

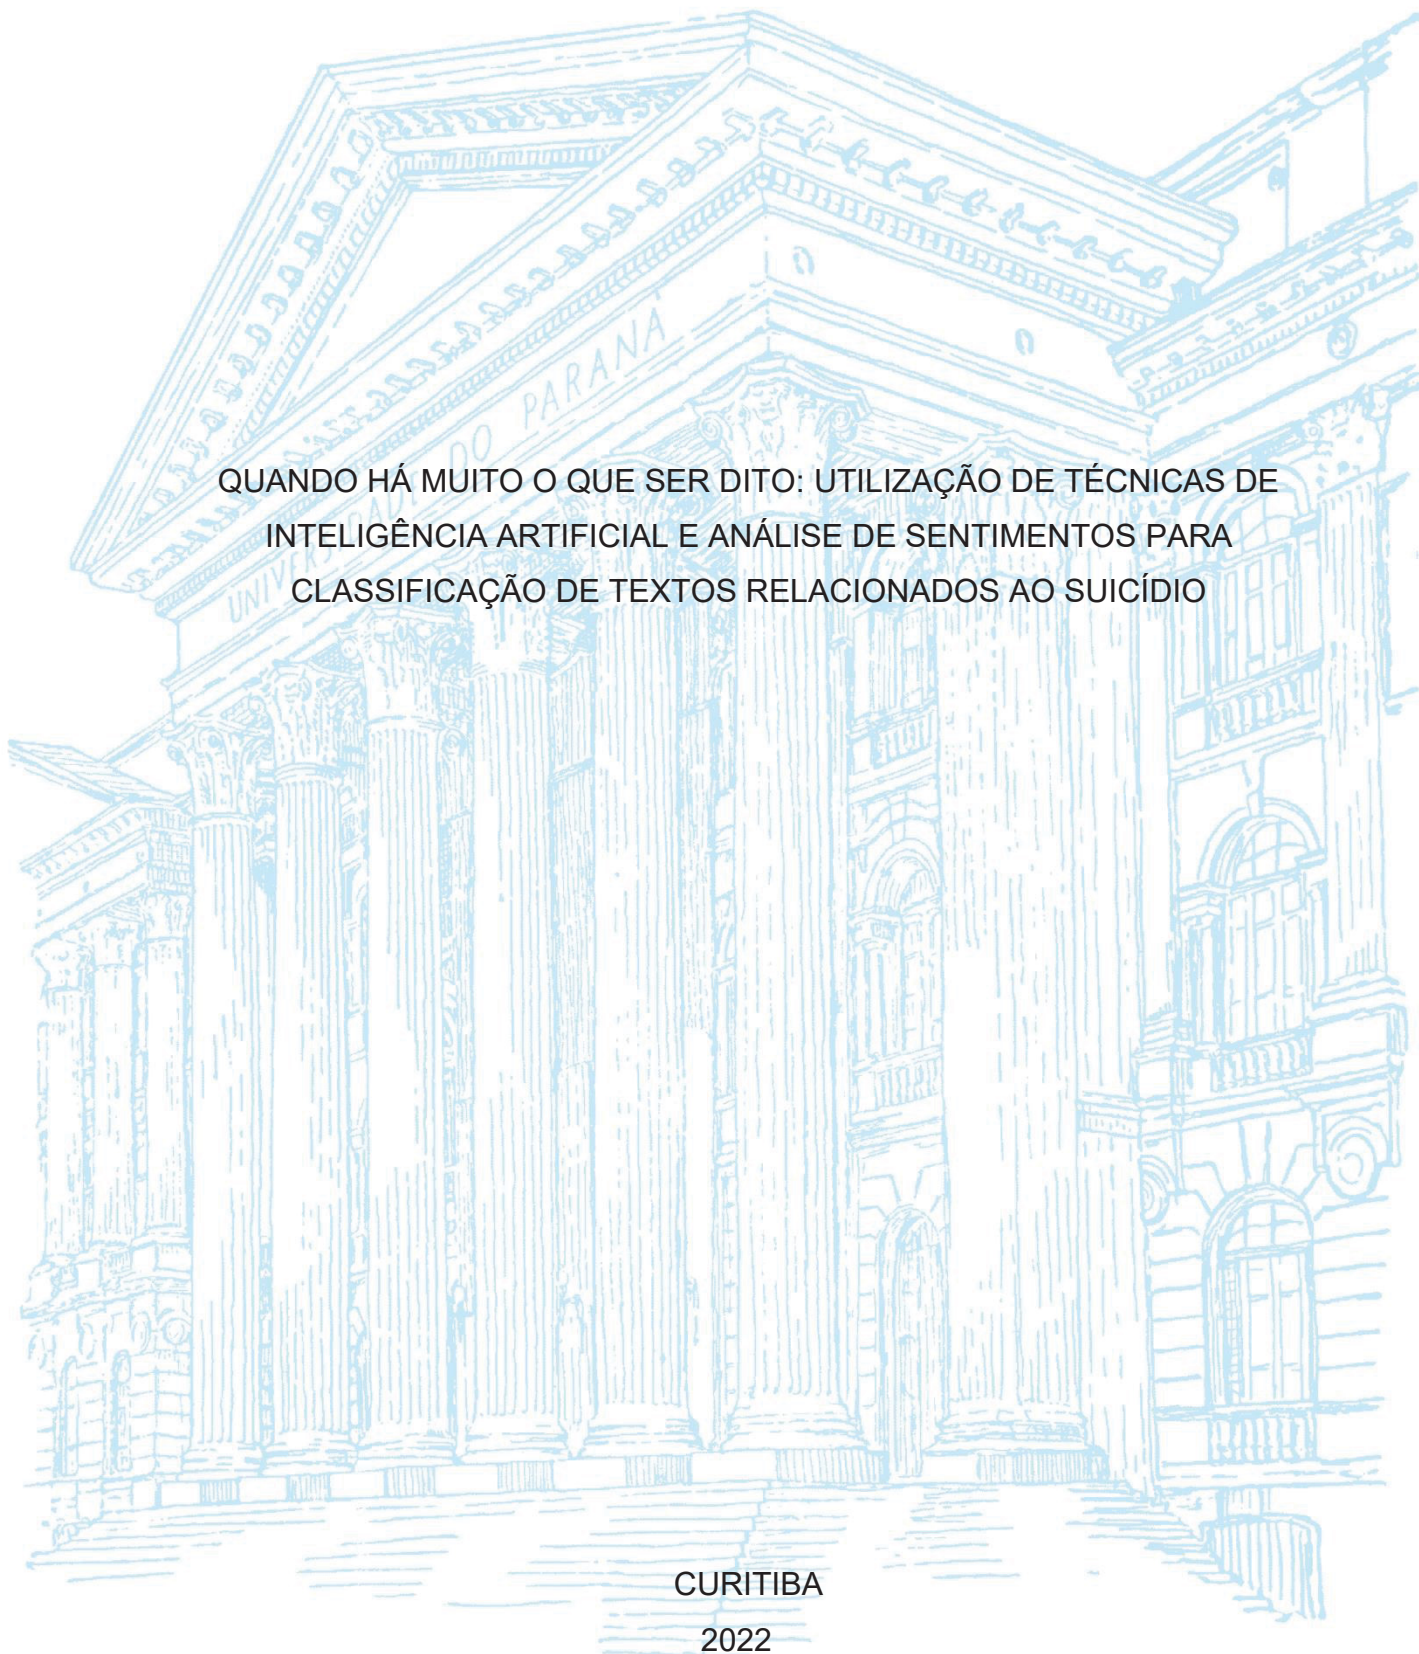
UNIVERSIDADE FEDERAL DO PARANÁ

GILBERTO RODRIGO RADECKI

QUANDO HÁ MUITO O QUE SER DITO: UTILIZAÇÃO DE TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL E ANÁLISE DE SENTIMENTOS PARA  
CLASSIFICAÇÃO DE TEXTOS RELACIONADOS AO SUICÍDIO

CURITIBA

2022



GILBERTO RODRIGO RADECKI

QUANDO HÁ MUITO O QUE SER DITO: UTILIZAÇÃO DE TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL E ANÁLISE DE SENTIMENTOS PARA  
CLASSIFICAÇÃO DE TEXTOS RELACIONADOS AO SUICÍDIO.

Trabalho de conclusão de curso apresentado ao curso de Especialização em Inteligência Artificial Aplicada, Setor de Educação Profissional e Tecnológica (SEPT), Universidade Federal do Paraná, como requisito parcial à obtenção do título de Especialista em Inteligência Artificial.

Orientador: Prof. Dr. Razer A. N. R. Montaña

CURITIBA

2022



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
CURSO DE PÓS-GRADUAÇÃO INTELIGÊNCIA ARTIFICIAL  
APLICADA - 40001016348E1


## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação INTELIGÊNCIA ARTIFICIAL APLICADA da Universidade Federal do Paraná foram convocados para realizar a arguição da Monografia de Especialização de **GILBERTO RODRIGO RADECKI** intitulada: **Quando Há Muito O Que Ser Dito: Utilização De Técnicas De Inteligência Artificial E Análise De Sentimentos Para Classificação De Textos Relacionados Ao Suicídio**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de especialista está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 27 de Outubro de 2022.

  
RAZER ANTHOMNIZER ROJAS MONTAÑO  
Presidente da Banca Examinadora

  
ALEXANDER ROBERT KUTZKE  
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

# Utilização de técnicas de inteligência artificial e análise de sentimentos para classificação de textos relacionados ao suicídio

Gilberto Rodrigo Radecki  
Especialização em Inteligência Artificial Aplicada  
Universidade Federal do Paraná  
Curitiba, Brasil  
gilberto.radecki@ufpr.br

Razer Anthon Nizer Rojas Montano  
Especialização em Inteligência Artificial Aplicada  
Universidade Federal do Paraná  
Curitiba, Brasil  
razer@ufpr.br

**Resumo**—Segundo dados da Organização Mundial da Saúde, anualmente, mais de 700 mil pessoas morrem por suicídio no mundo. Nesse contexto, buscou-se no presente artigo utilizar-se das técnicas de inteligência artificial e aprendizado de máquina para classificação de textos da internet cujo conteúdo possa estar relacionado à ideação suicida, alcançando-se ao final do processo 94% de acurácia com a utilização de uma rede neural artificial e 96% de sensibilidade com a aplicação de um algoritmo probabilístico. Além disso, a análise estatística combinada com análise de sentimentos revelou diferenças entre os grupos estudados.

**Palavras-chave**—*inteligência artificial, análise de sentimentos, mineração de textos, aprendizado de máquina.*

**Abstract:** According to data from the World Health Organization, annually, more than 700,000 people die by suicide in the world. In this context, the present article sought to use artificial intelligence and machine learning techniques to classify internet texts whose content may be related to suicidal ideation, reaching at the end of the process 94% of accuracy with the use of an artificial neural network and 96% of sensibility by using a probabilistic algorithm. In addition, statistical analysis combined with sentiment analysis revealed differences between the groups studied.

**Keywords**—*artificial intelligence, sentiment analysis, text mining.*

## I. INTRODUÇÃO

Segundo dados da Organização Mundial da Saúde, anualmente, cerca de 700 mil pessoas morrem por suicídio no mundo [1]. Estima-se que 1 milhão de pessoas tiraram a própria vida no ano de 2000 e que a cada 40 segundos uma pessoa comete suicídio no planeta [2]. O suicídio é a segunda principal causa de morte entre jovens entre 15 e 29 anos e cada suicídio tem impacto em pelo menos outras seis pessoas [1].

Mundialmente, houve decréscimo de 18% nas taxas mundiais de suicídio entre 2000 e 2016. Há correlação entre essa queda e a implementação de políticas públicas em muitos países. Na contramão está o Brasil, onde verificou-se aumento de 26,5% na taxa de suicídios no mesmo período [3].

Estudos indicam que pessoas com ideação suicida dão sinais verbais ou não verbais de suas intenções para amigos, familiares ou médicos e que a menção ao suicídio pode significar um pedido de ajuda, ainda que em alguns casos possa existir um viés manipulativo [4]. Perceber esses sinais precocemente é de suma importância para prevenir desfechos trágicos na vida dessas pessoas.

A palavra crise vem do grego *krisis* - separação. Uma crise circunstancial se origina de acontecimentos raros e extraordinários sob os quais o indivíduo não tem controle. Uma crise pode levar ao colapso existencial, acarretando vivências de angústia, desamparo e falta de perspectiva. Se ela ultrapassar a capacidade pessoal de reação pode aumentar a vulnerabilidade do indivíduo para o suicídio [4].

O ato suicida é apenas o evento final de uma longa e complexa cadeia de fatores. Não convém atribuir a causa do suicídio à um único fator, pois o que se apresenta aos olhos do observador como motivador é apenas o desencadeador da ação, o elo final de uma longa corrente [3].

A definição de comportamento suicida engloba toda ação através da qual o indivíduo causa lesão a si mesmo, independentemente do grau de letalidade. A abrangência dessa definição permite conceber o comportamento suicida ao longo de um *continuum*: a partir de pensamentos de autodestruição, ameaças, gestos, tentativas de suicídio e por fim, o suicídio [4].

A temática do suicídio está aberta a diferentes perspectivas e a várias ciências [4].

Desta forma, este trabalho tem como objetivo aplicar técnicas de processamento de linguagem natural e diferentes

algoritmos de aprendizagem supervisionada para classificar textos em dois grupos: relacionados a suicídio e não relacionados a suicídio.

### A. Motivações

Conforme mencionado anteriormente, muitos suicidas manifestam de alguma maneira seus desejos de autodestruição. Muitas vezes através de palavras deixadas em cartas, bilhetes ou mensagens.

Palavras que denotam totalidade são frequentemente chamadas de "absolutas". O pensamento absolutista está relacionado a muitas distorções cognitivas e possui robusta ligação empírica com três grupos de saúde mental: ideação suicida, transtorno de personalidade limítrofe e transtorno alimentar [5].

A internet é um veículo através do qual as pessoas encontram meios para manifestar suas opiniões e emoções. Nesse contexto, é relevante considerá-la um dos principais canais para veiculação de intenções suicidas.

