

Detecção de perfis sintomáticos de depressão no Twitter utilizando aprendizado de máquina

Kayque Vieira Netto
Departamento de Computação
CEFET-MG
Belo Horizonte, Brasil
kiquetto@gmail.com

Rogério Gomes, Bruno Santos e Edson da Silva
Departamento de Computação
CEFET-MG
Belo Horizonte, Brasil
{rogerio, bsantos, edson}@cefetmg.br

Abstract—Atualmente, a depressão é um dos transtornos mentais mais comuns em todo o mundo. Em 2015, por exemplo, foram contabilizadas aproximadamente 320 milhões de pessoas acometidas com a doença. O diagnóstico muitas vezes impreciso e o estigma social que a doença ainda causa, dificulta que pessoas sejam identificadas e tenham um tratamento correto. As redes sociais, que se popularizaram nos últimos anos e, portanto, têm sido um espaço aberto e propício para expor emoções, tornam-se um mecanismo de estudo para encontrar padrões de perfis de possíveis pacientes à patologia. Nesse contexto, este trabalho propõe a aplicação dos métodos Random Forest, k-NN, Naive Bayes, Regressão Logística, e NuSVC - SVM na classificação dos usuários do Twitter como depressivos, sintomáticos e assintomáticos. Para isso, foi criada uma base de dados composta por *tweets* enviados na língua portuguesa do Brasil de usuários do *Twitter*, nos quais serão analisadas as características que determinam o padrão de comportamento do usuário na rede social. Ao final, o classificador NuSVC - SVM obteve as melhores métricas de desempenho, apresentando uma acurácia, *recall* e F1-Score de 89% e uma *precision* de 90%.

Index Terms—Processamento de Linguagem Natural, Redes Neurais, Depressão, Aprendizado de Máquina

I. INTRODUÇÃO

Atualmente, a depressão é um dos transtornos mentais mais comuns em todo o mundo. Embora tenham havido avanços no tratamento da depressão, menos da metade das pessoas afetadas no mundo recebem tratamentos adequados devido a falta de diagnósticos corretos [1]–[4].

Apesar de cada pessoa apresentar um determinado conjunto de sintomas, pode-se perceber um grupo de características semelhantes entre os pacientes acometidos com o transtorno [5]. Dessa forma, diversos esforços têm sido empreendidos na tentativa de identificar comportamentos característicos de pessoas depressivas nos diversos *sites* e redes sociais da Internet [6]–[11].

Com base em postagens no Instagram, por exemplo, Reece e Danforth [12] tentaram prever um indicativo de depressão nas imagens publicadas pelos usuários usando detecção de faces, análise de cores e análise de metadados. Os resultados da predição foram surpreendentes, superando a taxa média de sucesso do diagnóstico clínico realizado por profissionais da área.

Ricard, Crosier e Hassanpour [8] também utilizaram dados do Instagram, tais como comunidades de amigos, seguidores e

comentários, para identificar usuários com transtorno mental depressivo. Eles obtiveram acesso aos perfis da rede social de mais de 740 voluntários e construíram um modelo computacional a partir das legendas e comentários nas postagens, *emojis*, número de *posts*, curtidas, comentários por *post*, entre outras variáveis. Ao final, os dados foram submetidos a um modelo de regressão linear usando uma penalidade de regularização de rede elástica como forma de evitar *overfitting*. Os autores treinaram o algoritmo considerando três conjuntos de dados: 1) dos usuários; 2) das comunidades; e 3) unindo comunidades e usuários. Ao comparar os resultados, constataram que o terceiro conjunto contendo a união dos dados de usuários e comunidades obteve um melhor desempenho com uma *Area Under the ROC Curve* (AUC) de 0,73.

