

**ANÁLISE DE SENTIMENTOS PARA SUBSIDIAR REFORMAS CURRICULARES
CONSIDERANDO O PONTO DE VISTA ESTUDANTIL**

**SENTIMENT ANALYSIS TO SUPPORT CURRICULUM REVISIONS
CONSIDERING STUDENT'S POINT OF VIEW**

Alice Feitosa Barbosa*

Érica de Lima Gallindo**

Mário Wedney de Lima Moreira***

RESUMO

De acordo com a Lei de Diretrizes e Bases da Educação (LDB), Lei nº 9.394/96, o sistema de educação escolar vigente no Brasil está organizado em dois níveis, sendo um deles o ensino superior. Neste nível, são asseguradas a criação, organização e extinção de cursos e programas educacionais, assim como a fixação de currículos. Considerando o desenvolvimento curricular dos cursos de nível superior, diversos pontos conflitantes são encontrados e que, com o passar do tempo, sua matriz se torna defasada, fazendo-se necessário um processo de revisão e atualização. Neste processo, os estudantes estão quase sempre à margem das discussões sobre seu desenvolvimento. Portanto, o presente estudo apresenta a aplicação da técnica de análise de sentimentos para extrair *insights* baseadas na opinião dos estudantes sobre a matriz curricular de um curso de graduação em Ciência da Computação, apontando, através de seus sentimentos, subsídios para uma reforma curricular. Espera-se como resultado deste estudo desenvolver uma nova grade curricular baseada na opinião do principal ator do sistema de educação superior, a saber, o estudante.

Palavras-chave: Matriz Curricular. Análise de Sentimentos. *Feedback* Estudantil.

ABSTRACT

According to the Lei de Diretrizes e Bases da Educação (LDB), Law nº 9.394/96, the current school education system in Brazil is organized on two levels. At the higher education level, the development, organization, and extinguishment of educational courses and programs are ensured, as well as the establishment of curriculum. Considering the curriculum development of higher-level courses, several conflicting points are found and that, over time, its contents

*Instituto Federal de Educação, Ciência e Tecnologia do Ceará, alice.feitosa.barbosa07@aluno.ifce.edu.br.

**Instituto Federal de Educação, Ciência e Tecnologia do Ceará, erica.gallindo@ifce.edu.br

***Instituto Federal de Educação, Ciência e Tecnologia do Ceará, mario.wedney@ifce.edu.br

becomes outdated, making updating and revision necessary. In this process, frequently students are left out of discussions. Therefore, this study presents the application of the sentiment analysis technique to obtain insights based on the students' opinion about the current course curriculum of an undergraduate course in computer science, pointing, through their feelings, subsidies for curricular revision. As a result of this study, it is expected to develop a new curriculum based on the opinion of the main actor of the higher education system, namely the student.

Keywords: Curricular Revision. Sentiment Analysis. Students' Feedback.

1 INTRODUÇÃO

O Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) é uma das instituições públicas de ensino superior no Brasil que oferta, entre outros, cursos de graduação e de pós-graduação. O IFCE, em conjunto com os outros 38 institutos federais, foi criado pela Lei nº 11.892, de 29 de dezembro de 2008¹. Essa mesma lei estabelece que, para efeito da incidência das disposições que regem a regulação, avaliação e supervisão das instituições e dos cursos, os institutos federais são equiparados às universidades federais.

No âmbito do ensino superior, a Lei de Diretrizes e Bases da Educação (LDB) estabelece que dentro de sua autonomia, as universidades podem criar cursos e programas educacionais, assim como fixar os currículos dos seus cursos e programas. Com base na equiparação supra-mencionada, o IFCE tem autonomia para organizar os projetos de seus cursos, contendo suas bases conceituais, o contexto regional para o qual ele foi pensado, a matriz curricular adotada, e o programa de unidade didática (PUD) de cada disciplina prevista, o qual, por sua vez, define a metodologia de trabalho e os conteúdos a serem abordados.

Após a elaboração de um projeto de curso, ao se implantar uma proposta de matriz curricular é comum surgirem problemas que resultam na necessidade de ajustes. Considerando-se, por exemplo, os casos de cursos de áreas tecnológicas, uma matriz curricular torna-se defasada em função da velocidade com a qual o conhecimento está evoluindo no mundo moderno, fazendo-se necessária uma revisão periódica da proposta concebida originalmente.

Durante o processo de reforma de uma matriz curricular, que utiliza critérios comparativos ou é realizada a partir de opiniões pessoais dos próprios elaboradores dos currículos, espera-se que também sejam ouvidos os sujeitos que usufruirão do que está sendo proposto. Em mudança recente, o Novo Ensino Médio, *e.g.*, inseriu no processo de elaboração dos cursos, uma fase de escuta dos estudantes para entender melhor os seus anseios e necessidades, visando ajudar as escolas e secretarias de educação a promover melhorias no sistema educacional (FERREIRA; RAMOS, 2018). Por serem os beneficiários diretos, é de se esperar que os estudantes possam ter uma maior clareza acerca de questões da matriz curricular no tocante à sua implementação.

¹Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2008/lei/111892.htm

A depender do tamanho da instituição, a inclusão de um processo de escuta dos estudantes pode resultar em grandes bases de dados que precisarão ser processadas posteriormente. Para facilitar a posterior tabulação, a coleta de dados normalmente é feita por meio de formulários padronizados que muitas vezes retratam mais a percepção do elaborador do mecanismo de coleta do que a dos próprios estudantes. Para minimizar a perda de informações relevantes que podem ser fornecidas pelos entrevistados, devem ser previstos questionários semiestruturados que não incluem somente questões objetivas e pré-estabelecidas.

Atualmente, existem técnicas avançadas para análise de dados não estruturados e semiestruturados, como é o caso da técnica de análise de sentimentos. A análise de sentimentos, ou mineração de opinião, consiste em uma solução computacional realizada mediante a extração de opiniões, sentimentos e emoções por meio de diferentes canais de comunicação, sendo o principal no formato textual (ARAÚJO; GONÇALVES; BENEVENUTO, 2013; NARAYANAN; LIU; CHOUDHARY, 2009; SANTOS et al., 2018). A técnica é considerada desafiadora e muito útil (LIU; ZHANG, 2012), tendo como principal objetivo identificar uma opinião, em relação a um tema em questão, para medi-la como positiva, negativa ou neutra (LIU, 2012).

