

Aplicação de Técnicas de Análise de Sentimento para Classificação de Postagens em Ambientes Virtuais de Aprendizagem

Mário Silva Ribeiro¹, Emanuel Ferreira Coutinho¹

¹Universidade Federal do Ceará (UFC) - Brasil

m_s_r@outlook.com, emanuel.coutinho@ufc.br

Abstract. *Professors and tutors in a Virtual Learning Environment (VLE) have to deal with large amounts of textual media, which is time consuming and labor intensive. In this scenario, the use of computational tools that assist them in the task of analyzing texts is very attractive. This work proposes the creation of a tool for sentiment analysis in texts of VLE forums. The idea is to identify the general tendency of a class in relation to the subject under discussion, without having to read all the texts, which can be bulky and laborious. An experiment was applied on the SOLAR VLE discussion forums. The results were satisfactory, with an accuracy reaching 79% in the ratings.*

Resumo. *Professores e tutores em um Ambiente Virtual de Aprendizagem (AVA) têm que lidar com grandes quantidades de mídia textual, o que é trabalhoso e demanda tempo. Nesse cenário, a utilização de ferramentas computacionais que os auxiliem na tarefa de analisar textos é muito atrativa. Este trabalho propõe-se a aplicar a técnica de Análise de Sentimento em textos de fóruns de um AVA para auxiliar um tutor. A ideia é que se possa identificar a tendência geral de uma turma em relação ao tema em discussão, sem a necessidade de ler todos os textos, que podem ser volumosos. Um estudo foi realizado em fóruns do AVA SOLAR. Em geral, os resultados foram satisfatórios, atingindo em geral 79% de acerto nas classificações.*

1. Introdução

Com a explosão da internet no início da década de 1990, muitas ferramentas foram desenvolvidas para explorar seus benefícios. A modalidade de ensino de Educação à Distância (EaD) é uma dessas tecnologias que surgiram, afetando a educação, visto a possibilidade de atingir um maior número de pessoas com a internet [Oliveira et al. 2013]. Desde a década de 1990, a comunidade de software educacional vem produzindo Ambientes Virtuais de Aprendizagem (AVA), que surgem com a proposta de suportar atividades de ensino e aprendizagem por meio da internet [O’Leary e Ramsden 2002]. Suas principais funcionalidades se resumem a: existência de um canal de comunicação entre estudantes e tutores, entregas de trabalhos compartilhados, estrutura de navegação clara e concisa, e espaço virtual capaz de imitar as funcionalidades de um espaço físico.

Mineração de Dados é o processo de descoberta de padrões em conglomerados de dados. É um processo automático ou semiautomático executado para obter padrões

de um volume de dados, para a obtenção de alguma vantagem [Witten et al. 2016]. Mineração de Dados tipicamente lida com dados já coletados para algum objetivo além da análise de dados propriamente dita. Esta é uma das formas em que a Mineração de Dados difere de boa parte da estatística, em que os dados são na maior parte das vezes coletados usando estratégias eficientes para responder questões específicas.

Uma de suas subáreas é a Análise de Sentimento. A Análise de Sentimento (*Opinion Mining*) é um campo de estudo que analisa as opiniões, sentimentos, valores, apreciação, atitudes e emoções das pessoas, direcionadas às entidades como produtos, serviços, organizações, indivíduos, problemas, eventos, tópicos e os seus atributos, embora estes conceitos não sejam necessariamente equivalentes. O significado de opinião é ainda muito amplo. Análise de Sentimentos, foca principalmente em opiniões que expressam ou implicam em sentimentos positivos ou negativos [Liu 2012].

Em um AVA, a interação entre aluno e professor/tutor e de aluno com outros alunos é principalmente feita por meio de textos, sejam conversas em *chats* ou fóruns virtuais. Um fórum é um espaço virtual onde criam-se postagens de texto, geralmente de acesso público, em que qualquer participante pode criar uma resposta à postagem inicial. Já um *chat* é uma conversa, que pode ou não ficar armazenada, em que somente os participantes da mesma possuem acesso ao conteúdo.

