos, inteligência competitiva, previsão de mercado, previsão de eleições e detecção de risco em sistemasbancários. Os estudos de análise de sentimentos começaram no início deste século e vêm ganhandocada vez mais relevância, sobretudo porque houve uma crescente utilização da internet e redes sociais para expressar opiniões, seja para elogiar ou criticar produtos e serviços, seja para expressarsentimentos acerca de um partido ou candidato político. Devido ao cenário atual da pandemia da COVID-19, esse alto volume de dados da web é ainda mais significante no setor do comércio online. Isso aumenta a importância de as empresas saberem o que os clientes estão comentando sobre determinado produto ou serviço, uma vez que boa parte da população utiliza os meios eletrônicos para buscar a opinião de clientes antes de concluir uma compra.

A Análise de Sentimentos é considerada a forma mais avançada de determinar opiniões, pois faz uso da Inteligência Artificial para automaticamente classificar um trecho de texto em positivo, negativo ou neutro [Zahoor e Rohilla 2020]. O presente artigo foca na análise de produtos e serviços do setor de Varejo, que vem ganhando cada vez mais relevância e novos desafios em função dos esforços na direção da Transformação Digital. Segundo Ratmele e Thakur [2020], com o crescimento da popularidade da web, cresce também o interesse na mineração de opinião, uma vez que as compras online são cada vez mais comuns e, nesta modalidade, os consumidores podem escrever comentários sobre características dos produtos. Neste contexto, o massivo volume desses dados disponíveis - atrelado ao fato deles não serem estruturados - dificulta a análise manual e aumenta a necessidade de técnicas computacionais para tratar estes dados de forma automática, e considerá-los para apoiar a tomada de decisões gerenciais, a gestão de operações e da produção nas organizações [Ceci et al. 2017]. Existem diversas técnicas e abordagens na área de análise de sentimentos, mas elas apresentam algumas limitações e necessidade de avanço, como por exemplo a identificação de sentimentos em frases objetivas e a construção de léxicos eficientes para qualquer domínio. Além disso, o cenário abordado neste trabalho apresenta desafios relacionados ao idioma Português - uma vez que estudos e algoritmos disponíveis de análise de sentimentos estão concentrados no Inglês.

Ainda, há uma escassez de pesquisas voltadas para a percepção do cliente no setor do Varejo, principalmente em estudos de regiões específicas. Uma busca no Scopus com as palavras “Sentiment Analysis" retorna 17.716 documentos, o que mostra o grande número de pesquisas neste tema; ao colocar “Sentiment Analysis” e “retail” tem apenas 66 resultados; ao adicionar “Rio de Janeiro” ou “Brazil” aos termos de busca, nenhum documento é encontrado. O varejo inclui todas as atividades relativas à venda de bens e serviços diretamente ao consumidor final, para uso pessoal [Kotler e Killer 2012]. Tal setor detém um papel fundamental na economia brasileira, uma vez que o varejo restrito (não inclui veículos e materiais de construção) e o varejo ampliado equivalem respectivamente a 19,24% e 26,2% do PIB, além de empregar 26% dos trabalhadores com carteira assinada no país [Terra et al. 2020]. A pandemia da Covid-19 impactou negativamente alguns setores do varejo, porém outros setores se beneficiaram com o momento ao inovar e migrar

rapidamente para o digital, já que houve uma mudança no comportamento dos consumidores com o aumento de compras online.

Considerando a importância do varejo na economia brasileira e a escassez de análises relacionadas a este setor, este artigo tem como objetivo classificar os comentários dos clientes para analisar suas percepções sobre lojas do Rio de Janeiro e extrair os assuntos mais falados. O trabalho utilizou uma abordagem não supervisionada com o léxico VADER[1] [Hutto e Gilbert 2015] através da linguagem de programação Python com o código desenvolvido na ferramenta Google Colab[2].

2. Análise de Sentimentos

A Análise de Sentimentos (AS), por vezes chamada de Mineração de Opinião, é a área de estudo que tem como objetivo analisar sentimentos, opiniões e avaliações de pessoas em relação a entidades como produtos, serviços, organizações, indivíduos, questões, eventos, tópicos e seus atributos [Liu 2012].

A Análise de Sentimentos se concentra entre o campo de Processamento de Linguagem Natural, Inteligência Artificial e Linguística Computacional [Yue et al. 2018]. Com o aumento do uso dos meios eletrônicos, há cada vez mais pessoas utilizando esses meios para expressar suas opiniões, com isso, a área de análise de sentimentos ganhou mais relevância e vem sendo aplicada em diversas áreas, uma vez que possibilita empresas e indivíduos a utilizar grandes conjuntos de dados para uma melhor tomada de decisão, o que não seria possível de forma manual.

Muitos consumidores buscam as opiniões de usuários de determinado produto antes de finalizar uma compra, além disso, diversos eleitores utilizam as opiniões de outras pessoas para decidir o destino do seu voto. A opinião do público sobre determinado produto ou serviço não tem interessado somente os consumidores, mas também as Organizações que por vezes buscam essas informações na web ou também por meio de pesquisas internas com seus clientes, como por exemplo pesquisa de satisfação. Isso mostra o quão importante a opinião é e justifica o crescimento das pesquisas e interesses em torno dela.

