

Avaliação de emoções no Twitter com métodos de Ciências de Dados

Renato de Oliveira Moraes (Universidade de São Paulo)



Esse artigo apresenta um modelo de monitoramento de emoções sobre Campos de Jordão em mensagens postadas no Twitter. A classificação das emoções foi feita através do Support Vector Machine porque a literatura indicava esse algoritmo como um dos que tinham melhores resultados em problemas desse tipo. Os dados foram colhidos durante o último quadrimestre de 2022 e rotulados manualmente por um dos autores com base na taxonomia de emoções básicas de Ekman. O tratamento inicial dos dados foi feito com dois procedimentos concorrentes. Foi observado que os melhores resultados, em função dos indicadores da qualidade da classificação, eram obtidos tratando as mensagens com o Bidirectional Encoder Representations from Transformers (BERT) antes da classificação, do que com o Bag of words. A performance geral do modelo de classificação, considerando apenas os indicadores de precisão e sensibilidade, ficou abaixo do relatado em outros trabalhos na literatura, apesar de se ter atingido significância prática. Por fim, cabe destacar a importância do processo de rotulagem e da taxonomia de emoções no resultado da classificação das emoções. A natureza do objeto ao qual as emoções estão associadas parece ter um papel importante na taxonomia a ser adotada, o que se contrapõe a ideia de um conjunto de emoções básicas universais.

Palavras-chave: Análise de Emoções, Support Vector Machine, Redes de Aprendizagem Profunda, Bidirectional Encoder Representations from Transformers, Redes Sociais, Twitter

1. Introdução

Existem hoje mais de 4,20 bilhões de usuários de mídias sociais em todo o mundo (KEMP, 2021), resultado da crescente popularidade dessas mídias. No Brasil, segundo o relatório Resultados Digitais¹, as redes sociais com maior número de usuários em 2023 são WhatsApp (169M), YouTube (142M) e Instagram (113M). Os usuários dessas redes expressam emoções, sentimentos, opiniões e percepções sobre as mais diversas entidades – locais, ideias, valores, crenças, comportamentos, eventos, pessoas, produtos, marcas e empresas, e essa liberdade de expressão pode gerar tantos resultados positivos como negativos em certas pessoas ou grupos de pessoas que recebem essas mensagens.

Os recentes avanços em tecnologias (softwares e algoritmos) para capturar e analisar dados não estruturados oferecerem meios para monitorar as manifestações das pessoas nas redes sociais bem como analisar as emoções a elas subjacentes (KEININGHAM et al, 2020).

O monitoramento de emoções nas redes sociais pode ser usado para acompanhar diversas entidades (SYKORA et al, 2022), inclusive localidades e regiões turísticas. Essas localidades têm uma economia fortemente baseada na atividade turística, da qual depende direta ou indiretamente grande parte de sua população. Assim, as mensagens nas redes sociais sobre essas localidades são do interesse das empresas de turismo que atuam na região como também do poder público responsável pelo bem-estar local.

O objetivo geral deste trabalho é identificar e avaliar as emoções nos posts feitos no Twitter em relação a Campos do Jordão. O Twitter foi escolhido como a rede social para o estudo pela facilidade que esta plataforma oferece para a coleta de dados. Talvez por esse motivo é que existam mais trabalhos sobre o monitoramento dessa rede do que outras que, pelo menos no Brasil, têm mais usuários. A localidade escolhida foi Campos do Jordão por ser um tradicional destino turístico da população da região metropolitana de São Paulo e de alto poder aquisitivo. Para que o objetivo geral fosse atingido, foram estabelecidos os seguintes objetivos específicos:

- a) Adotar uma taxonomia de emoções para analisar as mensagens coletadas.
- b) Adotar um procedimento para coletar as mensagens nos posts do Twitter
- c) Construir um modelo de classificação das emoções em posts no Twitter
- d) Avaliar o desempenho do modelo de classificação

