

# Um Estudo sobre a Percepção do Ensino Remoto Emergencial em Institutos Federais baseado em Mineração de Opinião

Mateus F. L. Souza<sup>1</sup>, Cristiane N. Targa<sup>1</sup>, Carlos A. Silva<sup>1</sup>

<sup>1</sup>Departamento de Informática – Instituto Federal de Minas Gerais (IFMG)  
CEP – 34590-390 – Sabará – MG – Brasil

mateusfilipe557@gmail.com, {cristiane.targa, carlos.silva}@ifmg.edu.br

**Abstract.** *Emergency Remote Teaching, the ERE, is a pedagogical strategy adopted by educational institutions around the world to reduce the impacts caused by Covid-19. In this period the use of social networks intensified, becoming one of the main sources of information, entertainment and outbursts. This research presents a study on the perception and feeling of the academic community of federal institutes in the period comprising the ERE from 2020 to 2021, using opinion mining techniques. We built a database collected from Twitter and applied the Multinomial Naive Bayes method to categorize feelings. It can be seen that in the period from June to August 2020 the community had a positive feeling.*

**Resumo.** *O ensino remoto emergencial (ERE) foi uma estratégia didática e pedagógica adotada por instituições educacionais do mundo inteiro para diminuir os impactos provocados pela Covid-19. Neste período o uso das redes sociais se intensificaram. Este trabalho apresenta um estudo sobre a percepção e os sentimentos da comunidade acadêmica de Institutos Federais no período compreendendo o ERE de 2020 à 2021, utilizando técnicas de mineração de opinião. Construímos uma base de dados coletada a partir do Twitter e aplicamos o método Multinomial Naive Bayes para categorizar os sentimentos. Os resultados mostram uma certa estabilização dos sentimentos da comunidade a partir de fevereiro de 2021.*

## 1. Introdução

A pandemia do coronavírus, causada pelo vírus SARS-CoV-2, impactou toda a sociedade mundial, a partir de 2020. Diversos setores da sociedade foram afetados, tendo suas atividades reduzidas ou paralisadas, parcialmente ou totalmente. O setor educacional foi um dos mais atingidos neste período. Cerca de 1,6 bilhão de alunos de mais de 190 países ficaram longe das salas de aula em 2020, e no Brasil, dos 56 milhões de alunos matriculados na educação básica e superior, cerca de 20 milhões de alunos tiveram as aulas suspensas [Oliveira and Silva 2022]. Os Institutos Federais de Educação, Ciência e Tecnologia, tiveram suas aulas presenciais suspensas a partir de março de 2020 [Castilho and da Silva 2020].

Para amenizar os prejuízos escolares causados pelo novo coronavírus, o Ministério da Educação (MEC) autorizou a substituição de disciplinas presenciais por aulas que utilizassem meios e tecnologias de informação e comunicação em cursos que estavam

em andamento (PORTARIA N° 343, DE 17 DE MARÇO DE 2020<sup>1</sup>). De acordo com [Oliveira and Silva 2022], aproximadamente 32 milhões de alunos no Brasil passaram a ter aulas remotas. Como alternativa à paralisação das atividades presenciais de ensino, diversas instituições de ensino, entre elas os Institutos Federais, adotaram o Ensino Remoto Emergencial (ERE) como mecanismo de manutenção das atividades pedagógicas. Por este modelo, pressupunha o uso de tecnologias para a realização das atividades do ensino remoto.

As redes sociais já faziam parte da vida das pessoas e, neste momento de quarentena, tornaram-se espaços ainda mais importantes de relacionamento e comunicação. Houve um crescimento considerável do uso das redes sociais, sobretudo buscando um meio de interação para suprir o contato físico e pessoal. Segundo o Sindicato Nacional das Empresas de Telefonia e de Serviço Móvel Celular e Pessoal<sup>2</sup>, o tráfego da internet durante a pandemia aumentou 30%, com *home office*, aulas *online*, entretenimento e redes sociais. Diante deste contexto, propomos um estudo sobre a percepção e os sentimentos da comunidade acadêmica dos Institutos Federais por meio da rede social *Twitter*, a fim de identificar e classificar as opiniões da seara acadêmica durante o período do ERE de 2020 à 2021.

