

Análise de sentimentos em turmas de programação com vistas ao apoio à permanência estudantil

Ricardo J. Pfitscher¹, Luiz C. Camargo², Benjamin G. Moreira¹,
Carolina Wang¹, Rosilaine Zedral², Tatiana R. Garcia¹

¹Universidade Federal de Santa Catarina (UFSC)
Joinville – SC – Brasil

²Centro Universitário Católica de Santa Catarina
Joinville – SC – Brasil

ricardo.pfitscher@ufsc.br, lzcamargo@outlook.com

benjamin.moreira@ufsc.br, carolina.wang.ufsc@gmail.com

rosilaine.zedral@catolicasc.org.br, tatiana.garcia@ufsc.br

Abstract. *Student dropout is a relevant problem faced in Brazil's higher education. Different studies have sought to understand the student dropout problem using psycho-pedagogical or data-based methods. This work investigates using sentiment analysis in computer programming classes at two higher education institutions to mitigate student dropout. In the study, students' sentiments were actively collected and classified through a methodology that combined psycho-pedagogical and automated analysis based on Natural Language Processing. The main results of this study are i) a low adherence rate to the questionnaire (50%), with greater adherence when students are constantly encouraged; ii) sentiments are similar across higher education institutions, with between 20 and 30% being negative, and; iii) an accuracy of 68% with PLN, indicating possible use for actions to mitigate dropout.*

Resumo. *A evasão e a desistência são alguns dos principais problemas enfrentados no ensino superior do Brasil. Diferentes frentes de estudos têm buscado compreender os motivos pelos quais os estudantes desistem dos estudos, sejam estudos de ordem psicopedagógicas ou baseados em dados. Neste trabalho, a utilização da análise de sentimentos é direcionada à turmas de programação de computadores de duas instituições de ensino superior, em que dados foram coletados de forma ativa e classificados por meio de uma metodologia que combinou análise psicopedagógica e automatizada baseada em Processamento de Linguagem Natural. Os principais resultados deste estudo mostram: i) uma taxa de adesão baixa ao questionário (50%), com maior adesão quando os estudantes são constantemente incentivados; ii) os sentimentos são similares entre as instituições de ensino superior, com entre 20 e 30% sendo negativos, e; iii) uma acurácia de 68% com PLN, indicando possível utilização para ações de mitigação da desistência.*

1. Introdução

A 13ª edição do mapa do ensino superior realizado pelo Instituto Semesp [SEMESP 2023] mostra um resultado alarmante quanto à evasão escolar nas instituições de ensino superior

no Brasil. Em 2021, as taxas de evasão no ensino presencial alcançaram valores próximos a 27%, considerando instituições públicas e particulares. Em termos de desistência estudantil, o estudo mostra que dentre os ingressantes no ano de 2017, a taxa acumulada foi de 52% até 2021. Nesse contexto, os cursos que envolvem Tecnologia da Informação (TI) e Engenharia destacam-se como pontos de atenção [Cafardo 2023]: nos cursos de TI, 66,5% dos estudantes desistem do curso antes de acabar, nas engenharias a taxa de desistência foi de 56,3%.

Durante a realização de um curso de graduação, percebe-se que diversos alunos não conseguem completar o cronograma de determinadas disciplinas por vários motivos, como falta de motivação e dificuldade em compreender o conteúdo. A não conclusão da matéria, que configura um tipo de fracasso escolar, a desistência, configura um prejuízo pessoal e profissional para o aluno, assim como de resultado sobre a produtividade das universidades e sociedade [Nagai and Cardoso 2017]. Especialmente, as disciplinas de programação de computadores acrescentam dificuldades adicionais, que envolvem a quebra do paradigma do raciocínio puramente matemático para o pensamento lógico iterativo de uma máquina computacional. A consequência direta dessas disciplinas de programação são altas taxas de desistência e reprovação [Christo et al. 2018].