O presente trabalho tem como objetivo definir uma metodologia para a obtenção da percepção dos alunos sobre a matriz curricular de cursos de graduação, ofertados no regime de crédito por disciplinas, onde os alunos escolhem os componentes curriculares que pretendem cursar em um determinado período letivo². Especificamente, para a validação da proposta apresentada aqui, a metodologia é aplicada na matriz curricular dos cursos de Ciência da Computação dos *campi* Aracati, Maracanaú e Tianguá, analisando o conjunto de opiniões dos estudantes e observando, sob vários aspectos, o sentimento desses alunos em relação ao curso, a partir da aplicação de uma pesquisa estrategicamente pensada. Neste contexto, a técnica de análise de sentimentos é aplicada no cenário da opinião dos alunos sobre a matriz curricular vigente, podendo assim capturar os sentimentos dos mesmos em relação a cada disciplina.

O presente artigo está estruturado como se segue. A Seção 2 descreve os aspectos relativos ao planejamento pedagógico dos cursos e a técnica de análise de sentimentos. Na Seção 3 são detalhados os trabalhos relacionados a proposta do presente trabalho. Na Seção 4 apresenta-se a proposta de avaliação da opinião dos estudantes acerca do curso. Na Seção 5 são expostos os resultados alcançados. Finalmente, na Seção 6, são apresentadas as considerações finais acerca do tema abordado.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção será abordado o apoio técnico deste trabalho, ou seja, os conceitos teóricos que norteiam e esclarecem o funcionamento da técnica de análise de sentimentos, assim como o contexto que o presente trabalho se insere.

²Disponível em: <https://ifce.edu.br/espaco-estudante/regulamento-de-ordem-didatica/2016-07-08-rod-revisao-aprovada-consup-13jun2016-v30.pdf>

2.1 Organização dos cursos de graduação

Atualmente o sistema de educação escolar no Brasil é dividido em educação básica e educação superior. A educação básica inclui a educação infantil, o ensino fundamental e o ensino médio e tem por finalidade desenvolver o aluno, garantindo uma formação comum indispensável para o exercício da cidadania, fornecendo meios para que eles possam progredir no trabalho e em estudos posteriores. A educação superior, por sua vez, deve atuar para estimular o desenvolvimento do espírito científico e do pensamento reflexivo, incentivando o trabalho de pesquisa e investigação científica, desenvolvendo a ciência, a tecnologia e o entendimento do homem e do meio em que vive (BRASIL, 2018).

Neste sentido, são idealizadas instituições de ensino superior como o IFCE, criado em 2008, a partir da integração do Centro Federal de Educação Tecnológica do Ceará e das escolas agrotécnicas federais do Crato e de Iguatu, possuindo atualmente uma estrutura organizacional que prevê uma unidade administrativa localizada em Fortaleza e 32 unidades acadêmicas distribuídas em 32 municípios do Estado do Ceará. Designado pela LDB os órgãos responsáveis pela educação, em nível federal, é o Ministério da Educação (MEC) e o Conselho Nacional de Educação (CNE) (BRASIL, 2018).

Como abordado na introdução, os institutos federais são equiparados às universidades federais (BRASIL, 2018), *i.e.*, o IFCE tem autonomia para organizar os currículos de seus cursos, usando o Regulamento da Organização Didática (ROD) como instrumento para tal fim. O ROD do IFCE tem o objetivo de tornar homogêneas as atividades acadêmicas em todos os *campi* da instituição e auxiliar o funcionamento da administração institucional. Nesse regulamento é estabelecido que cada curso ofertado no IFCE deverá ter um projeto pedagógico (PPC). O ROD prevê, ainda, que os cursos de graduação funcionam no regime de crédito por disciplina, sendo organizados em unidades curriculares denominadas disciplinas. No regime de crédito por disciplina, os alunos podem escolher os componentes curriculares que pretendem cursar, desde que sejam respeitados os limites de créditos e de pré-requisitos estabelecidos na matriz curricular de seus cursos.

É no PPC que se contempla a organização acadêmica, assim como a matriz curricular adotada e o programa de unidade didática de cada disciplina dos cursos. A elaboração do PPC em um curso de graduação é de responsabilidade do seu respectivo Núcleo Docente Estruturante (NDE). Vale ressaltar que, segundo o ROD, para haver atualização no que diz respeito à matriz curricular, é necessária a elaboração de uma proposta pelos respectivos colegiados dos cursos ou pela Coordenação Técnica Pedagógica (CTP) do *campus* em questão.

2.2 *Machine learning*

Também conhecido como Aprendizagem de Máquina (AM), ou *Machine Learning* (ML) consiste em um campo de estudo da Inteligência Artificial (IA), que tem como objetivo por meio de uma base de dados, treinar uma máquina para detectar padrões e tomar decisões com o mínimo de interferência humana.

De acordo com Monard e Baranauskas (2003, p. 39), os sistemas de AM trazem consigo características particulares que permitem, sobre diferentes formas, o tratamento de problemas de classificação, previsão, dentre tantas outras. Segundo (RUSSELL, 2013) existem dois principais tipos de AM, sendo estes:

- **aprendizagem supervisionada:** os dados são treinados por meio de exemplos rotulados, como uma entrada na qual a saída desejada é conhecida.
- **aprendizagem não supervisionada:** é utilizado com dados que não possuem rótulos históricos. A "resposta certa" não é informada ao sistema. O algoritmo deve descobrir o que está sendo mostrado. O objetivo é explorar os dados e encontrar alguma estrutura dentro deles.

A abordagem de AM aplicável à análise de sentimentos pertence principalmente à classificação supervisionada em geral. Portanto, para a realização da análise, regras gerais são extraídas de uma grande base de dados, que são previamente classificados para ser desempenhado o treinamento, no caso a aprendizagem.

