

# Identificação da Auto Eficácia dos Usuários do Twitter em Relação ao Tema “Geografia” com o Uso da Análise de Sentimentos

Sidney Felipe Moraes<sup>1</sup>, Seiji Isotani<sup>2</sup>, Bruno E. Penteado<sup>3</sup>

## Resumo

*Detectar a percepção de alunos sobre sua auto eficácia mediante a um tema, matéria ou estudo ainda hoje é limitado a psicologia ou é realizado de forma informal mediante feedbacks e análise manual por parte do Professor. Como a área educacional, na era digital, pode ter insights de como o aluno percebe e mede sua própria capacidade sem utilizar de métodos não convencionais? Uma proposta é a análise de sentimentos de dados educacionais, uma área de mineração de dados que ainda é hoje pouco explorada. A percepção e análise dos sentimentos de alunos sobre determinado assunto ou matéria ainda hoje é limitado ao espaço escolar e avaliado manualmente por professores ou agentes pedagógicos. Muitos professores de Geografia não sabem onde está a causa do problema em alunos que não tem bom desempenho e não consideram o saber geográfico como importante em sua trajetória. Os professores sentem falta de uma percepção macro do estudante em relação ao aluno, professor e matéria. Através de questionário e feedbacks é absorvido percepções categóricas e empíricas, onde a interpretação é demorada e manual, gerando assim desmotivação e não sequência do processo. Com o auxílio da tecnologia e da mineração de dados, é possível captar, interpretar e perceber como os alunos através das redes sociais e da internet expressam sua percepção, interpretam e avaliam determinado assunto, através de técnicas de análise de sentimentos, servindo de base para insights, tomada de decisão e mudança de estratégias ou comportamento por parte da organização educacional, assim agregando valor para o processo de ensino/aprendizagem e a educação de forma geral. Os resultados demonstram uma acurácia superior a 80%, gerando como resultado visual uma nuvem de palavras que auxilia os professores e tomada de decisão nas palavras mais utilizadas.*

1 .Pós-Graduando(a) em Computação Aplicada à Educação, USP, sidney.moraes@usp.br.

2 . Professor titular do instituto de Ciências Matemáticas e da computação, da Universidade de São Paulo (ICMC/USP), sisotani@usp.br.

3 .Doutor em Ciências da Computação pelo instituto de Ciências Matemáticas e da computação da Universidade de São Paulo (ICMC/USP), brunopenteado@usp.br

## ***Abstract***

*Detecting students' perception of their self-efficacy through a topic, subject or study is still limited to psychology or is carried out informally through feedback and manual analysis by the Professor. How can the educational area, in the digital age, have insights on how the student perceives and measures his own ability without using unconventional methods? One proposal is the analysis of feelings of educational data, an area of data mining that is still little explored today. The perception and analysis of students' feelings about a certain subject or subject is still limited to the school space and is manually evaluated by teachers or pedagogical agents. Many geography teachers do not know where the cause of the problem lies in students who do not perform well and do not consider geographic knowledge as important in their trajectory. Teachers miss a student's macro perception of the student, teacher and subject. Through questionnaire and feedbacks, categorical and empirical perceptions are absorbed, where interpretation is time-consuming and manual, thus generating demotivation and not sequence of the process. With the help of technology and data mining, it is possible to capture, interpret and perceive how students through social networks and the internet express their perception, interpret and evaluate a certain subject, through techniques of analysis of feelings, serving as a basis for insights, decision making and change of strategies or behavior by the educational organization, thus adding value to the teaching / learning process and education in general. The results demonstrate an accuracy greater than 80%, generating as a visual result a wordcloud that assists teachers and decision making in the most used words.*

## 1. Introdução

O ensino da Geografia implica o desenvolvimento do método utilizado na construção do conhecimento geográfico, conhecimento este que está em contínua transformação, dessa maneira, o ensino da geografia significa que se deve levar em consideração o processo histórico que levou a atual organização do espaço, e se esse é apropriado para que o trabalho seja feito, caso contrário há necessidade de sua modificação para tal fim.

Dessa maneira, conforme [DE ALMEIDA, 2015]: *“o ensino não ocorre apenas através da transmissão de conteúdos, mas através do professor atuando como tutor na criação dos conhecimentos, organizando o trabalho, orientando sua sequência, fornecendo informações, demonstrando técnicas e provendo recursos, para que o aluno consiga aprender a observar, coligir dados, fazer sua comparação e classificação para ter domínio das formas de produção de conhecimento científico”*.

Para que o aluno adquira habilidades e compreensão dos assuntos existem vários fatores que devem ser levados em consideração, tal como: meio sociocultural em que o estudante está inserido, nível de desenvolvimento emocional e segurança afetiva e nível de evolução cognitiva. Dessa forma, a maneira como o estudante vai se portar em sala de aula e nas relações que vai estabelecer com colegas e professores dependem dos fatores mencionados. Sendo que, conforme [DE ALMEIDA, 2015]: *“ Este seria o momento em que o professor deveria recorrer aos seus conhecimentos de psicologia para poder lidar melhor com seus alunos, fazendo-o com habilidade e sensibilidade”*.

Porém, seria necessário que o professor dominasse outras áreas de estudo, tal como a psicologia, de forma a adquirir novos métodos e formatos de compreensão da forma de pensar do aluno, seus gatilhos de avaliação e interpretação dos fenômenos estudados, bem como os mecanismos de uma aprendizagem significativa. Temos então o conceito da psicologia social denominado auto eficácia, um fator que impacta e que ajuda a compreender o desempenho educacional em uma determinada área.

---

[BANDURA, 1989] relata que a auto eficácia se refere *“às crenças do indivíduo em suas próprias capacidades para mobilizar motivação, recursos cognitivos e cursos de ação necessários ao sucesso das atividades em que se engajam”*. Assim[MENEZES,

2010], argumenta que através da auto eficácia supõe-se que os indivíduos, ao captarem que conseguem fazer as atividades aumentam seu grau de confiança, o que faz com que seu desempenho também aumente, ao contrário daqueles que se acham inaptos.

Dessa maneira, de acordo com [BANDURA, 1993], podemos resumir o conceito de auto eficácia com o que pode-se fazer com os recursos disponíveis, utilizando isso para lidar com as condições adversas e com o julgamento individual contra os acontecimentos. Por fim, para [SCHUNK & HANSON, 1985] autoeficácia é acreditar nos próprios conhecimentos, aptidões, atitudes e capacidades para que se possa levar a própria capacidade de aprendizagem e comportamento a uma determinada situação.

Uma outra forma de trabalhar com esse conceito é através do uso da tecnologia, como por exemplo utilizando técnicas de mineração de sentimentos, que tem o objetivo de identificar, classificar e sumarizar sentimentos, opiniões, avaliações e resultados [SANTOS; BECKER; MOREIRA, 2014]. “*A análise de sentimento identifica nos textos opinativos o sentimento expresso, por exemplo: textos com opiniões de objetos ou tópicos de interesse, onde as opiniões podem ser positivas, negativas ou neutras, indicando sua polaridade, onde nos textos são expressas por palavras opinativas*” [SILVA; LIMA; BARROS, 2012].