A evasão escolar apresenta consequências tanto para o sujeito/aluno (psicologicamente), quanto no retorno econômico e social que se espera da universidade. Para o aluno, quatro áreas podem ser afetadas: psicológica (depressão, ansiedade e ideias suicidas), física (alterações no sono e hipertensão), escolar (atitudes negativas para as tarefas e diminuição do rendimento) e interpessoais (desmotivação, diminuição da qualidade de vida e irritabilidade) [Mallada 2011]. Do ponto de vista econômico, quando se trata de instituições privadas, há o evidente desperdício financeiro do aluno para com a universidade, para o caso das instituições públicas, a falta de retorno monetário a partir do investimento realizado pela universidade ao aluno, diminui a rentabilização desse processo, inviabilizando o crescimento no âmbito local até o nacional [Fialho and Prestes 2014]. A sociedade é prejudicada pelo desperdício do investimento, visto que as vagas, uma vez ocupadas pelos alunos evadidos, não necessariamente são preenchidas [Gaioso 2005].

Alguns trabalhos na literatura investigam o uso de inteligência artificial (IA) e análise de dados para prever ou estimar o risco de desistência estudantil e a evasão escolar [Buschetto Macarini et al. 2019, Queiroga et al. 2020, Queiroga et al. 2018, Morais et al. 2018, Manhães et al. 2012]. Normalmente, esses esforços de pesquisa treinam algoritmos de classificação com métricas coletadas passivamente, ou seja, sem necessária intervenção dos estudantes, tais como a quantidade de interações em um período, frequência na disciplina e notas. Tal abordagem de coleta passiva, apesar de apresentar bons resultados, pode não apontar objetiva ou subjetivamente intenções de desistência, uma vez que as técnicas consideram correlações de comportamento e não indicativos explícitos de satisfação com um curso ou disciplina.

Tendo em vista a ausência de indicadores mais explícitos das intenções dos estudantes, entende-se que abordagens de coleta ativa de sentimentos como em sistemas de recomendação e avaliação de serviços [Vinodhini and Chandrasekaran 2012] poderiam servir como indicadores adicionais ao sistemas de predição de desistência em disciplinas. Assim, este trabalho faz parte de um esforço de pesquisa para investigar o uso de informações relacionadas ao sentimento de estudantes, coletadas de forma ativa, com

vistas ao uso de ferramentas automatizadas para apoio à permanência estudantil. Mais especificamente, este artigo tem as seguintes contribuições: *i)* apresenta um método para coleta e classificação dos sentimentos dos estudantes de disciplinas de programação; *ii)* compara bases de dados para classificação de sentimentos em português; *iii)* analisa sentimentos coletados utilizando uma abordagem que combina avaliação psicopedagógica com ferramentas de IA, e; *iv)* compara os resultados das classificações automatizadas com as psicopedagógicas.

2. Trabalhos relacionados

O presente trabalho objetiva o uso de análise de sentimentos para determinar a desistência de estudantes, sendo os sentimentos coletadas de forma ativa. Trabalhos similares buscam identificar o desempenho do aluno, prevendo a aprovação/reprovação dos estudantes [Akçapınar et al. 2019], prever a evasão dos estudantes em cursos [Morais et al. 2018, Queiroga et al. 2020] ou prever sua retenção [da Silva Garcia et al. 2020, de Oliveira et al. 2021].

Com relação à análise de sentimentos, um mapeamento sistemático é apresentado em [Coto et al. 2022]. Em [Atiq and Loui 2022], é apresentado um estudo sobre as emoções de estudantes durante a realização de atividades de programação, com observações qualitativas. A análise de sentimentos apresentada em [Bóbobó et al. 2022] é utilizada para prever o risco de evasão com dados coletados de textos presentes em um ambiente virtual de aprendizagem.