2.3 Análise de sentimentos

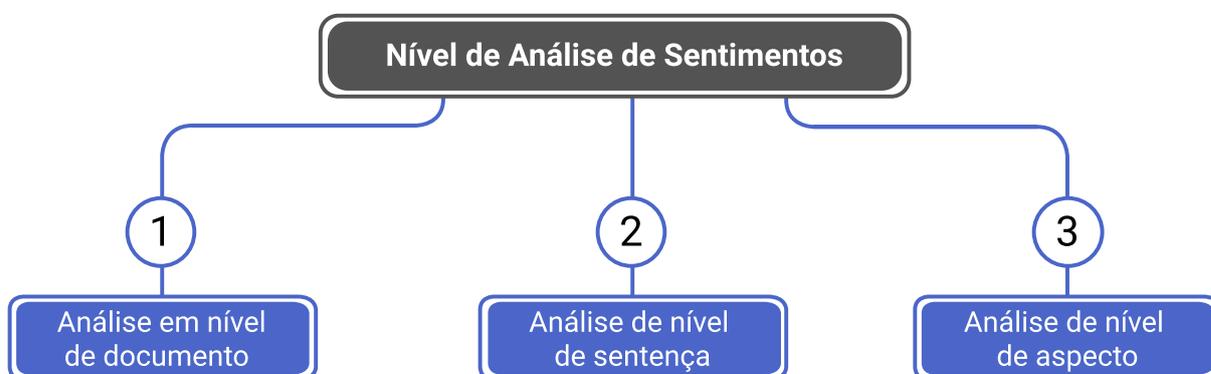
Segundo Liu (2012, p. 1), a Análise de Sentimentos (AS) ou Mineração de Opinião (MO), consiste em uma técnica que visa analisar as opiniões, sentimentos, avaliações e emoções das pessoas em relação a entidades como serviços, organizações, questões e todos os seus atributos relacionados. Esse autor sugere ainda que o termo análise de sentimentos talvez tenha aparecido pela primeira vez em (NASUKAWA; YI, 2003), e que o termo mineração de opinião tenha aparecido pela primeira vez em (DAVE; LAWRENCE; PENNOCK, 2003). No entanto, cabe destacar que a pesquisa sobre sentimentos e opiniões já havia aparecido anteriormente nos trabalhos de (DAS; CHEN, 2007; MORINAGA et al., 2002; PANG; LEE; VAITHYANATHAN, 2002; TONG, 2001; TURNEY, 2002; WIEBE et al., 2000)

A AS é uma área da Tecnologia da Informação e Comunicação (TIC) que vem crescendo constantemente, já que a disseminação da opinião pública atualmente tem se tornado muito mais ágil e prática com o advento da *Web 2.0*, em especial das mídias sociais. Portanto, tanto pesquisadores quanto organizações estão, cada vez mais, fazendo uso do conteúdo destas aplicações para a tomada de decisões. Como exemplo dessa utilização é possível citar a captação de opiniões dos clientes para constatar a satisfação diante de um serviço prestado ou de um produto adquirido.

De forma geral, a AS utiliza técnicas computacionais para extrair e identificar sentimentos e opiniões em textos, sejam eles em formatos objetivos, com perguntas e respostas pré-selecionadas ou subjetivas, consideradas perguntas abertas para expressar de forma livre um ponto de vista. A depender do contexto da pesquisa, a AS contempla diferentes níveis de análise, como ilustrado na Figura 1. De acordo com Liu (2012, p. 4), *e.g.*, a análise de sentimentos pode ser realizada em três níveis de granularidade distintos, a saber:

1. **Nível de documento:** neste nível, um texto é analisado de forma geral por expressar sentimento sobre uma única entidade. Por exemplo, dada uma revisão de um produto, o sistema determina se a revisão, de forma geral expressa uma opinião positiva ou negativa sobre o produto em questão.
2. **Nível de sentença:** neste nível, o texto já é analisado de forma independente, *i.e.*, analisa-se cada sentença que compõe a frase, para que assim seja possível identificar sentimentos como positivo, negativo ou neutro. Portanto, para realizar a identificação do sentimento, este nível deve estar intimamente relacionado à classificação da subjetividade, para distinguir sentenças objetivas, que expressam informações factuais, de sentenças subjetivas, que expressam visões e opiniões subjetivas.
3. **Nível de aspecto:** neste nível já é possível realizar uma análise com mais detalhes, não levando em consideração a estrutura do texto. O objetivo aqui é identificar sentimentos relacionados ao objeto em questão e seus aspectos. Portanto, em vez de examinar as construções da linguagem (documentos, parágrafos, sentenças, cláusulas ou frases), o nível do aspecto olha diretamente para a própria opinião, baseando-se na ideia de que em uma opinião consiste um sentimento, podendo vir a ser positivo ou negativo.

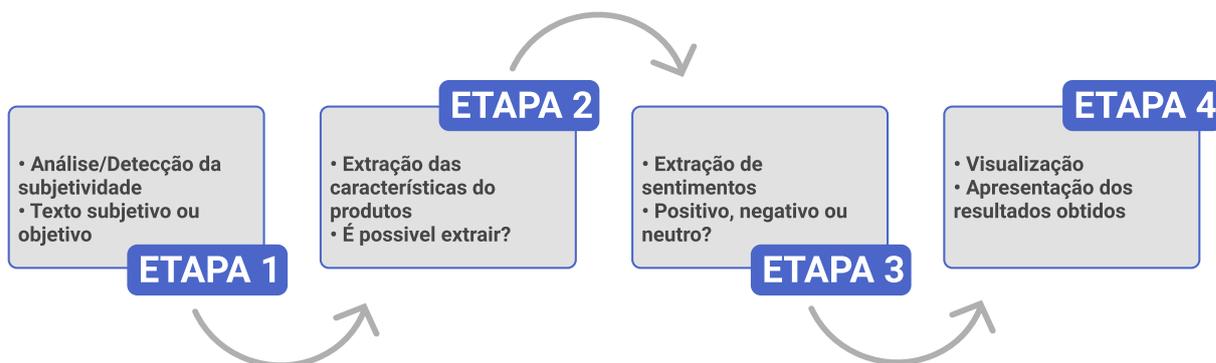
Figura 1 – Níveis de análise de sentimento.



Fonte: elaborado pelos autores.

Para muitos pesquisadores, o processo de AS é considerado bastante complexo e ao mesmo tempo completo. Segundo Silva, Lima e Barros (2012, p.2), o processo de análise pode ser dividido nas quatro etapas ilustradas na Figura 2. A primeira etapa consiste na análise/detecção de subjetividade, onde é identificado se o texto analisado é subjetivo ou objetivo. Logo após, na segunda etapa do processo de análise, é extraído do texto as características do produto ou serviço sob análise. Em seguida, na terceira fase do processo, é trabalhada a classificação de sentimentos, na qual é determinado a polaridade do texto em positivo, negativo ou neutro. Finalmente, na quarta etapa, é realizada a visualização, *i.e.*, a apresentação dos resultados alcançados na análise do texto.

Figura 2 – Etapas do processamento da técnica de análise de sentimentos.



Fonte: elaborado pelos autores.

3 TRABALHOS RELACIONADOS

Nesta seção, abordam-se outros contextos de aplicação da AS no cenário da educação, além da proposta deste trabalho de utilização desta técnica para subsidiar uma reforma curricular.