Por limitações do próprio meio de comunicação é possível que hajam dificuldades na hora de avaliar um *post* por parte do tutor, seja por ele não ter compreendido a mensagem que se desejava ser passada ou simplesmente por não conseguir decidir se um texto, baseado em seu conteúdo, mostra que há uma concordância ou não no ponto de vista apresentado. Também é possível que o tutor apenas deseje dar um *feedback* apenas para alunos que demonstrem a tendência de ir por um certo caminho de pensamento. Por fim, é ainda possível que um tutor apenas queira saber qual seria o momento ideal de intervir em uma discussão, de forma a incentivar, instigar ou redirecionar o tema que está sendo discutido pelos alunos. Por possuir essas características, a aplicação da Análise de Sentimento em AVAs se torna atrativa, de forma a se analisar os dados obtidos.

Neste contexto, seria possível aplicar técnicas da Análise de Sentimento de forma a auxiliar o tutor na avaliação da tendência de uma determinada turma em relação a um assunto exposto, baseada somente em se a maior parte dos *posts* no fórum são considerados neutros, positivos ou negativos. Este trabalho tem como objetivo geral a aplicação da técnica de Análise de Sentimento em textos de fóruns de um AVA de forma a auxiliar um tutor em suas atividades, otimizando seus esforços.

2. Referencial Teórico

2.1. Análise de Sentimento

Análise de Sentimento (*Opinion Mining*) é um campo de estudo que analisa opiniões, sentimentos, valores, apreciação, atitudes e emoções das pessoas, direcionadas a entidades como produtos, serviços, organizações, indivíduos, problemas, eventos, tópicos e seus atributos [Liu 2012]. Neste caso, opinião é o termo utilizado para denotar a expressão de sentimentos, valores, apreciação, atitudes e emoções, ainda que esses

conceitos não sejam equivalentes. Análise de Sentimentos foca principalmente em opiniões que expressam ou implicam sentimentos positivos ou negativos [Liu 2012].

Embora a linguística e o processamento de linguagem natural (NLP - *Natural Language Processing*) possuam uma longa história, pouca pesquisa havia sido realizada sobre as opiniões e sentimentos das pessoas antes do ano 2000 [Liu 2012]. Desde então, o campo se transformou em uma área bastante ativa para pesquisas. Existem três principais razões para o campo ser atrativo. Primeiro, existem várias aplicações práticas em basicamente todos os domínios, especialmente em aplicações comerciais. Segundo, oferece diversos problemas desafiadores de pesquisa, que nunca tinham sido estudados antes. Por último, pela primeira vez na história humana, possuímos um grande volume de dados contendo opiniões nas mídias sociais da web [Liu 2012].

Encontrar, monitorar e destilar informações contidas em opiniões é uma tarefa interessante [Liu 2012]. Todo *site* tipicamente possui um grande volume de texto opinativo que nem sempre é facilmente decifrado em longos *posts* de fóruns e blogs. Uma pessoa mais leiga terá dificuldade em identificar e sumarizar as opiniões nestes *posts*, tornando a análise de sentimento automatizada necessária.

Dentro da Análise de Sentimento, é possível identificar várias subtarefas, todas relacionadas à classificação de um determinado documento com uma opinião expressada: a) determinar a subjetividade de um documento, onde se decide se um texto é de natureza factual (descreve uma situação ou evento, sem expressar uma opinião positiva ou negativa sobre o mesmo) ou expressa uma opinião sobre o assunto à que se refere; b) determinar a orientação (polaridade) de um documento, onde se decide se o documento que possui a opinião é positivo ou negativo em relação ao assunto discorrido; c) determinar a força da orientação de um documento, onde se define, por exemplo, se uma opinião positiva expressada pelo texto sobre o seu assunto é fracamente positiva, mediamente positiva ou fortemente positiva [Esuli e Sebastiani 2006].

De forma a auxiliar estas atividades, trabalhos recentes têm como objetivo identificar a orientação de termos subjetivos contidos em texto, como, por exemplo, determinando se um termo que carrega conteúdo opinativo tem uma conotação positiva ou negativa [Esuli e Sebastiani 2006].