Há algumas abordagens para analisar sentimentos, tais como aprendizado supervisionado e não supervisionado. O aprendizado supervisionado requer um conjunto de dados já rotulado, é baseado em algoritmos de aprendizado de máquina (em particular classificação) e utiliza uma parte desses dados para treinamento e outra para teste a fim de determinar a polaridade de uma frase ou texto. Alguns métodos de aprendizado supervisionado são *Naive Bayes*[3] e *Support Vector Machines*[4] (SVM), esses classificadores podem obter uma alta precisão, mas têm seu desempenho reduzido ao serem aplicados em domínios diferentes. Já o aprendizado não supervisionado ou baseado em léxico não depende de dados já rotulados e utiliza léxicos de sentimentos através do qual são construídos dicionários de palavras com suas respectivas polaridades. Nesta abordagem o texto é considerado como um saco de palavras no qual cada palavra é comparada com o dicionário construído pelo léxico. Os métodos baseados em léxicos dependem apenas do conhecimento linguístico e são mais robustos em domínios e textos; no entanto, apresentam maior dificuldade de obter alta precisão [Avanco e Nunes 2014]. Alguns léxicos conhecidos são o VADER, TextBlob[5], SentiWordNet[6] e OpinionLexicon[7]. No presente trabalho, assume-se um dataset não rotulado, uma vez que cada registro do dataset (que representa um comentário feito por um cliente acerca de um estabelecimento) não está rotulado como um comentário que reflete uma opinião "positiva",

[1] https://github.com/cjhutto/vaderSentiment
[2] https://colab.research.google.com/notebooks/intro.ipynb?utm_source=scs-index
[3] https://scikit-learn.org/stable/modules/naive_bayes.html
[4] https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html
[5] https://textblob.readthedocs.io/en/dev/
[6] https://github.com/aesuli/SentiWordNet
[7] https://www.nltk.org/_modules/nltk/corpus/reader/opinion_lexicon.html

"negativa" ou "neutra" sobre o estabelecimento; ou seja, não existe uma classificação de referência já atribuída manualmente a cada comentário por algum analista de mercado, por exemplo.

Apesar dos benefícios, a análise de sentimentos não é considerada uma tarefa simples. Um dos fatores que a torna complexa é a disponibilidade excessiva de dados e sua característica desestruturada por não haver um padrão de escrita na web. Outro fator é a diferença de aplicação entre domínios, ou seja, uma palavra que é positiva em um domínio, pode ser negativa em um domínio diferente. Ademais, a presença de sarcasmo em frases pode dificultar a análise, como por exemplo "esse restaurante é ótimo e rápido, pedi o almoço e chegou na janta". Identificar sentimento em frases objetivas também não é simples, uma vez que essas frases não têm palavras de sentimentos (bom, ótimo, péssimo, etc). A sentença "o celular x gasta muita bateria" apesar de ser uma frase objetiva representa uma opinião negativa. Além disso, não há muitos recursos ou ferramentas em outros idiomas além do Inglês que possam ser usados para construir bons classificadores de sentimento rapidamente nessas linguagens [Liu 2012]. Apesar da grande quantidade de pesquisas em análise de sentimentos, a maioria dos métodos foram projetados para funcionar com o conteúdo em inglês [Reis et. al 2015]. Os métodos existentes para o português são poucos eficazes, Cirqueira et al. [2017] apresentaram um estudo comparativo com dados originalmente na língua portuguesa e concluíram que os métodos de mineração de opinião que trabalham com o português tiveram desempenho inferior ao das versões em inglês - mesmo com esses sendo traduzidos - devido ao nível de maturidade das implementações para a língua inglesa.

3. Trabalhos relacionados

Hecksher e Ebecken [2016] fizeram um estudo comparativo de mineração de opinião em rede varejista com o objetivo de contribuir com a ideia que afirma a eficiência e vantagem do uso da Análise de Sentimentos para conhecimento de opiniões e estudos de percepção e reputação de marcas. A comparação foi feita entre uma pesquisa de campo e uma aplicação de técnicas de mineração de texto como Análise de Sentimentos a partir da extração de textos de clientes na Fan Page de uma rede de comércio varejista. Para a pesquisa de campo foram coletados dados através de entrevistas pessoais com clientes em 3 lojas no Rio de Janeiro e 43% deles reprovaram as lojas. A Análise de Sentimentos trouxe um resultado similar à pesquisa de campo, com 47% de reprovação dos clientes, além disso, a extração de palavras-chave trouxe um resumo dos tópicos mais criticados pelos clientes, como o preço, assunto esse também muito criticado na pesquisa de campo. A análise comparativa mostrou a eficácia da aplicação de técnicas de Mineração de Texto e atingiu seu objetivo ao extrair as opiniões dos clientes.