A análise de sentimentos, também chamada *opinion mining*, é um campo de estudo que analisa as opiniões, sentimentos e emoções das pessoas acerca de determinado assunto [6]. Os estudos nesse campo viabilizaram a análise e descoberta de informações e de padrões em grandes conjuntos de mensagens.

Os estágios iniciais da depressão podem ser identificados nos textos escritos por pessoas com a doença, pois estudos indicam que essas pessoas fazem uso, com maior frequência, de um determinado grupo de palavras, chamado de "gramática da depressão" [7].

A gramática da depressão é um conjunto de palavras comuns em postagens de usuários com a doença nas redes sociais. Elas são fruto de um estudo dos departamentos de psicologia da University of Reading, na Inglaterra, e da Florida State University, dos EUA [7].

Três características em particular são próprias do estado das mentes suicidas [1]:

- **Ambivalência:** O desejo de morrer compete, como que em uma gangorra, com o desejo de viver;
- **Impulsividade:** O suicídio é um ato impulsivo e transitório, que pode durar alguns minutos ou algumas horas. O impulso é usualmente desencadeado por eventos negativos do dia a dia;
- **Rigidez:** Os pensamentos e sentimentos de pessoas suicidas são rígidos, no sentido de que elas pensam constantemente sobre suicídio e não tentam encontrar outras perspectivas.

### B. Objetivos

O objetivo desse artigo é apresentar uma comparação entre os resultados obtidos por diferentes algoritmos supervisionados de inteligência artificial e aprendizado de máquina na classificação de textos.

A seção II aborda conceitos acerca da análise de sentimentos, análise textual e técnicas utilizadas ao longo do processo desse tipo de análise. Nessa seção também são apresentadas as métricas utilizadas para avaliação dos resultados.

A seção III discorre acerca dos dados: a forma como foram obtidos e como estão organizados. Nessa seção são

apresentados os processos utilizados para modelagem e análise dos dados e sobre os recursos de *hardware* e *software* empregados.

Na seção IV os resultados das análises são apresentados e comentados, e por fim, a seção V traz as considerações finais acerca do trabalho desenvolvido.

## II. FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os principais conceitos utilizados ao longo desse trabalho.

### A. Estatística Descritiva e Inferencial e Lexicometria

Ao conjunto de técnicas para organização, coleção, análise e interpretação de dados dá-se o nome de estatística [47]. Esses dados podem ser expressos por valores numéricos (quantitativos) ou por características (qualitativos). A estatística é utilizada em vários setores para auxiliar na tomada de decisão mediante a compreensão da variação e a identificação de padrões nos dados [47].

A estatística descritiva usa técnicas para sumarizar e descrever dados numéricos viabilizando sua interpretação, seja através de gráficos ou de análise computacional [47].

A estatística descritiva utiliza determinadas medidas de posição para descrever os dados, como a média aritmética, média ponderada, mediana, moda, amplitude interquartilica e medidas de dispersão, como amplitude, diagramas esquemáticos (*box plots*) desvio médio, variância e desvio padrão, coeficiente de variação, coeficiente de assimetria de Pearson [48].

A média aritmética é calculada mediante a soma dos valores em um grupo de dados dividida pelo número de valores [47]:

$$\mu = \frac{\sum x}{N}$$

A variância é uma medida de dispersão calculada a partir da diferença entre cada valor em um conjunto de dados e a média desse grupo [47]:

$$v(x) = \sigma^2 = \frac{\sum (x - \mu)^2}{N}$$

A partir das medidas de posição e das medidas de dispersão, testes de hipótese podem ser conduzidos para determinar se um valor hipotético para um determinado parâmetro (como a média de uma população) deve ser aceito como plausível [47].

Algumas abordagens para testes de hipóteses são [47]:

- Abordagem do valor crítico;
- Abordagem do valor de  $p$ ; e
- Abordagem do intervalo de confiança.

Recentemente, a abordagem pelo valor de  $p$  tem se popularizado em função da sua facilidade de aplicação a programas de computador [47].

Em testes de hipóteses, uma hipótese nula e uma hipótese alternativa devem ser formuladas [47]. A hipótese nula ( $H_0$ ) é o valor hipotético do parâmetro a ser comparado com o tamanho da amostra. Ela é rejeitada se e somente se o resultado amostral for improvável de ocorrer, dado que a

hipótese seja considerada correta. A hipótese alternativa ( $H_1$  ou  $H_a$ ) é aceita somente se a hipótese nula for rejeitada [47].

A distribuição  $t$  é uma base apropriada para um teste estatístico padronizado quando se observa que os dados da amostra obedecem a uma distribuição normal [47].

A distribuição de probabilidade normal é uma distribuição de probabilidade contínua cuja curva de probabilidade é descrita como em forma de sino, ou seja, é mais provável que um valor hipotético de um parâmetro esteja próximo da média daquele parâmetro:




Figura 01: Exemplo de gráfico com dados normalmente distribuídos. Fonte: Elaborado pelo autor.

Já o teste de classificação sinalizada de Wilcoxon pode ser uma alternativa ao teste  $t$  quando os dados não podem ser considerados normalmente distribuídos [47].

A lexicometria é um procedimento metodológico, tecnológico, indutivo, descritivo, objetivo e científico para analisar estatisticamente dados qualitativos sob a ótica quantitativa de elementos lexicais de um *corpus* textual [48].

A análise lexicográfica permite a detecção de dependências entre os dados, detecção de desvios, análise de estruturas textuais com características comuns e descoberta de padrões e modelos para descrever os objetos e conceitos envolvidos [48].

A lexicometria envolve diversos métodos estatísticos, como por exemplo distribuições de frequência e medidas de posição para análise de dados textuais. Uma metodologia adequada à sua utilização pode ser constituída do processo de limpeza dos dados (pré-processamento) e predição, regressão, classificação, agrupamento, associações e visualizações (processamento).

Entre os métodos de classificação de textos é a classificação pelo método de Reinert, que produz *clusters* (agrupamentos) a partir da proximidade entre os termos presentes no texto e em seguida classifica os termos estatisticamente significativos [46].

### B. Análise de sentimentos

A análise da satisfação do cliente ou leitura de críticas a objetos específicos é de grande valor para a tomada de decisão, seja uma decisão estratégica pessoal ou organizacional, como determinar o segmento de mercado que deve receber o maior investimento naquele período [8].

Informações como essas podem ser obtidas de diversas maneiras, como por meio de formulários, telefonemas e entrevistas. Entretanto, esses métodos podem ser muito onerosos, inviabilizando dessa forma sua aplicação.

Diversas fontes textuais contendo opiniões e sentimentos surgiram ao longo dos últimos anos graças à popularização da internet e das mídias sociais. Essa alta disponibilidade de

dados contribuiu para o desenvolvimento da *Análise de Sentimentos*, ou *Mineração de Opinião*.

O processamento de linguagem natural, que está relacionado com a análise de sentimentos, é um estudo multidisciplinar, linguístico e computacional. [40]

A análise de sentimentos consiste na aplicação de técnicas computacionais para extrair e identificar sentimentos e opiniões em textos [9]. Ela ainda pode ser entendida como um tipo de mineração de dados que possibilita identificar o sentimento que as pessoas apresentam acerca de alguma entidade de interesse [10], ou ainda como o estudo de opiniões, sentimentos e emoções expressas em textos [11]. É considerada um importante campo de estudo para a Computação Afetiva e para a compreensão dos processos cognitivos em geral [12].

A ciência linguística estuda a semântica e a relação das estruturas da linguagem. Através do conhecimento dessa estrutura é possível identificar padrões. O estudo desses padrões é abordado na área de processamento de linguagem natural (NLP), que por meio de métodos estatísticos e análise de sintaxe possibilita a desambiguação no sentido da palavra, categoria, estrutura sintática e no escopo da semântica [13].

Segundo Cambria et al. [9] a análise automática de opiniões envolve um profundo entendimento da linguagem natural pelas máquinas.

Os primeiros trabalhos na área de análise de sentimento buscaram classificar a polaridade de uma sentença. Posteriormente, buscou-se distinguir sentenças que indicavam algum sentimento daquelas que não indicavam [14].

### C. Análise Textual

A análise de um *corpus* textual é um tipo de análise de dados na qual os objetos da análise são textos [44]. Diferentes modalidades textuais podem ser analisadas, como entrevistas, documentos e redações [44]. Também pode ser concebida como uma técnica voltada para a predição, descrição e identificação de elementos textuais [46]. É uma técnica predominantemente descritiva em que a subjetividade do pesquisador deve ser minimizada ao máximo [46].

Alguns conceitos importantes sobre análise textual são descritos a seguir [45]:

O conceito de *corpus* textual se refere ao conjunto de textos sobre o qual será feita a análise.

O texto, por sua vez, são as partes que compõem o *corpus* textual. Se o *corpus* é a coleção de, por exemplo, entrevistas, cada entrevista é um texto.

Os segmentos de texto são partições do texto em elementos menores, normalmente compostos por algumas frases.

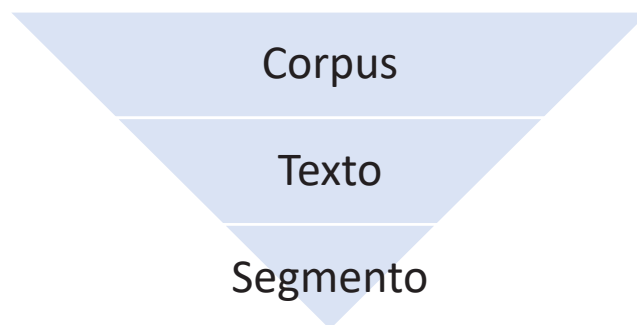


Figura 2. Hierarquia entre corpus, texto e segmento. Fonte: Elaborado pelo autor.

A análise textual pode ser realizada em diferentes níveis de granularidade [6]:

- Análise à nível de documento;
- Análise à nível de sentença;
- Análise à nível de entidade e aspecto/característica.

Quando um texto ou documento na sua totalidade pode expressar sentimentos acerca de uma entidade, o nível de análise que está sendo considerado é a *nível de documento*. Esse método é adequado quando o documento diz respeito a uma única entidade [6].

Por exemplo, analisar se a avaliação de um determinado produto ou serviço, o avaliador expressou sentimentos positivos ou negativos. Por exemplo, na frase “O violão é incrível. A madeira é de qualidade e o acabamento é perfeito” pode-se identificar sentimentos positivos sobre a entidade “violão”.

Quando a análise é feita à nível de sentença, cada frase é analisada de maneira independente. Essa técnica encontra aplicabilidade na separação de sentenças que possuem sentimentos daquelas que não possuem, ou ainda quando há mais de uma entidade envolvida [15].

Por exemplo, na frase “A loja parecia ser incrível. Pena meu tempo ser tão curto”, apesar das duas sentenças apresentarem sentimentos, na primeira, a entidade é “a loja”, e o sentimento é positivo, enquanto a segunda frase é sobre a entidade “tempo”, e o sentimento é negativo.

O nível de menor granularidade em análise de sentimentos é o nível de entidade e aspecto/característica. Essa técnica não considera a estrutura do texto ou documento. Seu objetivo é identificar sentimentos relacionados às entidades e aos seus aspectos [16].

Por exemplo, na frase “A loja parecia ser incrível. Pena meu tempo ser tão curto”, pode-se identificar um sentimento positivo sobre a entidade “loja”, que “parecia ser incrível” e um sentimento negativo relacionado à entidade “tempo”, que “era curto”.

#### D. Polaridade, emoção e sentimento

Diversos métodos são utilizados para mensurar sentimentos. Um dos métodos mais utilizados é a polaridade [17].

A polaridade de um sentimento pode ser classificada em categorias como positiva, neutra e negativa, ou ainda através de uma faixa de pontuação. [15]

Em relação às emoções básicas, diversos autores sugerem diferentes modelos de classificação.

Ekman [18] sugere que são 6:

- Surpresa;
- Alegria;
- Tristeza;
- Raiva;
- Medo; e
- Nojo.

Já Plutchik [19] adiciona outras duas emoções à essa lista:

- Confiança; e
- Expectativa.




Figura 3. Roda de Sentimentos de Plutchik [19].

Outro modelo denominado VAD, define as emoções sobre três aspectos [21]:

- Valência;
- Excitação; e
- Dominância.

A valência pode variar de feliz a infeliz e se refere ao quão agradável é um estímulo. A intensidade da emoção é caracterizada pelo componente ‘excitação’. O poder de um estímulo define a dominância deste, e pode variar de fraco/submisso a forte/dominante.

A pontuação atribuída a cada um desses componentes varia de 0 (baixo) a 10 (alto).

Parrot [20], sugere três níveis de emoções, sendo seis do nível primário:

- Amor;
- Alegria;
- Surpresa;
- Raiva;
- Tristeza; e
- Medo.

O nível secundário é composto por 25 emoções diferentes e o terceiro nível por 91.

A tabela 1 exemplifica a organização dos sentimentos relacionados ao amor em seus três níveis:

Tabela 1: Exemplo dos níveis de sentimento segundo Parrot.

Nível	Emoção			
I	Love			
II	Affection	Lust	Longing	Cheerfulness
III	Adoration, affection, love, fondness, liking, attraction, caring, tenderness, compassion, sentimentality	Arousal, desire, lust, passion, infatuation	Longing	Amusement, bliss, cheerfulness, gaiety, glee, jolliness, joviality, joy, delight, enjoyment, gladness, happiness, jubilation, elation, satisfaction, ecstasy, euphoria

### E. Níveis para análise de sentimento

A linguagem, oral ou escrita, pode ser concebida em diferentes níveis: fonético, sintático, semântico e pragmático [22].

A fonética estuda a fisiologia, os sons da fala e sua produção acústica. Inclui as regras para combinação de fonemas daquela língua e regras acerca do uso de características como tom, acentuação e duração de vogais ou consoantes [23].

A morfologia estuda a estrutura e a formação das palavras. Sua menor unidade é o morfema, que pode ser uma palavra real (morfema livre) ou uma de suas partes, como prefixos e sufixos [23].