3. Metodologia

A metodologia para a coleta e classificação de sentimentos dos estudantes está em constante aprimoramento, ensaios com diferentes turmas de disciplinas de programação de computadores em duas instituições de ensino foram efetuados no segundo semestre de 2022. Para esses ensaios, discutiu-se a forma de como conduzir a coleta de dados, o que resultou na coleta ativa por meio de um formulário online, o qual foi aplicado em três turmas de programação de computadores, duas de uma instituição pública e a terceira de uma instituição comunitária. O propósito da coleta de dados foi explicado às turmas de modo presencial e por meio de mensagens postadas na plataforma online, demonstrações de como responder a pergunta foram realizadas para ressaltar o anonimato dos respondentes. A pergunta utilizada no formulário do ensaio em 2022:

Como você está se sentindo em relação a disciplina e a universidade?

Como principais resultados do ensaio observou-se que *i)* a adesão dos estudantes ao questionário foi de cerca de 27%, portanto baixa; *ii)* foi preciso revisar a pergunta, uma vez que há a presença dos termos disciplina e universidade explicitamente; *iii)* é indispensável a participação da psicopedagogia no desenvolvimento da metodologia, sobretudo no auxílio a readequação do questionário e na classificação de sentimentos.

Assim, com o auxílio psicopedagógico, ajustes foram feitos na metodologia para coleta e análise de dados do primeiro semestre de 2023, em que um novo questionário foi elaborado contendo duas perguntas:

- pergunta obrigatória - *Como você está se sentindo em relação à disciplina?*

- pergunta não obrigatória - *Como você está se sentindo em relação à universidade?*

Foi estabelecido que o questionário seria aplicado antes da primeira avaliação e após uma ou mais avaliações das disciplinas de programação. O processo de coleta de dados do primeiro semestre de 2023 ainda está em andamento, mas há dados da primeira rodada do questionário com respostas de cinco turmas de programação.

3.1. Coleta ativa de sentimentos

A coleta ativa de sentimentos foi realizada por meio de um questionário com perguntas abertas, de modo que os estudantes elaborassem suas respostas de forma livre, formando frases. No entanto, essas frases podem apresentar termos que remetem a sentimentos, mas também podem não apresentar. Termos que significam emoção também podem estar presentes nas respostas o que dificulta a coleta de sentimentos, por vezes pode-se confundir emoções com sentimentos.

De acordo com [Da Silva 2002, Elisa G 2017], emoções são respostas comportamentais e cognitivas automáticas, geralmente inconscientes, disparadas quando o encéfalo detecta um estímulo significativo, positiva ou negativamente carregado. Enquanto que sentimento é para se referir à experiência consciente dessas alterações somáticas e cognitivas. Portanto, sentimento é o significado que o cérebro dá para a experiência fisiológica que a emoção gerou.

3.2. Classificação psicopedagógica

A classificação psicopedagógica foi realizada de modo manual por duas psicopedagogas, que empiricamente buscaram distinguir termos de sentimentos dos demais em cada frase das respostas dos estudantes. Para esta classificação, primeiramente as avaliadoras definiram as categorias e estabeleceram as listas de itens sobre os aspectos positivos e negativos na experiência com o curso/universidade utilizando a análise de conteúdo [Bardin 1977], que é uma análise qualitativa do discurso manifesto da comunicação.

Depois, foi realizada uma pré-análise flutuante, sendo a primeira leitura de contato com as transcrições e foram estabelecidos, em leituras posteriores, os núcleos de sentido constituídos e revelados pelas respostas, agrupando, por fim, os significados em categorias.

3.3. Ferramentas de classificação baseadas em PLN

Como a coleta de sentimentos foi realizada por meio de questionários abertos com respostas livres, foi necessário empregar ferramentas de Processamento de Linguagem Natural (PLN) para análise dos dados. Visando ao desenvolvimento de um modelo adequado, optou-se por uma arquitetura de rede neural recorrente *Long Short Term Memory* (LSTM) que é capaz de capturar dependências de longo prazo permitindo melhor entendimento do contexto das palavras [Hochreiter and Schmidhuber 1997].