¹ <https://resultadosdigitais.com.br/marketing/redes-sociais-mais-usadas-no-brasil/#:~:text=O%20relat%C3%B3rio%20Digital%202021%2C%20por,brasileiros%20que%20usam%20a%20plataforma>. Acessado em 24/03/2023 às 09:55

O modelo de classificação dos sentimentos é baseado no algoritmo Support Vector Machine (SVM ou Máquina de vetores de suporte, em Português). O pré-processamento das mensagens foi feito com dois procedimentos: bag of words, que é uma forma de procedimento mais tradicional, e através da rede BERT (Bidirectional Encoder Representations from Transformers), que é um algoritmo de aprendizado profundo criado pela Google para processamento de linguagem natural.

A construção e a avaliação de desempenho do modelo gerado sugerem que a adoção de uma taxonomia de emoções adequada a natureza do objeto em análise (destino turístico de inverno) é chave para o desempenho do procedimento de monitoramento das emoções. Esse resultado contrasta com a ideia de um conjunto de emoções básicas que poderia ser aplicado em aplicadas em diferentes contextos.

2. Referencial teórico

Nem sempre os trabalhos na área de Ciências de Dados fazem a distinção entre os termos emoção, sentimento, estados emocionais e opinião, e eles acabam sendo tratados como sinônimos (SYKORA et al, 2013). Segundo Jarymowicz e Imbir (2015), sentimentos resultam de processos cognitivos baseados em expectativas e percepções dos indivíduos em relação às suas experiências pessoais, e emoções são reações a episódios. Mesmo que relacionados, sentimentos e emoções são, nessa visão, conceitos claramente distintos. Contudo, na área de ciências de dados, diferentemente da psicologia, não costuma fazer uma distinção entre os dois conceitos, e quando é feita, é baseada em outra abordagem. Rosa (2015) associa a análise de sentimentos a uma visão polarizada em que os sentimentos são classificados em positivos, negativos ou neutros, enquanto a análise de emoções está associada ao uso de uma taxonomia de emoções.

Existem na literatura algumas taxonomias de emoções (ROSA, 2015; GONÇALVES et al, 2012; BOUAZIZI e OHTSUKI, 2016; EKMAN, 1972; PLUTCHIK, 1986; SHAVER, 1987; LOVHEIM, 2011; KANSAON et al, 2019; SYKORA et al, 2013), como mostra o Tabela 1. Parece haver uma mistura de conceitos em algumas dessas taxonomias. Kansaon et al (2019) usam adjetivos e substantivos para descrever emoções, o que mistura o estado do indivíduo (adjetivo) com a emoção (substantivo). Além disso, a Ironia parece mais ser um tipo de manifestação motivada por uma emoção como raiva ou desprezo do que uma emoção em si. Argumentação semelhante poderia ser feita em reação à fadiga, honestidade e diversão, por exemplo.

Por outro lado, algumas emoções são mais frequentes nas taxonomias dos que outras. Raiva, Surpresa e Tristeza aparecem em quase todas as taxonomias, o que reforça a ideia de que existam emoções básicas do ser humano que independem do contexto.

Há também que se destacar que algumas emoções são próximas como, por exemplo, alegria e felicidade, tristeza e desgosto, o que gera uma dificuldade extra de classificação.

Neste trabalho, optou-se por usar inicialmente a tipologia de Ekman (1972) pelas seguintes razões: (i) é bastante conhecida e referenciada nos trabalhos sobre análise de emoções (ii) usa emoções que aparecem com grande frequência em outras tipologias, e (iii) é relativamente pequena, com apenas seis emoções