2.2. Ambiente Virtual de Aprendizagem (AVA) SOLAR

O SOLAR é um AVA projetado para permitir a criação de um espaço virtual para participar de cursos presenciais ou semipresenciais [Coutinho et al. 2017]. Atualmente, possui cerca de 47.000 usuários cadastrados, com uma média de 2.000 acessos diários. Ele serve como um ponto de convergência para a criação do que está sendo chamado de *Blended Education* ou *Blended Learning*, uma mistura de características para ambos os modos de educação, para formar um novo modelo educacional que utiliza fortemente as TICs. O *Blended Education* é um derivado de *e-learning*, e refere-se a um sistema de treinamento em que a maior parte do conteúdo é transmitida em um curso à distância. No entanto, isso inclui necessariamente situações face-a-face, daí a origem da designação “*blended*”, algo misturado, combinado. Pode ser estruturado com atividades síncronas ou assíncronas da mesma forma que o *e-learning*, em situações em que professor e alunos trabalham juntos, com cada um cumprindo suas tarefas em horários

flexíveis. O AVA SOLAR é composto pelos seguintes módulos: Gerenciamento de usuários e controle de acesso, Integrador de AVA com o sistema de gestão acadêmica da universidade, Espaço pessoal interagente, Avaliação e monitoramento, Ferramenta de criação de conteúdo, Ferramentas de comunicação, Ferramentas administrativas, Ferramentas do curso, e Ferramentas colaborativas e cooperativas.

3. Trabalhos Relacionados

Kansaon et al. (2018) afirmam que existem diversos trabalhos sobre a análise de sentimentos para a língua inglesa, mas no caso do português brasileiro a quantidade de trabalhos é menor por não existirem muitas bases de dados disponíveis e métodos para realizar a análise. Os autores realizaram uma série de testes com a ferramenta WEKA em cima de milhares de *tweets* em português brasileiro, concluindo que na ferramenta existem algoritmos que conseguem atingir até 85% de acerto na análise, mas ao mesmo tempo também foi observado que a relação de acertos entre sentimentos próximos possuem taxa de acerto menor que 70% [Kansaon et al. 2018].

Christie et al. (2018) constataram que da grande quantidade de dados compartilhados na web, boa parte desses possuem posicionamentos expressos, sejam eles direta ou indiretamente, e que a detecção deste posicionamento pode identificar qual a polaridade de uma desta em relação a uma ideia alvo. Um experimento com uma grande amostra de *tweets* em português brasileiro sobre a corrida presidencial brasileira de 2018 foi projetado, com a detecção automática de posicionamento através de uma abordagem semi-supervisionada. Como conclusão foi possível apontar a existência de *bots* no twitter, e também que com o uso de três classificadores foi possível a obtenção de um *F-Measure* (média harmônica entre a *precision* e *recall*, formas de se aferir a acuidade estatística de uma predição) acima de 94% [Christie et al. 2018]

Dosciatti et al. (2013) apontam que a identificação automática de emoções em textos tem se provado como uma boa forma de obtenção de resultados em diversas aplicações. Os autores propuseram uma abordagem utilizando máquinas de vetores de suporte para a identificação de emoções em textos escritos em português brasileiro com dados de notícias extraídas de um jornal *online*. Como resultado, os textos previamente rotulados e submetidos a um classificador possuíam uma taxa de acerto de 61% [Dosciatti et al. 2013]

Caetano et al. (2017) definiram homofilia como a tendência de um indivíduo possuir características semelhantes aos de seus pares. Uma análise da homofilia da política entre os usuários do Twitter durante as eleições americanas de 2016 foi proposta. A base de dados utilizada foram *tweets* coletados num período de 122 dias e foram analisadas a homofilia das mensagens em relação à Trump e Hillary. Os resultados mostraram que existe maior homofilia entre usuários que compartilham sentimentos negativos em relação aos dois candidatos, e que existe maior heterofilia entre usuários que não manifestam sentimento em relação a nenhum candidato [Caetano et al. 2017].

A Tabela 1 compara os trabalhos, com as técnicas utilizadas, se houve experimento ou não, ferramentas utilizadas e a área de atuação. O trabalho proposto apresenta semelhança ao fazer uso do *Multinomial Naive Bayes* para a classificação de frases. A maior diferença é que todos os outros trabalhos se utilizam de aplicações pré-

existentes para a análise de dados. O trabalho aqui apresentado foca no desenvolvimento de uma aplicação customizada, que atende exclusivamente ao problema proposto.

