

ANÁLISE DE SENTIMENTOS APLICADA À REALIDADE DA DOAÇÃO DE SANGUE NO BRASIL USANDO DADOS DO TWITTER

Diego Henrique Ferreira¹ e Evandro Eduardo Seron Ruiz¹

¹Departamento de Computação e Matemática, FFCLRP - Universidade de São Paulo, Ribeirão Preto, Brasil

Resumo: Objetivo: Analisar os sentimentos e opiniões dos usuários do Twitter a respeito da doação de sangue no Brasil. Foram coletados mais de 19 mil tweets relacionados à doação de sangue, publicados entre 1º de janeiro de 2015 e 31 de dezembro de 2015. Deste total de tweets, uma amostra de 1364 tweets foi selecionada para compor dois conjuntos de dados: um para treinar e outro para avaliar. **Métodos:** Os 4 algoritmos de classificação adotados neste trabalho, são eles: Multinomial Naïve Bayes, Bernoulli Naïve Bayes, Gaussian Naïve Bayes e Maximum Entropy. **Resultado:** A classificação dos tweets em três possíveis classes (positiva, negativa e neutra) foi realizada. Os classificadores Multinomial Naïve Bayes e Maximum Entropy obtiveram os melhores resultados. **Conclusão:** Pudemos observar que o algoritmo Multinomial Naïve Bayes obteve o melhor desempenho na classificação do conjunto total de mensagens.

Palavras-chave: L01.313.500.750.280.199, G17.035.250.500.500, L01.224.230.110.500.750

Abstract: Objective: Analyze the sentiments and opinions from Twitter users about blood donation in Brazil. We collected 19 thousand tweets related to blood donation between January 1st and December 31st, 2015. From those, 1364 tweets were randomly select to compose the training and the evaluation test set. **Methods:** Four classifiers were applied: Multinomial Naïve Bayes, Bernoulli Naïve Bayes, Gaussian Naïve Bayes e Maximum Entropy. **Results:** The tweets have been classified as positive, negative and neutral. The classifiers Multinomial Naïve Bayes e Maximum Entropy achieved better results. **Conclusion:** We have observed that the Multinomial Naïve Bayes classifier achieved the best performance in the overall set of messages.

Keywords: D057225, D000069553, D061108

Introdução

Estudos envolvendo dados coletados em plataformas de *microblogs* vêm mostrando resultados bastante expressivos para o monitoramento de diversos eventos e tópicos relacionados à saúde pública como, por exemplo, o monitoramento de epidemias¹ e de campanhas de vacinação².

Com mais de 310 milhões de usuários ativos, o *Twitter*, é a principal plataforma atual de *microblogs* e tem sido cada vez mais adotado por pesquisadores de diversas áreas do conhecimento como uma excelente fonte de dados para suas análises e estudos envolvendo análises de opiniões públicas, difusão de informação, monitoramento de atividades e acontecimentos ao longo do tempo, entre outros. Usuários do *Twitter* fazem suas publicações de status através de mensagens de texto livre de no máximo 140 caracteres chamados *tweets*.

Recentemente, o fenômeno do *Health self-reporting* (“auto-relato de saúde”, em tradução livre) tem se mostrado cada vez mais presente nos *tweets* publicados. Este fenômeno ocorre quando um usuário publica informações sobre sua própria saúde, destacando doenças, diagnósticos e tratamentos

que está realizando ou realizou. Este fenômeno também permite que uma enorme quantidade de informação a respeito da saúde da população seja disponibilizada publicamente em tempo real³.

Outra aplicação importante dos dados obtidos em mídias sociais é a análise dos sentimentos presentes e demonstrados nas postagens que os usuários fazem. Usuários do *Twitter*, muitas vezes, demonstram suas opiniões sobre determinados assuntos em seus *tweets*, as quais são rapidamente propagadas entre vários outros usuários. Essas opiniões podem ser sobre os mais variados assuntos, como por exemplo eventos, serviços e produtos, campanhas, organizações e podem conter teores positivos e negativos, como duras críticas. Tendo em vista a grande quantidade de opiniões publicadas pelos usuários em seus perfis e a rapidez com essas opiniões são propagadas, percebeu-se que a análise dessas informações poderia contribuir para que empresas e organizações conhecessem melhor as opiniões dos usuários sobre seus produtos e serviços oferecidos a partir do que era publicado na web⁴.