Para trabalhar com esse tipo de análise, é necessário adquirir os dados de algum lugar, e uma opção é utilizar as redes sociais, como por exemplo o Twitter, que conforme [ARAÚJO E GABRIELA, 2014] é uma plataforma de *blog* através de pequenas postagens (no máximo 140 caracteres) que foi criado em 2006. O serviço tem um carácter altamente social e permite que outros usuários visualizem e interajam com as postagens. Conforme os autores, “*atualmente possui mais de 600 milhões de usuárioscadastrados e o Brasil está entre os cinco países com maior número de usuárioinscritos na rede, contando com mais de 214 milhões de usuários ativos.*”

Assim, o uso do Twitter torna-se adequado devido ele disponibilizar uma API de obtenção de dados, tais como mensagens, informações do perfil, dados geográficos, entre outros.

Baseado nisso, temos como objetivo geral desse trabalho a identificação, através da interação digital de usuários da rede social Twitter, o senso de auto eficácia sobre o tema **Geografia** e sua relação com o aprendizado e a auto motivação, fazendo uso de técnicas de reconhecimento de sentimento através da aplicação de mineração de dados, onde através destas, possa ser analisado, compreendido possíveis padrões ou anomalias que possam auxiliar o ensino e aprendizagem deste tema.

Para atingir tal fim, temos os seguintes objetivos específicos que irão nortear a pesquisa: reconhecer e compreender a percepção de uma amostra de dados da rede social *Twitter* em relação ao tema **Geografia**, através do uso de modelos de análise de sentimentos; fazer a extração de uma amostra de dados e seu tratamento; e por fim, aplicar técnicas de mineração de sentimentos de forma a criar um modelo sobre a percepção e auto eficácia do tema.

Esse trabalho está estruturado da seguinte maneira: na seção seguinte será apresentado o embasamento teórico a que esse trabalho está baseado, em seguida, serão demonstrados alguns trabalhos relacionados e a metodologia aplicada. Por fim, apresentados o estudo de caso e os resultados obtidos, finalizando com a conclusão e trabalhos futuros.

## 2. Revisão da Literatura

Nessa seção apresentamos os conceitos em que esse trabalho será baseado, tal como a mineração de dados e análise de sentimentos, o conceito de auto-eficácia e a rede social Twitter.

### 2.1. Auto Eficácia

[BZUNECK 2001] define o conceito de auto-eficácia não como “*reais capacidades apresentadas pelos indivíduos, mas a uma percepção subjetiva das mesmas, envolvendo ainda uma avaliação pessoal da eficiência para utilizá-las adequadamente, com vistas à solução de determinados problemas, tarefas ou situações.*”

[BANDURA, 1989] cita que o que cada indivíduo acredita sobre sua auto-eficácia é um dos fatores que determina a forma como ela irá se portar em seus relacionamentos, motivações, comportamentos, pensamentos, entre outros. Dessa maneira, esse auto-conhecimento irá indicar como será a interação com o ambiente em que está inserido e com isso serão planejados e executados cursos de ação, e isso pode ser chamado de crença de auto-eficácia.

Conforme [BANDURA, 1977; BZUNECK, 2001; MEDEIROS ET AL, 2000; FONTAINE, 2005] essas crenças são originadas das informações que o sujeito obtém e processa, segundo quatro fontes fisiológicas: experiências de êxito, experiências vicárias, persuasão verbal e indicadores.

As experiências de êxito são a origem mais importante do desenvolvimento das crenças de auto-eficácia, pois constituem para um estudante “*a prova de que consegue desempenhar os comportamentos ou executar as ações necessárias para a realização da tarefa, alcançando assim os objetivos pretendidos*” [FONTAINE, 2005, p. 123).

As experiências vicárias ou múltiplas seriam aquelas obtidas com base na observação e cópia dos comportamentos alheios, porém só apresentarão benefícios para o desenvolvimento da auto-eficácia se o indivíduo a ser copiado for um modelo social próximo do estudante, e se as condições forem acessíveis ao mesmo, o que significa que imitar um artista ou pessoa famosa pode não trazer resultados, visto que são mundos divergentes.

Um exemplo de como a observância dos colegas pode ser benéfica no dia a dia é quando ela ocasiona uma motivação para que o aluno inicie e conclua suas tarefas, acreditando que irá ter um bom resultado. Em contrapartida, caso o aluno que está sendo observado tenha dificuldades nas suas tarefas, o que está observando também pode se acreditar inapto, podendo inclusive desistir antes de tentar. Similarmente caso ele acredite que o colega é muito mais inteligente e apto do que ele.

Quanto a persuasão verbal, está relacionada a auto-eficácia quando o aluno é incentivado de forma verbal que está apto e consegue realizar suas tarefas, porém é necessário de que essa opinião seja convincente, tendo maior peso se for dada por uma pessoa a quem ele admira e confia.

Finalmente, [RODRIGUES E BARREIRA, 2005] citam que esses indicadores fisiológicos quando relacionados com os estados emocionais também podem ser considerados como outra fonte de desenvolvimento na certeza da auto-eficácia. Assim, “*sentimentos como ansiedade, medo ou desânimo podem levar o aluno a se julgar incapaz para a realização de uma determinada tarefa. Já o bem-estar, o bom humor e o otimismo levam, por sua vez, o aluno a acreditar e confiar nas suas capacidades.*”

## 2.2. Twitter

Segundo [SANTOS 2011], “*as redes sociais digitais se tornaram uma febre mundial*” em se tratando de informação e comunicação entre pessoas, gerando uma grande quantidade de informações publicadas contendo o mais diverso tipo de mensagens, imagens e opiniões. Isso porque, em um ambiente que acredita-se não monitorado como a internet, os usuários “*se sentem mais seguros em declarar suas opiniões referente à algum acontecimento ou produto*”.

Conforme [COMMS, 2014], o Twitter foi publicado em março de 2006 em São Francisco, US, chamado de Twtr, tendo sido desenvolvido em Ruby on Rails [BURNS E ELTHAM, 2009]. As mensagens enviadas pelo Twitter são chamadas de *tweets* e possuem tamanho máximo de 140 caracteres. Também é possível dar RT (*retweet*) em uma mensagem, ou seja, replicá-la para seus seguidores, com ou sem comentários adicionais, o que é chamado de *retweet*. Os usuários são identificados por uma @ na frente, ou seja, @amazonBR se refere ao usuário Amazon Brasil.

[KLINCZAK, 2016] cita que um diferencial da rede é que cada usuário pode seguir quantas pessoas desejar, sem que seja necessário haver reciprocidade, ou seja, não é necessário a criação de um vínculo entre as 2 pessoas, como ocorre no Facebook, por exemplo. Assim, figuras públicas como famosos ou políticos podem ter milhões de seguidores.