Tabela 1. Características dos trabalhos relacionados

Autores	Técnica	Exp.	Algoritmos	Ferramentas	Área de Atuação
[Kansaon et al. 2018]	Análise de sentimento	Sim	Naive Bayes	WEKA	Análise de sentimentos em redes sociais
[Christie et al. 2018]	Análise de sentimento	Sim	Naive Bayes; SVM; Random Forest	LIWC; WEKA	Análise de sentimentos e política em redes sociais
[Dosciatti et al. 2013]	SVM	Sim	SVM; KNN	LibSVM; WEKA	Análise de sentimentos
[Caetano et al. 2017]	Lexemas de dicionários	Sim	Não citado	SentiStrenght; Stanford Parser	Análise de sentimentos e política em redes sociais

4. Metodologia

Conforme Polak et al. (2011), este trabalho se classifica em: a) natureza: pesquisa aplicada, já que se procura aplicar algoritmos de Aprendizagem de Máquina e Análise de Sentimento nas amostras; b) abordagem: quali-quantitativa. Quantitativa já que métodos estatísticos serão aplicados nos resultados obtidos, de forma a se medir objetivamente a quantidade de “erros” e “acertos” do sistema a ser desenvolvido e analisado; qualitativa pois suposições de como os tutores/professores podem utilizar essas informações serão sugeridas; c) objetivos: descritiva, já que se planeja um aprofundamento na temática de Análise de Sentimento; d) procedimentos: pesquisa experimental. O estudo aqui feito não pode ser generalizado para outros sistemas, mas pode ser generalizado para qualquer usuário que pertença ao AVA SOLAR.

Utilizou-se o algoritmo de classificação *Naive Bayes*, com a plataforma Anaconda (Python - CLI), e o pacote scikit-learn. Os dados coletados foram salvos em um arquivo JSON (*JavaScript Object Notation*). O arquivo de dicionário foi um arquivo CSV (*Comma-separated values*).

O AVA SOLAR foi utilizado no experimento, e para o acesso aos seus dados dos fóruns é necessário contas de usuário ativos com turmas ativas. Formulários em papel e eletrônico foram projetados com a solicitação de autorização para o uso de login e senha dos usuários. As amostras colhidas para o processamento serão todos os *posts* de fóruns dos usuários em específico que aceitem os termos propostos no formulário.

As funcionalidades para a criação da aplicação foram definidas: um arquivo de base de dados de onde possam ser extraídos automaticamente pela aplicação os dados de usuários do AVA SOLAR; um primeiro módulo da aplicação que faça o registro em arquivo de todos os textos obtidos do AVA SOLAR e os guarde em uma base de dados; um segundo módulo da aplicação que faça a Análise de Sentimentos baseado no arquivo gerado pelo primeiro módulo; e por fim um menu, que disponibiliza ao usuário a opção de escolha de que módulo quer que seja executado. Em seguida, a aplicação é testada.

O experimento em si ocorre da seguinte maneira: a) Coleta de login e senha: os formulários eletrônico e de papel são divulgados, solicitando o acesso às contas de usuários ativos e com disciplinas ativas do AVA SOLAR; b) Coleta dos textos: com ao menos 10 contas ativas do AVA SOLAR no caso de alunos, ou 1 aluno com pelo menos 10 fóruns, ou 1 conta ativa de professor/tutor com ao menos 5 disciplinas, os logins são inseridos num banco de dados e o primeiro módulo da aplicação é executado. Um

segundo banco de dados com todos os textos coletados é gerado pela primeira aplicação; c) Classificação dos textos: de posse do arquivo de textos, o segundo módulo da aplicação é executado. Com base no método de Análise de Sentimentos Multinomial *Naive Bayes*, os textos são analisados e classificados em Positivos, Negativos ou Neutros. Essas informações são exibidas em uma interface web para melhorar a visualização dos dados; d) Referência cruzada: com as classificações geradas no passo anterior, uma porcentagem das amostras de texto é escolhida e as mesmas são exibidas a uma ou mais pessoas (que não possuem conhecimento dos resultados apontados pela aplicação), onde elas farão seu julgamento próprio. Após isso as classificações humanas são comparadas com as mesmas feitas pelo algoritmo. Este passo serve para apontar falsos-positivos e atestar a capacidade do sistema de funcionar sem supervisão posterior.

5. Execução do Experimento

Para este experimento, os dados de login de pelo menos 10 alunos com um fórum disponível, ou 1 aluno com pelo menos 10 fóruns, ou ao menos 1 professor com pelo menos 5 disciplinas ministradas são então coletados e armazenados no banco de dados citado anteriormente. Dados dos fóruns também são armazenados (disciplina, fóruns, mensagens e usuários que participaram do fórum).