Para o desenvolvimento deste trabalho utilizou-se como base de dados *tweets* relacionados ao ERE, distribuídos em intervalos de tempo que categorizaram expectativas anteriores, durante e posteriores a esta estratégia de ensino adotada. Fez-se o uso de bibliotecas de código aberto para mineração de opiniões e do método Multinomial Naive Bayes, a fim de construir um procedimento que classificaria os sentimentos da comunidade em cada intervalo de tempo proposto. A análise de dados referentes aos resultados obtidos não busca identificar soluções psicológicas, mas promover uma reflexão dos impactos do ERE nos Institutos Federais, servindo como uma pré-análise deste momento significativo para o cenário educacional da Rede Federal de Ensino Profissional e Tecnológico do Brasil.

O artigo está organizado da seguinte forma. Na seção 1 foi realizada uma introdução ao problema de pesquisa, sua relevância e a proposta de solução adotada. A fundamentação teórica e revisão bibliográfica é apresentada na seção 2. A metodologia empregada, bem como a descrição detalhada dos passos do desenvolvimento é descrita na seção 3. Na seção 4 são discutidos os resultados alcançados, e por fim, na seção 5 é apresentada a conclusão do trabalho.

## 2. Fundamentação Teórica

A popularização das redes sociais como *Twitter*, *Facebook* e *LinkedIn* proporcionou ao usuário uma nova maneira de expressar sua opinião. A análise de sentimento textual é um processo computacional que identifica e categoriza uma opinião em um texto que expressa uma atitude positiva, negativa ou neutra de um usuário para um determinado produto, evento ou personalidade [Alam and Yao 2019]. Podendo ser extremamente útil em diversas situações, mas não tão simples de ser aplicada, principalmente em virtude da complexidade envolvida na linguagem humana. Os humanos podem interpretar facilmente declarações, entretanto pode ser difícil para a máquina entender.

---

<sup>1</sup><https://www.in.gov.br/en/web/dou/-/portaria-n-343-de-17-de-marco-de-2020-248564376>

<sup>2</sup><https://www.sinditelebrasil.org.br/>

Diversos termos são comumente utilizados no contexto de análise de sentimentos. Um deles é a polaridade, definida por [Benevenuto et al. 2015] como o grau de positividade ou negatividade de um texto, não necessariamente sendo uma binariedade, podendo ser tratado com uma ternariedade entre, positivo, negativo e neutro. A força do sentimento também pode ser levada em consideração durante a análise, podendo ser medida entre  $-\infty$  e  $+\infty$ , definindo assim o quão forte é o sentimento naquele dado.

O pré-processamento de texto se trata da primeira etapa em relação à análise de sentimentos a partir de dados coletados no *Twitter*. Conforme [Haddi et al. 2013], tal etapa consiste na limpeza de ruídos presentes nos dados coletados, removendo assim do HTML, *tags*, *scripts* e anúncios. Além disso, nem todas as palavras presentes no texto coletado são importantes, muitas vezes se tratam de caracteres especiais, símbolos ou palavras sem relação com o propósito da análise. A remoção desses ruídos simplifica a definição do sentimento, fazendo com que o algoritmo aplicado aja diretamente no texto sem perder tempo de execução ou evitando códigos desnecessários.

Com o dado pré-processado é necessário sua simplificação. A abordagem de [Bakliwal et al. 2012] em sua mineração de *tweets*, trata de reduzir ao máximo os dados, porém de forma mais específica, sem a remoção generalizada de ruído como no pré-processamento. Em sua pesquisa, o *Stemming*, que é a redução de palavras flexionadas ou derivadas para uma versão mais simples, vem antes da remoção de *Stopwords*, que são palavras irrelevantes para o resultado final da frase, como por exemplo “a”, “o”, “e”.

O trabalho de [Moraes et al. 2015] aplica uma técnica semelhante à presente pesquisa, realizando a coleta dos dados por meio da API *Twitter4J*. Com um período de tempo especificado entre 30 de maio a 13 de julho de 2014, buscou-se coletar os *tweets* relacionados ao jogo de futebol da seleção brasileira contra a seleção alemã. Os textos foram classificados em três polaridades, negativo, neutro e positivo, porém, realizados de forma manual.