Por fim, segundo [DEV TWITTER, 2020], a plataforma oferece diversas bibliotecas chamadas de API (*application programming interface*), o que permite que seu conteúdo seja acessado por diferentes sistemas e plataformas, proporcionando também a diferentes empresas e pesquisadores a obtenção de mensagens e conteúdos públicos.

## 2.3. Mineração de Dados Educacionais

Conforme [TAN ET AL., 2009] “*a mineração de dados é o processo de descoberta automática de informações úteis em grandes repositórios de dados, sendo parte integral do processo de descoberta de conhecimento que converte dados brutos em informações úteis*”. Algumas aplicações são em setores de finanças, segurança da informação, marketing, educação, entre outros.

[KLINCZAK, 2016] cita que essa não é uma técnica utilizada sozinha, podendo combinar métodos tradicionais de análise de dados (redes neurais por exemplo) com algoritmos que permitem o processamento de uma grande quantidade de dados, com o objetivo de descobrir padrões e tendências que não seriam identificadas a olho nu.

A Figura 1 demonstra o processo de descoberta de conhecimento, que inicia com a obtenção de uma base de dados bruta, ou seja, sem nenhum tratamento anterior, que passa por um pré-processamento que varia de acordo com o estado dos dados e com a finalidade da obtenção de informações. Após isso podem ser aplicadas diversas técnicas, como por exemplo: agrupamento, árvore de decisão, associação, mineração de sentimentos, entre outros.



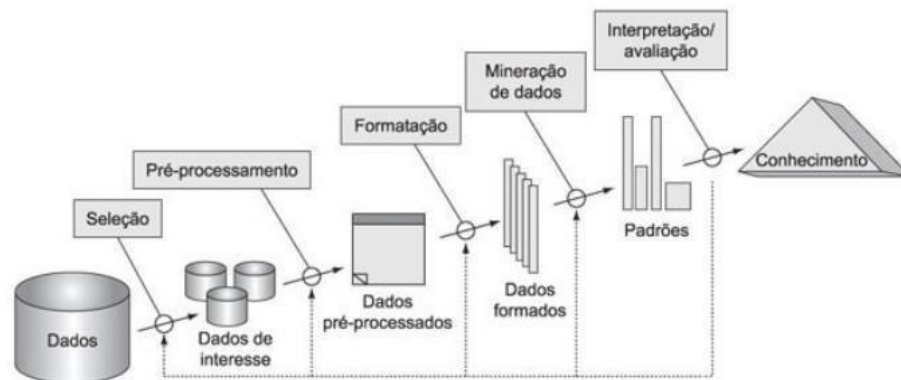


Figura 1. Processo de mineração de dados [TAN ET AL., 2009].

Já no caso da rede social Twitter, os dados brutos são extraídos a partir da API disponibilizada, em formato bruto, com outras diversas informações como por exemplo as mensagens em texto, links, metadados, figuras, quantidade de vezes que a mensagem foi favoritada ou compartilhada, dados geográficos, quando disponibilizados, entre outros. A base de dados pode ser obtida em formato de texto ou planilha, e em cima desses dados, que após passarem pelo pré processamento que serão aplicados os algoritmos de mineração de sentimentos.

Ainda quanto a aquisição de dados e pré-processamento pode-se utilizar também o Ngram, um mecanismo de pesquisa online do Google que faz o mapeamento de frequências encontradas em conjuntos de cadeias de pesquisa a partir de um delimitador. A busca pode ser feita por palavras ou frases, e pode considerar também erros ortográficos, distinção entre maiúsculas e minúsculas, entre outros.

A mineração de dados pode trabalhar com uma grande quantidade de algoritmos, como KNN, KMEANS, DBSCAN, NAÏVE BAYES, NGRAM, LDA, entre outros, cada um tendo um melhor uso para cada caso.

O algoritmo Naïve Bayes foi criado pelo matemático inglês Thomas Bayes, sendo um modelo probabilístico muito utilizado em aprendizado de máquina, conforme Gomes (2019). Conforme o autor citado ele costuma ser utilizado quando as instâncias são independentes de forma condicional, levando em consideração a probabilidade de caso ocorra o evento A, também ocorrer o evento B.

Já o algoritmo LDA (Análise de Discriminantes Lineares), segundo De Campos (2001), ficou conhecido pelo seu uso no reconhecimento facial no final da década de 90, conforme Belhumeur et al. (1997). A grande vantagem do LDA é que ele “*utiliza um método que utiliza informações das categorias associadas a cada padrão de forma a fazer a extração linear das características mais discriminantes*” ,segundo De Campos (2001), com isso ele tem como maior resultado a medida entre os agrupamentos gerados.

## 2.4. Mineração de Sentimentos

Conforme citado por [ATKINSON ET AL, 2015], o uso massivo das redes sociais gerou a oportunidade para que as pessoas pudessem se expressar e publicar opiniões. E essas postagens podem então ser extraídas por empresas e através dessas informações terem a visão dos clientes sobre determinado produto ou negócio, por exemplo.

Para isso é utilizado a análise de sentimentos, que conforme [GERRERO ET AL, 2015] “*é uma das temáticas mais recentemente pesquisadas no domínio do processamento de informação, e tem como objetivo explicitar elementos referentes às opiniões, em forma de texto*”. Dessa maneira, [PANG E LEE, 2016] definem como objetivo principal da análise de sentimentos a divisão de uma sentença como positiva ou negativa.

[FIGUEIREDO ET AL., 2018] menciona que essa área faz uso de técnicas de processamento de linguagem natural (PLN) e mineração de textos com o objetivo de identificar a polaridade de opiniões em negativa, positiva ou neutra. Isso é feito através da análise do corpo do texto, podendo ou não atribuir pesos para as palavras.

Por fim, [RAVI E RAVI, 2015] relatam que o principal desafio da técnica é devido aos dados obtidos em texto puro provém em geral de comentários de usuários na Internet ou em redes sociais, fazendo com que esses dados sejam não estruturados, o que cria dificuldades no processo de extração, seleção e classificação das mensagens.

## 3. Trabalhos Relacionados

Apresentamos alguns trabalhos similares encontrados na literatura, relacionados ao uso do Twitter na área da educação e também quanto a mineração de sentimentos e opiniões. Com base nisso, não encontramos nenhuma outra pesquisa focada no tema de Geografia conforme a proposta.

A pesquisa de [KIMMONS E VELETSIANOS, 2016] estuda a utilização do Twitter por alunos e professores da área de educação em 3 momentos, antes, durante e depois das conferências American Educational Research Association (AERA). Elas ocorreram em 2014 e 2015 e as mensagens enviadas possibilitaram que fosse feita uma análise descritiva e inferencial para explorar como os participantes utilizavam o serviço. Foram então obtidos mais de 360.000 mensagens ou *tweets* de 1.421 acadêmicos, demonstrando os padrões de interação dos usuários com a rede social com relação a conferência, sendo que os *tweets* feitos durante às conferências diferiram significativamente dos de depois das conferências.