Neste contexto destaca-se uma importante área de estudo em Processamento de Linguagem Natural (PLN), que juntamente com a Mineração de Textos, tem como objetivo a extração e identificação de sentimentos e opiniões expressados em mensagens de texto livre: a Análise de Sentimentos (AS). A AS tem sido amplamente usada no desenvolvimento de sistemas inteligentes e de recomendações, além de sistemas de suporte à decisão. Consumidores podem usar sistemas baseados na AS para ajudar na decisão de compra de algum produto ou uso de algum serviço antes de tomar a decisão final, ou também empresas podem ter uma visão geral sobre a satisfação pública sobre seus produtos, serviços e campanhas publicitárias⁵.

No contexto de tópicos relacionados à saúde, a AS pode ser considerada uma ferramenta adequada para a percepção dos sentimentos e opiniões da população sobre os serviços prestados por hospitais, clínicas e órgãos de saúde, campanhas realizadas por órgãos governamentais, tratamentos e medicações oferecidos por empresas e prestadores de serviços.

O objetivo deste trabalho foi classificar os *tweets* relacionados à doação de sangue no Brasil de acordo com os sentimentos contidos neles. Devido à grande variedade de tópicos relacionados à saúde brasileira, e afim de evitar problemas com os diferentes vocabulários que cada tópico possa ter, optamos por utilizar apenas *tweets* relacionados à doação de sangue que foram publicados durante o ano de 2015 para a classificação. Os *tweets* coletados foram pré-processados utilizando técnicas de PLN e foram classificados de acordo com o sentimento expressado: positivo, negativo e neutro.

Trabalhos relacionados

A literatura científica tem mostrado que a ferramenta de microblogs *Twitter* é uma fonte de dados adequada para análises populacionais, especialmente as análises e estudos envolvendo aspectos de saúde pública. Paul e Dredze³ mostraram em seu trabalho que como os tweets podem ser usados como ferramentas para tarefas tais como: monitoramento de doenças ao longo do tempo, medição de fatores de risco, identificação de doenças por localização geográfica, análise de medicações e tratamentos. Estes mesmos autores já haviam, em um trabalho anterior³, apresentado um modelo capaz de, a partir de uma coleção de *tweets*, coletar uma variedade de doenças que são discutidas pelos usuários do *Twitter*, agrupando-as por sintomas e tratamentos. Esta ferramenta se mostrou capaz de identificar descrições significativas das doenças, tornando-se uma ferramenta eficaz para vigilâncias sindrômicas³.

Anteriormente, a equipe de Chew¹ já havia utilizado *tweets* para analisar a dispersão de informação a respeito da epidemia de H1N1 nos EUA em 2009, bem como o potencial informacional desta ferramenta de *microblogs*. Este trabalho também mostrou que os *tweets* são uma importante fonte opiniões e sentimentos públicos. Em estudo recente, Almans e colaboradores² realizaram um monitoramento do conteúdo publicado no *Twitter* durante a campanha de vacinação de gripe no Brasil

em 2014. Apesar de o *Twitter* ter sido muito utilizado nesta campanha, neste trabalho foi constatado um baixo número de mensagens com conteúdo realmente relevante sobre a campanha e sobre a gripe.

Estudos em AS ganharam destaque quando Pang e colaboradores⁶ decidiram classificar textos pelos sentimentos expressos neles e não, como usualmente, uma classificação por tópicos. Utilizando *reviews* de filmes como conjunto de dados, aplicaram técnicas de aprendizado de máquina para classificar esses *reviews* como positivos (uma análise positiva do filme) e negativos (uma análise negativa do filme). Os pesquisadores obtiveram resultados satisfatórios na classificação destes *reviews* embora parte dos termos usados nestes são comuns a ambas as classes o que prejudica a categorização.

Dada a grande quantidade de trabalhos dedicados a identificar e analisar as opiniões, também não demorou para o *Twitter* ser adotado com fonte de dados em trabalhos envolvendo AS. Alec Go⁵ e co-autores, pioneiros na área, mostraram a viabilidade de se usar *tweets* para construir sistemas baseados na análise de sentimentos, afim de identificar opiniões públicas a respeito de produtos e serviços. Neste trabalho também foi mostrado que três dos principais algoritmos usados para problemas de classificação de texto (*Naïve Bayes*, *Maximum Entropy* e *SVM*) obtiveram um desempenho de pelo menos 80% de classificações corretas quando treinados usando *tweets* que continham *emoticons*.