[Rodrigues et al. 2013] aborda de forma ampla em sua pesquisa a classificação dos *tweets*, passados por um filtro de expressões da língua portuguesa, buscando demonstrações textuais explícitas de sentimentos. Adicionalmente os autores utilizaram tratamento de localização e condição climática, para um entendimento de como tais variáveis afetam os sentimentos dos dados.

### 3. Metodologia

Para o desenvolvimento deste trabalho foi utilizada a linguagem de programação Python, versão 3.6. Inicialmente é feita a coleta dos *tweets* e em seguida o pré-processamento das informações. Para a categorização dos *tweets* é utilizado um método de aprendizagem de máquina, e posteriormente realizada a análise dos dados. As etapas do desenvolvimento são ilustradas na Figura 1.

Para alcançar o propósito das etapas mencionadas na Figura 1, descrevemos a seguir os procedimentos referentes à obtenção e classificação da base de dados, bem como o tratamento da informação nesta fase, além da base de treinamento para a categorização dos *tweets* identificando os sentimentos expressos pelas opiniões da comunidade dos Institutos Federais.



**Figura 1. Fluxograma do processo algorítmico em relação aos dados.**  
**Fonte: Autores.**

### 3.1. Base de Dados

O intervalo de tempo considerado para a análise de sentimentos durante o ERE, abrangeu o período de junho de 2020 à outubro de 2021. Foram realizadas cinco coletas de dados caracterizadas conforme a Tabela 1. Os períodos foram estabelecidos de acordo com documentos oficiais do MEC, mais especificamente a Portaria nº 343 de 2020, e o Parecer CNE/CP 19/2020<sup>3</sup>, aprovado no dia 6 de outubro de 2020, onde foi alterada a Medida Provisória 934, que estabeleceu as normas para o ano letivo nos níveis da Educação Básica e da Educação Superior.

**Tabela 1. Caracterização das coletas de dados.**

Coleta	Intervalo	Significado
1 <sup>a</sup>	junho à agosto de 2020	Expectativa para o ERE
2 <sup>a</sup>	setembro à novembro de 2020	1 <sup>a</sup> avaliação do ERE
3 <sup>a</sup>	fevereiro à abril de 2021	2 <sup>a</sup> avaliação do ERE
4 <sup>a</sup>	maio à julho de 2021	1 <sup>a</sup> Expectativa para o retorno ao presencial
5 <sup>a</sup>	agosto à outubro de 2021	2 <sup>a</sup> expectativa para o retorno ao presencial

As cinco coletas referem-se a distintos períodos temporais, os quais foram definidos com o intuito de compreender o comportamento e a diferença dos dados em relação a cada momento do ERE. A primeira coleta busca identificar a polaridade do sentimento em relação a expectativa do início do ensino remoto. Na segunda coleta, já com o ERE em andamento, tem-se o primeiro *feedback* efetivo sobre esta estratégia de ensino. No período de fevereiro à abril de 2021 foi considerada a ocorrência da segunda avaliação em relação ao ensino remoto, buscando verificar se após um período efetivo do ERE manteriam-se as mesmas polaridades. A quarta coleta representa temporalmente a expectativa em relação à volta do ensino presencial, ainda em um cenário de incerteza sobre a possibilidade de retorno tendo em vista a situação da pandemia. A quinta coleta busca identificar a polaridade do sentimento, a partir da proximidade ao retorno presencial. Mediante os diferentes períodos propostos buscamos compreender a dinâmica dos sentimentos dos alunos, professores e demais envolvidos no ensino remoto.

Para a coleta dos *tweets* utilizou a biblioteca aberta *SNScrape* que realiza a raspagem dos dados, por meio de filtros de palavras sem a preocupação de *case sensitive*. Nesta coleta foram especificados filtros que atingissem diversas possibilidades de conteúdo em relação aos Institutos Federais, como: “IFMG, IF, IF Ensino Remoto, IF Sabará”. A base de dados é tratada, ou seja, ocorre um pré-processamento do texto, conforme descrito na

<sup>3</sup><http://portal.mec.gov.br/docman/dezembro-2020-pdf/167131-pcp019-20/file>

seção 2. Nessa etapa são removidos acentuações, *links*, caracteres especiais, e *emoticons* que poderiam causar dualidades nos resultados da categorização e análise dos *tweets*.