Sujanová et al. [2020] realizaram uma pesquisa qualitativa das mídias sociais e sua utilização por diferentes setores, essa pesquisa foi estendida para uma análise de sentimento comparativa na Europa entre a indústria automotiva e produtores de bens de consumo duráveis como móveis. Os dados foram coletados do Twitter e YouTube e perceberam que o comportamento na utilização dessas mídias, bem como a repercussão das publicações, possui uma diferença significativa entre os setores. A análise de sentimentos foi feita com base no léxico VADER com dados extraídos do Twitter. O resultado mostrou que a representação da indústria automotiva é expressivamente maior à indústria moveleira. A análise de sentimentos foi feita apenas para a indústria automotiva, uma vez que não houve tweet para a indústria moveleira no período coletado. Foi concluído que, para a indústria automotiva, o conteúdo dos tweets continham em sua maioria palavras positivas, tais como melhor e excelência.

Ratmele e Thakur [2020] extraíram comentários de clientes sobre telefones celulares na Amazon com o objetivo de identificar as características e opiniões. Foi utilizada a técnica LDA para obter as características identificadas e dentre as quais cinco foram escolhidas, tais como câmera, tela, bateria, desempenho e dinheiro. Após essa etapa, foram aplicados os métodos

baseados em léxico AFINN[8] e VADER para classificar os sentimentos de acordo com as características. Como resultado, ambos os métodos classificaram a maior parte dos comentários como positivos e observou-se que o VADER teve um bom desempenho na opinião positiva enquanto AFINN teve um bom desempenho na classificação da opinião negativa.

Wai e Aung [2017] extraíram opiniões e características de três produtos – computador, roteador e alto-falante - através de uma abordagem baseada em léxico proposta pelos autores, além disso, houve uma comparação dessa abordagem com outros dois léxicos já existentes. No geral, os comentários foram positivos para os três tipos de produto e, a abordagem proposta, apresentou um desempenho melhor quando comparada com as outras duas.

Em síntese, assim como este artigo, os trabalhos relacionados descreveram, em sua maioria, uma análise de sentimentos em setores do comércio, tais como indústria moveleira, automotiva e de eletrônicos, classificando os comentários dos clientes e mostrando a importância de conhecer as opiniões dos consumidores. Um artigo aplicou técnicas de mineração de opinião que, diferente do presente trabalho, analisou apenas uma rede varejista; alguns autores utilizaram abordagens baseadas em aprendizado de máquina e outros em léxicos, sendo majoritariamente o VADER.

4. Metodologia

A proposta desta seção do artigo é aplicar técnicas de Análise de Sentimentos para extrair a percepção dos clientes acerca da qualidade do setor de Varejo do Rio de Janeiro. A metodologia deste trabalho consistiu em primeiramente coletar os dados do Google API com os comentários dos clientes das lojas do Rio de Janeiro, analisá-los e selecionar os campos necessários para a Análise de Sentimentos. Depois foram aplicadas algumas etapas de pré-processamento, análise mais profunda desses dados, tradução e, finalmente, a extração dos assuntos mais falados e aplicação do VADER para classificação dos sentimentos dos consumidores.

4.1 Coleta dos dados

O dataset utilizado no presente trabalho foi extraído de comentários de avaliações de clientes no Google sobre aproximadamente 12.000 lojas do Rio de Janeiro, a extração foi feita através do Google API Console em Python[9], no período de Janeiro a Fevereiro de 2021. Os dados foram exportados para o formato CSV e, após uma análise, foram escolhidos somente os campos necessários para a realização da análise de sentimentos. Após a reorganização, cada linha passou a representar uma única avaliação e o dataset ficou com 8 colunas e 36.542 linhas. As colunas do dataset resultante representam as seguintes características:

- Id: identificador único de cada loja;
- Latitude: distância em graus de cada loja em relação à Linha do Equador;
- Longitude: distância em graus de cada loja em relação ao Meridiano de Greenwich;
- Endereço: endereço da loja;
- n_aval: número de avaliações que cada loja possui;
- aval: nota média da loja com variação de 0 a 5;
- nome: nome da loja;
- comentário: comentário de um cliente sobre esta loja específica.

Parte dos dados utilizados para analisar os sentimentos dos clientes está representada na

[8] https://darenr.github.io/afinn/
[9] https://developers.google.com/webmaster-tools/search-console-api-original/v3/quickstart/quickstart-python

Tabela 1. Pode-se perceber a existência de um padrão sintático nos comentários, que consiste no nome do avaliador e dois pontos seguidos da nota entre parênteses dada por ele variando de 0 a 5. Além disso, a coluna de comentário possui linhas vazias, com erros de ortografia como "otina" e linhas com apenas o nome do consumidor. Para preservar a identidade dos consumidores, foram ocultados da imagem os sobrenomes, restando apenas os nomes.