Inicialmente, é necessária uma etapa de pré-processamento dos dados coletados, que envolve limpeza de caracteres considerados indesejáveis ou sem informação útil para a análise. Em seguida, aplica-se a ferramenta *Tokenizer* para dividir os textos em unidades menores chamadas de *tokens*, de forma a segmentar o texto em unidades significativas e

prepará-lo para análise posterior. Esses *tokens* são aplicados a uma camada de *Embedding*, responsável por mapeá-las em um espaço vetorial numérico de acordo com suas relações semânticas e contexto, auxiliando a rede na interpretação dos dados.

Por fim, é aplicada função de ativação *Softmax* [Bridle 1990] na camada de saída do modelo, essa função é encarregada de converter as saídas do modelo em uma distribuição de probabilidade sobre as classes de classificação. Sendo assim, ao utilizar os modelos treinados, a saída gerada apresenta qual a probabilidade da entrada está associada a uma determinada classificação.

3.3.1. Bases de dados da literatura

Para realizar o treinamento das redes, buscou-se na literatura bases de dados existentes que rotulam palavras, termos, expressões ou frases em negativo e positivo. Nesta pesquisa, foram encontrados diversos *datasets* disponíveis, tanto em inglês como em português e que efetuavam a classificação em positivo, negativo, neutro ou ambos. Cada uma dessas bases era composta por informações extraídas de diferentes fontes, por exemplos resenhas na internet, livros, pesquisas de satisfação, postagens em redes sociais entre outros. O resumo das bases encontradas na literatura está disponível na Tabela 1.

Tabela 1. Resumo das bases de dados de sentimentos encontradas

Nome	Idioma	Descrição	Classificação	Numero de itens
IMDb PT-BR[Gonçalves 2018]	PT - BR	Resenhas de filmes no IMDb com polaridades opostas.	positivo e negativo	50.000
Large Movie Review Dataset (IMDb) [Maas et al. 2011]	Inglês	Resenhas de filmes no IMDb com polaridades opostas para formar o banco de dados	positivo e negativo	50.000
Linguistic Inquiry and Word Count (LIWC) [Pennebaker Conglomerates 2023]	Inglês	Software de análise linguística consolidado	positivo e negativo	615 palavras de emoção
LIWC-PT [Balage Filho et al. 2013]	PT - BR	Tradução automática da versão em inglês, conta com 64 categorias	positivo e negativo	615 palavras de emoção
OpLexicon [Souza and Vieira 2012]	PT - BR	Léxico de opinião em português do Brasil desenvolvido pela Universidade Federal de São Carlos.	positivo, negativo e neutro	32.000
ReLi [Freitas et al. 2012]	PT - BR	Resenhas de diversas obras literárias de diversos autores	positivo, negativo e ambos	259.978 palavras e 12.470 frases
Senticnet [Poria et al. 2014]	PT - BR	Palavras e termos classificadas em positivo e negativo	positivo e negativo	132.824
SentiLex-PT 02 [Carvalho and Silva 2015]	PT - BR	Classificação que inclui informações sobre: lema, a flexão em gênero e número do lema, categoria gramatical, polaridade e como foi atribuída a polaridade	positivo, negativo e neutro	7.014 lemas e 82.347 formas flexionadas
Sentiment140 [Alec Go and Huang]	Inglês	Tweets que expressavam opiniões sobre diversas categorias: companhias, eventos, locais, filmes, pessoas e produtos	positivo, negativo e neutro	500 tweets
Student Feedback Dataset [Brar]	Inglês	Feedback de estudantes de uma universidade na Índia, dividido em seis categorias.	positivo, negativo e neutro	1.105

Após análise abrangente, optou-se para, nesse primeiro estudo, utilizar duas bases distintas para criar dois modelos de classificação. Foram selecionadas as duas maiores bases em português e que apresentam classificação binária, ou seja, os dados são catalogados somente entre positivo ou negativo. A primeira delas foi baseada em resenhas de filmes do site IMDb [Gonçalves 2018], esses dados consistem em frases completas assim como os dados de coleta deste estudo. A segunda base escolhida foi da companhia SenticNet [Cambria et al. 2022, Poria et al. 2014], composta apenas por palavras e termos individuais. Em trabalhos futuros, pretende-se investigar com maior profundidade o uso das demais bases para geração de modelos de PLN.