A sintaxe está relacionada à estrutura das frases e às regras através das quais as palavras podem ser combinadas. Também está relacionada com a classificação das palavras em categorias lexicais principais ou secundárias, como verbos, adjetivos, substantivos etc [23].

A semântica lida com o significado dos morfemas dentro de uma frase.

Por fim, a pragmática está relacionada ao desempenho ou uso da linguagem, à percepção das regras que a governam em diferentes contextos sociais. Isso inclui o conhecimento do uso adequado da linguagem no sentido de produzir-se a resposta desejada necessária para transmitir uma mensagem.

No contexto da análise de sentimentos, os principais níveis linguísticos utilizados são [16]:

- Morfológico;
- Sintático; e
- Semântico.

A seguir, serão abordadas as principais técnicas utilizadas para o processamento de linguagem natural [16]:

#### 1. Tokenização:

A *tokenização* consiste em separar elementos textuais em componentes individuais através de caracteres separadores, como espaços em branco, quebras de linha etc. Assim é possível listar os *tokens* (componentes individuais) que serão processados para em seguida identificar possíveis sentimentos em um texto.

Por exemplo, no texto “Bom dia, o sistema está apresentando lentidão.” podem ser identificados os *tokens*: [Bom]; [dia]; [o]; [sistema]; [está]; [apresentando]; [lentidão].

Dependendo do método de *tokenização* aplicado, a expressão [Bom dia] pode ser considerada como um *token* único.

A nível morfológico, a remoção de *stop words* é uma estratégia aplicada durante a etapa de pré-processamento de textos. *Stop Words* são palavras ou termos que não agregam valor para a análise de sentimentos, como artigos, numerais etc.

#### 2. Radical, Stemming (Derivação) e Lema:

Ao elemento básico de uma palavra, sua parte indivisível, sem prefixo e sufixo, dá-se o nome de radical. Por exemplo, as palavras “igualdade”, “igualar” e “desigual” possuem o radical “igual”. O radical nem sempre consiste de uma palavra, como em “revisar”, que tem o radical “vis”.

A derivação, é uma técnica computacional cujo objetivo é identificar o radical de uma palavra.

Entre as aplicações de derivação mais utilizadas estão a *Porter's Stemmer*, *Snowball Stemmer* e *Lancaster Stemmer*. As duas primeiras consistem na derivação sistemática de cada palavra ao longo de cinco fases. O método Lancaster tenta reduzir palavras à sua forma mais básica possível, o que pode ocasionar um efeito indesejado chamado *overstem*, que é quando palavras morfológicamente parecidas, mas semanticamente diferentes, apresentem a mesma grafia ao final do processo.

Lema é uma palavra, reduzida a sua forma essencial. Por exemplo: “errar”, “erroneamente” e “errado” derivam do lema “erro”. Lematização, assim com derivação, são técnicas pertencentes ao nível linguístico morfológico.

#### 3. Etiquetagem morfossintática:

Também conhecida como *part of speech*, ou POS, consiste no processo aplicado para identificar a classe gramatical de um termo, baseando-se na sua definição e no contexto no qual está inserido.

Durante o processo de etiquetagem, cada elemento do texto é associado à sua respectiva classe gramatical, levando em consideração o contexto do texto como um todo.

A etiquetagem morfossintática é importante para a Análise de Sentimentos, pois algumas palavras apresentam a mesma grafia, mas são de classes gramaticais diferentes, têm significados diferentes e que também podem apresentar sentimentos diferentes, dependendo do contexto que esse *token* está presente.

As técnicas de *tokenização*, derivação e lematização geralmente são utilizadas em conjunto com a etiquetagem morfossintática [16].

No exemplo “Bom dia, o sistema está apresentando lentidão novamente.”, considerando apenas as principais classes gramaticais o processo de etiquetagem morfossintática resultaria em:

Adjetivos: Bom.

Substantivos: Dia, sistema, lentidão.

Verbos: Está, apresentando.

Advérbio: Novamente.

Essa técnica também pertence ao nível linguístico morfológico.

### F. Processos para análise de sentimentos

O processo de Análise de Sentimentos pode ser dividido em três etapas: Identificação, Classificação e Agregação [24]:

#### 1. Identificação

Essa etapa consiste na separação de conteúdos que apresentam sentimentos sobre um assunto de um texto. As entidades e seus aspectos são identificados nessa fase.

O processo de identificação varia de acordo com o nível de análise textual desejado, que podem ser: Documento, sentença ou entidade/aspecto.

Determinar de forma prévia quais entidades e aspectos são relevantes pode auxiliar nesse processo. Por exemplo: em textos sobre qualidade de cervejas, as fabricantes poderiam ser consideradas como entidades, e seus aspectos poderiam ser tipo, graduação alcoólica, textura etc.

Dessa forma, na frase “A Guinness é uma cerveja do tipo stout, sua textura é encorpada e seu sabor traz notas de café”

poderia ser identificada a entidade “Guinness” e os aspectos “tipo”, “textura” e “sabor”.

Em alguns casos, como em resenhas de produtos, a entidade é apenas uma, e consequentemente o documento como um todo está relacionado a ela. O foco nesses casos é a identificação dos aspectos dessa entidade.

Já em outros casos, como notícias e outros gêneros textuais, várias entidades podem estar relacionadas em um mesmo texto.

A separação de conteúdos que apresentam sentimentos ou opiniões daqueles que não possuem é realizado nessa etapa. É uma forma de facilitar e evitar erros na etapa seguinte, de classificação.

O processo pode ser realizado através do mapeamento de termos que apresentam sentimentos.

Usando o mesmo exemplo anterior, “A Guinness é uma cerveja do tipo *stout*, sua textura é encorpada e seu sabor traz notas de café”, as palavras ‘*stout*’ e ‘encorpada’ poderiam ser pré-definidas como candidatas a possuir sentimentos.

A identificação de entidades, aspectos e sentimentos varia de acordo com o nível linguístico considerado. Por exemplo, no texto “Ontem saí para jantar. O restaurante ao lado minha casa é horrível!”, pode-se identificar que a primeira frase não apresenta sentimentos ou opiniões, enquanto a segunda apresenta uma opinião em relação à entidade “restaurante”. Chega-se a essa conclusão a partir da identificação da palavra “horrível”, mas a classificação do sentimento dependerá da técnica utilizada.

## 2. Classificação

De acordo com Blaz [16], nessa etapa os sentimentos são associados às entidades e aspectos encontrados na etapa anterior.

Ainda segundo o autor, a esses sentimentos são atribuídas as polaridades ou as emoções relacionadas, conforme o modelo de sentimento utilizado. Por exemplo, no texto “A lanchonete tem um ambiente muito agradável, mas o atendimento é demorado e ainda fiquei enjoado”, a etapa de identificação pode mapear a entidade “lanchonete”, os aspectos “ambiente” e “atendimento”. Então, o processo de classificação pode associar sentimentos ou opiniões a essa entidade e aspectos.

Um exemplo de classificação resultante do processo é o seguinte:

- *Agradável*: polaridade positiva e emoção “alegria”;
- *Demorado*: polaridade negativa e emoções “raiva” e “tristeza”;
- *Enjoado*: polaridade negativa e emoções “tristeza” e “nojo”.

Finalmente, a classificação consolida os valores de sentimento encontrados. O resultado irá variar de acordo com o nível textual aplicado [16].

No exemplo mencionado anteriormente, apesar da palavra “agradável” ser positiva, pode-se considerar o texto como um todo negativo, e apresentando as emoções alegria, raiva, tristeza e nojo.

Diferentes técnicas de classificação podem ser utilizadas, independentemente do modelo de sentimentos aplicado. Entre as técnicas mais utilizadas estão a *léxica*, a de

*aprendizado de máquina*, a *semântica* e a *estatística* [16], que são abordados posteriormente.

Essas técnicas se diferenciam na forma como os resultados são processados, e como resultado, determinam quais sentimentos foram localizados no texto e suas respectivas intensidades.

## 3. Agregação

Na última etapa do processo de análise de sentimentos é feita a sumarização dos sentimentos dos textos, consolidando os sentimentos encontrados na etapa de classificação no sentido de determinar o sentimento final acerca da entidade a partir de seus aspectos, se existirem, ou do documento na sua totalidade [16].

Entre as métricas e cálculos envolvidos nessa etapa, muitos métodos para classificação de polaridade consideram faixas de valores contínuos, como por exemplo o intervalo entre -1 e 1, onde -1 representa um sentimento negativo e 1 representa um sentimento positivo [6].

A força do sentimento pode ser quantificada de acordo com a proximidade do valor correspondente a esse sentimento com um dos extremos da faixa de valores estabelecida. Nesse contexto, considerando *tokens* com diferentes valores de polaridade encontrados no texto, a agregação pode considerar a média aritmética entre os valores encontrados para assim determinar a polaridade final [16].

Por exemplo, seja a resenha de um filme: “O filme é cansativo.”, enquanto outro seja “As atuações são péssimas.”. Dessa forma podem ser identificados os *tokens* “cansativo” e “péssimas” como termos com sentimento. Ainda, digamos que na classificação cansativo seja pontuado com a polaridade -0,5 e péssimas com -1,0. Considerando a média aritmética a pontuação final do filme seria igual a -0,75. Ocasionalmente podem ser estabelecidos limites próximos a zero, nos quais o resultado é considerado neutro. Isso ocorre pois os cálculos podem resultar em valores próximos a zero e resultados incorretos podem ocorrer ao considerar que o texto tem alguma polaridade [16].

Considerando os limites -0,01 e 0,01 como neutros e que um texto apresente o *token* “legal” com a polaridade 0,11 e o *token* “chato” com a polaridade -0,09. Ao realizar a média aritmética teremos como resultado 0,005. Ou seja, o sentimento dos dois *tokens* praticamente se anularam. Assim, o resultado pode ser considerado neutro ao invés de positivo.

Para sentimentos discretos, como em alguns modelos de emoções, podem ser verificados quais valores estão presentes ou não para determinar as emoções finais agregadas. Contudo, a quantidade de valores encontrados também pode ser considerada, ou seja, quanto mais vezes a emoção foi encontrada mais forte ela é. No exemplo anterior, digamos que “cansativo” seja classificado como “tristeza” e “péssimas” como “tristeza” e “raiva”. Assim, a agregação pode considerar que as emoções “tristeza” e “raiva” caracterizam as opiniões dos filmes, ou que apesar das duas emoções estarem presentes, “tristeza” é mais forte, pois aparece duas vezes [16].

## G. Técnicas utilizadas para classificação de sentimentos

No contexto da inteligência artificial e aprendizado de máquina, duas abordagens são amplamente utilizadas para o desenvolvimento de soluções para problemas de classificação de dados: o aprendizado supervisionado e o aprendizado não supervisionado [25].

No aprendizado supervisionado as categorias a serem classificadas são previamente conhecidas. Assim, pretende-se realizar a classificação de novos dados a partir da utilização de um conjunto de dados rotulados para treinamento [25].

Na aprendizado não supervisionado as classes não são previamente conhecidas e a classificação ocorre através de métodos de agrupamento e análise de componentes principais [25].

Entre as principais técnicas para análise de sentimentos podem ser citadas as abordagens [15]:

- Léxica;
- Classificação por Aprendizado de Máquina;
- Estatística; e
- Semântica.

A abordagem léxica não é do tipo supervisionada. Essa abordagem faz uso de léxicos (dicionários) onde os termos são atrelados a um rótulo ou a um valor que denote sua intensidade. Assim, para verificar os sentimentos relacionados a determinado termo verifica-se a existência desse termo no dicionário e uma função de agregação calcula a pontuação final para o conjunto de palavras em questão.

A técnica de classificação por aprendizado de máquina é feita sobre um conjunto de dados previamente anotado, e portanto, é uma técnica supervisionada.

Essa técnica visa identificar regras gerais em grandes conjuntos de dados, permitindo que informações não explícitas sejam extraídas automaticamente, compondo dessa forma um modelo de classificação.

Em geral, existe predominância nos estudos de métodos supervisionados [15] e o bom desempenho de sua aplicação está relacionado ao tamanho do *corpus* (conjunto de dados) utilizado.

A abordagem estatística é uma abordagem não supervisionada baseada na proximidade entre os termos. Assim, a polaridade de determinada palavra pode ser calculada a partir da polaridade dos termos próximos a ela. [15].

A abordagem semântica se baseia na hipótese de que palavras semanticamente próximas apresentam os mesmos sentimentos [15].

A seguir, cada uma dessas técnicas é descritas com mais detalhes:

### 1. Abordagem Léxica

Essa técnica de análise não supervisionada (na qual o algoritmo não necessita de uma etapa de treinamento com dados já classificados previamente) faz uso de dicionários (léxicos) para atribuir polaridade aos termos que denotem sentimentos. Os *tokens* podem consistir em palavras ou expressões. Assim, a atribuição de sentimentos relacionados a determinado termo depende da presença daquele termo no dicionário [15].

Para todos os *tokens* encontrados em um texto, uma função consolida suas pontuações para determinar os sentimentos desse texto como um todo. Por exemplo, dentre diversas outras palavras, um dicionário ou léxico de sentimento pode conter as palavras ‘péssimo’, ‘ruim’, ‘ótimo’, ‘rápido’ e ‘muito rápido’: A palavra ‘péssimo’ tem a pontuação -1 como polaridade e as emoções ‘tristeza’ e ‘raiva’. A palavra ‘ruim’ apresenta as mesmas emoções, mas com polaridade -0,5. Já a palavra ‘ótimo’ tem a polaridade 1

e o sentimento ‘alegria’ associado a ela. Os *tokens* ‘rápido’ e ‘muito rápido’ têm as mesmas emoções: ‘alegria’ e ‘surpresa’, mas com polaridades diferentes: 0,25 e 0,50, respectivamente [15].

Normalmente, léxicos são compostos de termos que correspondem aos lemas ou aos radicais das palavras. Por esse motivo técnicas de lematização e derivação devem ser aplicadas durante as fases de identificação e classificação [15].

Alguns léxicos contam ainda com a classe gramatical de cada token, no sentido de melhorar a qualidade do processo desde que a etiquetagem morfosintática seja aplicada nas etapas anteriores.