Tabela 1 - Conjunto de dados

id	latitude	longitude	endereço	n_aval	aval	nome	comentario
ChIJ____0IllgAR	-22.3356683	-41.7524799	Rua Mota Carvalho 8	0	0.0	EHL Elétrica Hic	-
ChIJ____2MgmA	-22.2837292	-42.5904681	Av. Antônio Mario de	1	2.0	Rei do Caracol	Salvador (2) :Produto de qualidade, mas proprieta
ChIJ____4AHnAv	-22.8722170	-43.8070270	Av. Pref. Isoldackson	42	4.2	BRUTELHAS MAT	Leandro (5) :Ótimo atendi
ChIJ____4AHnAv	-22.8722170	-43.8070270	Av. Pref. Isoldackson	42	4.2	BRUTELHAS MAT	Magiazul (5) :otina variedade de material para
ChIJ____4AHnAv	-22.8722170	-43.8070270	Av. Pref. Isoldackson	42	4.2	BRUTELHAS MAT	Renato (2) :Pouca diversidade de produtos
ChIJ____4AHnAv	-22.8722170	-43.8070270	Av. Pref. Isoldackson	42	4.2	BRUTELHAS MAT	Ronaldo (1) :Péssimo atendimento por telefone ,
ChIJ____4AHnAv	-22.8722170	-43.8070270	Av. Pref. Isoldackson	42	4.2	BRUTELHAS MAT	ELETRICA (5) :Está aberto e funcionando,
ChIJ____7-_mQ	-22.747459	-42.86225	Av. Vinte e Dois de Ma	28	4.4	Brimar Materia	Carlos (5) :Preços justos. Localização boa. Atenc
ChIJ____7-_mQ	-22.747459	-42.86225	Av. Vinte e Dois de Ma	28	4.4	Brimar Materia	Claudinei (5) :A brimar é sempre uma excelente
ChIJ____7-_mQ	-22.747459	-42.86225	Av. Vinte e Dois de Ma	28	4.4	Brimar Materia	Maria (2) :Funcionários anti
ChIJ____7-_mQ	-22.747459	-42.86225	Av. Vinte e Dois de Ma	28	4.4	Brimar Materia	Paulo (5) :Bom atendimento, quero dar meus p
ChIJ____7-_mQ	-22.747459	-42.86225	Av. Vinte e Dois de Ma	28	4.4	Brimar Materia	Adriano (1) :Péssimo atendimento! Essa é a p
ChIJ____9jUvQA	-21.7187588	-41.3140813	Av. Dr. Hélio Montezza	3	4.0	SEAP Madeiras	leonardo (5) :
ChIJ____9jUvQA	-21.7187588	-41.3140813	Av. Dr. Hélio Montezza	3	4.0	SEAP Madeiras	Rogerio (4) :Boa
ChIJ____9jUvQA	-21.7187588	-41.3140813	Av. Dr. Hélio Montezza	3	4.0	SEAP Madeiras	Melquizedeque (3) :Foi boa

4.2 Pré-processamento e análise dos dados

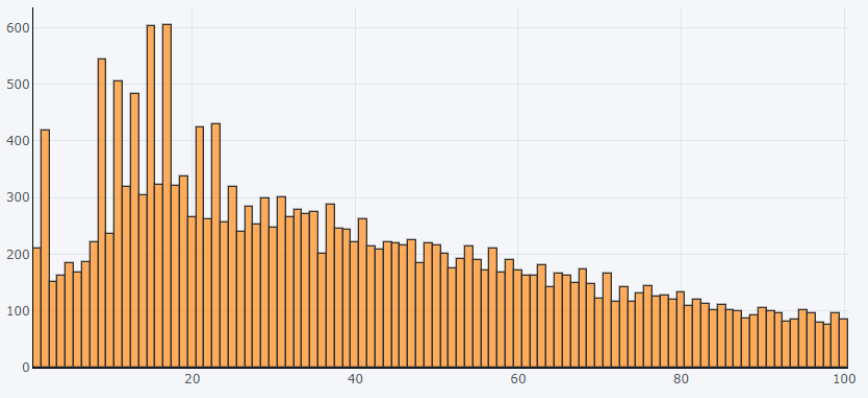
O passo seguinte foi instalar e importar todas as bibliotecas necessárias, além de carregar o dataset na ferramenta Google Colab para criar o código em python. Após essa etapa, foi feito um pré-processamento nos dados, que é uma parte fundamental do processo de Data Science e da Mineração de Texto, uma vez que os dados não estruturados precisam ser tratados antes de aplicar as técnicas de mineração de texto, como a remoção de caracteres indesejados, tendo assim mensagens reduzidas para conter apenas as palavras essenciais para que o algoritmo consiga fazer as associações adequadas [Ribeiro e Oliveira 2020].

Foi observado que inicialmente os dados possuíam 3.540 linhas com o campo "*comentario*" vazio, sendo esses removidos, uma vez que o objetivo é analisar os textos existentes. Após uma análise crítica dos textos considerando o padrão sintático já descrito dos comentários (sequência com o nome do avaliador, nota da avaliação entre parênteses e o comentário acerca do estabelecimento), decidiu-se que os trechos que antecedem o texto do comentário em si não são relevantes para analisar sentimentos. Portanto, a limpeza desses caracteres é desejada. Para isso foram criadas duas funções, uma com o objetivo de retirar números e nomes próprios através da biblioteca `Spacy`[10] e outra para a retirada customizada de pontuações através da biblioteca `re`[11].