Na pesquisa de Sahin (2014) o autor busca identificar o nível de auto-eficácia dos estudantes quanto a educação sobre geografia que receberam. Para isso foram utilizados grupos de estudantes da Dumrupinar University's Faculty of Education, University's Faculty of Education e Suleyman Demirel University's que forneceram os dados de forma voluntária e que estavam em diferentes níveis de estudo, totalizando 501 dados, 264 de homens e 237 de mulheres. A contagem dos pontos foi feito com base no peso de cada item. O estudo demonstrou que os estudantes do sexo masculino tinham níveis de auto-eficácia no tema de Geografia maiores que as mulheres e estatisticamente foi encontrada uma diferença significativa entre a auto-eficácia entre os níveis de Geografia e os departamentos onde ela é ministrada.



Já com relação a mineração de opiniões e sentimentos, o primeiro trabalho encontrado na literatura pelo autor foi o de [GO ET AL. 2009], que tentava analisar opiniões e sentimentos no Twitter para que pudesse automatizar essa extração de conhecimento. O trabalho foi feito com base no uso de *emojicons* digitados nas mensagens, sendo necessário criar uma rotulação para eles, para que se pudesse utilizar algoritmos de classificação supervisionados. Os dados foram coletados através da API fornecida pelo serviço em um período que abrange do dia 6 de Abril a 25 de Junho de 2009 e o pré processamento removeu mensagens duplicadas, compartilhadas ou consideradas neutras, totalizando uma base de dados com 1.600 mensagens. Esses dados foram divididos em 50% para treinamento e o restante para testes, sendo que os para testes foram coletados manualmente e escolhidos de forma aleatória de diferentes domínios, totalizando 177 negativos e 182 positivos. Os autores utilizaram o site Twittratr para formar uma lista com 174 palavras positivas e 185 negativas, rótulo que foi aplicado as mensagens obtidas. Como particularidade da pesquisa os autores citam que consideraram apenas mensagens na língua inglesa e observaram que a acurácia do Naïve Bayes e SVM diminui quanto a performance para o MaxEnt aumenta, porém a maior acurácia ficou com o SVM totalizando 82,9%.

#### **4. Metodologia e Avaliação**

A metodologia aplicada no trabalho está baseada em 2 procedimentos, o primeiro consiste no levantamento bibliográfico dos tópicos envolvidos, feito com base em publicações na área, tal como artigos, livros e revistas. O segundo consiste na aplicação dos conhecimentos adquiridos em um estudo de caso exploratório, conforme demonstrado de forma geral na Figura 2, com os seguintes procedimentos:

- A coleta de dados foi feita na API pública do *Twitter* com base em *tweets* com o tema “Geografia” no período de 15 a 22 de junho, totalizando 9.052 mensagens coletadas.
- Para execução, foi utilizado o software de mineração de dados *Rapidminer*.
- A base de dados foi separada em treinamento e testes.
- Para a base de treinamento foi feita a classificação manual das informações ( P-Positivo, N-Negativo e NE-Neutro) nos *tweets* e então aplicado o algoritmo Naïve Bayes com *cross validation*.
- E por fim, foi aplicado o algoritmo na base de testes, utilizando-se a métrica de acurácia para verificação dos resultados.

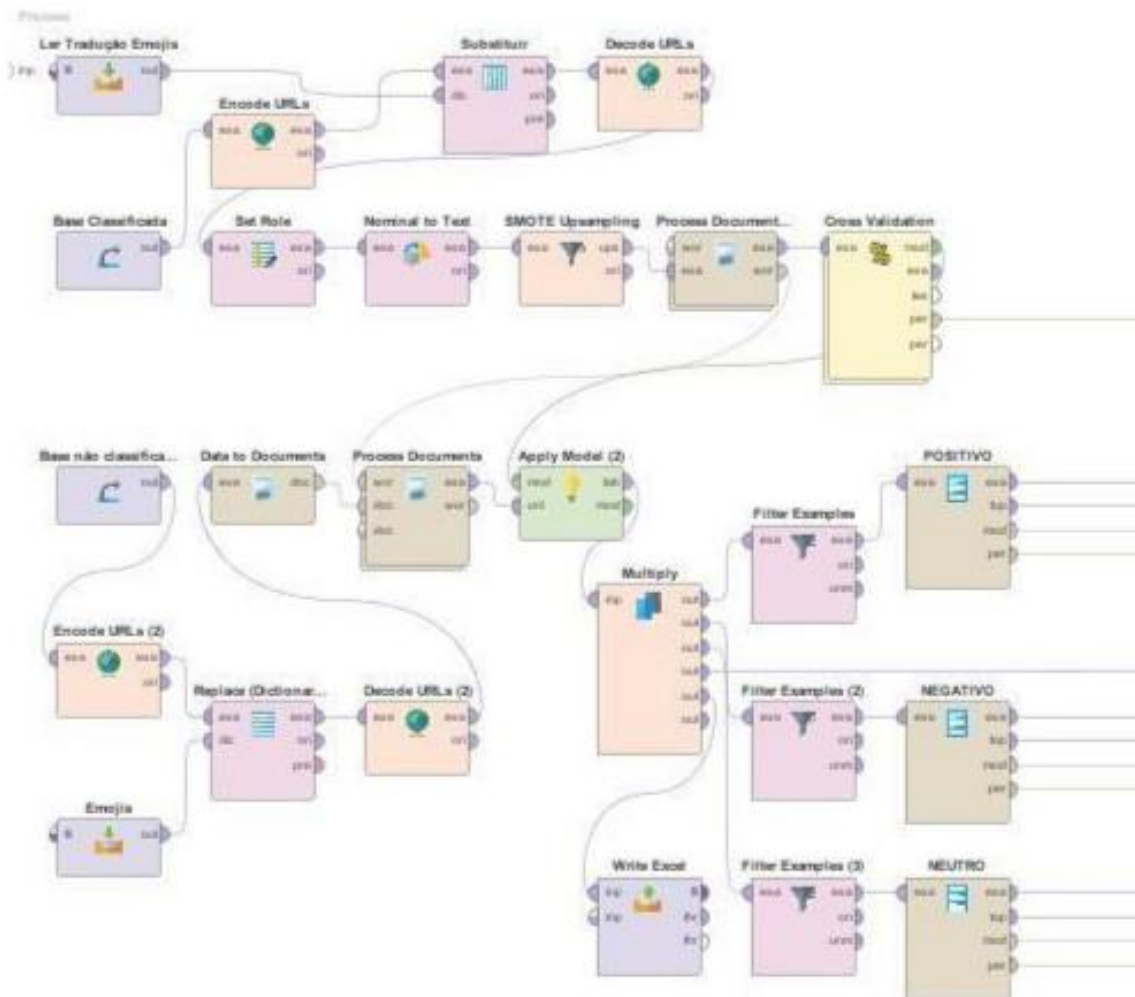


Figura 2. Procedimento geral (do Autor).