Métodos

Coleta de dados, os *tweets*

Os dados foram obtidos a partir de um sistema de coleta automático de *tweets* do Laboratório de Sistemas Computacionais Complexos. O Laboratório monitora continuamente tópicos tais como: ‘zica’, ‘microcefalia’, ‘gripe’, ‘vacina’, ‘vacinação’, ‘febre’, ‘dor’, ‘alergia’, ‘dengue’, ‘chikungunya’, ‘diarreia’, ‘aids’, ‘hiv’, ‘doação de sangue’, entre outros. Hoje, o sistema possui uma coleção de mais de 41 milhões de *tweets*. A partir deste conjunto de dados, recuperamos os *tweets* publicados no período entre 1º de janeiro de 2015 e 31 de dezembro de 2015 que continham em sua mensagem palavras iniciadas em ‘doa’ ou ‘doe’ e a palavra ‘sangue’. Através desta combinação de palavras pudemos abordar os termos mais significativos para esta temática, como por exemplo ‘doe sangue’, ‘doei sangue’ ‘doação de sangue’, ‘doador de sangue’, ‘doar sangue’, ‘doamos sangue’, entre outros.

Etapas de processamento

A Figura 1 a seguir ilustra as etapas de processamento deste trabalho, que são elas: Coleta, filtragem e classificação manual dos *tweets*, obtenção e análise dos modelos de classificação, e Análise de Sentimentos. Cada etapa é descrita a seguir:

Filtragem dos *Tweets*

Dada a possibilidade do uso das APIs do *Twitter* para a publicação de *microblogs*, muitos aproveitadores usam esta facilidade para a geração de *spams* e divulgação massiva de informações. Afim de obtermos uma amostra de *tweets* pessoais, ou seja, publicados diretamente por usuários comuns em suas contas pessoais, coletamos *tweets* publicados por softwares clientes conhecidos tais como: dispositivos *Android*, dispositivos *IOs* (*iPhone* e *iPad*), dispositivos *Windows Phone* e *Web Client* (página do *Twitter*).

Após esta etapa, os *tweets* coletados foram processados por uma aplicação em *Python* que removia *retweets* (*tweets* de terceiros que são reencaminhados) ou que haviam sido compartilhados via outro perfil (e.g. “via @estado”). Notamos que grande parte dos *tweets* compartilhados via outro perfil eram reportagens de grandes mídias (e.g. jornais, empresas de TV, rádio), as quais, em sua grande parte, não apresentam opiniões ou sentimentos e têm apenas a função de informar o leitor. Para a fase de geração dos modelos de classificação, os *retweets* não são interessantes também, por serem apenas cópias de *tweets* já presentes no conjunto de dados.

Também foram removidos *tweets* muito similares entre si, mantendo apenas uma cópia do *tweet*. Para avaliação da similaridade entre *tweets* calculamos a similaridade através do cosseno entre os *tweets* que é uma medida bastante utilizada em PLN para a análise de similaridade entre dois textos. Nesta medida, dois *tweets*, A e B, são representados pela frequência dos seus termos no conjunto. A similaridade do cosseno é calculada pela razão entre o produto escalar destes dois vetores e a multiplicação de suas magnitudes, seus módulos. O valor de similaridade é dado numa escala entre 0 e 1, em que 0 significa que os dois *tweets* são totalmente diferentes e 1 significa que eles são iguais. Definimos que todo *tweet* que possuísse similaridade maior que 0.7 fosse removido do nosso conjunto de dados por sua alta similaridade com outros *tweets* presentes neste conjunto.