Alguns textos do dataset continham apenas o nome do avaliador e a nota de avaliação, portanto, após aplicar as duas funções mencionadas acima, foi criada uma coluna com a quantidade de palavras em cada linha e aquelas com valor igual a zero foram removidas. Após essa aplicação, 5.938 linhas foram removidas, ou seja, 5.938 linhas estavam, inicialmente, apenas com o nome e a nota do avaliador na coluna "comentario". Ao final dessas etapas, restaram 27.064 linhas, sendo 26.779 com até 100 (cem) palavras, isto é, os comentários não costumam ser muito longos. A distribuição do número de avaliações por quantidade de palavras pode ser observada na Figura 1:

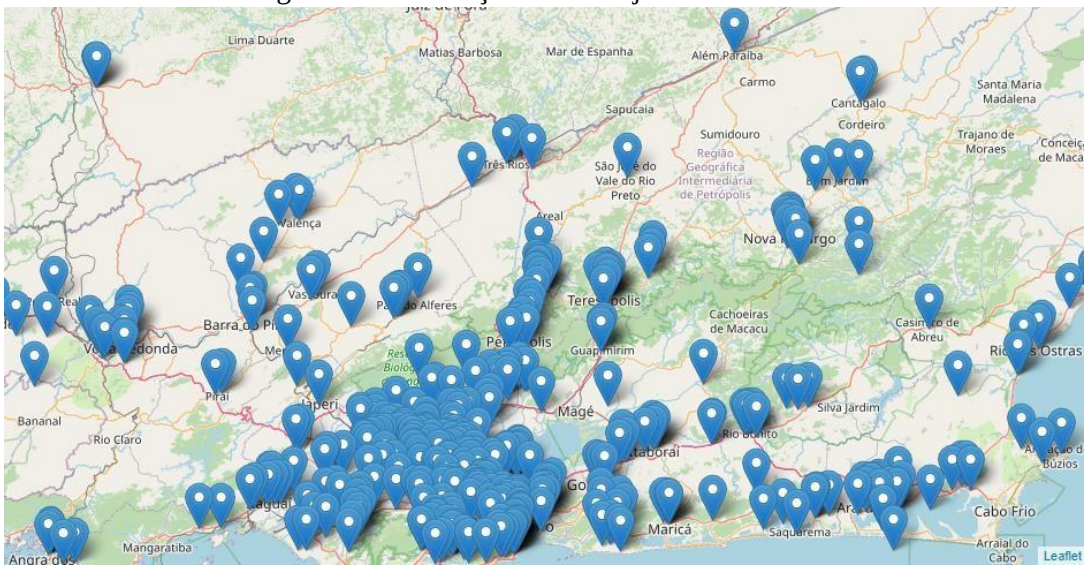
[10] https://pypi.org/project/spacy/
[11] https://docs.python.org/3/library/re.html

Figura 1 - Número de avaliações por quantidade de palavras



Após a retirada das linhas que não continham informações na coluna de comentários, as colunas de latitude e longitude foram exploradas a fim de conhecer um pouco mais a localização de cada loja. O objetivo desta etapa é plotar as coordenadas em um mapa e visualizá-las no espaço, para isso foi criada uma estrutura de dados contendo somente os valores únicos para o par latitude e longitude, o que trouxe um conjunto com 7.829 linhas. Essa quantidade de pontos não foi suportada pela biblioteca `folium`[12], além de poluir demasiadamente a imagem. Contudo, para efeito de ilustração, foram plotados 500 pontos, sendo observado que as lojas se concentram na região metropolitana do Rio de Janeiro conforme mostrado na Figura 2:

Figura 2 - Localização de 500 lojas do dataset



4.3 Análise de sentimentos no dataset

Como já mencionado anteriormente, as técnicas de análise de sentimentos existentes têm a limitação de não abranger muitos idiomas, pois a maioria se concentra no idioma inglês, tendo uma limitação ainda maior para o português. Para contornar essa limitação, os comentários dos clientes foram traduzidos para o inglês através do `Googletrans`[13], uma biblioteca Python que implementa a API do Google.

[12] https://python-visualization.github.io/folium/
[13] https://pypi.org/project/googletrans/

Foi realizado um aprendizado não supervisionado com o auxílio do VADER (Valence Aware Dicitionary e sEntiment Reasorner). O VADER é uma ferramenta de análise de sentimento baseada em regras e léxicos, e foi escolhida porque vem obtendo bons resultados ao lidar com textos de mídia social, editoriais do NY Times, resenhas de filmes e resenhas de produtos [Pandey 2018].

O pré-processamento abrange diversas técnicas que já são embutidas no léxico VADER, o que reforça a sua escolha. O VADER é um léxico padrão-ouro validado por humanos e sintonizado com contextos semelhantes ao de microblog, além de considerar cinco regras generalizáveis que incorporam convenções gramaticais e sintáticas que os humanos usam ao expressar ou enfatizar a intensidade do sentimento [Hutto e Gilbert 2015]. Essas regras incluem o reconhecimento da pontuação de exclamação e do capslock para aumentar a intensidade do sentimento sem alterar a orientação semântica do texto. Ainda, o VADER considera conjunções como "mas" que sinalizam mudança na polaridade de sentimento, intensificadores como "extremamente" e emoticons.