## 5. Estudo de Caso

As mensagens foram capturadas via API disponibilizada pelo Twitter durante o período de 15 a 22 de junho de 2020, totalizando 9.052 mensagens coletadas, dessas 2.572 tiveram seus sentimentos classificados manualmente, restando 6.480 que serão classificadas pelos algoritmos propostos.

Após isso, iniciou a etapa de pré-processamento para tratameto dos *emojicons* encontrados através da função de substituir para fazer a troca do mesmo por um texto traduzido, conforme Figura 3, com o uso de componentes encode URL para fazer a conversão para UTF8.

1	cod_utf	emoji	emoji ptbr
2	%F0%9F%98%81	<grinning_face>	emoji feliz
3	%F0%9F%98%82	<face_joy>	emoji alegre
4	%F0%9F%98%83	<smiling_open_mouth>	emoji feliz
5	%F0%9F%98%84	<smiling_face_with_open_mouth_and_smiling_eyes>	emoji alegre
6	%F0%9F%98%85	<smiling_face_with_open_mouth_and_cold_sweat>	emoji amedrontado
7	%F0%9F%98%86	<smiling_face_with_open_mouth_and_tightly-closed_eyes>	emoji risonho
8	%F0%9F%98%89	<winking_face>	emoji sapeca
9	%F0%9F%98%8A	<smiling_face_with_smiling_eyes>	emoji feliz
10	%F0%9F%98%8B	<face_savouring_delicious_food>	emoji guloso
11	%F0%9F%98%8C	<relieved_face>	emoji neutro
12	%F0%9F%98%8D	<smiling_face_with_heart-shaped_eyes>	emoji amoroso
13	%F0%9F%98%8F	<smirking_face>	emoji sorridente
14	%F0%9F%98%92	<unamused_face>	emoji sério
15	%F0%9F%98%93	<face_with_cold_sweat>	emoji doente
16	%F0%9F%98%94	<pensive_face>	emoji reflexivo
17	%F0%9F%98%96	<confounded_face>	emoji confuso
18	%F0%9F%98%98	<face_throwing_a_kiss>	emoji amoroso
19	%F0%9F%98%9A	<kissing_face_with_closed_eyes>	emoji amoroso
20	%F0%9F%98%9C	<face_with_stuck-out_tongue_and_winking_eye>	emoji sapeca
21	%F0%9F%98%9D	<face_with_stuck-out_tongue_and_tightly-closed_eyes>	emoji sapeca
22	%F0%9F%98%9E	<disappointed_face>	emoji desapontado
23	%F0%9F%98%A0	<neutral_face>	emoji neutro

Figura 3. Tabela de conversão *emoticon* - texto (do Autor).

Ainda na etapa de pré-processamento foi realizado a definição da coluna *label* (role), para a coluna de sentimento classificada manualmente, conforme Figura 4, após isso é feito a definição da coluna de tweets para texto, além de outras etapas de padronização, utilizando-se recursos de SMOTE Upsampling para balanceamento da base e assim inicio a etapa “*Process Document*” para tokenização e pré processamento.




Figura 4. Etapas de pré-processamento (do Autor).

A etapa de “*Process documents from Data*” ou pré processamento, contém as etapas apresentadas na Figura 5, que são: *Tokenize*, Transformar em maiúsculas, *Replace Tokens*, *Filter Tokens*, *Stop Words* e *N Gramns*. A etapa *Tokenize* converte em sequência de tokens os tweets, após isso alguns tratamentos são aplicados, como converter em maiúsculos, filtrar tokens por comprimento entre 3 e 25 caracteres, filtrar lista de palavras indesejadas (*stopwords*) e gerar sequências de no máximo 3 *n-grams* além do recurso de *stem*.




Figura 5. Etapas de *Process documents from Data* (do Autor).

Como terceira etapa, foi aplicado o método de *cross validation* e o algoritmo *Naive Bayes* para aprendizado e aplicação do modelo e assim geração das medidas de performance, conforme demonstrado na Figura 6.

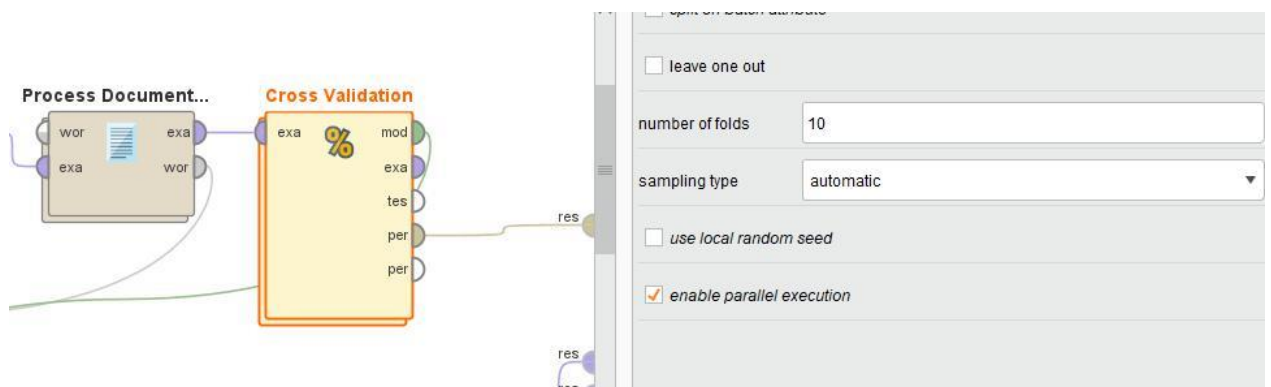


Figura 6. Aplicação do método e algoritmo (do Autor).

Por fim, o modelo treinado é aplicado na base de testes, assim conectamos os *tweets* de teste ainda não classificados, transformando os dados em padrão “*documents*”, ou seja, num formato que possa ser *tokenizado*, realizamos os mesmos procedimentos de pré processamento citados acima (padronização de *emojicons*, *tokenização* e pré-processamento) e aplicamos o modelo treinado.

E por fim, após a execução do algoritmo, são aplicados os tópicos LDA nas categorias que foram preditas, conforme Figura 7, sendo que os tópicos LDA são separados de acordo com as predições (P-Positivo, N-Negativo e NE-Neutro).