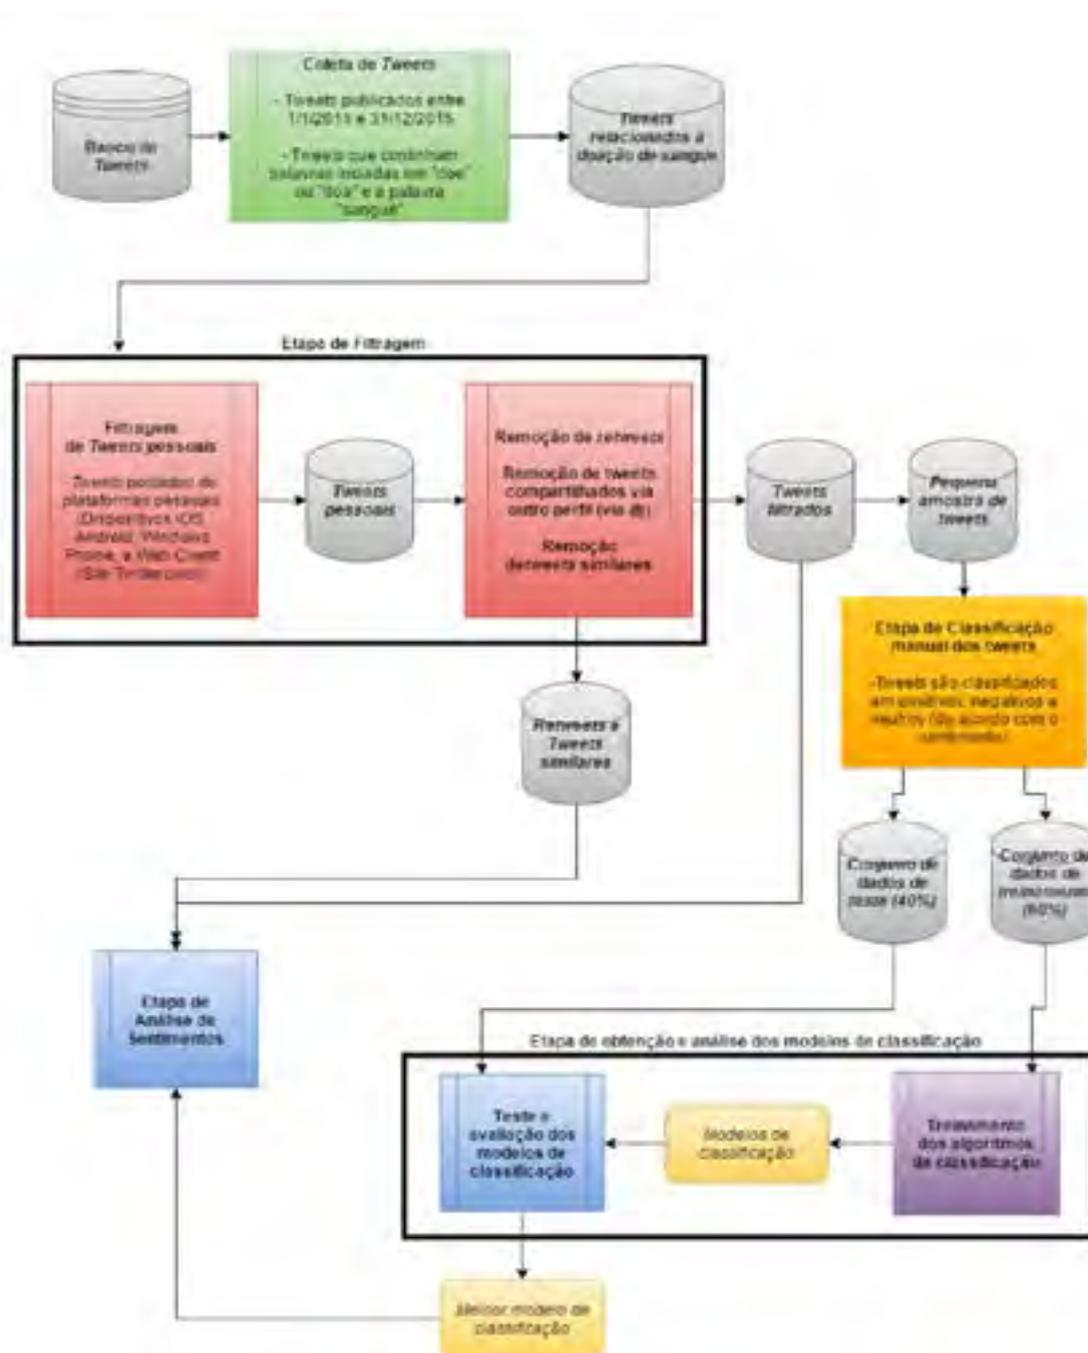


Figura 1. Etapas de processamento

Figura 1: Etapas de Processamento

Algoritmos de Classificação

Neste trabalho adotamos os quatro dos algoritmos de classificação mais utilizados nos estudos envolvendo AS: *Naive Bayes*, nas versões *Multinomial*, *Gaussian* e *Bernoulli*, e o *Maximum Entropy*. Para todos estes algoritmos utilizamos suas implementações presentes no *framework Scikit Learn*.