Para aplicar o VADER, é necessário instalar a biblioteca `vaderSentiment`[14], chamar as funções SentimentIntensityAnalyzer e polarity_scores, e aplicá-las no dataset. Após a aplicação, o VADER retorna um dicionário com as pontuações para cada polaridade, elas representam o quanto o texto se encaixa em cada categoria e juntas somam 1. Há também uma pontuação composta que soma todas as três classificações depois de normalizá-las entre -1 e 1. Com as pontuações calculadas, define-se a polaridade da frase, ou seja, se é positiva, negativa ou neutra. Foi definido que para frases com pontuação composta maior ou igual a 0,05, a polaridade é positiva e menor ou igual a -0,05 a polaridade é negativa, caso contrário, a polaridade é neutra.

De modo a demonstrar e entender melhor a ação do VADER, foram feitos alguns testes que podem ser visualizados na Figura 3. De fato, o VADER considera os intensificadores de sentimento como capslock, exclamação e emoticons na hora de pontuar cada frase, mas foi possível observar que a classificação não foi satisfatória na presença do verbo poderia.

Figura 3 - testes de classificação com VADER

```
print(analyser.polarity_scores('This is good'))
print(analyser.polarity_scores('This is good!!!'))
print(analyser.polarity_scores('This is very GOOD'))
print(analyser.polarity_scores('This is very GOOD!!!!'))
print(analyser.polarity_scores('This is good :-))'))
print(analyser.polarity_scores('This is not good :-(('))
print(analyser.polarity_scores('Is this good?'))
print(analyser.polarity_scores('This is not good'))
print(analyser.polarity_scores('This is better'))
print(analyser.polarity_scores('This could be better'))
print(analyser.polarity_scores('The acting was good, but the film could have been better'))
print(analyser.polarity_scores('The acting was good, but the film is bad'))
print(analyser.polarity_scores('You are 10'))
```

```
{'neg': 0.0, 'neu': 0.408, 'pos': 0.592, 'compound': 0.4404}
{'neg': 0.0, 'neu': 0.346, 'pos': 0.654, 'compound': 0.5826}
{'neg': 0.0, 'neu': 0.433, 'pos': 0.567, 'compound': 0.6028}
{'neg': 0.0, 'neu': 0.371, 'pos': 0.629, 'compound': 0.7264}
{'neg': 0.0, 'neu': 0.23, 'pos': 0.77, 'compound': 0.7717}
{'neg': 0.376, 'neu': 0.624, 'pos': 0.0, 'compound': -0.3412}
{'neg': 0.0, 'neu': 0.408, 'pos': 0.592, 'compound': 0.4404}
{'neg': 0.445, 'neu': 0.555, 'pos': 0.0, 'compound': -0.3412}
{'neg': 0.0, 'neu': 0.408, 'pos': 0.592, 'compound': 0.4404}
{'neg': 0.0, 'neu': 0.508, 'pos': 0.492, 'compound': 0.4404}
{'neg': 0.0, 'neu': 0.608, 'pos': 0.392, 'compound': 0.7003}
{'neg': 0.347, 'neu': 0.511, 'pos': 0.142, 'compound': -0.5859}
{'neg': 0.0, 'neu': 1.0, 'pos': 0.0, 'compound': 0.0}
```

Após a análise de sentimentos ser feita com a aplicação do VADER, foi possível entendera distribuição do dataset. Uma informação importante é saber a quantidade de frases classificadas

[14] https://pypi.org/project/vaderSentiment/

automaticamente pela abordagem proposta como positiva, negativa ou neutra. A partir da geração do gráfico abaixo é possível observar que a maioria dos comentários - cerca de 17.500 - são de ordem positiva. Ao comparar o resultado do VADER com o da biblioteca de processamento de dados textuais TextBloob, os resultados foram bastante similares.

Figura 4 – VADER

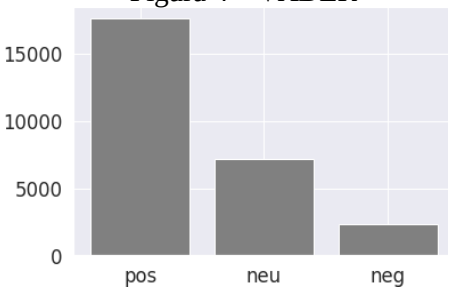
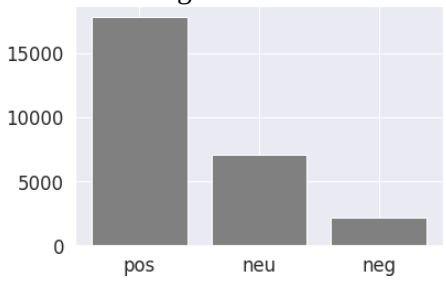


