

Análise de Sentimentos para Subsidiar Reformas Curriculares Considerando o Ponto de Vista Estudantil

Aline F. Barbosa¹, Erica L. Gallindo¹, Mário W. L. Moreira¹

¹Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
62.800-000 – Aracati – CE – Brazil

alice.feitosa.barbosa07@aluno.ifce.edu.br

{erica.gallindo, mario.wedney}@ifce.edu.br

Abstract. *Brazil's current school education system is organized into two levels, one of which is higher education. At this level, the creation, organization, and termination of educational courses and programs are ensured. Considering the curricular development of these courses, several conflicting points are found and, over time, their matrix becomes outdated, making a process of review and updating necessary. In this process, students are almost always on the sidelines of discussions. Therefore, this study presents the application of the sentiment analysis technique to extract insights based on the students' opinion about the curriculum, pointing, through their feelings, subsidies for curriculum reform.*

Resumo. *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. Considerando o desenvolvimento curricular destes cursos, diversos pontos conflitantes são encontrados e, 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. Portanto, este estudo apresenta a aplicação da técnica de análise de sentimentos para extrair insights baseadas na opinião dos estudantes sobre a matriz curricular, apontando, através de seus sentimentos, subsídios para uma reforma curricular.*

1. Introdução

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 supramencionada, 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 implantar uma proposta de matriz curricular é comum surgirem problemas que resultam na necessidade de ajustes. Considerando-se, *e.g.*, 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 and 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.

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 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 et al. 2013, Narayanan et al. 2009, Santos et al. 2018]. A técnica é considerada desafiadora e muito útil, tendo como principal objetivo identificar uma opinião, em relação a um tema em questão, para medi-la como positiva, negativa ou neutra.

2. Análise de Sentimentos

Segundo Liu [Liu 2012], a Análise de Sentimentos (AS) 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 and Yi 2003], e que o termo mineração de opinião tenha aparecido pela primeira vez em [Dave et al. 2003]. No entanto, cabe destacar que a pesquisa sobre sentimentos e opiniões já havia aparecido anteriormente nos trabalhos de [Das and Chen 2007, Tong 2001, Turney 2002, Wiebe et al. 2000].

De acordo com [Liu 2012], *e.g.*, a análise de sentimentos pode ser realizada em três níveis de granularidade distintos, a saber, *i) 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; *ii) 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; e *iii*) **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.

Segundo [Silva et al. 2012], o processo de análise pode ser dividido nas quatro etapas ilustradas na Figura 1. 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.

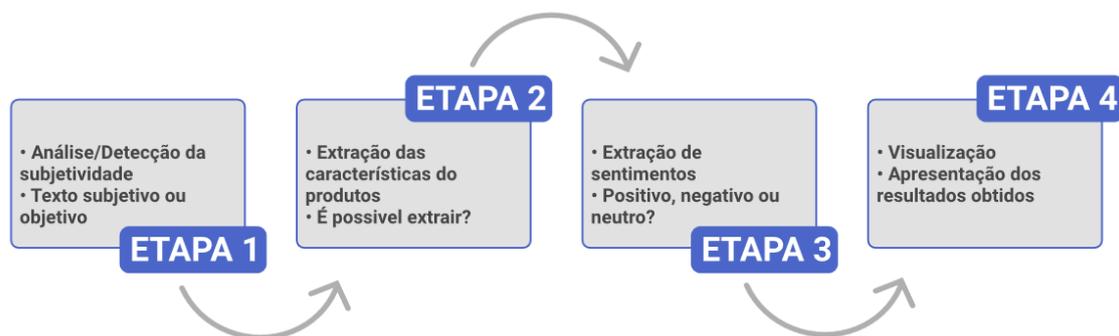


Figura 1. Etapas do processamento da técnica de análise de sentimentos.

3. Trabalhos Relacionados

Em [Altrabsheh et al. 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).

Ainda nesta vertente, a pesquisa realizada por [Nasim et al. 2017] apresenta uma combinação de aprendizado de máquina (AM) e abordagens baseadas em léxico para analisar o *feedback* dos alunos com a técnica de AS. Os *feedbacks* coletados provêm 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.

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 2 ilustra a metodologia deste estudo, particionada nas seguintes etapas:



Figura 2. Metodologia para coleta e processamento das informações.

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 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.

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* dos 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.

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: *i) 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*; *ii) 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; *iii) stopwords*: consiste na remoção de palavras e termos considerados irrelevantes para a análise, a exemplo de artigos e numerais. 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.

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 NB, RF e SVM. 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.

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.

5.1. Análise dos modelos de aprendizagem

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%

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 3, possibilita uma visão geral do *feedback* dado pelos alunos, sendo ainda possível analisar os resultados por *campus* a partir dos filtros disponibilizados.

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 2 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.