Conjunto de dados para treinamento e testes

A partir dos *tweets* filtrados e pré-processados selecionamos uma pequena amostra aleatória destes *tweets* para compor esta amostra. Neste trabalho, definimos o tamanho da amostra de acordo com a viabilidade da classificação manual. Os *tweets* desta amostra foram classificados manualmente e depois divididos em dois outros conjuntos de dados: 60% dos *tweets* compõem o conjunto de treinamento e o restante, ou seja 40%, compõem o conjunto de teste. Não foi considerado o balanceamento do número de exemplos para cada classe.

Classificação manual do conjunto de dados

Nesta fase, os *tweets* foram classificados manualmente de acordo com os sentimentos que eles apresentavam. Os *tweets* foram classificados em três diferentes polaridades: positivos, negativos e neutros. Primeiro foi analisado o texto dos *tweets* afim de encontrar a polaridade mais adequada para ele, caso o *tweet* tivesse emojis e amoticons, estes eram usados também na definição da polaridade do *tweet*. Definimos que *tweets* que apresentassem emoções positivas (e.g. alegria, felicidade, gratidão, entusiasmo, humor) fossem classificados como positivos; que demonstrassem emoções negativas (e.g. raiva, rancor, preocupação, medo) fossem classificados como negativos; e aqueles que apresentassem emoções indefinida ou que apenas eram informativos (e.g. “Doação de Sangue”, “Pedido de Doação de Sangue para Patrícia Fontes”) fossem classificados como neutros.

Extração de atributos

Neste trabalho consideramos como atributos de um *tweet* os unigramas extraídos dele obtidos através de tokenização dos *tweets*. Removemos unigramas que continham menções, tais como: *links* url, *emojis*, *emoticons*, *números*, *caracteres especiais* e pontuações. Convertemos os unigramas que continham *hashtags* para palavras comuns, removendo o símbolo (#). Optamos por manter as *stopwords*. A matriz de atributos tem como linhas os *tweets* e como colunas os unigramas. A matriz é composta por 0s e 1s, ou seja, ausência ou presença do *unigram* no *tweet*, respectivamente.

Análise de Sentimentos

A Análise de Sentimentos pode ser considerada um problema de classificação. Na AS o problema é identificar a polaridade ou sentimento de um texto e classificá-lo de acordo com este sentimento. Classificamos manualmente uma amostra (conjunto de dados de treinamento e teste) escolhida aleatoriamente dentre todos os *tweets* coletados neste trabalho em três possíveis polaridades: positivo, negativo e neutro. Após termos nossa matriz de atributos e a classificação manual dos nossos conjuntos de dados, iniciamos a fase de treinamento. Para o treinamento utilizamos 60% da amostra de *tweets* e para a fase de teste e análise, os demais 40%. A análise dos modelos foi mensurada pelas seguintes métricas: taxa de erro na classificação do conjunto de dados de teste, cálculos da Precisão e Revocação, F-score (ou média harmônica) e Validação Cruzada K-fold. Todas essas métricas foram calculadas usando implementações presentes no *framework Scikit-learn*. Após calculadas as métricas descritas acima, utilizamos o algoritmo que obteve um maior desempenho na classificação do nosso conjunto de dados para classificar todos os *tweets* relacionados a doação de sangue que foram coletados e filtrados neste trabalho.

Resultados e Discussão

Dados demográficos sobre os *tweets* coletados

Foram coletados ao todo 33.490 *tweets* relacionados à doação de sangue no âmbito brasileiro postados entre 1º de janeiro de 2015 e 31 de dezembro de 2015 de fontes (softwares clientes) consideradas “pessoais” (e.g. Android, iPhone, iPad, Windows Phone, site do Twitter). Após a filtragem para remoção de *retweets* (‘RT’), *tweets* postados via outras plataformas e perfis (‘via @’) e *tweets* similares, mantivemos 15.087 *tweets* para as fases de amostragem, treinamento e teste dos classificadores. Para a análise de sentimentos, reconsideramos os *tweets* removidos por serem similares ou *retweets*, obtendo 19.376 *tweets* para a fase de Análise de Sentimentos. Podemos observar que os três primeiros meses do ano (janeiro, fevereiro e março) tiveram menos de 1.000 publicações. Isso ocorreu devido a problemas no sistema de monitoramento de *tweets*. Podemos observar, também, que nos meses de pico, junho e novembro, um aumento em torno de 50% de *tweets* publicados comparado ao mês de maio do mesmo ano; este súbito aumento pode ter sido estimulado em decorrência do Dia mundial do doador de Sangue (14 de junho), Campanha Junho Vermelho (promovida em várias cidades do país) e Dia nacional do doador de Sangue (25 de novembro).