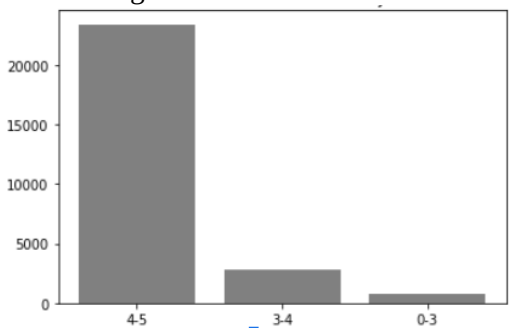
Figura 5 - TextBloob



5. Análise dos resultados

Para avaliar a precisão da classificação da abordagem proposta neste artigo, comparou-se a polaridade obtida pelo VADER (categorias "positiva", "neutra" ou "negativa") com as notas médias das lojas (de 1 a 5 estrelas) atribuídas manualmente pelos próprios clientes, e disponíveis no dataset. A intenção, portanto, foi avaliar quão bem a abordagem proposta conseguiu capturar o sentimento expresso pelos clientes em suas avaliações e comentários. Para tal avaliação, as notas atribuídas pelos clientes foram agrupadas em categorias de referência, de acordo com o seguinte critério: nota média da loja < 3 na categoria de referência "negativa", nota entre 3 e 4 na categoria de referência "neutra", e nota >= 4 na categoria de referência "positiva". O gráfico da Figura 6 mostra a quantidade de avaliações dentro das categorias citadas. Pode-se observar que as notas, em sua maioria, são positivas, além disso, a nota média geral dos comentários foi de 4.37, o que é mais um indício de coerência da classificação obtida automaticamente.

Figura 6 - Faixa média de notas



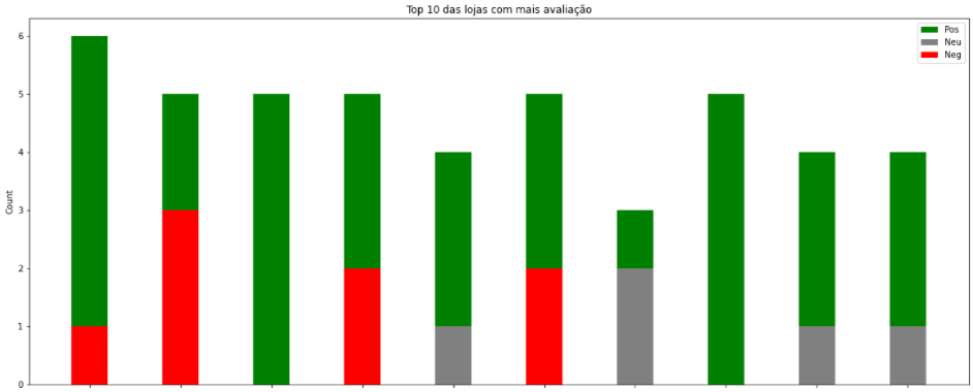
Além da Figura 6, foi construída uma nuvem de palavras para ter um resumo das palavras mais frequentes nos comentários dos clientes, ilustrada na Figura 7. Em uma nuvem de palavras, o tamanho do caractere é proporcional ao número de ocorrência do mesmo no texto. Com essa construção, notou-se palavras de sentimentos positivos com uma intensidade considerável, tais como good, excellent e great, confirmando mais uma vez a coerência do resultado do VADER. Ademais, é observado que muitos clientes comentam sobre o serviço, atendimento, material, produto e preço.

Figura 7 - Nuvem de palavras



Para obter um resumo dos resultados, foram analisadas as 10 lojas mais comentadas (Figura 8). Em duas dessas dez lojas todos os comentários são positivos, em seis lojas a maioria dos comentários é de ordem positiva, as duas restantes possuem maioria negativa e neutra cada uma. Todas as lojas possuem nota de avaliação média superior a 4, com exceção de uma que possui nota média 2,85.

Figura 8 - Top 10 das lojas mais comentadas

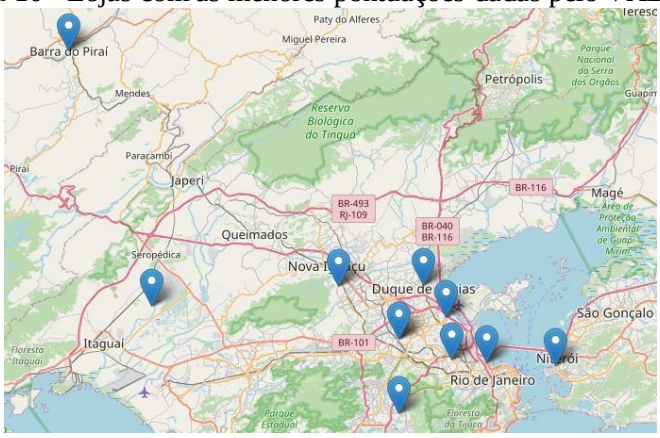


Com o objetivo de encontrar a localização das lojas mais positivas e mais negativas, foi construído um agrupamento com todos os comentários de cada loja e a média da coluna de pontuação composta extraída do léxico VADER, a partir desse agrupamento foram selecionadas as 10 lojas com as maiores médias e 10 lojas com as menores médias. Nas Figuras 9 e 10 são exibidos os mapas das lojas com maior e menor pontuação composta respectivamente.