Utilizando o conteúdo do *site* Yahoo Respostas, Nascimento et al. [13] desenvolveram um trabalho, que tinha entre os objetivos, a criação de uma base de dados em português contendo palavras relacionadas à doença. Para a criação da base, foram coletados, por meio do *site* Yahoo Respostas, textos com caráter depressivo. Após o processamento de 3000 documentos, os autores uniram seus resultados com dois conjuntos de dados existentes, ANEW-br [14] e LIWC2007-pt-br [15], formando a base *Depress-pt-br*. Posteriormente, eles incorporaram o conjunto de dados final na rede social brasileira, Meu Querido Diário (MQD), que serve como um diário *online* para seus usuários. Uma ferramenta interessante do MQD é a possibilidade de gerar uma saída, classificando cada entrada de texto, em uma das 6 emoções sugeridas pelo psicólogo Paul Ekman [16]. Das saídas geradas, os autores escolheram trabalhar com aquelas rotuladas em felicidade e tristeza. A base de dados rotulada foi utilizada como entrada no classificador J48, especificado na plataforma Weka¹, obtendo um F1-Score de 68,1.

Utilizando dados do Facebook, Islam et al. [17] aplicaram técnicas de aprendizagem de máquina para detectar indícios de depressão nos usuários da plataforma. Por meio dos comentários dos usuários nas publicações, os textos coletados foram analisados sob quatro aspectos: 1) processo emocional, que inclui, por exemplo, informações negativas de ansiedade e raiva; 2) processo temporal, indicando passado, presente

¹<https://www.cs.waikato.ac.nz/ml/weka/>

ou futuro; 3) linguístico, como artigos, verbos, pronomes, entre outros; e 4) um agrupamento dos três fatores anteriores. Posteriormente, para cada aspecto, os dados foram separados em duas classes, indicando positivo ou negativo à doença. No total, foram mais de 7100 comentários na composição da base de dados com relação à doença. Eles aplicaram técnicas de Aprendizagem de Máquina Supervisionada para obter informações a partir dos dados adquiridos, escolhendo Árvore de Decisão, k-vizinhos mais próximos (KNN), Support Vector Machine (SVM) e métodos de *Ensemble* como classificadores para a tarefa. A Árvore de Decisão apresentou o melhor resultado, tendo obtido os valores de 59%, 98% e 73% para as métricas de *precision*, *Recall* e *F-measure*, respectivamente.

Nadeem [2], por sua vez, utilizou uma base de dados pronta, em inglês, extraída do Tweeter [18], [19]. Os usuários dessa base de dados foram rotulados como positivos à doença quando afirmavam, em seus *tweets*, terem sido diagnosticados com depressão. Posteriormente, para cada perfil encontrado, foram selecionados os 3000 *tweets* mais recentes para compor a base de dados. Nadeem tratou cada *tweet* como um documento isolado. Para quantificar o conteúdo de cada *tweet*, ele mediu a frequência de aparecimento de palavras no texto usando o método *Bag of Words*. Dentre os classificadores analisados, Árvore de Decisão, Regressão Logística, Linear Support Vector Classifier e Naive Bayes, o que obteve melhor resultado foi o Naive Bayes com uma *precision* de 82% e uma acurácia de 86%.

Shen et al. [20] também utilizaram dados do Twitter para identificar usuários com depressão. Eles construíram três bases de dados: 1) usuários diagnosticados com a doença; 2) usuários não depressivos; e 3) usuários propensos à doença. Por meio dessas bases de dados, foram extraídos seis características que englobam o comportamento do doente na rede social e que são qualificadas como depressão clínica. Dessa forma, foi criado pelos autores um dicionário multimodal, usado no processo de aprendizagem de máquina, a partir de um treinador binário, que comparado a outros três métodos, Naive Bayes, Aprendizagem de Redes Sociais Múltiplas e Aprendizagem de Dicionário Wasserstein, alcançou um F1-Score de 85%.

Neste contexto, este trabalho tem por objetivo a criação de uma base de dados contendo usuários do Twitter com seus respectivos *tweets* e a utilização de técnicas de Aprendizagem de Máquina na identificação de usuários com depressão. A metodologia para construção da base de dados se inspirou nos trabalhos de [18]–[20] e os classificadores utilizados foram: 1) Random Forest; 2) K-Vizinhos mais próximos (KNN); 3) Naive Bayes; 4) regressão logística; e 5) NuSVC - SVM, conforme apresentado na próxima seção.

II. METODOLOGIA

A metodologia foi dividida nas seguintes etapas: 1) obtenção das bases de dados de *tweets* e de informações sobre os usuários (Seção II-A); 2) pré-processamento dos dados (Seção II-B); 3) balanceamento das classes de dados (Seção II-C); e 4) definição dos métodos de classificação (Seção II-D).