No dicionário hipotético citado anteriormente como exemplo, todos os tokens, com exceção de ‘muito rápido’ são adjetivos. *Tokens* com mais de uma palavra devem ser tratados especialmente.

### 2. Abordagem por aprendizado de máquina

Essa abordagem busca identificar regras gerais em grandes conjuntos de dados, de modo que as informações implícitas existentes no *dataset* possam ser extraídas de forma automática, compondo, dessa forma, um modelo [15].

Em se tratando de análise de sentimentos, observa-se que há um predomínio de métodos supervisionados, ou seja, que necessitam de dados previamente classificados para treinamento. Há duas etapas nesse método: a de aprendizado e a de aplicação do modelo [15].

Durante a etapa de aprendizado, um modelo de classificação é executado usando um subconjunto de dados para treino. Esses dados são rotulados anteriormente, ou seja, são previamente classificados de acordo com as categorias correspondentes, uma vez que o objetivo é justamente treinar o modelo [15].

Cada dado utilizado para treino consiste em um texto ao qual são atribuídos um atributo denominado alvo e outros, denominados *features*. Em análise de sentimentos, o alvo é a classe à qual aquele texto pertence, ou o sentimento a ele relacionado, conforme o modelo de sentimentos que está sendo considerado. As *features* são os *tokens* que compõem o registro, exportados de textos que apresentam sentimentos [15].

A seleção dos elementos que irão compor as *features* é imprescindível para a correta classificação dos textos. Técnicas de lematização, derivação e etiquetagem morfosintática normalmente são utilizadas. Uma prática comum consiste em restringir a escolha de *features* a adjetivos e advérbios, além de representá-las na forma binária (se aparecem ou não no texto). A presença de palavras que denotam negação também pode ser considerada [15].

Outras estratégias para seleção de *features* envolvem o uso de pesos, a análise de *emoticons*, palavras alongadas (populares em blogs e mídias sociais), repetição de pontuação e expressões compostas por mais de uma palavra [15].

Os dados utilizados para teste consistem em um subconjunto dos dados totais, desde que os mesmos dados não tenham sido utilizados na etapa de treinamento. Uma abordagem amplamente difundida é chamada de *validação cruzada*. Este método estatístico consiste na divisão dos dados em dois segmentos: um usados para treinamento do modelo e outro para validação do modelo [36].

Tipicamente, os conjuntos de validação e teste são cruzados sucessivamente, de forma que cada ponto de dado possa ser validado [36]. Na validação cruzada do tipo *k-fold* [36], os dados são aleatoriamente divididos em *k* partes. Em seguida, *k* etapas de treino/teste são realizadas, e a cada etapa *k-1* segmentos (*s*) são utilizados para treino, deixando o segmento restante para teste [36].

Tabela 2: Processo *k-fold cross-validation* com *k=5*

	s1	s2	s3	s4	s5
Iteração 1	TESTE	TREINO	TREINO	TREINO	TREINO
Iteração 2	TREINO	TESTE	TREINO	TREINO	TREINO
Iteração 3	TREINO	TREINO	TESTE	TREINO	TREINO
Iteração 4	TREINO	TREINO	TREINO	TESTE	TREINO
Iteração 5	TREINO	TREINO	TREINO	TREINO	TESTE

Assim, ao final de cinco rodadas de treino/teste, todos os dados foram utilizados, ora como parte do conjunto de treinamento, ora como conjunto de dados de teste [36].

Alguns exemplos de algoritmos de classificação com aprendizado de máquina são [37]:

- *Support Vector Machine* (ou SVM);
- *Naive Bayes*;
- Árvores de Decisão; e
- Redes neurais.

### 3. Abordagem estatística

A abordagem estatística baseia-se em termos encontrados juntos para detectar sentimentos. Ou seja, os sentimentos que um termo expressa podem ser identificados a partir da co-ocorrência com outros termos, cujos sentimentos são conhecidos.

Por exemplo, se uma palavra que se deseja saber a polaridade está próxima de outra cuja polaridade é sabida e é positiva, provavelmente a palavra em questão também é positiva. Essa abordagem é não supervisionada.

Primeiramente, *tokens* chamados de sementes têm seus sentimentos determinados, muitas vezes, de forma manual. A partir das sementes, processos de expansão podem ser utilizados para identificar os sentimentos de outros *tokens*.

Alguns modelos estatísticos são o *Latent Dirichlet Allocation* (ou LDA) [15], *Semantic-orientation Latent Semantic Analysis* (ou LSA) e *Pointwise Mutual Information* (ou PMI).

Entre as técnicas estatísticas utilizadas para análise textual, podem ser citados o método de Classificação Hierárquica Descendente (método de Reinert), análises lexicográficas, análise fatorial de correspondência (AFC) e análise de similitude. [46].

A classificação hierárquica descendente (CHD), também conhecida como método de Reinert, se baseia na ideia da existência de correlação entre termos de um mesmo segmento texto. A medição da intensidade da presença desses termos viabiliza a identificação de possíveis associações entre termos por proximidade e intensidade [46].

Este método é independente da subjetividade do pesquisador e de categorizações prévias ao texto [46].

O método de Reinert produz *clusters* (agrupamentos) a partir da proximidade entre os termos presentes no texto [46] e em seguida classifica os termos estatisticamente significativos.

Assim, a CHD se constitui de uma abordagem de análise léxica e estatística utilizada para analisar a distribuição de vocábulos em um *corpus* de texto [46].

A análise lexicográfica tem por objetivo identificar os vocábulos e segmentos de texto e em seguida calcular a frequência, média e contagem de *hápax* (palavras que aparecem uma única vez) no texto [46].

A análise fatorial de correspondência consiste na associação de textos com modalidades, possibilitando dessa forma a comparação da produção textual entre essas modalidades [46].

### 4. Análise de similitude

A análise de similitude se baseia na teoria dos grafos e estuda as relações entre objetos de um determinado conjunto. Em termos de análise textual, busca agrupar palavras em conjuntos com base na relação dos elementos desse conjunto. A análise de similitude permite identificar co-ocorrências entre os elementos textuais e indicar a conexidade entre eles [46].

### 5. Análise Semântica

A abordagem semântica é similar à estatística, contudo os cálculos consideram a distância entre o termo que se deseja identificar sentimentos e outros cujos sentimentos são conhecidos. A ideia é que palavras semanticamente próximas apresentam os mesmos sentimentos.

Sementes também são utilizadas como base e a expansão pode ocorrer via busca de sinônimos ou antônimos em várias iterações. Dessa forma, a distância de um *token* até uma semente ou outro *token* que seja um sinônimo ou antônimo, cujos sentimentos são conhecidos, é usada para calcular os sentimentos do *token* em questão.

### H. Aprendizado de Máquina

De acordo com Grus [26] o aprendizado de máquina pode ser definido como a “[...] criação de modelos que são aprendidos a partir dos dados”.

Segundo o autor o objetivo do aprendizado de máquina é prever possíveis saídas para novos dados a partir das características aprendidas durante a fase de treinamento do modelo e podem ser divididos em modelos supervisionados ou não supervisionados.

Consideram-se modelos supervisionados aqueles onde um conjunto de dados previamente etiquetados com a resposta correta para aprendizagem é apresentado ao algoritmo para aprendizagem. Em modelos sem supervisão tais etiquetas não existem [26].

Assim, a partir de um grande conjunto de dados um modelo matemático é utilizado para realizar inferências e classificações. Entre alguns dos algoritmos mais utilizados para tarefas de classificação podem ser citadas as:

#### a. Redes Neurais Artificiais

As redes neurais artificiais ou redes neuronais artificiais (RNA) são modelos baseados na forma como o cérebro

funciona. O neurônio matemático é uma simplificação do neurônio biológico. Seu funcionamento consiste em receber um ou mais sinais de entrada e entregar apenas um sinal de saída, que por sua vez pode ser o sinal de saída da rede ou o sinal de entrada para um ou mais neurônios da camada subsequente.




Figura 4 - Representação de um neurônio matemático onde x representa as entradas, w os pesos sinápticos. Fonte: Elaborado pelo autor.

A *Multi-layer Perceptron* (MLP) é um exemplo de rede neural de várias camadas. Constitui-se de uma rede neural que otimiza uma função de perda usando gradiente descendente[33].

As sinapses são representações matemáticas dos dendritos e axônios presentes nos neurônios biológicos. Cada sinapse possui um peso. Assim, cada sinal de entrada é multiplicado pelas sinapses, gerando uma soma ponderada. O resultado da soma é então imputado em uma função de ativação, cuja finalidade, entre outras, é evitar o crescimento progressivo dos valores das saídas ao longo da rede e determinar a ativação ou não ativação do neurônio correspondente de acordo com o grau de excitação das sinapses por ele recebidas [27].

Logo, quando a soma dos impulsos recebidos por um neurônio ultrapassa o limiar de excitação o neurônio é ativado.

Em redes neurais artificiais, cada neurônio possui um peso correspondente. Quando a rede neural recebe um estímulo na camada de entrada, esse valor é propagado através dos neurônios das camadas ocultas e o resultado é obtido na camada de saída.

Quando o resultado predito é diferente do observado, os pesos dos neurônios das camadas ocultas podem ser ajustados. A esse processo dá-se o nome de *backpropagation*. Esse ajuste é feito repetidas vezes durante a fase de treinamento da rede neural.

Contudo, a melhora na classificação de uma determinada classe pode prejudicar a acurácia da classificação das outras classes a serem preditas.

As funções de ativação têm um importante papel nesse processo, no sentido de minimizar esse efeito indesejado. Elas viabilizam a transformação dos resultados calculados, permitindo que pequenas alterações nos pesos não causem grandes alterações nos resultados. O nome *função de ativação* está relacionado ao conceito de que determinado neurônio somente será ativado caso o resultado calculado atinja um valor determinado ou limiar [27].

Em termos gerais uma função de ativação pode ser concebida a partir da seguinte equação:

$$Y = \text{Activation} \left( \sum (\text{weight} * \text{input}) + \text{bias} \right)$$

Entre os tipos de função de ativação mais populares estão [27]:

- Binária;
- Linear;
- Sigmóide (ou logística);
- Softmax;
- Tangente Hiperbólica;
- ReLU;
- Leaky ReLU;

**Função de ativação Binária:** Esta função se baseia no conceito de limiar. Ou seja, o neurônio será ativado somente se o valor Y estiver acima de um valor determinado:

$$\phi(x) = \begin{cases} 1, & \text{se } x \geq 1 \\ 0, & \text{senão,} \end{cases}$$

**Função de ativação Linear:** A transformação é linear e a derivada é uma constante:

$$f(x) = ax$$

**Função de ativação Sigmóide:** A função de ativação Sigmóide, ou logística, comprime os valores de entrada em um intervalo, por exemplo, [0,1]. Por ser uma função linear, sua saída também não é linear. Em termos gerais, a função busca empurrar os valores de Y para os extremos, sendo muito útil em tarefas de classificação:

$$\text{sigm}(x) = \frac{1}{1 + e^{-x}}$$

**Função de ativação Softmax:** Assim como a função de ativação sigmóide, a função de ativação Softmax é do tipo não linear e muito útil em tarefas de classificação quando o número de classes possíveis é maior do que 2:

$$\text{soft}(z_i) = \frac{e^{z_i}}{\sum e^{z_i}}$$

**Função de ativação Tangente Hiperbólica:** Utilizada em problemas envolvendo classificação, essa função comprime os valores de saída no intervalo (-1,1). É mais vantajosa que a função sigmóide em termos de tempo de processamento. Contudo, assim com na função sigmóide, à medida que os valores de saída aumentam, sua variação é muito pequena. Esse efeito é chamado de *vanishing gradient*. Isso ocasiona a desaceleração do aprendizado do modelo, dada a pequena variação nos pesos:

$$\sigma(z) = \frac{1 - e^{-2z}}{1 + e^{-2z}}$$

**Função de ativação ReLU:** Essa função consiste em preservar valores positivos e transformar valores negativos em zeros. A conversão é rápida mas se a ocorrência de saídas negativas for alta muitos neurônios não serão ativados:

$$g(z) = \begin{cases} 0, & z < 0 \\ z, & z \geq 0 \end{cases}$$

**Função de ativação Leaky ReLU:** Para minimizar os efeitos observados na função de ativação ReLU, ao invés de definir 0 para x menor que 0, um valor pequeno, como 0,01 é

definido como componente linear de  $x$ , removendo assim o gradiente zero:

$$g(z) = \begin{cases} az, & z < 0 \\ z, & z \geq 0 \end{cases}$$

#### b. Algoritmo Probabilístico Naive Bayes

Trata-se de um algoritmo aplicado no aprendizado supervisionado. O objetivo desse classificador é encontrar a probabilidade *a posteriori* da ocorrência de uma classe  $h$  em função do evento  $D$ . O modelo assume que os atributos analisados são independentes entre si. Para determinar se um elemento pertence ou não a uma determinada classe o algoritmo realiza uma análise estatística dos dados coletados conforme a equação a seguir [28]:

$$P(h|D) = \frac{P(D|h)P(h)}{P(D)}$$

Essa equação é conhecida como o Teorema de Bayes estabelece dessa forma que a probabilidade de um elemento pertencer à uma determinada classe depende da presença de um determinado atributo nesse elemento [28].

Embora o algoritmo seja baseado em suposições muito simples, os resultados por ele obtidos e a facilidade observada em sua implementação fazem dele um dos mais populares em tarefas de classificação [28].

#### c. Estimador estocástico de gradiente descendente (SGD)

Este estimador utiliza modelos com aprendizado estocástico de gradiente descendente [33]. O modelo matemático estocástico é um modelo em que suas variáveis correspondem a uma distribuição de probabilidades específica e o gradiente de perda é calculado a partir de cada amostra, atualizando o modelo a partir de uma taxa de aprendizado [33]. O gradiente descendente é um algoritmo iterativo cujo objetivo é encontrar os valores dos parâmetros que reduzem determinada função de interesse [34].

A obtenção desses parâmetros pode ser feita de maneira analítica, seja através da solução por mínimos quadrados ou pelo cálculo de derivadas [34].