4. Resultados

Nesta seção, são apresentados os resultados com as coletas de dados, classificação psicopedagógica e classificação baseada em PLN.

4.1. Visão geral das respostas

O resultado obtido com a coleta de dados nos semestres 2022/2 (considerado como ensaio) e 2023/1 é apresentado na Tabela 2. Nessa tabela, pode-se observar que a adesão dos estudantes em responder o questionário em 2022/2 é baixa (27%), considerando a média de 45 estudantes por turma contra a média 12,3 respostas por turma. As coletas de dados foram retomadas no primeiro semestre de 2023, seguindo a metodologia apresentada na Seção 3 e sendo a quantidade média de estudantes dessas turmas igual à 46, e a quantidade média de respostas por turma 23,4. Isto significa adesão média de 51% dos estudantes ao questionário. Ao comparar a adesão dos estudantes à coleta de dados de 2022/2 (ensaio) com a de 2023/1, tem-se aumento de 52%, embora seja uma amostra significativa, ainda é necessário promover o engajamento dos estudantes a coleta ativa de dados.

Tabela 2. Resultados das Coletas de Dados

Turma	Disciplina	Instituição	Resp. 2022/2	Resp. 2023/1
turma 1	Programação Computadores I	Pública	8	21
turma 2	Programação Computadores I	Pública	20	23
turma 3	Programação Computadores I	Pública	-	39
turma 4	Programação Embarcados	Comunitária	9	-
turma 5	Programação Server-side	Comunitária	-	23
turma 6	Programação Server-side	Comunitária	-	11
Total			37	117

Na Seção 4.2 é apresentada a quantificação da classificação psicopedagógica dos dados coletados em 2023/1.

4.2. Classificação psicopedagógica

A classificação psicopedagógica foi realizada sobre os dados coletados em 2023/1 (Tabela 2), com uma profissional da área psicopedagógica de cada instituição avaliando as respectivas respostas dos estudantes. Por questões de espaço, os sentimentos e emoções extraídos das respostas fornecidas pelos estudantes foram categorizadas em cinco categorias: *muito satisfeito*, *satisfeito*, *indiferente*, *insatisfeito* e *muito insatisfeito*. Ainda, decidiu-se por não avaliar, neste trabalho, as respostas relacionadas à instituição. Os sentimentos agrupados em cada categoria foram:

- *Muito satisfeito* - Animado, aprendendo muito, cheio de expectativas, contente, curioso, desafiado a aprender, empolgado, entusiasmado, especial pela oportunidade, esperançoso, feliz, gostando, gostando muito, motivado e otimista;
- *Satisfeito* - Adaptando, bacana, bem, confiante, confortável, “de boa”, muito bem, interessante, satisfeito e tranquilo;
- *Indiferente* - Indiferente;
- *Insatisfeito* - Ansioso, insatisfeito e lento;
- *Muito insatisfeito* - Com dificuldades, com medo, complicado, complexo, desanimado, lento, perdido, perplexo e receoso.

O resultado da classificação dos sentimentos expressos pelos estudantes pode ser observada na Tabela 3. É importante destacar que uma mesma resposta pode conter mais de um sentimento ou emoção, por isso a quantidade de sentimentos difere do total de respostas.