A. Obtenção de dados

A primeira etapa consistiu na obtenção dos dados, os quais foram obtidos por meio de uma API² fornecida pelo Twitter e disponibilizada para desenvolvedores cadastrados na plataforma. A obtenção dos dados foi realizada durante um período de 30 dias e utilizou exclusivamente *tweets* escritos na língua portuguesa do Brasil. Os dados coletados foram divididos em 3 bases de dados que serão referenciadas como base de dados 1, 2 e 3.

A divisão dos *tweets* entre as três bases foi realizada da seguinte maneira.

- *Base de dados 1*: composta por dados de usuários que relataram em seus perfis terem sido diagnosticados com a doença. Para tal, foi realizada uma busca pelas expressões “fui diagnosticado com depressão” e “fui diagnosticada com depressão” nos perfis dos usuários.
- *Base de dados 2*: composta por *tweets* de usuários que utilizaram, em suas postagens recentes, pelo menos três palavras vinculadas a doença. A API retorna os últimos 20 *tweets* do usuário, nos quais foi realizada a busca por palavras de cunho depressivo. As palavras buscadas foram propostas por Leis et al. [21] e são apresentadas na Tabela I.
- *Base de dados 3*: composta por *tweets* de usuários nos quais não foram encontradas, nas últimas vinte publicações, nenhuma das palavras mencionadas na Tabela I, bem como não foram encontradas nenhuma menção de diagnóstico relacionado à depressão.

TABELA I
PALAVRAS RELACIONADAS A DEPRESSÃO

Angustiado(a)	Ansiedade	Ansioso(a)
Cansado(a)	Chorar	Depressão
Deprimido(a)	Desanimado(a)	Desmotivado(a)
Exausto(a)	Insônia	Miserável
Nervoso(a)	Preocupado(a)	Sobrecarregado(a)
Sozinho(a)	Triste	Vazio

Fonte: Leis et al. [21]

Esses conjuntos, então, são representados por 13 colunas e um rótulo, com a classificação dos *tweets* como “depressivo”, “sintomático” ou “assintomático/não depressivo”. A partir da API do *Twitter* é possível obter diferentes recursos, considerando o *tweet* e o usuário como dois objetos. Esse conjunto de informações específicas pode ser visto na Figura 1.

B. Pré-processamento dos dados do usuário

A etapa de pré-processamento é responsável pela preparação, organização e estruturação dos dados antes de serem aplicados os algoritmos de aprendizagem de máquina. Nesta fase, foram aplicadas algumas técnicas de tratamento e transformação estatística nos dados dos usuários (Fig. 1), com o objetivo de se produzir as bases de dados finais a serem utilizadas no treinamento dos classificadores. O processamento realizado é descrito a seguir:

²Do inglês *Application Programming Interface*

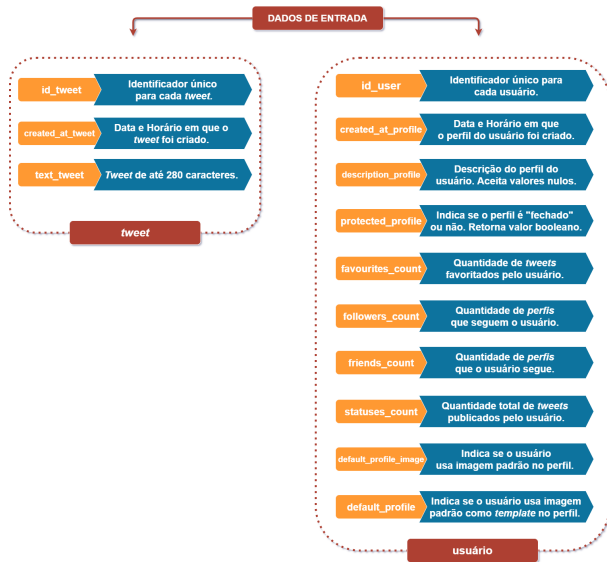


Fig. 1. Sumarização das Características (*Features*) extraídas dos tweets.