Conjunto de Dados, classificação manual e matriz de atributos

Para a classificação manual, selecionamos aleatoriamente uma amostra contendo 1364 *tweets* já filtrados. Classificamos manualmente estes 1364 *tweets* nas três classes: positiva, negativa e neutra. Dentro desta amostra, 351 *tweets* (26% da amostra) foram classificados como positivos, 417 *tweets* como negativos (31% da amostra) e 596 *tweets* como neutros (43% da amostra). Dividimos esta amostra em conjunto de treinamento, 818 *tweets* (60% da amostra), e teste 546 *tweets* (40% da amostra). Na etapa de construção da matriz de atributos, obtivemos 3623 unigramas, formando uma matriz de atributos de dimensões 1364 linhas X 3623.

Desempenho dos algoritmos de classificação

Neste trabalho adotamos quatro algoritmos de classificação para realizarmos nossa Análise de Sentimentos: *Naïve Bayes* nas versões *Multinomial*, *Gaussian* e *Bernoulli* e *Maximum Entropy*. Apresentamos os resultados obtidos a partir da aplicação das métricas na Tabela 1.

O algoritmo que apresentou uma melhor acurácia foi o *Multinomial Naïve Bayes* com uma taxa de 72% de exemplos classificados corretamente. Entretanto, podemos observar que ele tem uma taxa de Revocação muito baixo para a classe positiva (0.38), ou seja, classificou corretamente poucos exemplos que realmente pertenciam a classe positiva, o que pode ter sido ocasionado pelo baixo número de exemplos classificados como positivo presente em nosso conjunto de dados (25% de amostra). Entretanto, o algoritmo *Gaussian Naïve Bayes*, o qual foi o melhor ao classificar os exemplos pertencentes à classe positiva com uma Revocação de 0.6, obteve o segundo menor valor de acurácia (0.58).

Ao analisarmos o F-score, que é uma média geométrica entre as métricas Precisão e Revocação, podemos observar que, mesmo o algoritmo *Multinomial Naïve Bayes* tendo obtido uma classificação pobre para exemplos da classe positiva, ele teve o maior valor da média dos F-scores (0.66) juntamente com o algoritmo *Maximum Entropy*.

A Tabela 2 nos apresenta os resultados da Validação Cruzada, utilizando 5 *folds*, aplicada à cada algoritmo. Podemos observar, que por esta métrica, o algoritmo *Maximum Entropy* demonstrou o maior desempenho geral.

Tabela 1: Resultados das métricas: Taxa de Erro, Acurácia, Precisão, Recall e F-score de cada algoritmo. As métricas Precisão, Recall e F-score foram calculadas individualmente para cada uma das três classes. Para taxa de Erro: melhor valor é 0.28 e o pior 0.42.

	Taxa de Erro	Acurácia	Precisão				Revocação (Sensitividade)				F-score			
			Pos.	Neg.	Neut	Mé-dia	Pos.	Neg.	Neut	Mé-dia	Pos.	Neg.	Neut	Mé-dia
<i>Multinomial Naïve Bayes</i>	0,28	0,72	0,52	0,72	0,77	0,67	0,38	0,84	0,79	0,67	0,44	0,77	0,78	0,66
<i>Gaussian Naïve Bayes</i>	0,42	0,58	0,37	0,66	0,75	0,59	0,60	0,66	0,51	0,59	0,46	0,66	0,61	0,58
<i>Bernoulli Naïve Bayes</i>	0,35	0,65	0,75	0,73	0,61	0,7	0,11	0,66	0,93	0,57	0,19	0,69	0,73	0,54
<i>Maximum Entropy</i>	0,30	0,70	0,62	0,75	0,69	0,69	0,38	0,73	0,84	0,65	0,48	0,74	0,76	0,66

Tabela 2: Resultados da avaliação cruzada do método Maximum Entropy para todos os tweets coletados.