Após os textos serem salvos, a classificação dos textos é executada. Para os fins deste trabalho, os sentimentos a serem analisados são Positivo, Negativo e Neutro. Sentimentos positivos são aqueles que demonstram apoio a uma ideia, causa ou que simplesmente passe a sensação de que o sentido daquela frase é agradar a alguém ou a alguma coisa. Sentimentos negativos são definidos como oposto dos positivos: demonstram discordância com ideia, causa ou passam a sensação de desagrado com algo ou alguém. Sentimentos neutros são apenas aqueles que não se encaixam em nenhuma das duas classificações anteriores.

Para a classificação dos textos, o método *Naive Bayes* necessita aprender o que deve ser classificado. Por isso, é necessário um dicionário prévio, onde já tenha sido feita a classificação, geralmente manual, de textos. Um dicionário nada mais é que um banco de dados qualquer onde é há uma quantidade substancial de exemplos que possam ser utilizados pelo algoritmo para serem aprendidas as regras intrínsecas da classificação a ser feita. Neste caso, o dicionário é um arquivo composto por três bases de dados. A primeira é uma grande base com *tweets* recolhidos por um usuário anônimo sobre o governo do estado de Minas Gerais [Silva 2017] por um tempo desconhecido, que possui vários exemplos de textos classificados tanto como positivos, negativos e neutros. A segunda e terceira provém do mesmo local, uma base de palavras retiradas do site Kaggle [Tatman 2017]. Ao contrário da primeira, que contém vários textos classificados, ambas são apenas palavras avulsas mas ainda assim classificadas.

Para a classificação, o arquivo de dicionário é lido e o algoritmo de Análise de Sentimentos Multinomial *Naive Bayes* é executado. Em seguida, o arquivo de dados que contém os textos salvos é carregado para a aplicação. A classificação é então realizada pelo algoritmo e fica pronta para ser exibida pela aplicação.

Após a classificação, todos os textos são exibidos em uma página web formatada para a visualização final. A tela no navegador possui as seguintes informações: a) Precisão: a precisão geral média do algoritmo baseada nos dicionários que recebeu.

Valores são no intervalo de 0 a 1; b) Estatísticas: Tabela completa com várias estatísticas geradas automaticamente pelo algoritmo. Possui os campos *precision*, *recall*, *f1-score* e várias médias para cada tipo de sentimento classificado. *Precision* é definida como o número total de resultados relevantes obtidos dividido pelo número total de resultados obtidos; *recall* é definido como o total de resultados relevantes obtidos dividido pelo número total de resultados relevantes na base de dados [Ting 2017]. *F1-Score* é usado para analisar a acurácia da predição e é definido como a média harmônica da *precision* e do *recall*; assim sendo, se localiza entre os dois, mas é mais próximo do menor valor; um sistema com alto F1 tem então boa *precision* e bom *recall* [Sammut e Webb 2017]. Valores estão no intervalo entre 0 e 1. c) Matriz de confusão: Tabela que demonstra a acurácia para cada classificação em relação a si mesma e a outras. Valores inteiros.

Após a análise dos dados, uma amostra de 10% das frases é analisada por um humano que não tem conhecimento da classificação atribuída pelo algoritmo a cada frase, de forma a se testar a coerência da classificação pela máquina com a classificação feita por um humano. Após a classificação pelo humano, os dados são guardados em um banco de dados também em formato JSON para a referência cruzada com os dados obtidos pelo algoritmo, e será conferido manualmente por um terceiro. Esse passo é apenas uma forma adicional de se atestar a qualidade da classificação automática de textos pela aplicação.

6. Resultados e Análises

A aplicação do algoritmo atingiu uma taxa de sucesso de aproximadamente 79%, podendo ser considerada boa.

A Tabela 2 indica que a maior taxa de acertos é em relação aos textos com teor positivo, atingindo 93% de chance de classificação correta; em segundo lugar se coloca a classificação de textos com teor negativo, com 75% de chance de acerto; por último, com a menor chance mas ainda assim com um valor considerado aceitável vem a classificação de textos com teor neutro, com taxa de acerto de apenas 70%. Também pode-se observar que a melhor taxa de *recall* pertence à classificação de frases com teor negativo, com 90% das instâncias indicadas sendo corretas. Frases com teor neutro em segundo lugar, com 85% das instâncias indicadas sendo apontadas corretamente; por último, frases com teor positivo com apenas 64% das instâncias indicadas apontadas de forma correta. Por fim, dela podemos ainda conferir que a precisão média de todas as classificações ficou em 81%, enquanto que o *recall* ficou com 79%.