Tabela 1 – Taxonomias de emoções

Autores	Emoções básicas
Ekman 1972	Raiva, Medo, Alegria, Tristeza, Surpresa, Desgosto
Plutchik 1986	Raiva, Medo, Alegria, Tristeza, Surpresa, Desgosto, Confiança, Antecipação
Shaver 1987	Raiva, Medo, Alegria, Tristeza, Surpresa, Amor
Lovheim 2011	Raiva, Medo, Alegria, Desgosto, Surpresa, Interesse, Angústia, Vergonha
Gonçalves et al, 2012	Medo, Tristeza, Culpa, Honestidade, Timidez, Fadiga, Surpresa, Jovialidade, Autoconfiança, Atenção, Serenidade
Rosa 2015	Raiva, Alegria, Tristeza, Surpresa, Nojo
Bouazizi e Ohtsuki 2016	Amor, Felicidade, Diversão, Entusiasmo, Alívio, Ódio, Raiva, Tristeza, Tédio, Preocupação, Surpresa, Neutralidade
Kansaon et al 2019	Triste, Chateado, Amor, Feliz, Raiva, Inveja, Ironia
Sykora et al, 2013	Raiva, Confusão, Desgosto, Medo, Felicidade, Tristeza, Vergonha, Surpresa

As diferenças entre as tipologias de emoção podem estar ligadas aos contextos onde cada um dos trabalhos foi desenvolvido. Assim, as emoções são influenciadas por aspectos culturais como a língua, e pela natureza do objeto das emoções em estudo. Neste trabalho, o objeto das emoções em estudo é um destino turístico. Apesar disso, mesmo reconhecendo a possibilidade de que existiria uma tipologia de emoções mais adequada a este objeto, parte-se de uma tipologia da literatura.

Os trabalhos sobre análise de emoções (e ou sentimentos) utilizam um processo de três fases principais: coleta, tratamento e análise de dados Silva (2016). Os dados coletados na plataforma não estão em um formato adequado para análise de seu conteúdo, sendo necessário um tratamento prévio dos dados. Silva (2016) usou as etapas de extração e redução das

caraterísticas: (i) Extrair as palavras de cada tweet, (ii) Remover pontuação e símbolos, (iii) Remover stop words, (iv) Extrair bigramas e trigramas, e (v) Normalização Léxica.

Diferentes métodos de aprendizagem supervisionada são utilizados, como Naive Bayes, Suport Vector Machine (SVM), árvore de decisão, random forest e regressão logística, e não está claro em quais condições cada método apresenta melhor resultado. Aguiar et al (2018) usou um comitê de algoritmos e verificou (i) que o resultado obtido não é melhor que os resultados individuais e que (ii) alguns métodos apresentam resultados bem próximos – Naive Bayes, Support Vector Machine (SVM). Dessa forma optou-se por usar neste trabalho o SVM como método de classificação das emoções.

A análise de desempenho de um algoritmo de classificação, como o que se pretende desenvolver aqui, é baseada em uma matriz de confusão como a mostrada na Tabela 2 para uma variável com apenas duas categorias. As ideias de avaliação para essa situação podem ser facilmente expandidas quando a variável em questão tem mais categorias.

Tabela 2 – Exemplo de matriz de confusão

		Realidade	
		Positivo (1)	Negativo (0)
Previsão	Positivo (1)	VP – Verdadeiro Positivo	FP – Falso Positivo
	Negativo (0)	FN – Falso Negativo	VN – Verdadeiro Negativo

O desempenho do método de classificação pode ser avaliado com base em 4 indicadores: eficácia, precisão, sensibilidade e especificidade. A eficácia, ou acurácia, refere-se a taxa de acerto global do modelo e é calculada pela expressão $\frac{(VP+VN)}{(VP+FN+FP+VN)}$. A precisão do modelo representa a probabilidade (frequencial) da previsão positiva do modelo ser verdadeira e é dada pela expressão $\frac{VP}{(VP+FP)}$. A sensibilidade (revocação ou recall) refere-se à capacidade estimada do modelo de identificar os casos positivos e a especificidade à capacidade de identificar os negativos e são das pelas expressões $\frac{VP}{(VP+FN)}$ e $\frac{VN}{(FP+VN)}$, respectivamente.