- 1) Como a API do Twitter retorna um objeto do tipo data, para facilitar o processamento, esse tipo de dado foi transformado no tipo inteiro, considerando unicamente a hora em que o perfil foi criado na rede social e a hora em que o usuário fez alguma postagem.
- 2) Como a API do Twitter retornou apenas perfis públicos, a coluna da base de dados que indicava se o perfil era privado foi excluída.
- 3) Os parâmetros que indicam se a imagem do perfil e o plano de fundo são padrão da rede social, também foram excluídas.
- 4) Os seguintes campos foram calculados e adicionados à base de dados:
 - a) hora na qual o usuário mais posta em seu perfil;
 - b) média de caracteres dos tweets de cada usuário;
 - c) somatório de tweets por período do dia considerando os intervalos: [00h00, 06h59]; [07h00, 12h59]; [13h00, 18h59]; e [19h00, 23h59];
 - d) porcentagem de publicação de cada usuário nos intervalos de horários descritos.

Os campos, quantidade de perfis seguidos na rede social, o número de seguidores do perfil, o número de publicações curtidas ou "favoritadas" e o total de tweets publicados, foram mantidos por ter influência direta nas interações do usuário e que poderiam demonstrar alguma tendência comportamental em relação aos demais usuários.

Ao final, os campos das bases de dados, utilizados como entrada dos classificadores, foram: o total de publicações por período do dia; a relação desse total de publicações por período do dia com o total postado pelo usuário; o horário mais frequente de tweets por usuário; a média de caracteres dos tweets de cada usuário; a hora em que o perfil foi criado; o número de seguidores, o número de perfis seguidos; a quantidade de tweets curtidos e a quantidade total de publicações.

C. Balanceamento das classes

A Tabela II apresenta o resultado da coleta dos dados que compõem as classes depressivo (base de dados 1), sintomático (base de dados 2) e assintomático/não depressivo (base de dados 3). A base de dados 1, por exemplo, possui 46595 tweets pertencentes a 283 usuários. Visto que a quantidade de usuários por classe está desbalanceado, foi necessário realizar uma normalização. Para esta tarefa foi usada a biblioteca *NearMiss*, que utiliza um algoritmo que tende a equilibrar a distribuição das classes para a classe que possui o menor número de elementos.

TABELA II
RESULTADO DA COLETA DE DADOS DO TWITTER

	Total de usuários	Total de Tweets
Base de dados 1	283	46595
Base de dados 2	4562	326545
Base de dados 3	3646	339584

Após a aplicação da técnica *NearMiss*, as classes desbalanceadas, referentes a base de dados 2 e 3, passam a ter o total de usuários igual a 283 e um total de tweets com valor próximo de 46600.

D. Classificação

Para analisar o perfil do usuário, foram escolhidas as seguintes abordagens de aprendizagem de máquina supervisionadas: 1) Random Forest; 2) K-Vizinhos mais próximos (KNN); 3) Naive Bayes; 4) regressão logística; e 5) NuSVC - SVM.

O Random Forest é um modelo de *machine learning* que agrupa várias árvores de decisão [22]. Entre as vantagens desse modelo de classificação está a forma como ele lida tanto com atributos numéricos, por exemplo, o número de tweets, amigos e seguidores do usuário, quanto com atributos categóricos como, por exemplo, se o usuário possui imagem padrão no perfil ou não [23]. Para avaliar os resultados no Random Forest foi levado em consideração o resultado que alcançou a maior frequência entre as árvores. No desenvolvimento desse modelo, foi utilizada a ferramenta de aprendizagem de máquina Scikit-learn. O número de árvores da floresta utilizado foi igual a 10 e a função para medir a qualidade de uma divisão foi o *Gini*. Os demais parâmetros seguiram a configuração padrão da biblioteca.