Contudo, nem sempre é possível encontrar a solução do sistema de forma fechada, sobretudo quando algumas variáveis são grandes demais [34].

O gradiente descendente pode ser aplicado para minimizar problemas como esse, além de acelerar a convergência de soluções de problemas de segunda ordem.

Em termos gerais, os parâmetros procurados são obtidos a partir da determinação arbitrária de um valor inicial para tais parâmetros (chute inicial) cujos valores são atualizados de acordo com o negativo do gradiente. O ajuste dos valores desses parâmetros é feito a cada iteração e o tamanho do passo é determinado de acordo com uma taxa de aprendizagem [34].

### I. Métricas

As métricas têm por finalidade analisar a qualidade dos modelos de aprendizado de máquina. Em problemas

relacionados a classificação, as métricas obtidas a partir das matrizes de confusão estão entre as mais comuns [26].

Em problemas relacionados a classificação, duas são as soluções possíveis: Acerto ou erro. Nos casos de classificação binária há duas classes a serem classificadas: Classe positiva e a classe negativa [35]. Considerando que o objetivo a ser alcançado é determinar se um determinado texto está relacionado a suicídio, a classe *suicide* será a classe positiva.

Assim, considerando os dois resultados possíveis para classificação e as duas classes a serem classificadas, quatro resultados são possíveis:

- Verdadeiro Positivo (VP): O algoritmo classificou corretamente um texto sobre suicídio como pertencendo a classe *suicide*.
- Falso Positivo (FP): O algoritmo classificou incorretamente um texto que não estava relacionado a suicídio como sendo da classe *suicide*.
- Verdadeiro Negativo (VN): O algoritmo classificou corretamente um texto que não estava relacionado a suicídio como *non-suicide*.
- Falso Negativo (FN): O algoritmo classificou incorretamente um texto relacionado a suicídio como *non-suicide*.

Na tabela 3, os valores  $a$ ,  $b$ ,  $c$  e  $d$  correspondem, respectivamente, aos elementos VP, FN, FP e VN:

Tabela 3: Matriz de Confusão.

Valor Real	Valor Predito	
	Non-suicide	Suicide
Non-suicide	d	c
Suicide	b	a

Os valores reais correspondem àqueles de fato observados na amostra ou na população em estudo, enquanto o valor predito é aquele resultante do processamento realizado computacionalmente.

A partir da matriz de confusão, tem-se cinco conceitos importantes para avaliar a qualidade dos modelos de aprendizado de máquina [26]:

- Acurácia: Indica o percentual de acerto e representa a soma dos elementos classificados corretamente dividida pelo total de elementos:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

- Sensibilidade (Recall ou Revocação): Indica o quão bem o modelo é capaz de classificar itens pertencentes à classe negativa. É a razão entre os elementos Verdadeiros Positivos e a soma dos elementos Falsos Negativos e Verdadeiros Positivos:

$$Sensibilidade = \frac{VP}{VP + FN}$$

- Especificidade: A especificidade avalia a capacidade do modelo em classificar corretamente elementos da classe positiva. É a razão entre os elementos Verdadeiros Negativos e a soma dos

elementos Verdadeiros Negativos e Falsos Positivos:

$$Especificidade = \frac{VN}{FP + VN}$$

- d. Precisão: É calculada a partir da razão entre Verdadeiros Positivos e a soma Verdadeiros Positivos e Falsos Positivos e avalia a assertividade das classificações feitas acerca da classe positiva:

$$Precisão = \frac{VP}{VP + FP}$$

- e. F-Score: É a média ponderada entre a precisão e a sensibilidade e indica a relevância da acurácia do modelo. Quanto maior o F-Score, mais relevante é a acurácia:

$$F - Score = 2 * \frac{Precisão * Sensibilidade}{Precisão + Sensibilidade}$$

Em testes de diagnósticos existe a necessidade de determinar a presença de uma determinada doença em um indivíduo com suspeita e a partir disso indicar o tratamento mais apropriado. Nos casos em que se busca diagnosticar uma doença o teste mais apropriado é aquele onde observa-se alta especificidade, pois tem maior impacto sobre o valor preditivo positivo [39].

Já nos casos em que se busca afastar o diagnóstico de uma condição, considera-se o melhor teste aquele com alta sensibilidade. Portanto, para fins de avaliação dos modelos de aprendizado de máquina apresentados nesse trabalho, essa será a métrica utilizada [39].

#### J. Principais dificuldades na análise de sentimentos

Identificar sentimentos implícitos e separar sentimentos de relatos essencialmente negativos estão entre as principais dificuldades para a análise de sentimentos [15].

Além disso, o uso de ironia, sarcasmo e negação contribuem no sentido de dificultar ainda mais esse tipo de análise [29].

Em textos como ‘o dia está lindo’ as opiniões são explícitas, mas em outros, como ‘risquei o tanque da minha moto’ há sentimentos colocados de forma implícita.

De acordo com Blaz [15], grande parte das ferramentas e técnicas para análise de sentimentos consideram apenas os casos explícitos, aja vista que casos implícitos carecem de uma análise mais complexa.

Outro desafio é separar sentimentos de objetos em um texto de natureza negativa, como em relatos de problemas, necessidades e tragédias. No entanto, eles podem fazer parte da descrição do evento e não expressam necessariamente os sentimentos ou opiniões da pessoa que os escreveu.

Ainda segundo o autor, o uso de ironia inviabiliza o processo de análise à medida que o verdadeiro sentimento expressado é, em termos de polaridade, inverso.

O tratamento da ironia pode ser feito analisando o contexto do texto. Por exemplo, em um texto que diz ‘nossa, que político honesto!’. Se não houver mais dados nesse texto, não será possível definir se o autor está fazendo um elogio ou se está sendo irônico.

Palavras que denotam negação também merecem especial atenção, pois sua presença em um texto inverte ou altera o

sentimento expresso em um texto. Assim, uma coleção de palavras dessa categoria pode ser utilizada ao analisar sentimentos em um texto. Dessa forma, caso uma dessas palavras seja encontrada em um texto, é apropriado presumir que ela nega o termo subsequente, que por sua vez pode apresentar sentimentos.

Expressões utilizadas na língua coloquial também podem tornar a análise de sentimentos mais complexa, como em frases que apresentam dupla negação. Por exemplo, na frase ‘o que você fez não foi nada bonito’ o termo ‘nada’ nega o termo bonito, dando a ele uma conotação negativa. Contudo o termo ‘não’ aparece de forma redundante e em termos de análise proposicional, inverte a polaridade de ‘nada bonito’.

Termos de negação podem ainda atenuar um sentimento sem necessariamente invertê-lo [15]. Por exemplo, o autor da frase ‘o hotel não é maravilhoso’ não está dizendo, necessariamente, que o hotel é ruim. A ideia por trás da frase é que *apesar de* não ser maravilhoso, o hotel pode ser *muito bom*.

A identificação de entidades e aspectos também pode variar de acordo com o contexto ou situações específicas. Em notícias relacionadas ao mundo esportivo, é comum que termos como *tricolor*, *alvo e negro* e *rubro e negro* se refiram a determinados times, mas quais times seriam esses irá depender, por exemplo, da região onde a notícia foi publicada.

Os sentimentos relacionados a determinados termos também variam de acordo com o contexto ao qual se refere. Por exemplo, o termo *processado*, presente em uma notícia ou em um documento jurídico, possui conotação negativa. Já em um texto sobre suporte de TI o mesmo termo pode ter conotação neutra ou ainda positiva.

Casos como esse podem afetar tanto a polaridade quanto a intensidade dos sentimentos, pois quando relacionado à uma pessoa, o termo *processado* tem um impacto muito maior do que quando relacionado a um arquivo digital.

#### K. Ferramentas para análise de sentimentos

No processo de análise sentimentos diversas ferramentas podem ser aplicadas. Entre elas se destacam ferramentas para PLN, classificação e diversos léxicos disponíveis para geração de novas ferramentas [15], como por exemplo *TreeTagger*, *Stanford NLP*, *NLTK* e a *SentiStrength*, que servem para processamento de linguagem natural e análise de sentimentos. A *TreeTagger* é uma ferramenta utilizada durante o processo de lematização e etiquetagem morfosintática. Conta com suporte a diversos idiomas, incluindo o português, disponibilizando, para cada token, o seu lema e a sua classe gramatical [30].

A Stanford NLP é uma ferramenta para processamento de linguagem natural desenvolvida na Universidade de Stanford. Essa ferramenta conta com funções para etiquetagem morfosintática, *tokenização*, entre outras [15].

Para a linguagem Python a biblioteca NLTK disponibiliza diversos recursos para PNL e análise de sentimentos.

Diversas bibliotecas e métodos de classificação por aprendizado de máquina podem ser usados para análise de sentimentos [15].

O Iramuteq é uma interface R para análise multidimensional de textos [41]. Permite analisar estatísticas em *corpus* de texto e é baseado no software R. O software

reproduz métodos de classificação hierárquica, busca por especificidade a partir da segmentação de textos e estatísticas descritivas clássicas [41].

O SentiStrength é uma solução para análise de polaridade que consiste em uma fórmula para atribuição de sentimentos e um léxico próprio. Ela fragmenta o texto em palavras ou sentenças e identifica em cada fragmento termos que denotam sentimentos. Em seguida, um valor é atribuído a cada termo. Esse valor varia de -5 a 0 e de 0 a 5. A pontuação do texto como um todo é calculada a partir disso [15].

Entre os léxicos disponíveis para análise de sentimentos está o WordNet. Esse léxico conta com palavras agrupadas em conjuntos de sinônimos, denominados *synsets*. Novos léxicos podem ser criados ou expandidos através da utilização dessa ferramenta [15].

Uma versão do WordNet, chamada WordNet-Affect, contém domínios e sentimentos relacionados a várias palavras. Através dela é possível identificar substantivos, verbos, adjetivos e advérbios com suas respectivas classificações, que podem variar entre neutro, positivo, negativo ou ambíguo e suas relações com 28 diferentes categorias de emoções [15].

Outro léxico popular é o SentiWordNet. Construído a partir do WordNet essa ferramenta conta com scores de polaridade de palavras e de termos compostos por mais de uma palavra [15].

Quando a polaridade de um determinado termo é pesquisada, a média ponderada entre todas as ocorrências desse termo é calculada, levando em consideração seu peso e a média aritmética entre os valores positivos e negativos [15].

O NRC é um léxico para análise de emoções baseado nas oito emoções básicas de Plutchik. Para cada palavra presente nesse dicionário, há a indicação de quais emoções estão relacionados a ela e também a respectiva polaridade do sentimento [42]. Na data em que este trabalho foi escrito esse léxico era composto de 14.182 termos no idioma inglês, traduzidos mecanicamente para mais de 100 outros idiomas [42].

Este léxico consiste em uma lista de palavras em inglês e suas associações com oito emoções básicas (nojo, alegria, tristeza, surpresa, confiança, antecipação, medo e raiva) e dois sentimentos (positivo e negativo).

A fonte dos unigramas e bigramas que compõem o NRC é o *Macquarie Thesaurus*, associado ao *Macquarie Dictionary*. Outros termos foram coletados também do *General Inquirer* e do *WordNet Affect Lexicon*. Entre os cerca de 57.000 termos comuns da língua inglesa e mais de 40.000 expressões comuns, os criadores do NRC selecionaram os 200 unigramas (palavras) e os 200 bigramas (palavras compostas) mais frequentemente usados no *Google n-gram corpus* de quatro categorias diferentes: substantivos, verbos, advérbios e adjetivos [43]. Foram também adicionados ao léxico todas as palavras do subconjunto *Ekman* do *WordNet Affect Lexicon* que tinham no máximo dois sentidos, agregando assim outros 640 pares de palavras-sentido [43].

Para obter as anotações de emoção em larga escala, os criadores do NRC utilizaram o serviço *Mechanical Turk* da Amazon [43], um serviço de *crowdsourcing*, que consiste um modelo de produção em que as tarefas são terceirizadas [43]. As tarefas atribuídas a cada colaborador consistiam em responder um conjunto de perguntas relacionadas aos termos

que farão parte do léxico. Cinco pessoas diferentes avaliaram cada um dos termos [43].

As diferentes anotações feitas para cada um dos termos foram consolidadas e para quase 60% dos termos, ao menos quatro anotadores concordam entre si [43]:

Tabela 4. Concordância entre as anotações acerca das emoções. Fonte: Elaborado pelo autor.

Emoção	Tamanho da Classe Majoritária					
	= 2	= 3	= 4	= 5	>= 3	>= 4
anger	13.7	21.7	25.7	38.7	86.1	64.4
anticipation	19.2	31.7	28.3	20.7	80.7	49.0
disgust	13.8	20.7	23.8	41.5	86.0	65.3
fear	16.7	27.7	25.6	29.9	83.2	55.5
joy	16.1	24.3	21.9	37.5	83.7	59.4
sadness	14.3	23.8	25.9	35.7	85.4	61.6
surprise	11.8	25.3	32.2	30.6	88.1	62.8
trust	18.8	27.4	27.7	25.9	81.0	53.6
micro-average	<b>15.6</b>	<b>25.3</b>	<b>26.4</b>	<b>32.6</b>	<b>84.3</b>	<b>59.0</b>

A concordância também foi analisada em relação à valência dos sentimentos (positivo ou negativo) [43]:

Tabela 5. Concordância entre as anotações acerca da valência dos sentimentos. Fonte: Elaborado pelo autor.

Emoção	Tamanho da Classe Majoritária			
	= 3	= 4	= 5	>= 4
anger	13.2	19.4	67.2	86.6
anticipation	18.8	32.6	48.4	81.0
disgust	13.4	18.4	68.1	86.5
fear	15.3	24.8	59.7	84.5
joy	16.2	22.6	61.0	83.6
sadness	12.8	20.2	66.9	87.1
surprise	10.9	22.8	66.2	89.0
trust	20.3	28.8	50.7	79.5
micro-average	<b>15.1</b>	<b>23.7</b>	<b>61.0</b>	<b>84.7</b>

A seguir a estatística Kappa de Fleiss para interpretação da concordância [43]:

Tabela 6. Escala Kappa de Fleiss de concordância. Fonte: Elaborado pelo autor.