3. Metodologia

O desenvolvimento deste trabalho foi baseado nas seguintes etapas:

- Entendimento/definição do problema de negócio. Essa fase inclui a definição do escopo do problema e a geração do banco do estudo.
- Entendimento dos dados. Nesta etapa será feita a rotulagem dos dados (classificação dos tweets da base de dados), definição da taxonomia de emoções usadas no estudo.

- c) Preparação dos dados. Será feita uma limpeza e preparação dos dados para o seu processamento, com tarefas como: remoção de pontuação, símbolos e stop words, extração bigramas e trigramas, e normalização Léxica.
- d) Treinamento/modelagem. Desenvolvimento dos modelos de classificação de emoções com Python e suas bibliotecas.
- e) Avaliação. As medidas de desempenho serão comparadas as observadas na literatura.

A coleta dos dados usou a API do Twitter e a ferramenta Postman disponível gratuitamente na internet.

As mensagens diárias sobre a localidade em estudo (Campos do Jordão) passaram ser colhidas a partir de 2 de outubro de 2022 (cada arquivo de dados continha todas as mensagens de um dia sobre a localidade) até o 31 de dezembro de 2022. As mensagens foram inicialmente classificadas de acordo com a taxonomia adotada no estudo em função da emoção principal, a mais proeminente, relevante.

Para desenvolver o modelo, os dados colhidos foram divididos aleatoriamente em duas partes, uma base de dados de desenvolvimento/treinamento (70%) e outra de avaliação/teste (30%). A rotulagem das mensagens foi feita pelo autor a partir da tipologia proposta por Ekman (1972) sobre as emoções básicas. Esta é uma tarefa importante porque os métodos de aprendizagem supervisionada pedem um conjunto de dados já corretamente classificados, e a qualidade do processo de classificação está ligada ao volume de dados já previamente classificados.

A implementação do método de classificação foi feita na linguagem Python com o apoio das seguintes bibliotecas:

- Pandas. Para manipulação de dados em formato de tabelas (linhas e colunas).
- Numpy. Para manipulação de dados em formato de matrizes.
- Scikit-learn. Com algoritmos de aprendizagem para treinamento, teste e avaliação de modelos de classificação e predição. Foi usada nesse trabalho para desenvolver o modelo de classificação baseado no Support Vector Machine (SVM), e para redução da dimensionalidade do problema pela aplicação do método de componentes principais (PCA).
- Nltk. Para manipulação e tratamento de textos. Foi usada para o pré-processamento das mensagens para a criação do bag of words (BoW).
- Transformers. Para geração de embeddings com a técnica BERT (Bidirectional Encoder Representation from Transformers) usada nos modelos revisados.

A avaliação dos resultados foi feita usando uma matriz de confusão e os indicadores de desempenho a ela associados: eficácia, precisão, sensibilidade e especificidade, como exposto anteriormente.

4. Resultados observados

Uma primeira base com 2.184 mensagens sobre a cidade de Campos do Jordão postadas no período de 2/out/22 até 8/nov/22 foi usada para desenvolver o processo de rotulagem das mensagens. A rotulagem dessas mensagens foi feita manualmente pelo autor usando inicialmente a tipologia de Ekman. O processo de coleta de dados continuou até 31/dez/22, gerando um total de 5.571 mensagens colhidas.