O modelo KNN ou K-Vizinhos mais próximos é um classificador que indica a qual grupo uma amostra pertence analisando os vizinhos dessa amostra [24]. Nesse algoritmo, o valor de K, ou seja, a quantidade de vizinhos a ser utilizada no cálculo da distância entre as amostras, foi ajustado em 10. A métrica de distância utilizada, por sua vez, foi a Distância Euclidiana. Outro modelo de classificação utilizado foi o método probabilístico Naive Bayes [25]. Na construção desse modelo, implementado também na biblioteca Scikit-learn, foi escolhida a distribuição Gaussiana. O método de regressão logística [25], também muito usado na predição de classes,

foi utilizado a partir da biblioteca Scikit-learn, configurada da seguinte forma: 100 iterações, regularização L2, inverso da força de regularização $C=1$, critério de parada $tol=1e-4$, e otimizador dos parâmetros LBFGS. Os demais parâmetros, para os três métodos descritos, seguiram a configuração padrão da biblioteca.

Outro algoritmo usado em problemas de classificação e regressão é a Máquina de Vetores de Suporte (SVM) [26]. Para problemas que possuem ruídos ou a natureza dos dados não é linear, como é o nosso caso, o algoritmo SVM baseia-se no teorema de Cover [27]. Ele mapeia o conjunto de dados de treinamento para um novo espaço de maior dimensão no qual é criada uma fronteira ou hiperplano linear que separa as classes dos dados [25]. O algoritmo utilizado foi o NuSVC, presente na biblioteca do Scikit-learn [28]. Para este trabalho, o valor escolhido para controlar o erro de margem foi de 0,2 e o *kernel* foi o RBF. Os demais parâmetros seguiram a configuração padrão da biblioteca.

Para cada classificador foi realizada também a divisão dos dados em vários subconjuntos de treinamento e teste a partir da técnica de *K-fold cross-validation* com $k=5$, aumentando a confiabilidade da avaliação do classificador [13], [25].

III. RESULTADOS

Inicialmente, será apresentada uma análise dos *tweets* por período do dia com o objetivo de compreender o comportamento dos diferentes usuários no Twitter. Em seguida, serão apresentados os resultados obtidos pelos métodos de classificação.

Os usuários diagnosticados com depressão (total de 283 usuários) postaram, nos 30 dias avaliados, um total de 46.595 *tweets*. A distribuição de horário em que esses *tweets* foram postados é apresentada na Fig. 2. Entre 19h00 e 23h59, período de maior compartilhamento de informações na rede, foram registrados 40,4% dos *tweets* publicados. Entre 13h00 e 18h59, ocorreram 30,2% das postagens. Os menores resultados foram no período 0h00 e 6h59, com 21,6%, e de 7h00 e 12h59, com 7,8%.

O horário mais frequente de postagens dos usuários diagnosticados com depressão é apresentado na Fig. 3. Nota-se que o horário com maior frequência de publicação dos usuários depressivos foi às 20 horas, com 10,25% de perfis, seguido de um segundo pico de atividade, às 19 horas, com 9,5% do total de perfis.




Fig. 2. Horário mais frequente de postagens. Azul: entre 0h00 e 6h59, Laranja: entre 7h e 12h59, Verde: entre 13h e 18h59, Vermelho: entre 19h e 23h59




Fig. 3. Horário mais frequente de postagens dos usuários diagnosticados com depressão.

Já os sintomáticos (total de 4.562 usuários) postaram, nos 30 dias avaliados, 326.545 *tweets*. Para esse grupo, como mostrado na Fig. 2, 40,8% dos textos postados concentraram-se no período entre 19h00 e 23h59. A atividade na rede social obteve 26,1% das postagens entre 0h00 e 6h59, tendo os horários entre 13h00 e 18h59, 24,3% dos *tweets* e os horários entre 7h00 e 12h59, uma frequência de 8,9% em relação ao total de todas publicações obtidas.

Analisando o horário mais frequente de postagens dos usuários sintomático (Fig. 4) é possível notar que pouco mais de 9% postaram às 22 horas. Meia noite e 2 horas, no entanto, são o segundo e terceiro horário em que cada usuário sintomático mais "tweetou". Percebe-se que, em relação aos outros períodos do dia, os usuários sintomáticos estão bastante ativos na madrugada.




Fig. 4. Horário mais frequente de postagens dos usuários sintomáticos.

O perfil de usuários assintomáticos ou não diagnosticados com depressão somam um total de 3.646 usuários com 339.584 *tweets*. No gráfico da Fig. 2, quase 48% das publicações foram no período compreendido entre 19h00 e 23h59.