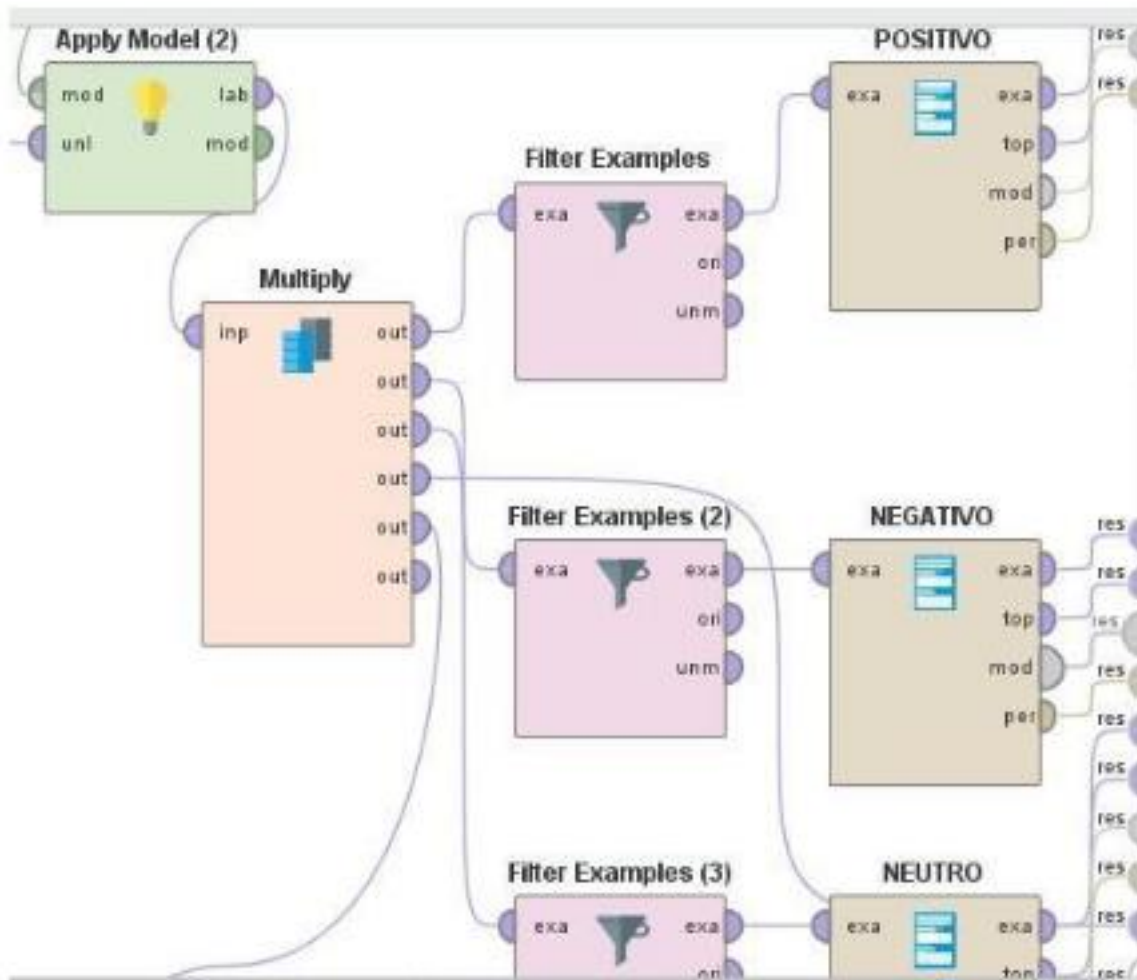


Figura 7. Aplicação dos tópicos LDA nas categorias que foram preditas (do Autor).

## 6. Discussão

Após desenvolvimento do estudo de caso, temos as seguintes medidas de acurácia e erro apresentadas nas Figuras 8 e 9, respectivamente. E por fim, na Figura 9, a apresentação final das predições e demonstração visual das mesmas, e LDA's feitas através do software Power BI.

Com isso, os resultados são especialmente relevantes no apoio do ensino da geografia, podendo auxiliar professores na tomada de decisão quanto ao entendimento que os alunos estão tendo do tema, ou então no preparo de revisões e maior abordagem de determinados tópicos, utilizando para isso a nuvem de palavras, por exemplo.

Quanto a análise dos sentimentos, a pesquisa nos leva a entender o grande conflito de sentimentos que os estudantes tem sobre o tema, pois 43% deles demonstraram uma abordagem negativa sobre o tópico, em geral associada com outras disciplinas conforme a nuvem de palavras gerada. Enquanto aproximados 50% mostraram uma abordagem positiva, tendo cerca de 6% de comentários considerados netros. Essa avaliação, em conjunto com a nuvem de palavras considera que os sentimentos acerca da disciplina são mais positivos que negativos, visto que uma das



palavras com maior peso, logo mais digitadas pelos alunos, é “AMOROSOEMOJI”, ou seja, a conversão de texto do emoticon positivo.

Finalmente, a acurácia demonstra que mais de 80% dos resultados tiveram uma classificação correta, sendo necessário avaliar girias e termos fora do dicionário que poderiam ampliar esses resultados.

accuracy: 84.86% +/- 1.77% (micro average: 84.86%)

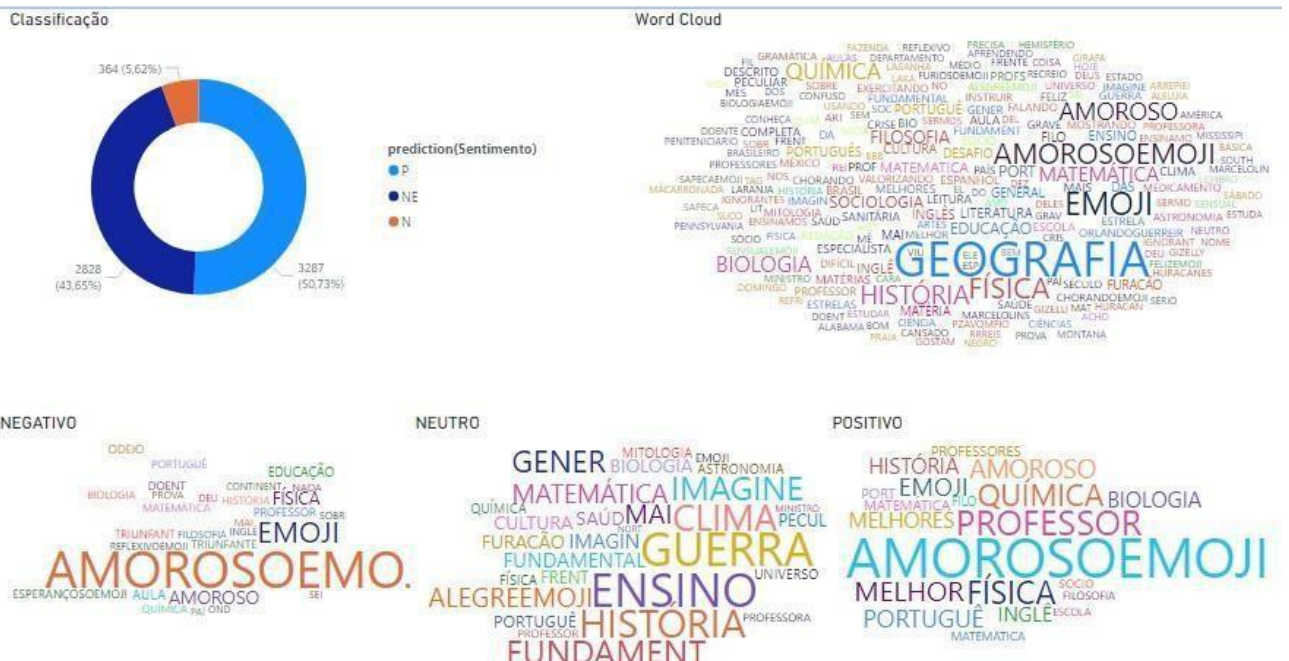
	true NE	true N	true P	class precision
pred. NE	669	138	89	74.67%
pred. N	91	1063	58	87.71%
pred. P	61	73	1127	89.37%
class recall	81.49%	83.44%	88.46%	