A classificação das emoções mostrou-se mais complicada do que se supunha inicialmente. A ideia de uma tipologia a priori sobre emoções básicas mostrou-se pouco adequada ao objeto do estudo (localidade turística), o que levou a ajustes da tipologia. Duas emoções foram agrupadas em uma nova (Raiva e Medo se uniram em Aversão), e foram inseridas uma nova emoção (Desejo) e as categorias Propaganda e Informação. Além disso, a ideia de uma mensagem possuir uma emoção única ou dominante também se revelou questionável e problemática, como no tweet “meu pai não quis desviar a rota p eu passar em campos do jordão, tóxico!” (Grafia original mantida) (Usuário leclertz em 11/12/2022). A mensagem mostra que o autor está zangado ou triste com o pai (Raiva ou Tristeza), mas também que gostaria de ir a Campos do Jordão (Desejo). Nesse caso, como objetivo do estudo é avaliar as emoções em relação a Campos do Jordão, e não em relação aos pais, a emoção da mensagem foi classificada como Desejo. Em outros casos mais de uma emoção poderia ser inferida em relação a localidade, como na mensagem “Meu ex ficante me convidando pra ir pra Campos do Jordão, e agora o que eu faço” (Grafia original mantida) (Usuário bele_barbosa04 em 27/11/2022). A autora da mensagem pode estar alegre pelo convite, pode estar surpresa e ela pode estar com medo das consequências de aceitar (ou não) o convite. Assim, a escolha de uma emoção (e a própria identificação das emoções associadas à mensagem) da tweet está ligada também a percepção de quem lê a mensagem, e não só de quem a emite. Uma outra questão que poderia ser levantada é se a mensagem, e a sua emoção, se refere a Campos do Jordão, que é o objeto em estudo, ou ao convite feito, que estaria fora do escopo do estudo.

A quantidade de mensagens usadas na construção do modelo foi 4.183 tweets. A maior parte não teve emoção identificada (35%) ou era propaganda (12,6%) e informação (16,1%). Assim, apenas 36,3% das mensagens continham alguma emoção.

Foram extraídos 2.700 componentes durante a análise de componentes principais com variação explicada de 96,2% do problema original. Apesar do número alto de componentes extraídos, ele representa apenas 25,9% do tamanho do problema original, que tinha 10.443 colunas. Ou seja, reduziu-se o problema em cerca de 75% (3/4 do problema original), mas manteve-se cerca de 96,2% do comportamento do conjunto de todas as variáveis originais – uma leve perda da informação.

Para o desenvolvimento treinamento do modelo SVM, a base de dados foi dividida em treinamento e teste (70% e 30%, respectivamente).

A avaliação da qualidade da classificação das emoções de forma individual foi feita com base em matrizes auxiliares específicas para cada emoção, o que permitiu avaliar o modelo em termos de cada uma das emoções. Essas matrizes específicas são sínteses da matriz de confusão original. Um exemplo desse tipo de matriz para a emoção Aversão é mostrada na Tabela 4. Com ela é possível calcular os indicadores da qualidade da classificação do modelo – eficácia/curácia, sensibilidade, precisão e especificidade. A Tabela 5 mostra esses indicadores para cada emoção.

Tabela 3 – Matriz de confusão com os dados de teste com uso de SVM

		Classe Predita								
		Nenhuma	Propaganda	Informação	Aversão	Alegria	Tristeza	Surpresa	Desgosto	Desejo
Classe Real	Nenhuma	479	18	7	16	36	6	16	15	2
	Propaganda	24	163	1	1	2	0	2	0	0
	Informação	11	4	245	0	0	0	0	0	0
	Aversão	43	0	1	18	21	8	7	6	5
	Alegria	59	0	0	23	53	17	14	10	5
	Tristeza	21	0	0	4	13	21	8	5	1
	Surpresa	45	1	0	5	17	6	20	7	5
	Desgosto	24	0	0	4	19	11	8	21	8
	Desejo	12	0	0	1	4	6	6	14	17

Tabela 4 – Matriz de confusão para o sentimento Aversão

Aversão		Classe Predita	
		Positiva	Negativa
Classe Real	Positiva	18	91
	Negativa	54	1.509

Tabela 5 – Indicadores de desempenho do modelo de classificação para dada emoção

Emoção	Indicadores de desempenho			
	Eficácia/Acurácia	Sensibilidade	Precisão	Especificidade
Propaganda	96,8%	87,6%	84,5%	98,0%
Informação	98,6%	96,5%	94,2%	98,9%
Aversão	91,3%	25,0%	16,5%	94,3%
Alegria	85,6%	32,1%	29,3%	91,5%
Tristeza	93,7%	28,0%	28,8%	96,7%
Surpresa	91,2%	24,7%	18,9%	94,6%
Desgosto	92,2%	26,9%	22,1%	95,4%
Desejo	95,9%	39,5%	28,3%	97,4%

Apesar de bons indicadores para Propaganda e Informação, os indicadores de sensibilidade e precisão para as emoções foram bastante baixos. Na tentativa de melhorar o modelo, usou-se o classificador BERT (Bidirectional Encoder Representation from Transformers) para codificar as mensagens.