### 3.2. Base de Treino

Após a coleta e limpeza de dados, inicia-se o processo de treinamento e teste do modelo para categorizar os sentimentos das expressões (dados) coletadas. Considerando um aprendizado supervisionado, foram utilizados 8.199 *tweets*<sup>4</sup> para construir um dicionário a ser utilizado no *corpus*. A base de dados utilizada foi disponibilizada por “Minerando Dados”<sup>5</sup>, e conta com milhares de *tweets* relacionados à educação e a política do Estado de Minas Gerais no ano de 2017. No processo de classificação de dados por aprendizagem de máquina, mediante o uso de modelos estatísticos é usual dividirmos nossa amostra em dados de treinamento e de teste, a fim de evitar o sobreajuste (*overfitting*), ou seja, o modelo se ajusta ao conjunto de dados, mas se mostra ineficaz em prever novos resultados.

Os dados de treinamento são utilizados para determinar os parâmetros do modelo e em seguida comparamos as predições do modelo para os dados de teste com os dados que realmente observamos, e usamos esta comparação para aferir sobre a precisão (acurácia) do nosso modelo. É necessário definir a quantidade de dados que será utilizada para o treinamento e a quantidade que será utilizada para ser testada. Análises empíricas indicam que os melhores resultados são obtidos se alocarmos 30-20% dos dados originais para teste e o restante, ou seja, 70-80% para o treinamento [Gholamy et al. 2018].

## 4. Análise dos Resultados

Com os dados tratados a partir das coletas realizadas e após o treinamento do modelo para a classificação dos *tweets*, fez-se a categorização dos sentimentos de acordo com as coletas e seus respectivos períodos de tempo no contexto do ERE. Por ser uma mudança brusca de rotina e um cenário social e educacional totalmente novo, era esperado que as opiniões iniciais, ou seja, referentes à **primeira coleta**, fossem classificadas como negativas, porém, a Figura 2 mostra um recebimento favorável em relação à nova metodologia de ensino. Podem ter influenciado esse resultado, o fato de ser o início da pausa do ensino presencial e a expectativa sobre o planejamento funcional do ensino.

Inserido de fato no ERE, a **segunda coleta** gera uma nova possibilidade para a análise, abrindo espaço para o *feedback* do modelo em vigor. Dados do IBGE<sup>6</sup> apontam um detalhe importante em relação aos alunos que foram abrangidos nos *tweets* coletados. Cerca de 49% das secretarias municipais de educação indicaram dificuldade dos estudantes em acessar a internet e a partir disso, é possível perceber uma menor interação dos alunos nas redes sociais. Apesar deste fato, percebe-se, a partir da Figura 2 a prevalência dos *tweets* “positivos” em relação aos “negativos”. Nota-se o aumento dos sentimentos “neutros” (+120%) e “negativos” ( $\approx +70\%$ ) e o declínio dos sentimentos “positivos” ( $\approx -44\%$ ).

Uma questão associada à **terceira coleta** é verificar se o início do ERE poderia ter causado uma impressão diferente da que viria a ser a opinião verdadeira da comunidade,

<sup>4</sup>[https://github.com/stacktecnologias/stack-repo/blob/master/Tweets\\_Mg.csv](https://github.com/stacktecnologias/stack-repo/blob/master/Tweets_Mg.csv)


<sup>5</sup><https://web.archive.org/web/20211229192424/https://minerandodados.com.br/>

<sup>6</sup><https://undime.org.br/noticia/14-04-2021-13-19-segundo-ibge-43-milhoes-de-estudantes-brasileiros-entraram-na-pandemia-sem-acesso-a-internet>

após um maior tempo em atividade do ensino remoto. Com a dominância da neutralidade na terceira coleta é possível perceber o início de um padrão de comportamento em relação às polaridades. Nota-se a partir da Figura 2 a diminuição da positividade, o aumento da negatividade e uma dominância da polaridade neutra. Tal fato pode ter sido influenciado pela grande quantidade de notícias informativas em relação aos Institutos Federais, dado a evolução sobre os protocolos de saúde e as normas de ensino.