Figura 9 - Lojas com as maiores pontuações dadas pelo VADER



Figura 10 - Lojas com as menores pontuações dadas pelo VADER



6. Conclusão

Devido ao uso extensivo da web para expressar opiniões acerca de diversos assuntos, além do seu uso crescente para buscar opiniões de consumidores sobre determinado produto ou serviço antes de finalizar uma compra, as empresas devem se preocupar ainda mais em saber como seu produto está sendo recebido pelo público. Assim, as Organizações podem ajustar sua estratégia de vendas e marketing conforme a opinião de seus consumidores. Sabendo da importância do Varejo na economia brasileira e da escassez de análises nessa área que consideram o ponto de vista do consumidor, este trabalho reforça esses pontos, aplicando uma abordagem de análise de sentimentos que utiliza o VADER sobre dados históricos do setor do comércio do Rio de Janeiro. De acordo com os resultados experimentais, as lojas são majoritariamente bem avaliadas pelos consumidores, e dentre os assuntos avaliados, os mais frequentes são o serviço, preço, produto e material, o que mostra os pontos mais importantes para os clientes e, consequentemente, pontos os quais as Organizações devem se preocupar ainda mais em manter uma alta qualidade. Além disso, a nuvem de palavras mostrou que os termos mais comuns são great, excellent e good, reforçando assim a conclusão da percepção dos clientes em relação às lojas do Rio de Janeiro ser positiva.

7. Referências

Avanco, L. V. e Nunes, M. G. V. (2014). Lexicon-Based Sentiment Analysis for Reviews of Products in Brazilian Portuguese. in 2014 Brazilian Conference on Intelligent Systems (BRACIS), pp. 277-281, São Paulo.

Campos, J. Baião, F. A., Gonçalves, J. C. A. R. e Santoro, F. M. (2018). Análise de Sentimentos em Mensagens de E-mails Sobre Resolução de Incidentes de TI. III Seminário Internacional de Estatística com R, Niterói.

CECI, F., Alvarez, G. M. e Gonçalves, A. L. (2017). Análise de Sentimento e Mineração de Opinião: uma revisão bibliométrica da literatura. Revista Espacios, v. 38, p. 12-26, [S.I.]

Cirqueira D., Jacob A., Lobato F., de Santana A.L., Pinheiro M. (2017) Performance Evaluation of Sentiment Analysis Methods for Brazilian Portuguese. In Business Information Systems Workshops, pp. 245-251. Springer, Cham.

Hecksher, A. e Ebecken, N. F. F. (2017). Estudo comparativo de mineração de opiniões em rede varejista. *Sistemas & Gestão*, *11*(4), 423-430

Hutto, C.J. e Gilbert, E. (2015). VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text. Proceedings of the 8th International Conference on Weblogs and Social Media, ICWSM.

Kotler, P. e Keller, K. L. (2012). Administração de Marketing, Editora Pearson, São Paulo.

Liu, Bing (2012). Sentiment Analysis and Opinion Mining. Editora Morgan & Claypool Publishers, Chicago.

Pandey, P. (2018). Simplifying Sentiment Analysis using VADER in Python (on Social Media Text).https://medium.com/analytics-vidhya/simplifying-social-media-sentiment-analysis- using-vader-in-python-f9e6ec6fc52f

Ratmele, A. e Thakur, R. (2020). Feature Based Opinion Classification (FBOC) of Customer Reviews. Indian Journal Of Computer Science And Engineering, p. 892-898, Indore.

Reis, J., Pollyanna G., Matheus A., Adriano C. P., e Fabricio B. (2015). Uma Abordagem Multilíngue para Análise de Sentimentos. Anais do IV Brazilian Workshop on Social Network Analysis and Mining, Recife, SBC, 2015, pp.

Ribeiro, P. C. e Oliveira, V. S. (2020). Aplicação de Data Science para classificação automática de mensagens em um processo intensivo em conhecimento através de mineração de textos. TFC em Engenharia de Produção, Pontifícia Universidade Católica do Rio de Janeiro.

Sujanová, J., Nováková, R., Pavlendová, G., Cagánová, D. e Canet, N. (2020). Preliminary Qualitative Analysis and Implications of Wood Products Perception on Social Media. Drvna Industrija, p. 295-300, Eslováquia.

Sun, S., Luo C. e Chen, J.. A review of natural language processing techniques for opinion mining systems. Information Fusion 36, p. 10-25, Shanghai.

Terra, E., Serrentinp, A., Biagi, H., Nossig, R., Alves, M. O., Besnosoff, F. e Muller, R. (2020).O Papel do Varejo na Economia Brasileira. Sociedade Brasileira de Varejo e Consumo, [S.I.].

Wai, M.S. e Aung, S. S. (2017). Simultaneous opinion lexicon expansion and product feature extraction, IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS), pp. 107-112, Wuhan.

Yue, L., Chen, W., Li, X., Zuo, W., Yin, M (2019). A survey of sentiment analysis in social media .Knowl Inf Syst 60, 617–663

Zahoor, S. e Rohilla, R. (2020). Twitter Sentiment Analysis Using Lexical or Rule Based Approach: A Case Study. 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), pp. 537-542, Noida.