Segundo Barbosa et al (2020), o BERT é “um modelo de linguagem baseado em redes neurais que vem atingindo bons desempenhos em classificação de textos”. Com ele as strings das mensagens são representadas (e substituídas) por um conjunto de 512 valores numéricos. Ele substitui a geração da bag of words e a aplicação do método de análise componentes principais para redução da dimensionalidade do problema, já que o problema com 512 variáveis (gerados pelo BERT) fica menor do que o problema original com 2.700 componentes.


Foram criados outros 3 modelos alternativos com base no kernel do BERT. O kernel se refere ao algoritmo usado para construção dos embeddings. Foram usados aqueles que permitem trabalhar com problemas com mais de duas classes. Os modelos gerados foram: B-Linear (kernel = “linear”), B-rbf (kernel = “rbf”), e B-Sigmoid (kernel = “sigmoid”).

Para melhor avaliar a qualidade do ajuste de cada modelo, foi feita a avaliação cruzada com k-folds de 5 com os dados de treinamento. O processo detalhado está descrito em Moraes (2023). A Figura 1 mostra o intervalo de confiança (ao nível de 95%) dos modelos para a precisão de cada uma das emoções. Ela também mostra a frequência observada de cada emoção na amostra de teste.

Usou-se como critério mínimo de aceitação da precisão um valor que seja pelo menos 50% maior do que a frequência observada. A ideia é que um critério aleatório teria uma precisão igual à frequência de ocorrência e que um modelo teria utilidade prática apenas se ele tivesse uma taxa de acertos (precisão) pelo menos 50% superior a um processo aleatório de classificação.

É fácil notar que para emoção Desgosto, os modelos B-Linear e B-Sigmoid não atendem esse critério, e que para emoção Desejo, o modelo B-rbf é superior ao modelo BoW. A análise dos intervalos de confiança para todos os quatro indicadores desempenho mostra que o modelo B-rbf nunca é inferior a qualquer outro modelo, o que o torna o modelo de melhor desempenho aqui. O modelo BoW, no que se refere ao indicador Precisão, foi o que teve o pior desempenho – observe os indicadores de Precisão para as emoções Aversão e Desejo na Figura 1.

Figura 1 – Precisão dos modelos



5. Considerações finais

Este trabalho teve o objetivo de avaliar as emoções em mensagens do Twitter sobre o destino turístico Campos de Jordão. Para tanto, foram colhidas as mensagens postadas no último trimestre de 2022 - outubro, novembro e dezembro. As mensagens foram classificadas manualmente pelo autor em função da emoção predominante nelas. Inicialmente foi adotada a tipologia de emoções de Ekman (1972), mas logo no início do processo de rotulagem das mensagens percebeu-se que seria necessário um ajuste na tipologia. Como resultado, as

mensagens foram classificadas em uma tipologia com as seguintes classes: Nenhuma (emoção), Propaganda, Informação, Aversão, Alegria, Tristeza, Surpresa, Desgosto, Desejo. Dentre essas 9 classes, apenas 6 referem-se ao que se poderia chamar de emoção básica.

O modelo inicialmente proposto usou o conceito de bag of words (BoW), análise de componentes principais (PCA – principal components analysis) e Support Vector Machine (SVM) para classificação das mensagens. Seu desempenho não foi bom. Os indicadores de precisão e de sensibilidade foram baixos.