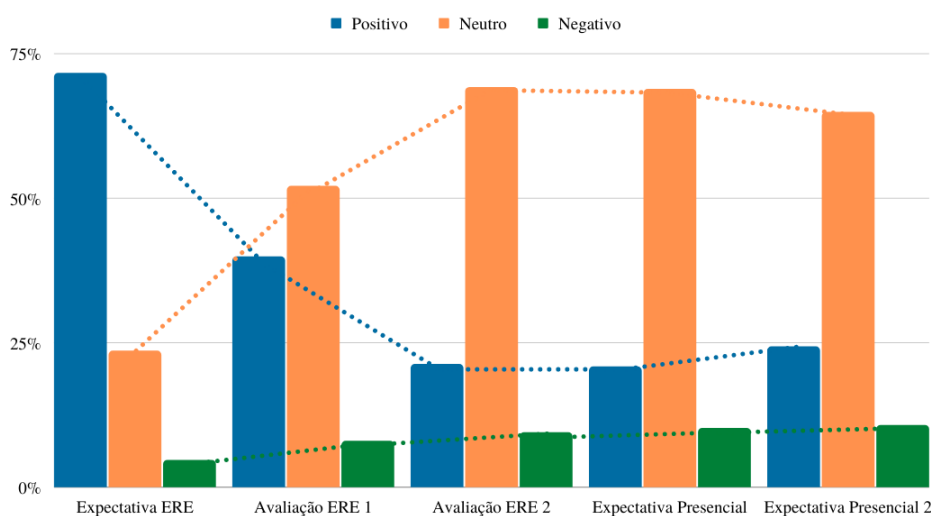
A **quarta coleta** visava captar o sentimento a respeito da expectativa de volta às aulas presenciais. Percebe-se, conforme a Figura 2 a ocorrência do padrão mencionado anteriormente. As diferenças percentuais da terceira para a quarta coleta são  $-0,42\%$  (“positivo”),  $+0,76\%$  (“negativo”) e  $-0,34\%$  (“neutro”).

Na última coleta, ou seja, a **quinta coleta**, o sentimento de positividade aumenta aproximadamente  $16,5\%$  enquanto os sentimentos “neutro” e “negativo” tiveram queda, de acordo com os dados do quinto gráfico da Figura 2.



**Figura 2. Gráficos de polaridades de todas as coletas.**  
**Fonte: Autores.**

A Figura 3 exibe o comportamento dos sentimentos a partir dos dados coletados nos cinco períodos de análise em torno do ERE. Verifica-se que os sentimentos “positivo” e “neutro” apresentaram maior variação, e com tendências opostas, ou seja, enquanto houve um crescimento do sentimento de neutralidade ao longo do período avaliado, constatou-se um declínio do sentimento de positividade. Nota-se que em termos absolutos, o sentimento de positividade vindo das redes sociais foi maior do que os demais sentimentos de junho de 2020 à setembro do mesmo ano, correspondendo ao período de expectativa ao ERE. No restante do período avaliado a neutralidade prevaleceu e a partir da segunda avaliação do ERE (fevereiro a abril de 2021) os sentimentos apresentaram pouca variação, com um “leve” crescimento do sentimento de positividade a partir do segundo semestre civil de 2021.



**Figura 3. Evolução das coletas.**

A fim de validar o modelo utilizado e garantir maior veracidade de sua assertividade calculamos as principais métricas para a classificação de dados, conforme apresentado na Tabela 2.