6. Conclusão e Trabalhos Futuros

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 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

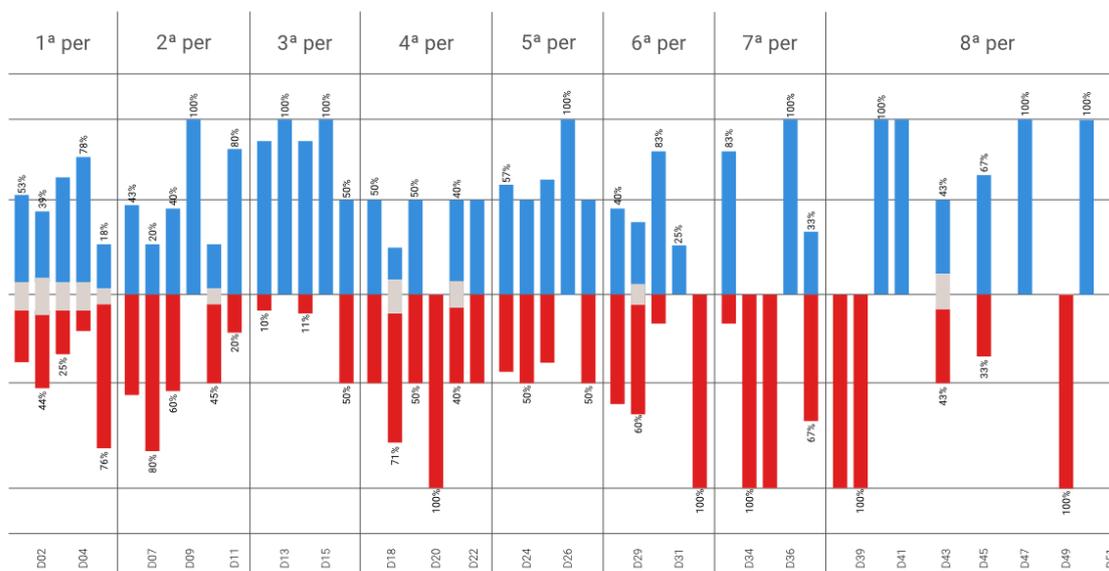


Figura 3. Sentimento em relação às disciplinas dos cursos analisados, considerando cada semestre/periódodo.

QUESTÕES	ARACATI	MARACANAÚ	TI-ANGUÁ
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%

Tabela 2. Escala de feedback dos alunos.

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., and Haig, E. (2013). Sa-e: Sentiment analysis for education. *Frontiers in Artificial Intelligence and Applications*, 255:1–10.
- Araújo, M., Gonçalves, P., and Benevenuto, F. (2013). Measuring sentiments in online social networks. In *19th Brazilian Symposium on Multimedia and the Web*, pages 97–104, Salvador, BA, Brazil. ACM.
- Das, S. and Chen, M. (2007). Yahoo! for amazon: Sentiment extraction from small talk on the web. *Management Science*, 53:1375–1388.
- Dave, K., Lawrence, S., and Pennock, D. M. (2003). Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. In *12th International Conference on World Wide Web*, page 519–528, New York, NY, USA. ACM.
- Ferreira, J. (2014). *Google Apps Script: Web Application Development Essentials*. O’Reilly, Newton, MA, USA.
- Ferreira, R. A. and Ramos, L. O. (2018). O projeto da MP nº 746: entre o discurso e o percurso de um novo ensino médio. *Ensaio: Avaliação e Políticas Públicas em Educação*, 26(101):1176–1196.
- Liu, B. (2012). Sentiment analysis and opinion mining. *Synthesis lectures on human language technologies*, 5(1):1–167.
- Narayanan, R., Liu, B., and Choudhary, A. (2009). Sentiment analysis of conditional sentences. In *Conference on Empirical Methods in Natural Language Processing*, page 180–189, USA. Association for Computational Linguistics.
- Nasim, Z., Rajput, Q., and Haider, S. (2017). Sentiment analysis of student feedback using machine learning and lexicon based approaches. In *2017 international conference on research and innovation in information systems (ICRIIS)*, pages 1–6, Langkawi, Malaysia. IEEE.
- Nasukawa, T. and Yi, J. (2003). Sentiment analysis: Capturing favorability using natural language processing. In *2nd International Conference on Knowledge Capture*, page 70–77, New York, NY, USA. ACM.
- Santos, G., Santos, M., Mota, V. F. S., Benevenuto, F., and Silva, T. H. (2018). Neutral or negative? sentiment evaluation in reviews of hosting services. In *Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia)*, page 347–354, Salvador, BA, Brasil. ACM.
- Silva, N. R., Lima, D., and Barros, F. (2012). SAPair: Um processo de análise de sentimento no nível de característica. *4th International Workshop on Web and Text Intelligence (WTI’12)*, page 2.
- Tong, R. (2001). An operational system for detecting and tracking opinions in on-line discussions. In *Workshop on Operational Text Classification Systems*, pages 1–6, New Orleans, LA, USA. ACM.
- Turney, P. D. (2002). Thumbs up or thumbs down?: semantic orientation applied to unsupervised classification of reviews. In *40th Annual Meeting on Association for Computational Linguistics*, pages 417–424, Philadelphia. Cornell University.

Wiebe, J. et al. (2000). *Learning subjective adjectives from corpora*. AAAI, Menlo Park, CA, USA.