Fleiss's <i>k</i>	Interpretação
< 0	concordância pobre
0.00 - 0.20	ligeira concordância
0.21 - 0.40	justa concordância
0.41 - 0.60	moderada concordância
0.61 - 0.80	substancial concordância
0.81 - 1.00	quase perfeita concordância

O ANEW é um dicionário voltado para análise de sentimentos que classifica os termos de acordo com as dimensões de valência, excitação e dominância. Esse dicionário conta com cerca de 14 mil palavras de diversas categorias [15].

### III. MATERIAIS E MÉTODOS

Nesta seção são abordados dois métodos para análise dos dados: No primeiro são empregados algoritmos de classificação baseados em inteligência artificial e aprendizado de máquina. No segundo utiliza-se a análise de sentimentos, com abordagem léxica e a nível de entidades.

#### A. Obtenção e descrição dos dados

Os dados obtidos do site *Kaggle* consistem em um *dataset* com cerca de 230 mil textos em inglês rotulados em duas categorias: *suicide* e *non-suicide*:

Tabela 7. Amostra do conjunto de dados.

ID	text	class
2	Ex Wife Threatening Suicide Recently I left my wife for good because she has cheated on me twice and lied to me so much that I have decided to refuse to go back to her. As of a few days ago, she began threatening suicide. I have tirelessly spent these past few days talking her out of it and she keeps hesitating because she wants to believe I'll come back. I know a lot of people will threaten this in order to get their way, but what happens if she really does? What do I do and how am I supposed to handle her death on my hands? I still love my wife but I cannot deal with getting cheated on again and constantly feeling insecure. I'm worried today may be the day she does it and I hope so much it doesn't happen.	suicide
3	Am I weird I don't get affected by compliments if it's coming from someone I know irl but I feel really good when internet strangers do it	non-suicide

Tabela 7.1. Tradução livre da amostra do conjunto de dados.

ID	text	class
2	Ex-esposa ameaçando suicídio Recentemente eu deixei minha esposa para sempre porque ela me traiu duas vezes e mentiu tanto para mim que eu decidi me recusar a voltar para ela. A partir de alguns dias atrás, ela começou a ameaçar suicídio. Passei esses dias incansavelmente falando com ela e ela continua hesitando porque quer acreditar que eu vou voltar. Eu sei que muitas pessoas vão ameaçar isso para	suicide

	conseguir o que querem, mas o que acontece se ela realmente fizer isso? O que eu faço e como devo lidar com a morte dela em minhas mãos? Eu ainda amo minha esposa, mas não posso lidar com ser traído novamente e me sentir constantemente inseguro. Estou preocupado que hoje possa ser o dia em que ela faça isso e espero muito que não aconteça.	
3	Eu sou estranho eu não sou afetado por elogios se vem de alguém que eu conheço na vida real, mas eu me sinto muito bem quando estranhos da internet fazem isso.	non-suicide

Os textos foram originalmente coletados do *Reddit*, uma rede social que agrega conteúdos por meio de fóruns. Três fóruns foram utilizados para obtenção dos dados: “*Suicide Watch*”, “*Depression*” e “*Teenagers*”.

As classes não foram rotuladas manualmente. Pressupõe-se que postagens coletadas de “*Suicide Watch*” contém publicações cujo conteúdo está relacionado ao suicídio. Portanto, essas postagens foram rotuladas como *suicide*. Da mesma forma, as postagens obtidas a partir dos fóruns “*Depression*” e “*Teenagers*” foram rotuladas como *non-suicide*.

As postagens rotuladas como *suicide* foram coletadas entre 16 de dezembro de 2008 e 2 de janeiro de 2021. As demais postagens foram coletadas entre 1 de janeiro de 2009 e 2 de janeiro de 2021.

Ao todo, o conjunto de dados contém 116032 postagens rotuladas como *suicide*, coletadas do fórum *Suicide Watch* e 116037 postagens rotuladas como *non-suicide*, obtidas dos fóruns *Depression* e *Teenagers*:




Figura 5. Contagem de postagens por categoria. Fonte: Elaborado pelo autor.

#### B. Software

Para a análise dos dados e desenvolvimento dos algoritmos de classificação, foram utilizados os softwares Anaconda 4.10.1, Python 3.8.3, IDE Spyder 4.1.4, em conjunto com as bibliotecas Scikit-learn 1.1.0, Pandas 1.4.2, Seaborn 0.11.2, Pickle 3.10.6, Numpy 1.23, NLTK 3.7, e SpaCy 3.4.

Para a análise estatística e análise de sentimentos foram utilizados os softwares R 4.0.3, IDE RStudio 1.3.1093 em

conjunto com as bibliotecas Tm 0.7-8, Syuzhet 1.0.6, Ggplot2 3.3.3, Strigr 1.4.0 e RColorBrewer 1.1-2.

Para análise léxica foi utilizado o software IRaMuTeQ 0.7 alpha 2.

### C. Hardware

O hardware utilizado foi um notebook HP 246 G7 com processador Intel I5 de 1.6GZ e 8GB de memória RAM. Sistema operacional Windows 10 de 64 bits.

### D. Abordagem baseada em aprendizado de máquina.

#### 1) Pré-processamento

Os métodos a seguir foram aplicados ao conjunto de dados durante a fase de pré-processamento. Ao final do processo, observou-se 9,73% de redução no tamanho do conjunto de dados em termos de quantidade de caracteres.

##### i. Conversão para minúsculas:

A conversão das palavras para sua forma minúscula foi utilizada nesse trabalho. Isso se justifica pois, em alguns experimentos, piores resultados foram observados quando a distinção entre palavras com a primeira letra maiúscula foi feita. Como a conversão das palavras para letras minúsculas não altera a semântica há obtenção de benefícios em termos de regularização [31].

##### ii. Pontuação:

A pontuação encontrada nos textos adiciona ruído ao conjunto de dados. A aplicação de métodos de pré-processamento pode melhorar a qualidade do conjunto de dados para tarefas de classificação de texto [32]. Assim, na etapa de pré-processamento, os sinais gramaticais de pontuação foram removidos.

##### iii. Remoção de *stop-words*:

A remoção de palavras que não agregam valor em termos semânticos foi aplicada com o objetivo de remover do conjunto de dados o ruído por elas causado.

##### iv. Derivação e Lematização:

Ambas as técnicas visam simplificar a estrutura morfológica das palavras, ora substituindo-as pelo seu radical, ora pelo seu lema. Em termos práticos, o custo computacional observado aplicando derivação foi consideravelmente menor e os resultados obtidos na etapa de classificação em termos de acurácia e sensibilidade foram os mesmos obtidos com a lematização. O método aplicado neste trabalho utilizou o Snowball Stemmer, por se tratar de uma versão atualizada da Porter's Stemmer e pelo baixo risco de overstem.

#### 2) Modelagem dos dados e extração de características

Toda a etapa de pré-processamento dos dados foi realizada a partir da estrutura tabular provida pelo Pandas 1.4.2, uma biblioteca para uso em Python. Em seguida, os dados foram armazenados em uma matriz esparsa de recursos TF-IDF através do módulo *feature\_extraction* da biblioteca *Scikit-Learn 1.1.0*. TF-IDF significa *term frequency – inverse document frequency*, ou frequência do termo sobre a frequência inversa do documento. Caracteriza-se por ser um algoritmo cuja finalidade é transformar um texto em uma

representação numérica compreensível pelos algoritmos de aprendizado de máquina. Essa representação é obtida a partir do cálculo da relevância de uma palavra em um documento, assumindo que quanto maior o número de aparições de uma palavra em um texto, maior a sua relevância. A frequência do termo é igual ao número de ocorrências de uma determinada palavra nesse documento.

Ao conceber um documento como um conjunto de termos, e uma coleção como um conjunto de documentos, denomina-se frequência do documento (DF) o número de documentos em que um determinado termo está presente. O inverso da frequência é incorporado ao cálculo para diminuir o peso dado aos termos com frequência muito alta e que ao mesmo tempo têm pouca significância semântica.

Assim, armazena-se na matriz apenas os termos estatisticamente relevantes pretendendo desta forma melhorar o desempenho dos modelos de I.A. durante o processo de aprendizagem de máquina.

Os dados foram modelados a nível de aspecto, adotando como menor nível de granularidade a palavra e desconsiderando qualquer sequência contígua destas.

#### 3) Separação da base de dados em treino e teste

O conjunto de dados foi dividido através do método *Hold-Out* em função do baixo custo computacional e do volume suficientemente grande de dados tornou viável a utilização desse método. Vinte por cento dos dados foram separados para teste.

Foi utilizada uma *seed* com valor 33, uma semente que torna o experimento reprodutível, a fim de comparar diferentes modelos de aprendizado de máquina.

#### 4) Técnicas de aprendizagem supervisionada

Três modelos da biblioteca *Scikit-learn* foram selecionados para classificar os textos do conjunto de dados:

##### • SGDClassifier - Estimador de gradiente estocástico:

Parâmetros:

*Random\_state*: 21, para tornar o modelo reprodutível; e

*Max\_iter*: 100: número máximo de iterações.

##### • MLPClassifier – Rede Neural Artificial:

Parâmetros:

Camadas ocultas: 1

*Random State*: 21, para tornar o modelo reprodutível; e

*Early Stopping: True*: permite que o modelo pare de treinar quando sua performance não melhora após seguidas rodadas de treinamento.

##### • MultinomialNB - Classificador probabilístico baseado na teoria de Bayes.

Parâmetros: Os parâmetros utilizados correspondem aos padrões default estabelecidos no modelo disponibilizado através da biblioteca *scikit learn*, os quais são:

*Alpha*: 1.0, parâmetro de suavização aditiva utilizada para suavizar dados categóricos;

*Fit\_Prior: True*, Define se o modelo aprenderá probabilidades anteriores de classe; e

*Class\_Prior: None*, Probabilidades prévias de classe.

## E. Análise estatística de sentimentos a nível de entidade

### 1) Pré Processamento

Os seguintes métodos foram utilizados na fase de pré-processamento dos dados:

- a. Remoção de pontuação, números e símbolos:  
A ocorrência de caracteres desta classe não agrega valor em termos de análise estatística ou análise de sentimentos e constituem ruídos na base de dados [32]. Assim, estes caracteres foram removidos da base de dados.
- b. Descapitalização:  
Como mencionado anteriormente, a conversão das palavras da base de dados para sua forma minúscula não altera seu valor semântico [31]. A importância do emprego desse método também está relacionada à abordagem léxica, pois os termos relacionados no dicionário (léxico) utilizado durante a fase de identificação estão em sua forma minúscula.

### 2) Identificação de sentimentos conforme o modelo de Plutchik

Cada um dos textos que compõem a base de dados foi submetido ao método `get_nrc_sentiment` disponibilizado pelo pacote `syuzhet`. Este método implementa o léxico NRC e retorna um quadro de dados em que as colunas representam a contagem de palavras relacionadas a cada uma das 8 emoções básicas do modelo de Plutchik e a contagem das palavras relacionadas a sentimentos positivos e negativos.

### 3) Análise Estatística

Técnicas de estatística descritiva foram aplicadas aos dados a fim de sumarizar os dados através de tabelas e gráficos e descrevê-los através de medidas de tendência central e de variabilidade.

Em seguida, testes de hipótese foram aplicados com o objetivo de comparar as médias dos grupos de texto em estudo.

Também fez-se uso de técnicas lexicográficas a partir do software *Iramuteq* para agrupamento e visualização

## F. Análise Lexicográfica

### 1) Pré-processamento

Os dados foram carregados para o software RStudio para execução da etapa de limpeza dos dados. Nessa etapa foram removidos os caracteres do tipo não textual e descapitalização dos textos e em seguida foi realizado a remoção de *stop words*.

Em seguida os dados foram codificados, pois o software *Iramuteq* exige que os textos que compõem o *corpus* sejam separados entre si através de um padrão composto pela sequência de quatro asteriscos (\*\*\*\*). A utilização desse conjunto de caracteres permite ao programa interpretar corretamente a divisão inequívoca dos textos que compõem o *corpus*.

Uma vez codificados, os dados foram separados em dois conjuntos diferentes de acordo com o atributo 'classe' (*suicide* ou *non-suicide*), e exportados em formato *.csv*.

### 2) Criação do corpus textual

Os arquivos *.csv* foram então convertidos em arquivos de texto na codificação *UTF-8* para possibilitar a leitura dos arquivos pelo software *Iramuteq*.

## IV. RESULTADOS

Nessa seção serão abordadas três diferentes análises acerca do conjunto de dados: análise lexicográfica, análise de sentimentos combinada com análise estatística e análise por aprendizagem de máquina.

### 1. Análise Lexicográfica dos corpus textuais

A análise textual teve como objetivo realizar a sumarização dos dados em termos de distribuição de frequência e agrupamento de termos em função da proximidade.

A análise foi dividida em duas etapas: na primeira a análise foi feita na classe *non-suicide* e na segunda, na classe *suicide*.

O *corpus* da classe *non-suicide* é composto por 1.000 textos, 32.886 palavras, 6318 formas (palavras não repetidas) e 3432 *hapax* (palavras que aparecem uma única vez).

O gráfico de Zipf a seguir indica que poucas palavras se repetem muito e que poucas palavras se repetem pouco:

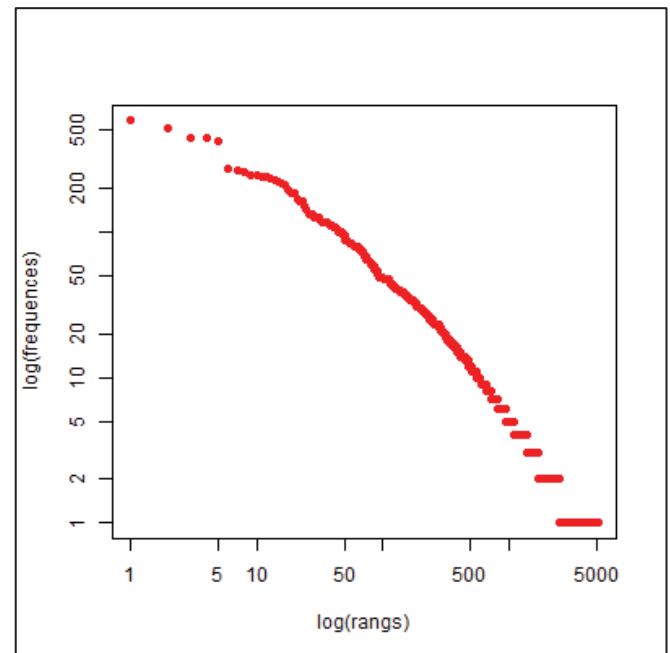


Figura 6. Distribuição Zipf da classe *non-suicide*.