Na Tabela 3 observa-se de forma quantificável os resultados do *recall*. Aqui se mostram as quantidades de “positivos” e “falso-positivos” de cada classe, em relação de uma com a outra. A classe de textos negativos é a que realmente possui a maior taxa de reais positivos, enquanto que a classe de textos positivos é a que possui a maior chance de ativar um falso-positivo.

Tabela 2. Taxa de acertos

Categoria	Precision	Recall	F1-Score
Positivo	0.93	0.64	0.76
Negativo	0.75	0.90	0.81
Neutro	0.70	0.85	0.77

Tabela 3. Matriz de confusão

Valor Real	Predito Negativo	Predito Neutro	Predito Positivo
Real Negativo	4693	405	129
Real Neutro	253	2088	112
Real Positivo	1350	488	3246

A Figura 2 exibe textos que foram classificados corretamente como positivos. Como explicado anteriormente, positivo aqui se considera como uma frase que apoie uma ideia desejada. A disciplina de onde esses textos foram extraídos se chama Diferença e Enfrentamento Profissional nas Desigualdades Sociais, e o fórum em específico continha discussões que falavam exatamente sobre este assunto. Levando em conta o tema do fórum, é possível observar que os textos corroboram positivamente com o tema discutido.

101	Positivo	Quando o movimento feminista trabalha com mulheres acima de 18 anos e encontram crianças de 11 ou 12 anos, que estão em situação de exploração sexual, eles encaminham para a secretaria de Direitos Humanos e para os movimentos em defesa da criança
223	Positivo	O conhecimento é a chave para acabar com o preconceito

Figura 2. Texto corretamente classificado como positivo

A Figura 3 apresenta textos que tem a conotação negativa, que mostram discordância com o que foi falado anteriormente e que possuem o atributo de negarem qualquer argumento antes proposto. Assim, demonstram que o algoritmo possui a capacidade de julgar corretamente este tipo de informação.

328	Negativo	Independente dos danos causados ao planeta e consequentemente às pessoas
335	Negativo	Que absurdo
467	Negativo	Não, não se trata disso

Figura 3. Texto corretamente classificado como negativo

A Figura 4 demonstra um texto que pode muito bem ser considerado neutro, mas é um caso um pouco mais complicado de ser julgado por um humano, já que ao mesmo tempo que neutras, existem conotações positivas, como o professor elogiar o interesse que os textos despertam. A Figura 5 exibe o tipo de falha que pode ocorrer na classificação de textos. Na Figura 5A, por algum motivo, o algoritmo declara que abraços e o nome do professor tem a conotação negativa, mas na Figura 5B o mesmo texto é considerado como positivo, apenas por ter sido colocado por extenso e na mesma linha. Entretanto, sendo analisado por um humano, esses dois trechos além de terem a mesma conotação, neste caso deveriam se encaixar em neutro, pois temos o conhecimento que esse tipo de encerramento é mera formalidade. Já a Figura 5C poderia encaixar melhor na classificação positiva, afinal é por nós vista como uma mensagem de encorajamento.

472	Neutro	Caríssimas (os), Não tenho como comentar cada uma das postagens de vocês, mas observando o conjunto delas tenho uma ideia dos temas e/ou questões que parecem despertar grande interesse e levantar polêmicas
-----	--------	---

Figura 4. Texto subjetivamente classificado como neutro

470	Negativo	Abraços, Prof	A
524	Positivo	Abraços, Professor	B
600	Neutro	Um bom semestre para todos	C

Figura 5. Textos erroneamente classificados como negativos (A), positivos (B) e neutros (C)

A Figura 6 exibe outro tipo de falha que pode ocorrer, mas que parece mais estar relacionada ao fato do dicionário utilizado ser de um escopo limitado. Por observação, é possível perceber que o algoritmo demonstra uma certa tendência em relação às frases negativas e neutras, já que geralmente é este tipo de teor de mensagem que as pessoas que se engajam com mídias sociais relacionadas à política.