Em (ALTRABSHEH; GABER; HAIG, 2013), os autores levantam a questão de ter *feedback* dos alunos acerca dos desafios que enfrentam durante o desenvolvimento de seus cursos. A pesquisa propõe um sistema em tempo real, permitindo assim uma abordagem mais clara dos problemas de ensino-aprendizagem enfrentados na escola. O objetivo da pesquisa consiste em analisar o *feedback* dos alunos utilizando as técnicas de AS, coletando a opinião dos estudantes de diversas maneiras, incluindo redes sociais como o *Facebook* e o *Twitter*. Em sua pesquisa, o autor buscou exaltar a importância de se ter o *feedback* dos estudantes, já que são eles o foco principal de atuação das instituições de ensino. Para a realização da classificação foi feito o uso dos algoritmos *Naive Bayes* (NB) e *Support Vector Machine* (SVM).

Na linha do primeiro trabalho, a pesquisa desenvolvida por Balahadia (2016) apresenta uma ferramenta de avaliação ao desempenho de um professor usando a AS (BALAHADIA; FERNANDO; JUANATAS, 2016). Em linhas gerais, os alunos avaliam seus professores em classificação numérica e escala qualitativa, usando uma ferramenta de avaliação de professores online, fornecendo assim aos administradores e educadores das escolas um alerta em relação aos seus sentimentos e preocupações.

O autor aborda de forma ampla todo o funcionamento e lógica utilizada no processo de construção da ferramenta. O estudo explica, em sua metodologia, que o sistema proposto permite ao usuário fornecer classificações quantitativas e *feedback* na forma de comentários e/ou sugestões sobre o docente. As classificações qualitativas serão analisadas usando a pesquisa de opinião com o mecanismo de AS. Vale ressaltar que a princípio todos os comentários são armazenados em um banco de dados, logo em seguida são filtrados utilizando o *opinion mining*. Finalmente, o algoritmo NB é aplicado, indicando a classificação do comentário em positivo ou negativo.

Ainda nesta vertente, a pesquisa realizada por (NASIM; RAJPUT; HAIDER, 2017) apresenta uma combinação de AM e abordagens baseadas em léxico para analisar o *feedback*

dos alunos com a técnica de AS. Os *feedbacks* coletados provém do questionário semestral de avaliação dos professores, considerando que, segundo o autor, este questionário fornece *insights* úteis sobre a qualidade geral do ensino e sugere maneiras para melhorar a metodologia de ensino.

O artigo descreve um modelo de AS treinado com *Term Frequency-Inverse Document Frequency (TF-IDF)* e recursos baseados em léxico para analisar os sentimentos expressos pelos alunos em seu *feedback* textual. Uma análise comparativa entre o modelo proposto e outros métodos de AS também é realizada, como o uso de algoritmos de classificação *Random Forest (RF)* e *SVM*. O conjunto de dados usado neste artigo compreende 1.230 comentários extraído do portal acadêmico da instituição alvo da pesquisa. O conjunto de dados foi classificado manualmente com rótulos de polaridade de sentimento positivo, negativo ou neutro.

O trabalho de (ESPARZA et al., 2018) apresenta um modelo denominado *social mining*. A base de dados consiste nos comentários em espanhol dos alunos sobre o desempenho dos professores. Em sua pesquisa o autor fez uso do algoritmo *SVM* com três *kernels* (núcleos) diferentes, *e.g.*, linear, radial e polinomial, tendo como objetivo prever uma classificação de comentários em positivo, negativo ou neutro. Vale frisar que foi realizado um cálculo de sensibilidade, especificidade e valores preditivos como medidas de avaliação.

O conjunto de dados usado neste trabalho compreende 1.040 comentários em espanhol de três grupos de estudantes de engenharia de sistemas da Universidade Politécnica de Aguascalientes. Tais estudantes avaliaram 21 professores do primeiro ano escolar. Para este estudo foram considerados apenas os comentários isentos de ruídos ou *spam*, *i.e.*, textos com caracteres estranhos, espaços vazios sem opinião ou comentários alheios à avaliação dos professores.

4 PROPOSTA

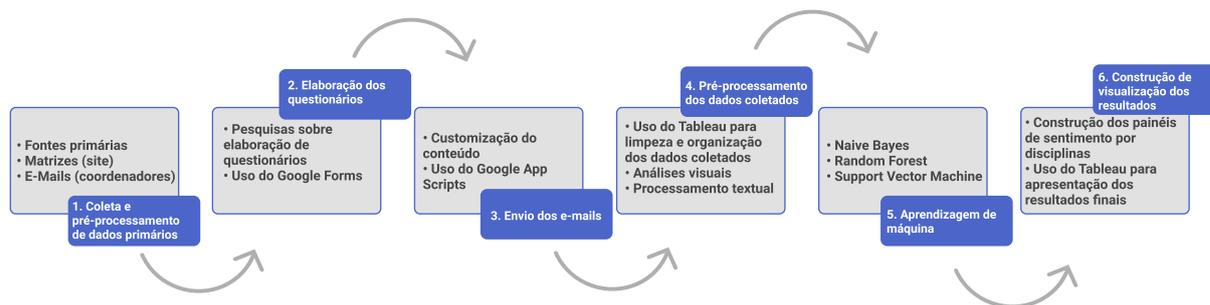
Nesta pesquisa é proposta uma metodologia para a obtenção dos sentimentos dos alunos em relação às matrizes curriculares de seus cursos, de forma que suas opiniões sejam levadas em consideração durante um processo de reestruturação curricular. Especificamente, é analisado o conjunto de opiniões dos estudantes do curso de Ciência da Computação dos *campi* Aracati, Maracanaú e Tianguá do IFCE, observando-se o sentimento expresso acerca do curso e das disciplinas que o compõem, a partir da aplicação de uma pesquisa estrategicamente pensada e de uma análise computacional posterior dos textos subjetivos coletados. A Figura 3 ilustra a metodologia deste estudo, particionada nas seguintes etapas:

4.1 Coleta e pré-processamento de dados primários

A primeira etapa da presente metodologia consiste na obtenção dos dados primários referentes às matrizes curriculares vigentes nos *campi* de interesse, bem como os respectivos *e-mails* institucionais dos alunos que se encontram com status de matrícula ativa, *i.e.*, estão registrados como “em curso” no sistema acadêmico do IFCE.

Para o envio da pesquisa, os *e-mails* e nomes dos estudantes foram coletados a partir do sistema acadêmico da instituição. Vale frisar que todos os dados institucionais coletados

Figura 3 – Metodologia para coleta e processamento das informações.



Fonte: elaborado pelos autores.

foram com a ciência e anuência formal dos respectivos coordenadores dos cursos envolvidos na pesquisa.