Os dados gerados indicam ainda que os horários entre 13h00 e 18h59 somam um total de 24,2% das publicações, enquanto entre 0h00 e 6h59, 21,5% dos textos foram postados no perfil desse grupo. Apenas 6,5% de *tweets* foram compartilhados entre 7h00 e 12h59. O horário mais frequente de postagens

dos usuários desse grupo é apresentado Fig. 5. Dessa forma, é possível notar que às 21 horas houve o maior número de publicações entre os usuários. Os horários de 20, 22 e 23 horas, aparecem com maior frequência, enquanto que de meia noite às 2 da manhã é possível observar apenas uma pequena variação na quantidade de publicações.




Fig. 5. Horário mais frequente de postagens de usuários assintomáticos ou não diagnosticados com depressão.

Prosseguindo com a análise estatística, algumas métricas revelam a tendência central dos dados, como a média vista na Tabela III. A média pode ser definida como uma demonstração da concentração dos dados de uma distribuição. Para esse exame, foi considerado, para cada grupo de usuários, os seguintes parâmetros: Número de *tweets* em que o usuário curtiu ou "favoritou"; o total de seguidores; total de perfis seguidos e a quantidade de publicações.

É possível notar, que usuários sintomáticos (Base de dados 2) possuem os menores valores das médias calculadas, chegando a ter pouco mais da metade da média das publicações postadas pelos usuários assintomáticos (Base de dados 3).

Baseado nesses valores, pode-se inferir que usuários que não possuem indícios da doença publicam mais em suas redes sociais que os usuários sintomáticos ou diagnosticados com a doença, possuindo, dessa forma, um maior número de pessoas que seguem seu perfil. Semelhantemente, percebe-se que perfis diagnosticados com o transtorno depressivo possuem um menor número de seguidores quando comparado com os demais grupos.

No entanto, a quantidade total de *tweets* curtidos por esses grupos e a média de perfis seguidos não apresentaram uma diferença relevante quando foram analisadas separadamente. Porém, durante a etapa de classificação, percebeu-se que esses parâmetros impactavam consideravelmente os resultados quando eram usados como entrada nos classificadores.

Portanto, na etapa de classificação, utilizou-se os seguintes dados do perfil, o total de publicações por período do dia, a relação desse total de publicações por período do dia com o total postado pelo usuário, o horário mais frequente de *tweet* por usuário, a hora em que o perfil foi criado, o número de seguidores, o número de perfis seguidos, a quantidade de *tweets* curtidos e a quantidade total de publicações, como

TABELA III
MÉDIA ENTRE ALGUMAS VARIÁVEIS POR BASE DE DADOS

	Base de dados 1	Base de dados 2	Base de dados 3
Média de tweets favoritos	25.184,57	16.174,32	22.154,40
Média de seguidores	1.602,97	9.755,59	12.414,08
Média de perfis seguidos	1406,53	759,22	1.102,94
Média de quantidade de publicações	21.930,33	18.601,52	36.298,98

entrada dos modelos escolhidos para predição. Os resultados obtidos pelos classificadores podem ser vistos na Fig. 6.

Os algoritmos Random Forest, Regressão Logística, KNN e *Naive Bayes*, como é possível notar, obtiveram um desempenho próximo com suas métricas variando entre 75% e 80%. As melhores métricas, no entanto, foram obtidas pelo classificador Nu-SVC, com uma acurácia, *recall* e *F1-Score* de 89% e uma *precision* de 90%.

	Métricas			
	Acurácia	Precision	Recall	F1-score
NuSVC	89%	90%	89%	89%
Random Forest	76%	77%	76%	76%
Regressão Logística	75%	76%	75%	75%
KNN	75%	76%	75%	75%
Naive Bayes - Gaussian	77%	80%	77%	77%

Fig. 6. Métricas de desempenho dos algoritmos classificadores.