Figura 8. Medida de acurácia (do Autor).

classification\_error: 15.14% +/- 1.77% (micro average: 15.14%)

	true NE	true N	true P	class precision
pred. NE	669	138	89	74.67%
pred. N	91	1063	58	87.71%
pred. P	61	73	1127	89.37%
class recall	81.49%	83.44%	88.46%	

Figura 9. Medida de classificação incorreta (do Autor).





## Figura 10. Predições e LDA's geradas através do programa Power BI (do Autor).

### 7. Conclusão

As redes sociais são ambientes onde as pessoas costumam se sentir mais livres, pois trata-se de um ambiente não supervisionado, o que pode dar as pessoas a liberdade de escreverem abertamente sobre qualquer assunto. Juntamente a isso temos uma possibilidade de coleta e análise de informações diretamente dos usuários, através da API disponibilizada pelo Twitter, por exemplo.

Temos então que, após o estudo e aplicação do algoritmo com os dados coletados e sua apresentação, podemos concluir que de forma geral o termo “Geografia” aparece com sentimento positivo em 50,7% dos dados. Já nos tópicos, ele se relaciona com outras matérias tais como Química, Biologia, e a relação do Professor ao termo.

De forma a obter respostas concretas sobre a auto eficácia do termo “Geografia”, estudos futuros são necessários, onde precisamos de uma maior quantidade de dados, possibilitando assim um melhor treinamento do modelo, sendo para isso necessário a obtenção de uma API paga que possibilite a aquisição de uma quantidade maior de dados, bem como em um intervalo de tempo maior, visto que a gratuita possui limitações quanto a quantidade e intervalo a serem obtidos.

Também se faz necessário avaliar formas de pré processamento de “correntes” tais como “qual foi seu melhor professor do ensino médio”, pois isso descaracteriza a pesquisa, poluindo a base, além de conter respostas não tão interpretativas, caracterizando o sentimento como “NE-neutro” e impactando assim o aprendizado do algoritmo e conforme podemos ver, um médio desempenho na acurácia neste item de predição. Outra análise a melhorar é o entendimento de *emoticons* pelo sistema, visto que novos vão surgindo no dia-a-dia, bem como a avaliação de novos algoritmos de análise de sentimentos que realizem aprendizado e predição para variáveis polinomiais, garantindo assim uma acurácia mais precisa e principalmente estudar formas de tratar as gírias, dialetos e sarcasmos ou ironias através de um dicionário de dados ou outro recurso / tecnologia, pois como podemos ver, *emoticons* considerados “bons” aparecem na categoria LDA negativo, indicando que foi usado pelo usuário de forma irônica ou em caráter de sarcasmo.

### 8. Referências

Atkinson, John; Salas, Gonzalo; Figueroa, Alejandro. Improving opinion retrieval in social mediaby combining featuresbased coreferencing and memorybased learning. *Information Sciences*, v.299, p. 2031, 2015.

Belhumeur, P. N., Hespanha, J. P., and Kriegman, D. J. (1997). Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7):711-720.

Burns, A. Eltham, B. (2009). Twitter free iran: an evaluation of twitter’s role in public diplomacy and

information operations in iran's 2009 election crisis. Communications Policy Research Forum – University of Technology, Sydney.

Comms, T. (2014). <https://twitter.com/twittercomms>. Acesso em 02/10/2020.

De Campos, Teo. Discriminantes Lineares (LDA). Disponível em <<http://www.vision.ime.usp.br/~teo/publications/dissertacao/node36.html>>. Acessado em 06 dezembro de 2020. 2001.

Go, Alec Bhayani, R. . H. L. (2009). Twitter sentiment classification using distant supervision. CS224N Project Report, Stanford.

Kimmons, R. and Veletsianos, G. (2016). Education scholars' evolving uses of twitter as a conference bachellet and social commentary platform. *British Journal of Educational Technology*, 47(3):445–464.

Klinczak, Marjori. (2016). Identificação e Propagação de Temas em Redes Sociais, Dissertação de Mestrado apresentado a UTFPR.

Pang, Bo; Lee, Lillian. Opinion Mining and Sentiment Analysis. Foundations and Trends Information Retrieval. Vol 2, p. 1135, 2008.

Tan, P.-N., Steinbach, M., and Kumar, V. (2009). Introduction to data mining – mineração de dados. Editora Ciência Moderna Ltda. Rio de Janeiro.X

Ang, K. L. M., Ge, F. L., & Seng, K. P. (2020). Big Educational Data Analytics: Survey, Architecture and Challenges. *IEEE Access*, 8, 116392–116414. <https://doi.org/10.1109/ACCESS.2020.2994561>

Araujo, G. D. (2014). Análise de sentimento de mensagens do Twitter em português brasileiro relacionadas a temas de saúde. <http://repositorio.unifesp.br/handle/11600/41280>

Araújo, M., Gonçalves, P., & Benevenuto, F. (2013). Métodos para Análise de Sentimentos no Twitter. Artigo, 1–8.

Barrón Estrada, M. L., Zatarain Cabada, R., Oramas Bustillos, R., & Graff, M. (2020). Opinion mining and emotion recognition applied to learning environments. *Expert Systems with Applications*, 150. <https://doi.org/10.1016/j.eswa.2020.113265>

Ferreira, A., & Santoso, A. (2008). Do students' perceptions matter? A study of the effect of students' percept...: EBSCOhost. *Accounting and Finance*, 48(May 2007), 209–231. <http://web.b.ebscohost.com.ezproxy.rollins.edu:2048/ehost/pdfviewer/pdfviewer?vid=1&sid=05dc37c7-ee52-401d-9f88-8d2e74628f45%40sessionmgr104..>

Gomes, Pedro C. T. Classificação com Naive Bayes. Disponível em <<https://www.datageeks.com.br/naive-bayes/>>. Acessado em 06 de dezembro de 2020. 2019.