As matrizes curriculares dos cursos, contendo o rol de disciplinas de cada um, foram obtidas a partir de áreas públicas no site do próprio IFCE. As informações coletadas encontravam-se em formato PDF e precisaram passar por um processo de conversão para um formato estruturado em linhas e colunas, sendo uma linha para cada disciplina com colunas que representavam o nome da disciplina, seu código de identificação e qual o período letivo em que esta se encontrava na matriz curricular.

4.2 Elaboração dos questionário

Após a coleta dos dados de entrada, a segunda etapa consistiu na elaboração do formulário a ser enviado aos alunos. Os questionamentos foram pensados para instigar e identificar a contribuição do curso na vida acadêmica (e profissional) do estudante, assim como capturar os seus sentimentos em relação às disciplinas do curso. Para maximizar as chances de resposta de cada estudante, optou-se por reduzir o número de disciplinas de interesse para 3 (três), solicitando a ele seus comentários sobre as três disciplinas com mais pontos positivos e as três disciplinas com mais fatores negativos em sua opinião.

No início do formulário, o estudante deve selecionar o *campus* ao qual estava vinculado. De acordo com a escolha, o estudante será direcionado para um questionário específico, considerando que os *campi* estudados possuem distintas matrizes curriculares para o mesmo curso de Ciência da Computação.

Os alunos responderão seis questões objetivas com relação ao curso de forma geral. Estas questões estão apresentadas no estilo de escala *Likert* (que varia de 1 a 5), em que o aluno atribui um peso máximo de concordância ao selecionar “5” e máximo de discordância ao selecionar o “1”. Após responder às seis questões, o estudante será direcionado para área de escolha das três disciplinas com mais pontos negativos e das três com mais pontos positivos. Ao escolher uma disciplina, o aluno detalha o porquê daquela escolha. O questionário previa ainda um espaço livre para que o aluno possa sugerir mudanças e expor suas ideias ou críticas sobre as disciplinas ou sobre o curso como um todo.

Utilizou-se o *Google Forms* como ferramenta para a disponibilização e construção do questionário. O *Google Forms* é uma plataforma de pesquisa robusta, personalizável, que dispõe de um conjunto sólido de recursos para pesquisas complicadas e de um sistema de análise estatística. Neste sistema, as pesquisas puderam ser encaminhadas ao público-alvo por *e-mail*, de forma automatizada e personalizada conforme detalhado na seção a seguir.

4.3 Distribuição dos *e-mails* personalizados

Com o objetivo de maximizar as chances de resposta à pesquisa, em uma tentativa de fazer o entrevistado sentir-se mais envolvido, buscou-se enviar *e-mails* de forma personalizada aos 880 matriculados que faziam parte da população estudada. Adicionalmente, em função do grande volume de envios necessários, além da personalização, foi necessário também desenvolver uma automatização para este envio, o que foi realizado utilizando-se *Apps Script*.

O *Google Apps Script* é uma plataforma de codificação e desenvolvimento de aplicativos embutida no *Google Apps* que permite adicionar funcionalidades a planilhas, *Gmail*, sites e outros serviços do *Google* (FERREIRA, 2014). A partir de uma planilha com os respectivos dados e *e-mails* do alunos, foi desenvolvido uma aplicação com *HTML*, para a estrutura textual do *e-mail* e *GS* (linguagem de programação do *Google Apps Script* baseado em *JavaScript*) para a conexão com as colunas da planilha e envio do *e-mail*. Vale frisar que ao abrir o *e-mail*, o estudante tinha acesso a um texto de apresentação com o objetivo do trabalho, assim como o link para o questionário.

O envio do questionário se deu na primeira semana de setembro de 2020 e contou com diversos meios para se obter o maior número respostas. É importante salientar que a aplicação desta pesquisa se deu no cenário de quarentena devido ao COVID-19, então o contato com os alunos foi estritamente virtual. Desta forma, contamos com o engajamento dos coordenadores dos cursos de interesse, incentivando e pedindo a colaboração dos alunos, assim como a disponibilização do questionário nas redes sociais cotidianas, como *WhatsApp* e ainda contamos com a ajuda da comunicação do *campus*, por meio da publicação desta pesquisa nas redes sociais da instituição.

4.4 Pré-processamento dos dados coletados

De acordo com o retorno dos alunos, todas as respostas foram armazenadas em uma base de dados do próprio *Google forms*. Cabe destacar que as respostas coletadas puderam ser extraídas da plataforma por meio de um mecanismo de exportação que, ao final, produziu uma planilha no formato *Comma-Separated-Values* (CSV).

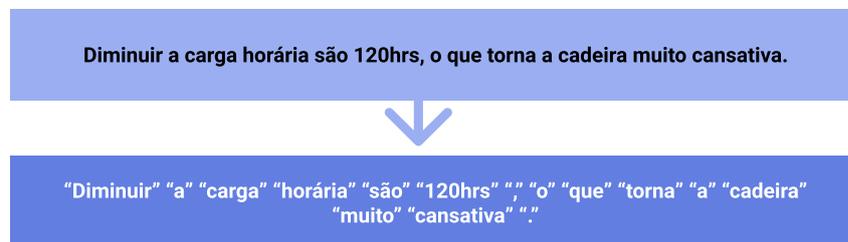
De posse dos *feedbacks* dos alunos foi realizado o pré-processamento na base de dados. A princípio esta etapa foi efetuada com o auxílio da ferramenta *Tableau*, a partir da qual foi possível detectar, de forma visual, os erros na estrutura dos dados após exportação CSV. O *Tableau* também auxiliou no processo de detecção de respostas consideradas nulas, já que o *feedback* consistia apenas em caracteres especiais (. , !). Após os ajustes no arquivo foi efetuado o

pré-processamento no texto, tendo em vista aumentar a precisão e diminuir os erros no processo de aprendizagem.

As técnicas de pré-processamento textual adotadas nesta pesquisa são apresentadas e descritas a seguir:

- **Tokenização:** também conhecida como segmentação de palavras, a *tokenização* geralmente consiste na primeira etapa do pré-processamento textual na qual se realiza uma quebra na sequência de caracteres do texto localizando o limite de cada palavra. As partes resultantes deste processo são denominadas de *tokens*. A Figura 4, a seguir, ilustra os *tokens* resultantes após o processo de *tokenização* de um texto exemplo.