IV. CONSIDERAÇÕES FINAIS

Na condução deste estudo, a primeira etapa de obtenção de dados³, foi de extrema importância, pois a maioria dos trabalhos relacionados faziam uso de bases de dados em inglês. Nesse sentido, houve um esforço de se encontrar perfis em português de pessoas que tinham sido diagnosticados com

³Disponível em: encurtador.com.br/uLMSW

a doença e também de perfis que apresentavam sintomas relacionados à depressão, levando em consideração o grupo de palavras expostas na Tabela 2, relacionadas ao transtorno. Da mesma forma, foi obtido o grupo de controle, presente na base de dados 3, com *tweets* de usuários que não haviam apresentado diagnóstico nem sintomas em suas publicações recentes.

Analisando os modelos de aprendizado desenvolvidos é possível concluir que o algoritmo *Nu-SVC* obteve o melhor desempenho dentre os algoritmos utilizados na predição de casos da doença a partir do perfil do usuário. Outro fator importante a se pontuar é que o uso da biblioteca *NearMiss* promoveu um maior equilíbrio na distribuição dos rótulos refletindo, dessa forma, nas métricas obtidas para cada um dos classificadores utilizados (Fig. 6). Pode-se observar, por exemplo, que as métricas de *precision*, *recall* e, conseqüentemente, de *F1-Score* apresentaram valores semelhantes mostrando um equilíbrio entre o número de falsos positivos e falsos negativos obtidos pelos modelos.

Para o neurologista Leandro Teles [5] a depressão pode ser dividida em vários níveis e tipos. As formas de apresentar a doença também são diversas e a sua classificação é de extrema importância na condução do tratamento [5], o que faz desse transtorno uma doença mental complexa em que o indivíduo pode apresentar variados sintomas em diversos níveis. Nesse sentido, este estudo, que analisou as características comportamentais de usuários da rede social *Twitter*, pode auxiliar profissionais da saúde e cientistas a entenderem a doença e como os usuários da rede social manifestam seus sentimentos, apresentando sintomas ou não.

AGRADECIMENTOS

Os autores gostariam de agradecer ao CEFET-MG pelo suporte financeiro.