A tabela a seguir relaciona as formas mais frequentes, sua frequência e sua categoria:

Tabela 8: Frequência das 15 formas mais comuns na classe *non-suicide*.

Forma	Frequência	Forma	Frequência
like	428	nostalgia	221
day	270	think	209
gt	261	friend	194
lt	249	feel	187
pop	247	fuck	165
know	243	filler	143
person	242	time	133
don	236		

A árvore de similitude (Figura 20) apresenta almas relações entre a relação entre as palavras, ao mesmo tempo que classifica essas relações em *clusters*, permitindo avaliar palavras que se opõem. É possível identificar no grupo *game* outras palavras relacionadas a jogos, como *play*, *minecraft*, *fun* e *pc*. Assim como é possível verificar no grupo *feel* outros sentimentos ou palavras relacionadas a eles, como *good*, *bad*, *wrong*, *stupid*, *great*, entre outras. Observa-se também que as palavras se organizam em torno de uma palavra central: *know*. À ela estão relacionadas palavras como *talk*, *tell* e *ask*:

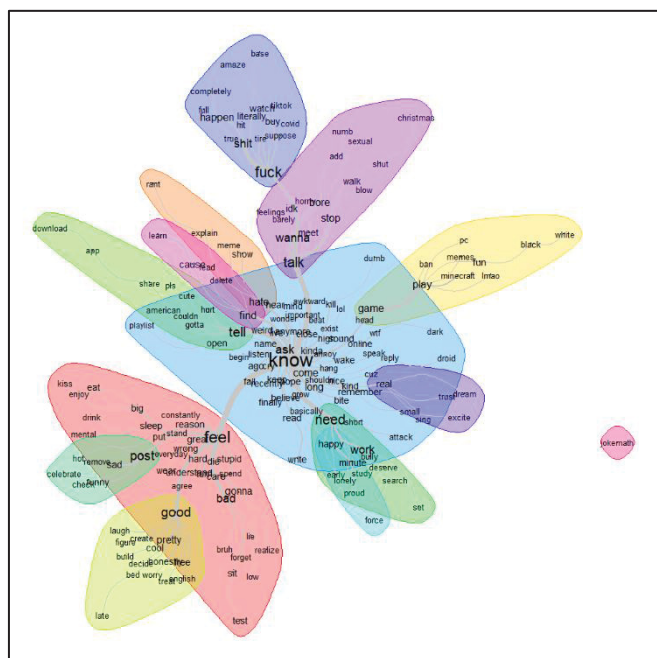


Figura 7. Árvore de similitude na classe: *Non-suicide*.

O *corpus* da classe *suicide* é composto por 1.000 textos, 101164 palavras, 9347 formas (palavras não repetidas) e 4617 *hapax* (palavras que aparecem uma única vez) e o gráfico de Zipf (Figura 8) indica que poucas palavras se repetem muito e que poucas palavras se repetem pouco:




Figura 8. Gráfico de Zipf da classe *suicide*

A tabela a seguir relaciona as 15 formas mais frequentes, sua frequência e sua categoria:

Tabela 9: Frequência das 15 formas mais comuns na classe *suicide*.

Forma	Frequência	Categoria
don	1332	nom
feel	1271	ver
like	1084	nom
know	986	ver
life	953	nom
ve	941	nr
person	871	nom
think	811	nom
even	685	ver
time	681	nom
year	622	nom
fuck	590	nom
thing	542	nom
friend	541	nom
day	518	nom

A árvore de similitude (Figura 9) apresenta as relações existentes entre os verbos da classe *suicide*:




Figura 9. Árvore de similitude na classe: *suicide*.

Observa-se no centro a palavra *feel* e próximas à ela, no mesmo cluster, palavras como *hate*, *shit* e *depressed*.

Também é possível observar em outro *cluster* a relação entre as palavras *need*, *help* e *care*.

## 2. Análise Estatística de Sentimentos

A análise estatística iniciou-se com o cálculo das principais medidas de posição relativas à contagem de palavras com conotação emotiva. As medidas calculadas estão indicadas nas tabelas 10 e 11 a seguir:

Tabela 10. Medidas de posição – Classe: Non-Suicide

Medidas de Posição - Classe: Non-Suicide		
anger	anticipation	disgust
Min. : 0.0000	Min. : 0.000	Min. : 0.0000
Median : 0.0000	Median : 1.000	Median : 0.0000
<b>Mean : 0.7954</b>	<b>Mean : 1.097</b>	<b>Mean : 0.6761</b>
Max. : 72.0000	Max. : 64.000	Max. : 57.0000
fear	joy	sadness
Min. : 0.0000	Min. : 0.0000	Min. : 0.0000
Median : 0.0000	Median : 0.0000	Median : 0.0000
<b>Mean : 0.8648</b>	<b>Mean : 0.9426</b>	<b>Mean : 0.8764</b>
Max. : 92.0000	Max. : 64.0000	Max. : 85.0000
surprise	trust	
Min. : 0.0000	Min. : 0.000	
Median : 0.0000	Median : 1.000	
<b>Mean : 0.5234</b>	<b>Mean : 1.418</b>	
Max. : 36.0000	Max. : 91.000	
negative	positive	
Min. : 0.000	Min. : 0.000	
Median : 1.000	Median : 1.000	
<b>Mean : 1.676</b>	<b>Mean : 2.119</b>	
Max. : 164.000	Max. : 158.000	

Tabela 11. Medidas de posição – Classe: Suicide

Medidas de Posição - Classe: Suicide		
anger	anticipation	disgust
Min. : 0.000	Min. : 0.000	Min. : 0.000
Median : 3.000	Median : 3.000	Median : 2.000
<b>Mean : 3.696</b>	<b>Mean : 3.769</b>	<b>Mean : 2.775</b>
Max. : 110.000	Max. : 78.000	Max. : 72.000
fear	joy	sadness
Min. : 0.000	Min. : 0.000	Min. : 0.000
Median : 3.000	Median : 2.000	Median : 4.000
<b>Mean : 4.719</b>	<b>Mean : 2.818</b>	<b>Mean : 5.344</b>
Max. : 121.000	Max. : 63.000	Max. : 98.000
surprise	trust	
Min. : 0.000	Min. : 0.000	
1st Qu.: 0.000	1st Qu.: 1.000	
Median : 1.000	Median : 3.000	
<b>Mean : 1.668</b>	<b>Mean : 4.371</b>	
3rd Qu.: 2.000	3rd Qu.: 6.000	
Max. : 40.000	Max. : 108.000	
negative	positive	
Min. : 0.000	Min. : 0.000	
1st Qu.: 3.000	1st Qu.: 2.000	
Median : 6.000	Median : 4.000	
Mean : 7.987	Mean : 6.563	
3rd Qu.: 11.000	3rd Qu.: 9.000	
Max. : 207.000	Max. : 175.000	

A partir dos dados sumarizados, observa-se que a média calculada em todas as variáveis dos dados da classe *suicide* é superior às observadas na classe *suicide*.

Os gráficos a seguir (Figuras 10 a 19) ilustram a predominância da ocorrência de palavras carregadas de sentimento na classe *suicide*.




Figura 10. Emoção: raiva.




Figura 11. Emoção: antecipação.




Figura 12. Emoção: nojo.




Figura 13. Emoção: medo.




Figura 14. Emoção: alegria.




Figura 15. Emoção: tristeza.




Figura 16. Emoção: surpresa.




Figura 17. Emoção 'confiança'.




Figura 18. Sentimentos negativos.




Figura 19. Sentimentos positivos.

Para avaliar a hipótese de que a contagem de palavras que denotam sentimento é em média diferentes em cada classe o teste *t* foi realizado para cada uma das emoções analisadas.

As hipóteses formuladas para cada um dos testes foram:

$H_0$ : Médias são iguais

$H_a$ : Médias são diferentes

O valor de *p* foi indicado na tabela a seguir, onde o G1 corresponde à classe *suicide* e G2 à classe *non-suicide*:

Tabela 12. Resultados dos testes *t de Student* para comparação da média dos atributos das classes *suicide* e *non-suicide*.

Emoção	Média G1	Média G2	Valor de <i>p</i>
<i>Anger</i>	0,795	3,695	<0.00000
<i>Anticipation</i>	1,097	3,769	<0.00000
<i>Disgust</i>	0,676	2,775	<0.00000
<i>Fear</i>	0,864	4,719	<0.00000
<i>Joy</i>	0,942	2,817	<0.00000
<i>Sadness</i>	0,876	5,344	<0.00000
<i>Surprise</i>	0,523	1,667	<0.00000
<i>Trust</i>	1,417	4,370	<0.00000

Portanto, como o valor de *p* é menor que 0,05 em todos os atributos, aceita-se a hipótese alternativa de que as médias são diferentes entre si, com nível de significância de 5% e intervalo de confiança de 95%.

### 3. Abordagem baseada em aprendizado de máquina

A tabela 13 apresenta uma comparação entre as métricas dos modelos utilizados:

Tabela 13: Comparação entre os modelos

	MLP	SGD	MNB
Acurácia:	0,94	0,93	0,91
Precisão:	0,94	0,93	0,92
F1 Score:	0,94	0,93	0,91
Sensibilidade:	0,93	0,91	0,96
Especificidade:	0,95	0,94	0,87

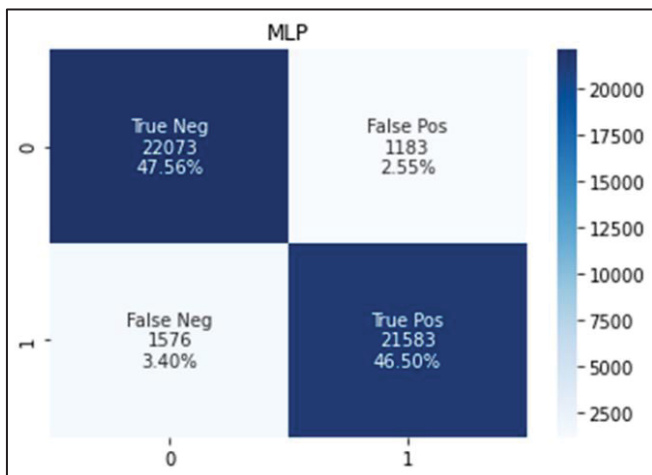


Figura 20. Matriz de confusão resultante da classificação feita com o algoritmo baseado em redes neurais artificiais. Fonte: Elaborado pelo autor.

Conforme a tabela 13, o modelo baseado em redes neurais (MLP) foi, entre os modelos utilizados, aquele que obteve a maior acurácia (94%). A relevância da acurácia se confirma com um F1 Score igualmente elevado, indicando que os acertos obtidos pelo modelo não foram obra do acaso.

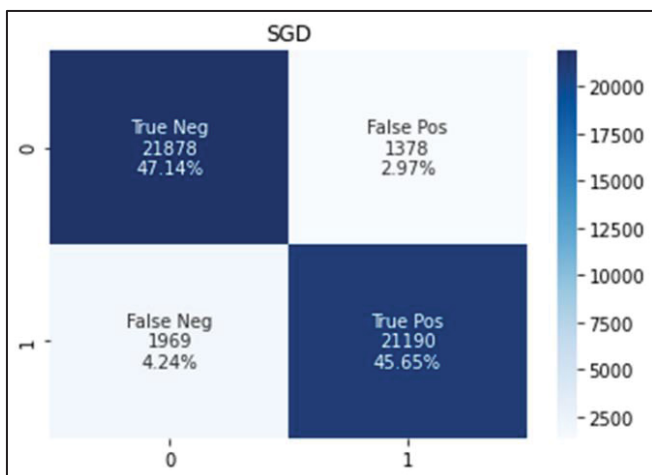


Figura 21. Matriz de confusão resultante da classificação feita com o algoritmo baseado em gradiente descendente estocástico. Fonte: Elaborado pelo autor.

O modelo SGD obteve 93% de acurácia e precisão. Contudo, foi o que obteve a menor sensibilidade. Os efeitos decorrentes dos erros na classificação do tipo 2 (falso negativo) são mais nocivos quando o objetivo é o diagnóstico de uma doença.




Figura 22. Matriz de confusão resultante da classificação feita com algoritmo probabilístico. Fonte: Elaborado pelo autor.

Os três modelos de classificação testados apresentaram acurácia superior a 90%. O modelo baseado em redes neurais artificiais alcançou 94% de acurácia e 93% de sensibilidade.

Contudo, o modelo com a maior sensibilidade foi o classificador probabilístico (MNB). O modelo classificou corretamente 96% dos casos não relacionados a suicídio e foi o modelo em que menos se observou erros do tipo II.

Alguns erros de classificação decorrem do método de rotulagem. Ao pressupor que todos os textos postados no grupo *Suicide Watch* estão relacionados à ideação suicida houve margem para entrada de sujeira na base de dados.

No exemplo a seguir, a postagem foi feita no grupo *Suicide Watch*, e portanto, rotulada como *suicide*. Contudo, o conteúdo da mensagem é um conselho positivo:

*“Two years. It has been 2 years since my attempt. To everyone that is browsing this subreddit, you are loved. Please do not make the same mistake I did.”* [38].