Validação Cruzada (5 folds)	
	Média
Multinomial Naive Bayes	0,71
Gaussian Naive Bayes	0,59
Bernoulli Naive Bayes	0,57
Maximum Entropy	0,72

Ambos algoritmos, *Multinomial Naïve Bayes* e *Maximum Entropy*, obtiveram valores aproximados nas métricas calculadas neste trabalho, sendo o primeiro escolhido para realizarmos a Análise de Sentimentos de todos *tweets* remanescentes da coleta. Apesar de apresentarem bons desempenhos neste trabalho, estes algoritmos baseiam-se somente na probabilidade de uma ou mais palavras definirem a classe à qual o *tweet* pertence, sem considerar a ordem relativa destas palavras.

Análise de Sentimentos

Para esta fase consideramos todos os 19.376 *tweets* filtrados. Utilizamos o modelo de classificação *Multinomial Naïve Bayes*. Entre todos os *tweets* analisados, 77% (15.034 *tweets*) foram considerados neutros, ou seja, como não apresentando sentimentos perceptíveis ou apresentando ausência deles, muitas vezes podendo ser apenas divulgações de pedidos de doação de sangue e campanhas de doação, ou simplesmente informativos. Outros 14% (2.763 *tweets*) foram classificados como contendo sentimentos negativos (*e.g.* raiva, medo, insegurança, tristeza, entre outros) e apenas 9% (1.579 *tweets*) apresentaram sentimentos positivos (*e.g.* alegria, esperança, humor, entre outros).

Conclusão

Neste trabalho fomos capazes de realizar uma análise dos sentimentos expressados pelos usuários do Twitter em seus tweets relacionados à doação de sangue na realidade da saúde brasileira no ano de 2015. Das quatro abordagens de classificação aplicadas (*Naïve Bayes — Multinomial, Gaussian e Bernoulli e Maximum Entropy*) e após a comparação entre estes algoritmos através de cinco diferentes métricas: Taxa de erro, Precisão, *Recall*, *F-score* e validação cruzada usando 5 *folds*, notamos que os melhores desempenhos foram obtidos por *Multinomial Naïve Bayes* e *Maximum Entropy*. Aplicando o *Multinomial Naïve Bayes* para todos os 19.376 *tweets* coletados 77% (15.034 *tweets*) foram considerados neutros, 14% (2.763 *tweets*) foram classificados como contendo sentimentos negativos e apenas 9% (1.579 *tweets*) apresentaram sentimentos positivos. Embora estes classificadores sejam baseados apenas na probabilidade de ocorrência de palavras chaves, os resultados indicam uma presença expressiva de sentimentos negativos no tema de doação de sangue. Os aspectos relativos a estes qualificadores negativos justificam estudos mais avançados.

Agradecimentos

Agradecemos ao Analista de Sistemas do Departamento de Computação e Matemática da FF-CLRP - USP, Mateus Tarcinalli Machado pela organização e manutenção do sistema de coleta de dados em saúde a partir do Twitter.

Referências

- [1] Chew C, Eysenbach G. Pandemics in the age of Twitter: content analysis of Tweets during the 2009 H1N1 outbreak. *PloS one*. 2010 Nov 29;5(11):e14118.
- [2] Almansa LF, Machado MT, Bosco GG, Merlo EM, Ruiz EE. Information Learned from Monitoring Microblogs during the 2014 Seasonal Flu Vaccination in Brazil. In 2014 IEEE 10th International Conference on e-Science 2014 Oct 20.
- [3] Paul MJ, Dredze M. A model for mining public health topics from Twitter. *Health*. 2012;11:16-6.
- [4] Gomes HJ. Text Mining: análise de sentimentos na classificação de notícias. *Information Systems and Technologies (CISTI)*, 2013 8th Iberian Conference on. Lisboa.
- [5] Go A, Bhayani R, Huang L. Twitter sentiment classification using distant supervision. *CS224N Project Report*, Stanford. 2009 Dec;1:12.
- [6] Pang B, Lee L, Vaithyanathan S. Thumbs up?: sentiment classification using machine learning techniques. In *Proceedings of the ACL-02 conference on Empirical methods in natural language processing — Volume 10* 2002 Jul 6 (pp. 79-86). Association for Computational Linguistics.

Contato

Diego H. Ferreira, dhferreira.ibm@gmail.com
Evandro E. S. Ruiz, evandro@usp.br