**Tabela 2. Métricas do modelo.**

	Negativo	Neutro	Positivo
Acurácia	97%	97%	100%
Precisão	90%	95%	100%
Sensibilidade	90%	95%	100%
F1-score	90%	95%	100%

Na determinação das polaridades nota-se que o sentimento “positivo” foi bem classificado em todas as métricas. Para os demais sentimentos, o menor patamar de classificação, considerando os dados treinados, foi de 95% para a polaridade neutra e 90% para a polaridade negativa. Vale ressaltar que na acurácia, ou seja, dentre todas as classificações verdadeiras que o modelo fez, todas positivas estavam corretas, sentimentos neutros e negativos atingiram 97%. As porcentagens métricas encontradas apresentaram-se muito próximas ou exatas em 100%, ocorrido advindo de um possível *overfitting*, uma vez que os dados utilizados no treino e nos testes faziam parte de um contexto específico e correlacionado. Uma possível solução para a melhora do modelo seria o aumento da variedade de *tweets* da base de treino.

## 5. Conclusão

Neste trabalho propomos identificar a percepção e sentimento da comunidade relacionada aos Institutos Federais durante a vigência do ensino remoto emergencial. Os dados coletados via *Twitter* foram tratados e submetidos a um modelo de treinamento utilizando aprendizagem de máquina supervisionada para classificar as opiniões coletadas como “positiva”, “negativa” ou “neutra”.

As maiores variações de sentimentos foram percebidas pelas polaridades “positiva” e “neutra”, sendo que o sentimento “positivo” apresentou um declínio até o início da segunda avaliação do ERE (fevereiro a abril de 2021) e o sentimento “neutro” uma ascensão no mesmo período. O sentimento “negativo” apresentou crescimento mais expressivo na transição da expectativa para o ERE para sua primeira avaliação.

A análise de sentimentos por meio de rede social configura uma expressiva temática de pesquisa, com diversas possibilidades de coleta e uma variedade de sentimentos a serem utilizados. O modelo de análise apresentado nesta investigação, pode ser aprimorado a ponto de interpretar com maior precisão os dados coletados, por meio de cruzamento de bases ou com a identificação de contexto para o momento da análise.

Esperamos que estes resultados sirvam como base para uma pré-análise do sentimento gerado pelo ERE no contexto do ensino dos Institutos Federais, e que possamos aproveitar o conhecimento gerado para eventuais desafios desta grandeza no futuro.

## Referências

- Alam, S. and Yao, N. (2019). The impact of preprocessing steps on the accuracy of machine learning algorithms in sentiment analysis. *Computational and Mathematical Organization Theory*, 25(3):319–335.
- Bakliwal, A., Arora, P., Madhappan, S., Kapre, N., Singh, M., and Varma, V. (2012). Mining sentiments from tweets. In *WASSA@ ACL*, pages 11–18.
- Benevenuto, F., Ribeiro, F., and Araújo, M. (2015). Métodos para análise de sentimentos em mídias sociais. *Sociedade Brasileira de Computação*.
- Castilho, M. L. and da Silva, C. N. N. (2020). A covid-19 e a educação profissional e tecnológica: um panorama das ações de acompanhamento e enfrentamento da pandemia nos institutos federais. *Revista Nova Paideia-Revista Interdisciplinar em Educação e Pesquisa*, 2(3):18–34.
- Gholamy, A., Kreinovich, V., and Kosheleva, O. (2018). Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation. Technical report, University of Texas at El Paso.
- Haddi, E., Liu, X., and Shi, Y. (2013). The role of text pre-processing in sentiment analysis. *Procedia computer science*, 17:26–32.
- Moraes, S. M., Manssour, I. H., and Silveira, M. S. (2015). 7x1pt: um corpus extraído do twitter para análise de sentimentos em língua portuguesa. In *Anais do X Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana*, pages 21–25. SBC.
- Oliveira, E. A. M. and Silva, C. A. (2022). *Ensino Remoto Emergencial (ERE): múltiplas visões e vivências no ensino técnico e tecnológico em tempos de pandemia*, volume 1, chapter Os desafios da gestão pedagógica na vigência do Ensino Remoto Emergencial em 2020, pages 37–51. Editora Fi, Porto Alegre, 1 edition.
- Rodrigues, A. O., de Melo-Minardi, R. C., and Junior, W. M. (2013). Como nos sentimos: Uma ferramenta de mineração visual de sentimentos no twitter. In *Anais do II Brazilian Workshop on Social Network Analysis and Mining*, pages 91–102. SBC.