O texto, em uma tradução livre, diz: *“Dois anos. Dois anos se passaram desde a minha tentativa. A todos que estão navegando por este subreddit, vocês são amados. Por favor, não cometam o mesmo erro que eu cometi.”*

Outro exemplo:

*“The past is the past dont cry because its over its never too late to make long lasting memories Everybody is talking about memories from the past but no one is talking about making good memories now. Its never too late to do so dont be afraid to ask out that girl dont be afraid to spend an entire weekend doing what you love. Dont be afraid to do something a little out of your comfort zone. Dont be afraid of something that has come and gone. Dont be afraid about moving somewhere new.”* [38].

*“O passado é passado. Não chore porque acabou. Nunca é tarde para fazer novas boas recordações. Todos falam sobre boas recordações do passado, mas ninguém fala sobre fazer novas boas recordações agora. Nunca é tarde para fazê-lo ...”*. (Tradução livre).

Considera-se, portanto, que o objetivo proposto foi atingido. A análise lexicográfica permitiu identificar diferenças entre os vocabulários utilizados nas diferentes classes. A análise de sentimentos e estatística permitiu identificar diferenças na contagem média de termos relacionados à emoções e por fim a análise baseada em

aprendizado de máquina obteve modelos com níveis satisfatórios de acurácia e sensibilidade.

## V. CONSIDERAÇÕES FINAIS

No presente trabalho, buscou-se utilizar das técnicas de processamento de texto e do aprendizado de máquina para classificar textos relacionados ou não ao tema suicídio ou ideação suicida.

Várias técnicas de processamento de linguagem natural e diferentes algoritmos de classificação foram utilizados para classificar cerca de 230 mil textos entre duas classes possíveis: *suicide* ou *non-suicide*, entre elas técnicas de lexicometria, estatística, análise de sentimentos, limpeza de dados, normalização de dados, algoritmos de aprendizado de máquina e redes neurais artificiais.

Os modelos baseados em aprendizado de máquina testados obtiveram acurácia superior a 90% e o melhor modelo obteve sensibilidade de 96%, sendo que em apenas 2,14% dos textos foram observadas falhas graves quanto à sua classificação.

A partir dos resultados demonstrados no presente trabalho, podem-se sugerir como trabalhos futuros a incorporação de algoritmos de classificação à uma infinidade de sites, sobretudo redes sociais e fóruns de opinião no sentido de monitorar postagens cujo conteúdo esteja relacionado ao suicídio e consequentemente viabilizar ações preventivas.

## VI. REFERÊNCIAS

- [1] Organização Mundial da Saúde (OMS) (2021, 28 Jun). Prevenção do Suicídio: Um manual para profissionais da mídia [On-line]. Disponível em: [https://www.who.int/mental\\_health/prevention/suicide/en/suicideprev\\_media\\_port.pdf](https://www.who.int/mental_health/prevention/suicide/en/suicideprev_media_port.pdf)
- [2] Organização Pan-Americana da Saúde (OPAS) (2021, 28 Jun). Tópicos sobre suicídio. Disponível em: <https://www.paho.org/pt/topicos/suicidio>
- [3] R.M.S Cassorla (2021, 28 Jun). *Estudos sobre suicídio: Psicanálise e saúde mental* [E-book]. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786555062908/>
- [4] N.J. Botega (2021, 28 Jun). *Crise suicida* [E-book]. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788582712382/>.
- [5] A.T. Beck. *Cognitive therapy and the emotional disorders*. London: Penguin, 1979.
- [6] B. Liu (2012). *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers [On-line]. Disponível em: [https://www.morganclaypool.com/doi/abs/10.2200/s00416ed1v01y201204\\_hlt016](https://www.morganclaypool.com/doi/abs/10.2200/s00416ed1v01y201204_hlt016)
- [7] M. Al-Mosaiwi, et al. (2018, Jan). In an Absolute State: Elevated Use of Absolutist Words Is a Marker Specific to Anxiety, Depression, and Suicidal Ideation. *Clinical Psychological Science* [On-line]. Disponível em: <https://journals.sagepub.com/doi/full/10.1177/2167702617747074>
- [8] G.A. Dias. *Análise de Sentimentos em artefatos de software* [On-line]. Porto Alegre: UFRGS, 2018. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10183/185039/001074209.pdf?sequence=1&isAllowed=y>.
- [9] E. Cambria, B. Schuller et. al., "New Avenues in Opinion Mining and Sentiment Analysis," in IEEE Intelligent Systems, vol. 28, no. 2, pp. 15-21, March-April 2013, doi: 10.1109/MIS.2013.30.
- [10] C.A. Rodrigues et al. *Mineração de Opinião e Análise de Sentimento* [On-line]. Florianópolis: UFSC, 2010. Disponível em: <http://www.inf.ufsc.br/~luis.alvares/INE5644/MineracaoOpinioa.pdf>
- [11] B. Liu. *Sentiment Analysis and Subjectivity, Handbook of Natural Language Processing*, 2 ed [E-book]. Illinois: University of Illinois, 2010. Disponível em: <https://www.cs.uic.edu/~liub/FBS/NLP-handbook-sentiment-analysis.pdf>.
- [12] K. Silva et al. (2017). Análise de sentimento pela ótica da abordagem multimodal. *Revista Novas Tecnologias na Educação* [On-line], 15(1). Disponível em: <https://www.seer.ufrgs.br/renote/article/view/75112>
- [13] C.D. Manning, H. Schütze. *Foundations of statistical natural language processing*. Cambridge: The MIT Press, 2010.
- [14] P.M.P Storrer. *Percepção dos usuários do Twitter em Curitiba sobre a mobilidade no transporte público* [On-line]. Curitiba: UTFPR, 2017. Disponível em [http://riut.utfpr.edu.br/jspui/bitstream/1/9219/1/CT\\_COSIS\\_2017\\_2\\_2.pdf](http://riut.utfpr.edu.br/jspui/bitstream/1/9219/1/CT_COSIS_2017_2_2.pdf)
- [15] C.C.A Blaz. "Análise de Sentimentos em Tiquetes para o Suporte de TI" [On-line], dissertação de mestrado, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2017. Disponível em: <https://lume.ufrgs.br/handle/10183/172455>
- [16] R.B. Franco, M.H.A.C Adaniya (2018, jul). Sistemas de análise de sentimentos usando dados do Twitter. *Revista Terra & Cultura: Cadernos de Ensino e Pesquisa* [On-line], 34(n. esp.), 111-118, jul. 2018. ISSN 2596-2809. Disponível em: <http://periodicos.unifil.br/index.php/Revistateste/article/view/301>
- [17] P. Feliciano and P. Farah. "Avaliação de Algoritmos de Análise de Sentimentos em Tweets no Domínio da Copa do Mundo FIFA 2018", in Anais da II Escola Regional de Engenharia de Software, 2018, pp. 73-80.
- [18] P. Ekman. *Basic Emotions: Handbook of cognition and emotion*. Feb. 1999. [On-line]. <https://doi.org/10.1002/0470013494.ch3>.
- [19] R. Plutchik, H. Kellerman. *Theories of emotion*. Nova Iorque: Academic Press, 2013.
- [20] W. Parrot. *Emotions in Social Psychology*. Philadelphia: Psychology Press, 2001.
- [21] A.B. Warriner, V. Kuperman, M. Brysbaert (2013, Dez). Norms of valence, arousal, and dominance for 13,915 English lemmas. *Behavior research methods*, 45(4), 1191-207.
- [22] L. McCleary, E. Viotti, T.A. Leite (2010). Descrição das línguas sinalizadas: a questão da transcrição dos dados. *ALFA: Revista de Linguística*, 54(1).
- [23] H.B. Mota, M.G.C Melo Filha, S.S. Lasch (2007). A consciência fonológica e o desempenho na escrita sob ditado de crianças com desvio fonológico após realização de terapia fonoaudiológica. *Revista CEFAC*, 9(4), 477-482.
- [24] M. Tsytsarau, T. Palpanas (2011, Set). Survey on mining subjective data on the web. *Springer* [On-line]. 24, 478-514. Disponível em <https://link.springer.com/article/10.1007%2Fs10618-011-0238-6>
- [25] P.H.R. Cerqueira. "Um estudo sobre reconhecimento de padrões: um aprendizado supervisionado com classificador bayesiano" [On-line], tese de doutorado, Universidade de São Paulo, São Paulo, 2010. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11134/tde-11022011-101732/en.php>
- [26] J. Grus. *Data Science do Zero: Primeiras Regras com Python*. Rio de Janeiro: Alta Books, 2016.
- [27] Data Science Academy. *Deep Learning Book* [On-line]. Data Science Academy, c2022. Disponível em: <https://www.deeplearningbook.com.br/>
- [28] S.P. Pivetta. *Classificação de documentos do exército brasileiro utilizando o classificador Naive Bayes e técnicas de seleção de sentenças*. Alegrete: Universidade Federal Pampa, 2013.
- [29] F.S Araújo, F.N. Kepler (2012). Análise Automática de Sentimentos. *Anais do Salão Internacional de Ensino*, 4(2).

- [30] H. Schmid. "Improvements in part-of-speech tagging with an application to German". in *Natural language processing using very large corpora*. Ed. Springer, Dordrecht, 1999. p. 13-25.
- [31] X. Zhang, J. Zhao, Y. Lecun (2015). Character-level convolutional networks for text classification. *Advances in neural information processing systems*, 28.
- [32] Y. Hachohen-Kerner, D. Miller, Y. Yigal (2020). The influence of preprocessing on text classification using a bag-of-words representation. *PLoS one*, 15(5), e0232525.
- [33] Scikit-Learn, MLPClassifier (2022, Abr. 22). *sklearn.neural\_network.MLPClassifier* [On-line]. Disponível em: [https://scikit-learn.org/stable/modules/generated/sklearn.neural\\_network.MLPClassifier.html](https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html)
- [34] Universidade Federal do Paraná (2022, Abr. 22). Laboratório de Estatística e Geoinformação. Disponível em: [http://cursos.leg.ufpr.br/ML4all/apoio/Gradiente.html#\\_gradiente\\_descendente](http://cursos.leg.ufpr.br/ML4all/apoio/Gradiente.html#_gradiente_descendente)
- [35] D. Mariano (2021, Jun 19). Métricas de avaliação em machine learning. *Bioinfo* [On-line]. Disponível em <https://bioinfo.com.br/metricas-de-avaliacao-em-machine-learning-acuracia-sensibilidade-precisao-especificidade-e-f-score/>
- [36] Liu et. al.. *Encyclopedia of Databases Systems*. Nova Iorque: Springer, 2016. p. 532-538.
- [37] Mahesh (2020, Jan. 01). *Internacional Journal of Science and Research*. Disponível em: [https://www.researchgate.net/profile/Batta-Mahesh/publication/344717762\\_Machine\\_Learning\\_Algorithms\\_-\\_A\\_Review/links/5f8b2365299bfb53e2d243a/Machine-Learning-Algorithms-A-Review.pdf?eid=5082902844932096](https://www.researchgate.net/profile/Batta-Mahesh/publication/344717762_Machine_Learning_Algorithms_-_A_Review/links/5f8b2365299bfb53e2d243a/Machine-Learning-Algorithms-A-Review.pdf?eid=5082902844932096). Acesso em: 25/08/2022.
- [38] Kaggle - Suicide and Depression Detection. Disponível em: <https://www.kaggle.com/nikhileswarkomati/suicide-watch>. Acesso em: 21/06/2021.
- [39] Deeks JJ. Using evaluations of diagnostic tests: understanding their limitations and making the most of available evidence. *Ann Oncol*. 1999 Jul;10(7):761-8. Review.
- [40] Freitas, Cláudia et al. Tagsets and datasets: some experiments based on Portuguese language. In: *International Conference on Computational Processing of the Portuguese Language*. Springer, Cham, 2018. p. 459-469.
- [41] Iramuteq (2022). *Iramuteq* Disponível em: [iramuteq.org](http://iramuteq.org). Acesso em: 03/10/2022.
- [42] NRC Emotion Lexicon. *NRC Word-Emotion Association Lexicon*. Disponível em <https://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm>. Acesso em: 03/10/2022.
- [43] Mohammad, Saif et. al. Corwsourcing a Word-Emotion Association Lexicon. Institute for Information Technology, National Research Council Canada. Ottawa, 2013. Disponível em: <https://arxiv.org/pdf/1308.6297.pdf>. Acesso em: 04/10/2022.
- [44] Lebart et. al. Analyse stistique des donnés textuelles. *Questions ouvertes et lexicométrie* [Online]. França: Histoire & Mesure, 1989. Disponível em: [https://www.persee.fr/doc/hism\\_0982-1783\\_1989\\_num\\_4\\_3\\_1637](https://www.persee.fr/doc/hism_0982-1783_1989_num_4_3_1637). Acesso em: 06/10/2022.
- [45] Camargo, Brigido Vizeu et. al. Tutorial para uso do software Iramuteq (Interface de R pour les Analyses Multidimensionnelles de Textes et de Questionnaires [Online]. Laboratório de Psicologia Social da Comunicação e Cognição – UFSC. Florianópolis. 2021. Disponível em: <http://www.iramuteq.org/documentation/fichiers/tutoriel-en-portugais>. Acesso em: 06/10/2022.
- [46] Cervi, Emerson. Análise de conteúdo automatizada para conversações em redes sociais online: uma proposta metodológica [Online]. Caxambu-MG. 2018. Disponível em: <https://www.anpocs.com/index.php/papers-40-encontro-3/gt-31/gt17-22/11253-analise-de-conteudo-automatizada-para-conversacoes-em-redes-sociais-online-uma-proposta-metodologica/file#:~:text=O%20m%C3%A9todo%20Reinert%20produz%20clusters.possibilidade%20de%20replicar%20a%20t%C3%A9cnica..> Acesso em: 06/10/2022.
- [47] L. J. Kazmier, *Estatística Aplicada à Administração e Economia* 4ª edição, Porto Alegre: Bookman, 2007.
- [48] E. A. Damasceno, "Lexicometria, geração de descritores, construção de ontologias e ensino de línguas: implicações e perspectivas," *Múltiplas Perspectivas em Linguísticas*. 1a ed, pp. 01-3037, 2008.
- [49] Y. S. O. Sousa, "O Uso do Software Iramuteq: Fundamentos de Lexicometria para Pesquisas Qualitativas," *Estudos e Pesquisas em Psicologia*, 2021.