Hilmi Sahin, S. (2014). ÜNİVERSİTEPARK Bülten @ Volume 4 @ Issue 1-2 @ 2015 @ Comparison of Geography Self-Efficacy Levels of Students Taking Geography Course. ÜNİVERSİTEPARK Bülten, 3(1– 2), 19–27.

JMelo, T. De. (2020). User Questions from Tweets on COVID-19 : An. 1–7.

Meneses, P. P. M., & Abbad, G. da S. (2010). Construção e validação de um instrumento para avaliar auto-eficácia em situações de treinamento, desenvolvimento e educação de pessoas. *Psicologia: Reflexão e Crítica*, 23(1), 121–130. <https://doi.org/10.1590/S0102-79722010000100015>

Mite-Baidal, K., Delgado-Vera, C., Solís-Avilés, E., Espinoza, A. H., Ortiz-Zambrano, J., & Varela- Tapia, E. (2018). Sentiment analysis in education domain: A systematic literature review. *Communications in Computer and Information Science*, 883, 285–297. [https://doi.org/10.1007/978-3-030-00940-3\\_21](https://doi.org/10.1007/978-3-030-00940-3_21)

Moreno, Á. C. (2015). Análise de Sentimentos na Classificação de Comentários Online Aplicando Técnicas de Text Mining.

Rodrigues, L. C., & Barrera, S. D. (2007). Auto-eficácia e desempenho escolar em alunos do Ensino Fundamental Self-efficacy and school achievement in students of elementary school Luciana Cantarino Rodrigues \* Sylvia Domingos Barrera \*\*. 1(02), 41–53.

Sharma, S. K., Daga, M., & Gemini, B. (2020). Twitter Sentiment Analysis for Brand Reputation of Smart Phone Companies in India. *Lecture Notes in Electrical Engineering*, 605, 841–852. [https://doi.org/10.1007/978-3-030-30577-2\\_75](https://doi.org/10.1007/978-3-030-30577-2_75)

Silva da Silva, R., Loh, S., & Orientador, -. (2016). Sistema Para Identificação De Sentimentos Em Textos Na Web. 2012, 1–20. <http://www.intext.com.br/tcc-rafael-silva.pdf>

Tziortzis, S. (2013). Sentiment Analysis by Emoticons and Unsupervised Comment Summarization in Greek e-Government data. November 2013. [http://www.icsd.aegean.gr/website\\_files/diplomatikes/undergraduate/24458408.pdf](http://www.icsd.aegean.gr/website_files/diplomatikes/undergraduate/24458408.pdf)

Ang, K. L. M., Ge, F. L., & Seng, K. P. (2020). Big Educational Data Analytics: Survey, Architecture and Challenges. *IEEE Access*, 8, 116392–116414. <https://doi.org/10.1109/ACCESS.2020.2994561>

Araújo, G. D. (2014). Análise de sentimento de mensagens do Twitter em português brasileiro relacionadas a temas de saúde. <http://repositorio.unifesp.br/handle/11600/41280>

Araújo, M., Gonçalves, P., & Benevenuto, F. (2013). Métodos para Análise de Sentimentos no Twitter. *Artigo*, 1–8.

Barrón Estrada, M. L., Zatarain Cabada, R., Oramas Bustillos, R., & Graff, M. (2020). Opinion mining and emotion recognition applied to learning environments. *Expert Systems with Applications*, 150. <https://doi.org/10.1016/j.eswa.2020.113265>

Ferreira, A., & Santoso, A. (2008). Do students' perceptions matter? A study of the effect of students' percept...: EBSCOhost. *Accounting and Finance*, 48(May 2007), 209–231. <http://web.b.ebscohost.com.ezproxy.rollins.edu:2048/ehost/pdfviewer/pdfviewer?vid=1&sid=05dc37c7-ee52-401d-9f88-8d2e74628f45%40sessionmgr104>.

Figueiredo, Elaine B & Catini, Rita de Cássia & Mendes, Leonardo Manoel. *Mineração de Textos: Análise de Sentimento em Redes Sociais-Revisão Sistemática*. *Anais do WCF*, Vol 5, pp 24-29, 2018, ISSN 2447-4703, XIV WCF 24-25 set 2018. [http://www.cc.faccamp.br/anaisowcf/edicoes\\_anteriores/wcf2018/arquivos/04/paper\\_04.pdf](http://www.cc.faccamp.br/anaisowcf/edicoes_anteriores/wcf2018/arquivos/04/paper_04.pdf).

Meneses, P. P. M., & Abbad, G. da S. (2010). Construção e validação de um instrumento para avaliar auto-eficácia em situações de treinamento, desenvolvimento e educação de pessoas. *Psicologia: Reflexão e Crítica*, 23(1), 121–130. <https://doi.org/10.1590/S0102-79722010000100015>

Mite-Baidal, K., Delgado-Vera, C., Solís-Avilés, E., Espinoza, A. H., Ortiz-Zambrano, J., & Varela-Tapia, E. (2018). Sentiment analysis in education domain: A systematic literature review. *Communications in Computer and Information Science*, 883, 285–297. [https://doi.org/10.1007/978-3-030-00940-3\\_21](https://doi.org/10.1007/978-3-030-00940-3_21)

Moreno, Á. C. (2015). Análise de Sentimentos na Classificação de Comentários Online Aplicando Técnicas de Text Mining.

Ravi, Kumar & Ravi, Vadlamani. A survey on opinion mining and sentiment analysis: tasks, approaches and applications. *Knowledge-Based Systems*, v. 89, p. 14-46, 2015.

Rodrigues, L. C., & Barrera, S. D. (2007). Auto-eficácia e desempenho escolar em alunos do Ensino

Fundamental Self-efficacy and school achievement in students of elementary school Luciana Cantarino Rodrigues \* Sylvia Domingos Barrera \*\*. 1(02), 41–53.

Shain, Suleyman I. Comparison of Geography Self-Efficacy Levels of Students Taking Geography Course. Üniversitepark Bülten, 3(1-2), 19-27. 2014.

Sharma, S. K., Daga, M., & Gemini, B. (2020). Twitter Sentiment Analysis for Brand Reputation of Smart Phone Companies in India. Lecture Notes in Electrical Engineering, 605, 841–852. [https://doi.org/10.1007/978-3-030-30577-2\\_75](https://doi.org/10.1007/978-3-030-30577-2_75)

Silva da Silva, R., Loh, S., & Orientador, -. (2016). Sistema Para Identificação De Sentimentos Em Textos Na Web. 2012, 1–20. <http://www.intext.com.br/tcc-rafael-silva.pdf>

Tziortzis, S. (2013). Sentiment Analysis by Emoticons and Unsupervised Comment Summarization in Greek e-Government data. November 2013. [http://www.icsd.aegean.gr/website\\_files/diplomatikes/undergraduate/24458408.pdf](http://www.icsd.aegean.gr/website_files/diplomatikes/undergraduate/24458408.pdf)