REFERÊNCIAS

- [1] OPAS, "Depressão: Organização pan-americana de saúde," acessado: 2020-04-07. [Online]. Available: <https://www.paho.org/pt/topicos/depressao>
- [2] M. Nadeem, "Identifying depression on twitter," *ArXiv*, vol. abs/1607.07384, 2016.
- [3] P. S. Wang, M. Lane, M. Olfson, H. A. Pincus, K. B. Wells, and R. C. Kessler, "Twelve-month use of mental health services in the united states: results from the national comorbidity survey replication," *Archives of general psychiatry*, vol. 62, no. 6, pp. 629–640, 2005.
- [4] M. Cepoiu, J. McCusker, M. G. Cole, M. Sewitch, E. Belzile, and A. Ciampi, "Recognition of depression by non-psychiatric physicians—a systematic literature review and meta-analysis," *Journal of general internal medicine*, vol. 23, no. 1, pp. 25–36, 2008.
- [5] L. Teles, *Depressão não é fraqueza: como reconhecer, prevenir e enfrentar a doença mais incapacitante do cérebro*, 1st ed. Editora Alaúde, 2019.
- [6] M. De Choudhury, M. Gamon, S. Counts, and E. Horvitz, "Predicting depression via social media," in *Proceedings of the International AAAI Conference on Web and Social Media*, vol. 7, no. 1, 2013, pp. 128–137.
- [7] M. Deshpande and V. Rao, "Depression detection using emotion artificial intelligence," in *2017 International Conference on Intelligent Sustainable Systems (ICISS)*. IEEE, 2017, pp. 858–862.
- [8] B. J. Ricard, L. A. Marsch, B. Crosier, and S. Hassanpour, "Exploring the utility of community-generated social media content for detecting depression: an analytical study on instagram," *Journal of medical Internet research*, vol. 20, no. 12, p. e11817, 2018.
- [9] S. Graham, C. Depp, E. E. Lee, C. Nebeker, X. Tu, H.-C. Kim, and D. V. Jeste, "Artificial intelligence for mental health and mental illnesses: an overview," *Current psychiatry reports*, vol. 21, no. 11, pp. 1–18, 2019.
- [10] M. Stankevich, A. Latyshev, E. Kuminskaya, I. Smirnov, and O. Grigoriev, "Depression detection from social media texts," in *Elizarov, A., Novikov, B., Stupnikov, S (eds.) Data Analytics and Management in Data Intensive Domains: XXI International Conference DAMDID/RCDL*, 2019, p. 352.
- [11] H. Zogan, X. Wang, S. Jameel, and G. Xu, "Depression detection with multi-modalities using a hybrid deep learning model on social media," *arXiv preprint arXiv:2007.02847*, 2020.
- [12] A. G. Reece and C. M. Danforth, "Instagram photos reveal predictive markers of depression," *EPJ Data Science*, vol. 6, pp. 1–12, 2017.
- [13] R. da Silva Nascimento, P. Parreira, G. dos Santos, and G. P. Guedes, "Identificando sinais de comportamento depressivo em redes sociais," in *Anais do VII Brazilian Workshop on Social Network Analysis and Mining*. Porto Alegre, RS, Brasil: SBC, 2018. [Online]. Available: <https://sol.sbc.org.br/index.php/brsnam/article/view/3597>
- [14] C. H. Kristensen, C. F. d. A. Gomes, A. R. Justo, and K. Vieira, "Normas brasileiras para o affective norms for english words," *Trends in Psychiatry and Psychotherapy*, vol. 33, no. 3, pp. 135–146, 2011.
- [15] P. Balage Filho, T. A. S. Pardo, and S. Alufio, "An evaluation of the brazilian portuguese liwc dictionary for sentiment analysis," in *Proceedings of the 9th Brazilian Symposium in Information and Human Language Technology*, 2013, pp. 215–219.
- [16] P. Ekman, "An argument for basic emotions," *Cognition and Emotion*, vol. 6, no. 3–4, pp. 169–200, 1992. [Online]. Available: <https://doi.org/10.1080/02699939208411068>
- [17] M. R. Islam, M. A. Kabir, A. Ahmed, A. R. M. Kamal, H. Wang, and A. Ulhaq, "Depression detection from social network data using machine learning techniques," *Health information science and systems*, vol. 6, no. 1, pp. 1–12, 2018.
- [18] G. Coppersmith, M. Dredze, and C. Harman, "Quantifying mental health signals in twitter," in *Proceedings of the workshop on computational linguistics and clinical psychology: From linguistic signal to clinical reality*, 2014, pp. 51–60.
- [19] G. Coppersmith, M. Dredze, C. Harman, K. Hollingshead, and M. Mitchell, "Clipsych 2015 shared task: Depression and ptsd on twitter," in *Proceedings of the 2nd Workshop on Computational Linguistics and Clinical Psychology: From Linguistic Signal to Clinical Reality*, 2015, pp. 31–39.
- [20] G. Shen, J. Jia, L. Nie, F. Feng, C. Zhang, T. Hu, T.-S. Chua, and W. Zhu, "Depression detection via harvesting social media: A multimodal dictionary learning solution," in *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, IJCAI-17*, 2017, pp. 3838–3844. [Online]. Available: <https://doi.org/10.24963/ijcai.2017/536>
- [21] A. Leis, F. Ronzano, M. A. Mayer, L. I. Furlong, and F. Sanz, "Detecting signs of depression in tweets in spanish: Behavioral and linguistic analysis," *J Med Internet Res*, vol. 21, no. 6, p. e14199, Jun 2019. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/31250832>
- [22] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [23] J. Grus, *Data Science do Zero: Primeiras regras com Python*, 1st ed. Alta Books, 2016.
- [24] L. E. Peterson, "K-nearest neighbor," *Scholarpedia*, vol. 4, no. 2, p. 1883, 2009.
- [25] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An introduction to statistical learning*. Springer, 2013, vol. 112.
- [26] A. C. Lorena and A. de Carvalho, "Uma introdução às support vector machines," *Revista de Informática Teórica e Aplicada*, vol. 14, no. 2, pp. 43–67, 2007. [Online]. Available: https://seer.ufrgs.br/rita/article/view/rita_v14_n2_p4367
- [27] T. M. Cover, "Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition," *IEEE Transactions on Electronic Computers*, vol. EC-14, no. 3, pp. 326–334, 1965.
- [28] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.