Tabela 3. Resultado da classificação psicopedagógica das respostas quanto à disciplina

Categoria	Respostas IES Pública	Respostas IES Comunitária
Muito satisfeito	35 (33,3%)	45 (32,1%)
Satisfeito	47 (44,7%)	46 (32,9%)
Indiferente	-	1 (0,7%)
Insatisfeito	5 (4,8%)	11 (7,9%)
Muito insatisfeito	18 (17,1%)	37 (26,3%)
Total	105	140

4.3. Classificação baseada em PLN

A fim de avaliar e validar os resultados gerados pelos modelos, todos os dados coletados foram manualmente classificados sem viés psicopedagógico. Foi estabelecido um conjunto de categorias de classificação para orientar esse processo:

- *Positivo*: respostas exclusivamente positivas;
- *Negativo*: respostas exclusivamente negativas;
- *Ambos*: respostas com menções positivas e negativas;
- *Neutro*: respostas sem identificação de informação polarizada ou respostas que a depender do contexto poderiam ser vistas como positivas ou negativas.

A partir disso, todas os dados coletados nos dois semestres que contemplam este estudo (2022/2 e 2023/1) foram submetidos aos dois modelos desenvolvidos (um treinado para cada base de dados discutida na Seção 3.3.1). Então, a partir das respostas acusadas pelos modelos, ainda foi gerado um último método de classificação adicional:

- Caso os dois modelos acusassem positivo: positivo;
- Caso os dois modelos acusassem negativo: negativo;
- Caso um modelo acusasse positivo e outro negativo: escolheu-se aquele que apresentasse maior porcentagem de probabilidade;
- Caso um modelo acusasse 100% positivo e outro 100% negativo, optou-se por classificar como negativo levando em consideração o pior cenário no contexto de desistência estudantil.

Com as classificações feitas, analisou-se a acurácia de cada modelo com base na classificação manual, tanto para a base de respostas sobre a universidade quanto sobre as disciplinas. Respostas neutras ou em branco não foram contabilizadas e respostas manualmente classificadas como “ambas” foram consideradas negativas pensando novamente no pior cenário do contexto de desistência estudantil. Por fim, utilizou-se uma métrica simples de acurácia que consiste na divisão das respostas que coincidiram com a classificação manual pelo total de respostas avaliadas, gerando três conjuntos de respostas com suas respectivas acurácias:

- SenticNet: 66,98%

- IMDb: 63,58%
- Classificação pela combinação dos modelos: 68,21%

Para obter uma visão mais ampla desta classificação, as respostas do algoritmo combinado foram detalhadas em uma matriz de confusão, a Tabela 4 apresenta esta matriz. Os resultados do detalhamento da classificação mostram um acerto na predição para 116 respostas, sendo 87 verdadeiros positivos (47,8%) e 29 verdadeiros negativos (15,9%), o que corresponde a uma acurácia de 63,7%. Os falsos positivos somaram 20 respostas e os falsos negativos 22 predições, correspondendo a 11 e 12% do total, respectivamente. Ao calcular a métrica de especificidade, que corresponde a força do modelo em prever resultados negativos, encontra-se um valor igual a 59%, o que indica que o modelo acerta a maioria dos casos negativos, mas há espaço para melhorias no modelo de classificação.

Tabela 4. Matriz de confusão para as classificações das respostas a respeito da disciplina pela combinação dos dois modelos

		Classe da resposta			
		Positivo	Negativo	Neutro	Ambos
Classe predita	Positivo	87	20	3	11
	Negativo	22	29	1	9

Também é possível observar na matriz de confusão que o modelo classificou as 24 (13%) respostas manualmente classificadas em “Neutro” ou “Ambos” para as classes “Positivo” ou “Negativo”, isto se deve ao fato do modelo não ter sido treinado para estas classes, ainda, é importante notar que quando a frase de resposta tinha ambas as menções negativas e positivas, o modelo fez uma divisão equilibrada entre positivo e negativo, o que indica dificuldade de classificação automatizada das mesmas.

Ao considerar o pior cenário do contexto de desistência estudantil, os falsos negativos e as classificações de frases com ambas as conotações como negativas não são tão ruins, uma vez que podem chamar a atenção de interessados para o problema da desistência. Por outro lado, os falsos positivos e a classificação positiva para casos dúbios podem pesar uma avaliação dos resultados, pois podem indicar ao interessado que a situação da turma está “tudo bem”, quando de fato, é o contrário.