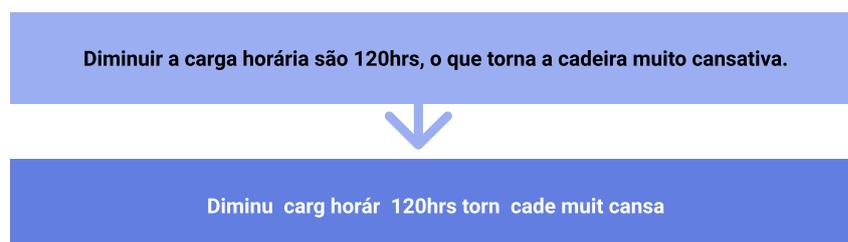
Figura 4 – Aplicação de *tokenização*.



Fonte: Elaborado pelos autores.

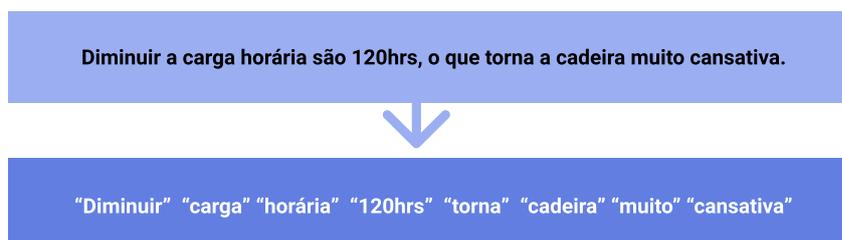
- **Stemming:** é o processo que reduz palavras derivadas ao seu radical. A língua portuguesa possui diferentes palavras flexionadas em gênero, número ou grau, além de inúmeros tempos verbais distintos. Desta forma, são identificadas as palavras e decompostas em seu *stem* invariante, como representado na Figura 5.

Figura 5 – Exemplo de *stemming*.



Fonte: Elaborado pelos autores.

- **Stopwords:** consiste na remoção de palavras e termos considerados irrelevantes para a análise, a exemplo de artigos e numerais, como ilustrado na Figura 6. Estes termos são considerados irrelevantes pois a sua remoção não influencia no resultado final. Vale destacar que a lista de palavras removidas sofre variância de acordo com o idioma no qual o texto está escrito.

Figura 6 – Remoção de *stopwords*.

Fonte: Elaborado pelos autores.

4.5 Modelos de aprendizagem

Após a fase de pré-processamento, os dados são preparados para a construção de um modelo, vale ressaltar que os dados desta pesquisa são supervisionados, *i.e.*, são previamente rotulados.

O objetivo desta etapa é construir um modelo que possa classificar os textos, indicando sua polaridade. Para tal, os algoritmos selecionados para este fim foram: o *Naive Bayes* (NB), que é um classificador probabilístico, o *Random Forest* (RF), classificador baseado em procura e o *Support Vector Machine* (SVM), um algoritmo baseado na criação de *clusters* a partir de *kernels*.

Para a codificação dos modelos utilizou-se o ambiente de desenvolvimento *Spyder*. Uma aplicação de código aberto desenvolvida para análise, depuração e exploração de dados em *python*, linguagem de programação adotada neste trabalho.

4.6 Representação visual dos resultados

Para se tirar proveito de todas as vantagens de uma representação visual de dados, a sexta etapa consistiu na construção de um dos produtos finais desta pesquisa, *i.e.*, a construção de um painel para a visualização dos dados coletados e processados, que serão apresentados na Seção 5.2.

5 ANÁLISE DOS RESULTADOS

Nesta seção são apresentados os resultados obtidos de acordo com a metodologia criada para a obtenção dos sentimentos dos alunos em relação às matrizes curriculares dos cursos de Computação supramencionados. Os questionamentos foram submetidos à apreciação de 880 *e-mails* de alunos regularmente matriculados, sendo 226 do *campus* Aracati, 471 de Maracanaú e 183 de Tianguá. Foram coletados, ao fim da aplicação do questionário, 96 *feedbacks*, sendo 47 (49%) de Aracati, 36 (37,5%) de Maracanaú e 13 (13,5%) de Tianguá.

5.1 Análise dos modelos de aprendizagem

Conforme mencionado anteriormente, a fase de treinamento em análise de modelos de aprendizagem consiste em por meio de uma base de dados, treinar uma máquina para detectar

padrões e tomar decisões. Para a realização da fase de treinamentos e testes, com o objetivo de classificar os *feedbacks* dos alunos com relação às disciplinas em positivo, negativo ou neutro foram adotados os algoritmos de classificação NB, RF, utilizando o índice de *Gini*. Este índice consiste em uma métrica aplicada para decidir qual é o melhor atributo que divide os dados gerando a partição mais pura, ou seja, uma partição que permite um maior ganho de informações e o SVM tendo como parâmetro o *kernel* linear.

Para a avaliação dos modelos, os algoritmos são treinados e testados para gerar uma estimativa média de acertos e erros. A acurácia verifica o desempenho do modelo, *i.e.*, quantas instâncias foram classificadas corretamente. Outra importante métrica é a precisão, que exibe quantas instâncias de uma determinada classe o algoritmo classificou corretamente. Estas métricas são extraídas a partir da matriz de confusão, cuja representação é uma matriz composta por valores reais e valores preditos pelo classificador.

A acurácia avalia a proximidade entre o valor obtido pelo algoritmo e o valor real no que concerne à tarefa de classificação. Desta forma, o algoritmo que alcançou o melhor desempenho neste critério foi o RF, com 79%, seguido do NB com 78% e do SVM com 77%.

A segunda análise realizada é com relação a precisão dos modelos a partir das classes negativa, positiva e neutra. Como pode ser observado a partir da Tabela 1, o algoritmo NB foi o que exibiu melhor performance neste item, seguido dos algoritmos RF e SVM, nesta ordem.

Tabela 1 – Precisão dos modelos.

Validação	Modelos de aprendizagem		
	NB	SVM	RF
Precisão Positiva	79%	66%	77%
Precisão Negativa	77%	75%	78%
Precisão Neutra	96%	91%	88%

Fonte: elaborado pelos autores.

Mesmo o modelo possuindo uma alta acurácia e precisão, estas taxas podem ocorrer em apenas uma determinada classe. Desta forma, para se identificar os acertos, o modelo também foi validado com a matriz de confusão. A partir das tabelas 2 a 4 a seguir é possível notar que o número de erros é pequeno em todas as classes mas, em linhas gerais, a classe “negativo” apresentou mais erros que as demais.

Tabela 2 – Matriz de confusão NB.

Real	NEGATIVO	NEUTRO	POSITIVO
Negativo	192	1	58
Neutro	10	24	5
Positivo	48	0	232

Fonte: elaborado pelos autores.