19	Negativo	E esta democracia garantiria o espaço não só o desejo da maioria, mas a garantia de representação das minorias
42	Positivo	Notem que a falta de qualificação destas pessoas são também um processo de violência que faz com que elas não tenham acesso garantido a Educação e possibilidades justas de se inserir no mercado
113	Positivo	A finalidade dessa lei, "

Figura 6. Classificação incorreta do texto como negativo por dicionário falho, classificação incorreta do texto como positivo por dicionário falho, e classificação incorreta do texto como positivo por dicionário falho

7. Conclusões e Trabalhos Futuros

Este trabalho apresentou técnicas simples para análise de sentimento de *posts* de fóruns de um AVA, concluindo que é possível se atingir um nível satisfatório. A análise de sentimento de textos em português brasileiro ainda não está sendo abordada em grande quantidade, levando a uma limitação de referências, algoritmos, técnicas e dicionários. A maior dificuldade neste trabalho foi não se encontrar facilmente um dicionário de textos em português já classificado e de boa qualidade. O dicionário utilizado possui certa tendência com classificações neutras e negativas justamente por parte dele ter origem de *tweets* sobre o governo de um estado. Ainda assim, os resultados se mostraram corretos em sua maioria.

Como possíveis trabalhos futuros pretende-se: criação de uma ferramenta mais abrangente e que funcione em AVAs diferentes; um estudo semelhante envolvendo a utilização de outras redes sociais, como o Facebook ou Twitter; e aplicação de outros métodos de Análise de Sentimento.

Referências

- Caetano, J. A., Lima, H. S., dos Santos, M. F., e Marquesneto, H. T. (2017). Utilizando análise de sentimentos para definição da homofilia política dos usuários do twitter durante a eleição presidencial americana de 2016. In XXXVII Congresso da Sociedade Brasileira de Computação (CSBC).
- Christie, W., Reis, J. C. S., Benevenuto, F., Moro, M. M., e Almeida, V. (2018). Detecção de posicionamento em tweets sobre política no contexto brasileiro. In Brazilian Workshop on Social Network Analysis and Mining (BraSNAM-CSBC).
- Coutinho, E. F., Santos, I., e Bezerra, C. I. M. (2017). A software ecosystem for a virtual learning environment: Solar seco. In 2017 IEEE/ACM Joint 5th International Workshop on Software Engineering for Systems-of-Systems and 11th Workshop on Dis-tributed Software Development, Software Ecosystems and Systems-of-Systems (JSOS).
- Dosciatti, M. M., Ferreira, L. P. C., e Paraiso, E. C. (2013). Identificando emoções em textos em português do brasil usando máquina de vetores de suporte em solução multiclasse. In X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC).
- Esuli, A. e Sebastiani, F. (2006). Determining term subjectivity and term orientation for opinion mining. In 11th Conference of the European Chapter of the Association for Computational Linguistics.
- Kansan, D. P., Brandao, M. A., e de Paula Pinto, S. A. (2018). Análise de sentimentos em tweets em português brasileiro. In Brazilian Workshop on Social Network Analysis and Mining (BraSNAM-CSBC), volume 7.
- Liu, B. (2012). Sentiment analysis and opinion mining. *Synthesis lectures on human language technologies*, 5(1).
- O'Leary, R. e Ramsden, A. (2002). Virtual learning environments. In *Learning and Teaching Support Network Generic Centre/ALT Guides, LTSN*, volume 12.
- Oliveira, E., Sales, G., Pereira, P., e Moreira, R. (2013). Identificação automática de estilos de aprendizagem: Uma revisão sistemática da literatura. In *Anais do 26o. Workshop sobre Educação em Computação (WEI2018)*.
- Polak, Y. N. S., Diniz, J. A., e Santana, J. R. (2011). *Dialogando sobre metodologia científica*. Editora Universidade Federal do Ceará.
- Sammut, C. and Webb, G. I. (2017). *Encyclopedia of Machine Learning*. Springer.
- Silva, L. (2017). Tweets from mg/br. <https://www.kaggle.com/leandrodoze/tweets-from-mgbr>. Online; acessado em setembro de 2018.
- Tatman, R. (2017). Sentiment lexicons for 81 languages. <https://www.kaggle.com/rtatman/sentiment-lexicons-for-81-languages/sentiment-lexicons.zip>. Online; acessado em setembro de 2018.
- Ting, K. M. (2017). *Precision and Recall - Encyclopedia of Machine Learning*. Springer.
- Witten, I. H., Frank, E., e Hall, M. A. (2016). *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.