Um modelo alternativo foi então proposto com base no BERT (Bidirectional encoder representation from transformers), que substituiu o uso de BoW e PCA. A classificação por SVM foi mantida. Os resultados melhoraram, especialmente com o uso do Kernel rbf.

Foram construídos intervalos de confiança, ao nível de 95%, para todos os indicadores. Os valores de precisão no modelo final sempre ficaram acima de 50% maior do que o valor da frequência da ocorrência da emoção. Por exemplo, a emoção Surpresa apareceu em 6,3% e o intervalo de confiança para precisão dessa emoção no modelo escolhido era de 29,7% a 47,4%. Isso faz com que o modelo ainda tenha alguma utilidade prática, já que o limite inferior da precisão ainda está acima de 9,5%, que é um valor 50% maior do que a frequência de ocorrência de todas as emoções.

Isso aconteceu para todas as emoções. Os indicadores de precisão e sensibilidade baixos, mas ainda de alguma utilidade prática, ainda são melhores que processos aleatórios de classificação. É bom lembrar que precisão e sensibilidade são indicadores relacionados. A precisão se refere a probabilidade de o modelo classificar corretamente uma determinada emoção, e sensibilidade se refere a probabilidade de a emoção identificada pelo modelo estar correta.

As classes Nenhuma, Propaganda e Informação tiveram indicadores (eficácia, precisão, sensibilidade e especificidade) bem melhores, variando entre 86,1% e 99,5%. Contudo, a proposta original do problema era a construção de modelo para identificação de emoções presentes nas mensagens do Twitter sobre a localidade turística. Propaganda e informação não são emoções, mas apareciam de forma clara e frequentemente nas mensagens coletadas, por isso foram consideradas como classes da tipologia.

É evidente que outros métodos e algoritmos poderiam ter sido usados e que levariam a resultados melhores aos observados aqui. Porém, um processo mais formal de rotulagem das mensagens pode contribuir para o melhor entendimento do problema tratado aqui e o desenvolvimento de melhores modelos. A leitura (e a rotulagem) das mensagens deixou claro que as mensagens postadas são resultados de diferentes processos. Algumas mensagens

procuram expressar as opiniões, sentimentos e emoções do autor, e outras procuram estimular certos comportamentos, ações e atitudes do leitor. Esses últimos se referem as mensagens que foram classificadas de propaganda e informação e, nesse sentido, diferem completamente das primeiras, já que nesses casos a intenção do autor não é apenas expressar-se, mas sim influenciar o leitor. Assim, a distinção conceitual entre sentimentos e emoções, encontrada na psicologia, parece ser menos útil em um problema de monitoramento e classificação de mensagens, na medida em que elas resultam de processos distintos, podendo ora estar mais ligados aos sentimentos e ora às emoções.

Uma limitação deste trabalho é o processo de definição das classes de emoções da tipologia adotada. Um maior rigor e formalização na definição das emoções da tipologia adotada – como declarações escritas da definição do sentimento, rubricas e critérios de classificação, além de exemplos de classificações corretas e incorretas – poderia contribuir para resultados mais consistentes, mesmo que isso pudesse aumentar, de forma significativa, a complexidade do trabalho. Este procedimento poderia reduzir o percentual de mensagens classificadas como sem nenhuma emoção, que neste trabalho ficou em 35,6%.

Um outro aspecto importante a considerar, é que este trabalho considerou que apenas uma emoção é mais importante ou proeminente em uma mensagem. A leitura das mensagens mostrou que isso não é verdade para uma parcela significativa delas. Considerar a possibilidade de mais de uma emoção em uma mesma mensagem tornaria o modelo mais próximo da realidade observada, mais isso levaria a substanciais alterações na estrutura dos modelos desenvolvidos aqui.