Tabela 3 – Matriz de confusão SVM.

Real	NEGATIVO	NEUTRO	POSITIVO
Negativo	40	1	7
Neutro	1	3	2
Positivo	15	0	45

Fonte: elaborado pelos autores.

Tabela 4 – Matriz de confusão RF.

Real	NEGATIVO	NEUTRO	POSITIVO
Negativo	32	0	14
Neutro	0	12	2
Positivo	7	0	47

Fonte: elaborado pelos autores.

5.2 Análise visual

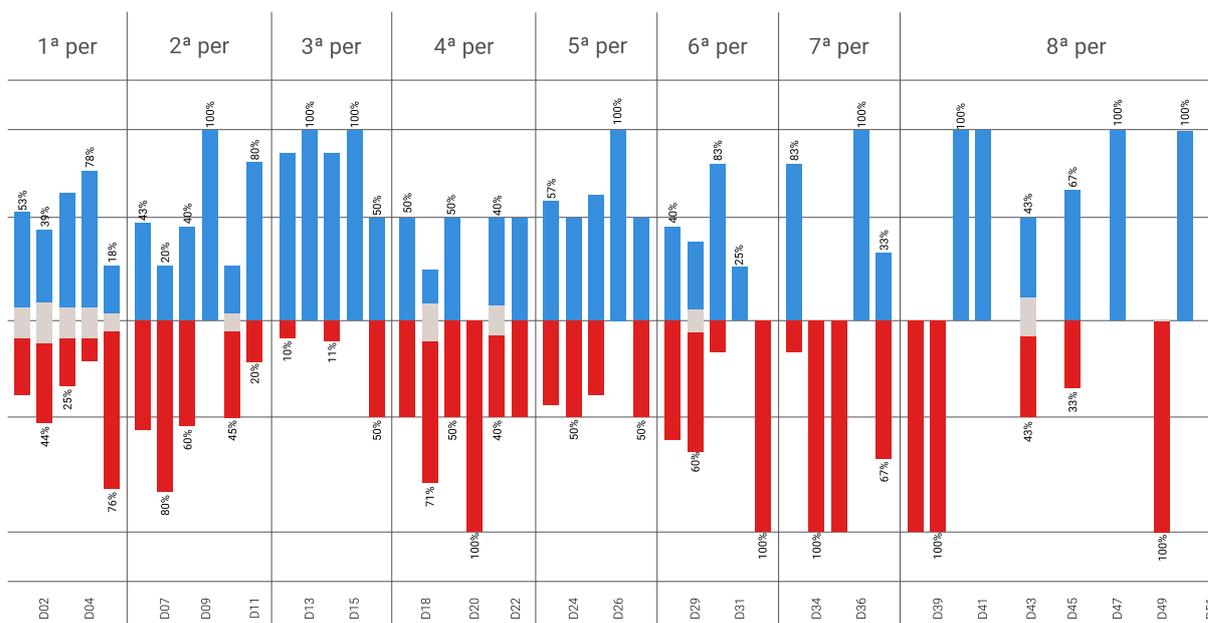
Para uma apresentação dinâmica e visual dos resultados obtidos foi utilizada a ferramenta de *Business Intelligence* (BI) denominada *Tableau*. O *Tableau* auxilia na compreensão dos dados alcançados, possibilitando uma detecção visual de eventuais falhas presentes na base de dados, proporcionando ainda a implementação de filtros, imagens, painéis interativos que expõem de forma clara os dados alcançados.

A última etapa da metodologia seguida neste trabalho consistiu, então, da criação de um painel para visualização dos resultados das análises dos dados, que foram realizadas usando os modelos de aprendizagem supracitados. O painel, que pode ser visualizado na Figura 7, possibilita uma visão geral do *feedback* dado pelos alunos, sendo ainda possível analisar os resultados por *campus* a partir dos filtros disponibilizados.

No painel, é possível visualizar as disciplinas, agrupadas pelo período letivo em que aparecem na matriz curricular, e suas respectivas avaliações de acordo com as análises dos dados dos alunos. A quantidade de avaliações negativas está destacada em vermelho, enquanto as positivas estão em azul e as neutras estão na cor cinza. Nesta visualização, optou-se por ocultar o nome das disciplinas e apresentar apenas seu código de identificação, indicando o número do semestre no qual elas estão localizadas na matriz.

Com a ferramenta *tableau* também foi possível consolidar as respostas das questões objetivas estruturadas na escala *Likert*. As questões, como mencionado anteriormente, são com relação ao curso em seu contexto geral, visando compreender o grau de satisfação dos alunos. Na Tabela 5 a seguir é possível visualizar os questionamentos realizadas e a escala mais escolhida pelos alunos, onde notou-se que as avaliações em sua maioria é de escala 4.

Figura 7 – Sentimento em relação às disciplinas dos cursos analisados.



Fonte: elaborado pelos autores.

Tabela 5 – Escala de *feedback* dos alunos.

Questões	ARACATI	MARACANAÚ	TIANGUÁ
As atividades realizadas nas disciplinas têm trabalhado meu senso de liderança.	Escala 4 39,1%	Escala 3 38,9%	Escala 4 46,2%
O curso tem me auxiliado a identificar e a resolver problemas, incluindo avaliar alternativas e articular o raciocínio lógico	Escala 4 47,8%	Escala 5 38,9%	Escala 4 46,2%
No curso, há a integração de diferentes materiais, viabilizando atividades globais que envolvem temas de disciplinas distintas.	Escala 3 e 4 30,4%	Escala 3 33,3%	Escala 3 38,2%
O curso tem me ajudado a escrever e a apresentar informações de maneira clara e efetiva.	Escala 5 32,6%	Escala 3 33,3%	Escala 4 38,2%
O curso tem me estimulado a pensar de forma criativa e a assumir riscos intelectuais.	Escala 4 43,5%	Escala 4 e 5 27,8%	Escala 4 61,5%
O curso vem me ajudando a desenvolver minhas habilidades de trabalho em grupo.	Escala 4 47,8%	Escala 4 27,8%	Escala 4 61,5%

Fonte: elaborado pelos autores.

6 CONSIDERAÇÕES FINAIS

A AS vem em constante crescimento, sendo aplicada nas mais diversas áreas do conhecimento como na área da educação e suas ramificações. Diante dos desafios que existem no processo de reforma curricular, o presente trabalho vem com o intuito de auxiliar este processo,

trazendo para a discussão elementos oriundos da percepção dos sujeitos estudantes, fazendo uso da técnica de análise de sentimentos. A validação da proposta foi realizada no contexto dos cursos de Bacharelado em Ciência da Computação do IFCE, utilizando as opiniões dos alunos como base de identificação de eventuais pontos negativos a serem analisados e de pontos positivos a serem ressaltados.

A utilização da AS proporciona uma visão macro avaliativa da atual matriz curricular, fornecendo tanto para os gestores como aos professores uma visão mais clara dos fatores que estão afetando o curso e quais devem ser estudadas, sob o ponto de vista dos estudantes.

Os resultados alcançados neste estudo mostram que o algoritmo RF apresenta os melhores indicadores considerando as métricas de desempenho da matriz de confusão. Este método de aprendizagem de conjunto (*ensemble learning, em inglês*) apresenta uma excelente performance em tarefas de classificação, regressão e outras tarefas que operam construindo uma infinidade de árvores de decisão durante o treinamento. Com uma acurácia de 79% e precisão média de 81%, esta abordagem apresenta um desempenho satisfatório em relação aos outros métodos bem conhecidos do atual estado da arte, a saber, 78% e 77% de acurácia para os algoritmos NB e SVM, respectivamente, e precisão média de 84% e 77,3% para os mesmos algoritmos. Em relação à precisão média do modelo baseado no Teorema de *Bayes*, vale ressaltar que esta abordagem desconsidera a dependência entre os atributos, o que quase nunca ocorre em tarefas rotineiras complexas.

Como sugestão para trabalhos futuros vislumbra-se a aplicação de novos algoritmos de aprendizagem de máquina. Sugere-se também, o desenvolvimento de uma ferramenta que dê suporte a construção de matrizes curriculares tendo como base a aplicação da análise de sentimentos para a avaliação do *feedback* dos alunos, podendo inclusive ser integrada às ferramentas de avaliação semestral já existentes na instituição.

REFERÊNCIAS

- ALTRABSHEH, N.; GABER, M.; HAIG, E. Sa-e: Sentiment analysis for education. **Frontiers in Artificial Intelligence and Applications**, New York, NY, USA, v. 255, Jul. 2013.
- ARAÚJO, M.; GONÇALVES, P.; BENEVENUTO, F. Measuring sentiments in online social networks. In: . New York, NY, USA: ACM, 2013. p. 97–104.
- BALAHADIA, F. F.; FERNANDO, M. C. G.; JUANATAS, I. C. Teacher's performance evaluation tool using opinion mining with sentiment analysis. In: IEEE. **2016 IEEE Region 10 Symposium (TENSYP)**. Bali, Indonesia, 2016. p. 95–98.
- BRASIL. **Lei de diretrizes e bases da educação nacional**. Brasília, DF: Brasília, 2018.
- DAS, S.; CHEN, M. Yahoo! for amazon: Sentiment extraction from small talk on the web. **Management Science**, v. 53, p. 1375–1388, 09 2007.
- DAVE, K.; LAWRENCE, S.; PENNOCK, D. M. Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. In: **12th International Conference on World Wide Web**. New York, NY, USA: ACM, 2003. p. 519–528.

ESPARZA, G. G. et al. A sentiment analysis model to analyze students reviews of teacher performance using support vector machines. In: OMATU, S. et al. (Ed.). **14th International Conference of Distributed Computing and Artificial Intelligence**. Cham: Springer, 2018. p. 157–164.

FERREIRA, J. **Google Apps Script: Web Application Development Essentials**. Newton, MA, USA: "O'Reilly Media, Inc.", 2014.

FERREIRA, R. A.; RAMOS, L. O. L. O projeto da MP nº 746: entre o discurso e o percurso de um novo ensino médio. **Ensaio: Avaliação e Políticas Públicas em Educação**, SciELO Brasil, v. 26, n. 101, p. 1176–1196, 2018.

LIU, B. Sentiment analysis and opinion mining. **Synthesis lectures on human language technologies**, Morgan & Claypool Publishers, v. 5, n. 1, p. 1–167, 2012.

LIU, B.; ZHANG, L. A survey of opinion mining and sentiment analysis. In: _____. **Mining Text Data**. Boston, MA: Springer US, 2012. p. 415–463.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: **Sistemas Inteligentes Fundamentos e Aplicações**. 1. ed. Barueri-SP: Manole Ltda, 2003. p. 89–114.

MORINAGA, S. et al. Mining product reputations on the web. In: **Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: ACM, 2002. p. 341–349.

NARAYANAN, R.; LIU, B.; CHOUDHARY, A. Sentiment analysis of conditional sentences. In: **Conference on Empirical Methods in Natural Language Processing**. USA: Association for Computational Linguistics, 2009. p. 180–189.

NASIM, Z.; RAJPUT, Q.; HAIDER, S. Sentiment analysis of student feedback using machine learning and lexicon based approaches. In: IEEE. **2017 international conference on research and innovation in information systems (ICRIIS)**. Langkawi, Malaysia, 2017. p. 1–6.

NASUKAWA, T.; YI, J. Sentiment analysis: Capturing favorability using natural language processing. In: **2nd International Conference on Knowledge Capture**. New York, NY, USA: ACM, 2003. p. 70–77.

PANG, B.; LEE, L.; VAITHYANATHAN, S. Thumbs up? sentiment classification using machine learning techniques. In: **Conference on Empirical Methods in Natural Language Processing (EMNLP 2002)**. Philadelphia, PA, USA: Association for Computational Linguistics, 2002. p. 79–86.

RUSSELL, S. J. **Inteligência artificial**. 3. ed. Tradução de Regina Célia Simille. – Rio de Janeiro: Elsevier, 2013. v. 3.

SANTOS, G. et al. Neutral or negative? sentiment evaluation in reviews of hosting services. In: **WebMedia '18**. New York, NY, USA: ACM, 2018. p. 347–354.

SILVA, N. R.; LIMA, D.; BARROS, F. Sapair: Um processo de análise de sentimento no nível de característica. **4nd International Workshop on Web and Text Intelligence (WTI'12)**, Curitiba, p. 2, 2012.

TONG, R. An operational system for detecting and tracking opinions in on-line discussions. **ACM SIGIR 2001 Workshop on Operational Text Classification Systems**, New Orleans, Louisiana, v. 1, n. 6, p. 1–6, 2001.

TURNEY, P. D. Thumbs up or thumbs down?: semantic orientation applied to unsupervised classification of reviews. In: **40th Annual Meeting on Association for Computational Linguistics**. Philadelphia: Cornell University, 2002. p. 417–424.

WIEBE, J. et al. Learning subjective adjectives from corpora. **Association for the Advancement of Artificial Intelligence**, 2000.