Por fim, a definição dos tipos de emoções a serem usadas no modelo de classificação deva considerar a natureza do objeto monitorado. Por exemplo, no caso estudado de Campos do Jordão, foram pouquíssimas as mensagens que manifestavam Medo, tanto que Raiva e Medo foram agrupadas em Aversão. Mas seria razoável supor que as mensagens sobre a cidade de Recife, manifestem medo ou apreensão em função dos seus índices de violência urbana e de ataques de tubarões aos banhistas na praia de Boa Viagem. Isto é, apenas definir o objeto das mensagens monitoradas não é suficiente para identificar as emoções (sentimentos ou opiniões) a serem considerados.

REFERÊNCIAS

- AGUIAR, E. et al. **Análise de Sentimento em Redes Sociais para a Língua Portuguesa Utilizando Algoritmos de Classificação**. In: XXXVI SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES E SISTEMAS DISTRIBUÍDOS, 2018. Anais do XXXVI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, SBC, Campos do Jordão, 2018. p.393-406.
- BARBOSA, B. et al. **Predição do movimento do índice Ibovespa a partir de notícias**. Relatórios Técnicos. ICMC - São Carlos – SP. Dez-2020.
- BOUAZIZI, M. e OHTSUKI, T. (2016). **Sentiment Analysis in Twitter: From Classification to Quantification of Sentiments within Tweets**. In: GLOBAL COMMUNICATIONS CONFERENCE (GLOBECOM), 2016. Proceedings of Global Communications Conference, USA, 2016.
- EKMAN, P.. All emotions are basic. IN FOX, A. S et al (ed). **The nature of emotion: Fundamental questions** Oxford University Press, pp 15-19. 1994
- GONÇALVES, P.; DORES, W. e BENEVENUTO, F. PANAS-t: **Uma escala psicométrica para medição de sentimentos no Twitter**. In: Brazilian Workshop on Social Network Analysis and Mining, 2012. Anais do I Brazilian Workshop on Social Network Analysis and Mining. SBC, 2012.
- JARYMOWICZ, M. T. e IMBIR, K. K. **Toward a Human Emotions Taxonomy (Based on Their Automatic vs. Reflective Origin)**. Emotion Review. v. 7, n. 2, p. 183–188, April 2015. Doi: 10.1177/1754073914555923
- KANSAON, D., BRANDÃO, M. A. e PINTO, S. A. P. **Análise de Sentimentos em Tweets em Português Brasileiro**. iSys: Revista Brasileira de Sistemas de Informação, v. 12, n. 3, p. 116-138, 2019.
- KEININGHAM, T. et al. **Customer experience driven business model innovation**. Journal of Business Research, n. 116, p. 431–440, 2020.
- KEMP, S. (2021). **Digital 2021: Global Overview Report**. Retrieved from <https://datareportal.com/reports/digital-2021-global-505-overview-report>
- LOVHEIM, H. **A new three-dimensional model for emotions and monoamine neurotransmitters**. Medical Hypotheses v. 78, n. 2, p. 341–348, 2012.
- MORAES, R. O. **Avaliação de emoções no Twitter sobre localidades turísticas**. Trabalho de conclusão de Cursos. MBA em Ciência de Dados. Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2023
- PLUTCHIK, R. **Emotion: A Psychoevolutionary Synthesis**. Longman Higher Education. 1980
- ROSA, R. L. **Análise de sentimentos e afetividade de textos extraídos das redes sociais**. 2015. 99f. Tese (doutorado) Escola de Politécnica da Universidade de São Paulo. 2015.
- SHAVER, P. et al. **Emotion knowledge: Further exploration of a prototype approach**. Journal of Personality and Social Psychology. v. 52, n. 6, 1987.
- SILVA, N. F. F. **Análise de sentimentos em textos cursos provenientes de redes sociais**. 2016. 112f. Tese (doutorado) - Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo, pp 112. 2016
- SYKORA, M. D. et al. **Emotive ontology: extracting fine-grained emotions from terse, informal messages**. IADIS International Journal on Computer Science & Information Systems. v. 8 n. 2, p. 106-118, 2013.
- SYKORA, M. et al. **The power of emotions: Leveraging user generated content for customer experience management**. Journal of Business Research, v. 144, p. 997–1006, 2022.