Para tentar compreender se existe alguma relação explícita entre as respostas negativas e as taxas de desistência das turmas, comparou-se a taxa de desistência em cada turma com o percentual de respostas classificadas como negativas ou “ambas”. A Tabela 5 mostra esta comparação.

Tabela 5. Relação entre respostas com conotação negativa ou ambos e a taxa de desistência

Turma	Acurácia modelo	% negativo ou ambos	Taxa de desistência
turma 1	66,6%	38,1%	6,7%
turma 2	82,6%	34,8%	20,0%
turma 3	59,0%	25,6%	25,6%
turma 5	69,5%	34,8%	19,0%
turma 6	100%	36,4%	13,0%

Os resultados da Tabela 5 corroboram com os números apresentados em [Cafardo 2023], no que diz respeito a desistência em cursos de TI e engenharias, com taxas entre 6,7% e 25,6%. Ainda, destaca-se que as turmas apresentaram números próximos de sentimentos classificados como negativos, entre 25,64% e 38,10%. Contudo, apesar de, na maioria dos casos, os valores sugerirem que eles podem auxiliar na mitigação da desistência ao permitir que entidades interessadas utilizem estes dados para tomar ações antes da desistência, não é possível observar uma correlação explícita entre a expressão de sentimentos negativos e a taxa de desistência. Por exemplo, enquanto a turma 1 teve uma baixa taxa de desistência (6,7%) e 38% das respostas com conotação negativa, a turma 2, com o mesmo professor, teve uma menor quantidade de respostas com conotação negativa (34,8%) e maior taxa de desistência (20%).

4.4. Discussão

Apesar do estudo realizado neste trabalho apresentar resultados que se mostram promissores para o uso de sentimentos dos estudantes para apontar necessidades de intervenção dos professores, seja com base na análise psicopedagógica, seja com base em ferramentas automatizadas baseadas em PLN, existem alguns limites do estudo a serem discutidos.

Os resultados apresentados neste trabalho estão sujeitos à subjetividade. A análise de sentimentos empírica realizada pelas profissionais da área psicopedagógica dependem da sua observação sobre o significado da frase. Ainda, a classificação desses sentimentos em categorias também implicam em viés, uma vez que alguém poderia considerar que o sentimento *ansioso* poderia significar muita insatisfação ou ainda satisfação (a depender do contexto da frase). A mesma subjetividade vale para a classificação das respostas para aplicação das técnicas baseadas em PLN, pois esta também está sujeita a subjetividade.

Ausência de relação explícita entre a desistência e a resposta negativa. O estudo foi realizado considerando como premissa o anonimato de quem responde o questionário, o que na intenção dos pesquisadores, incentivaria os estudantes a responderem, pois inibiria o receio por represálias. Por consequência, não é possível determinar correlação explícita entre respostas com sentimentos negativos e a taxa de desistência, mesmo que houvesse correlação estatística nos dados. Assim, para que se tenha estimativas mais precisas da desistência, é necessário avaliar se o indivíduo que respondeu de forma negativa de fato desistiu. Para isso, tem-se como um trabalho futuro, o desenvolvimento um mecanismo que permita relacionar o indivíduo com sua resposta e seu andamento no curso sem identificá-lo ao professor (para garantir a anonimidade).

5. Conclusões

A evasão e a desistência estudantil são problemas críticos no ensino superior do Brasil, especialmente nos cursos de TI e engenharia que apresentam as maiores taxas de desistência segundo o último Censo da Educação Superior. Com vistas a promover ferramentas para mitigar a desistência e apoiar a permanência estudantil em turmas de programação, esta pesquisa investigou a análise de sentimentos coletados de forma ativa de estudantes. O estudo coletou respostas de estudantes em seis turmas de programação de duas instituições de ensino, sendo uma comunitária e outra pública. As respostas foram avaliadas tanto por equipe psicopedagógica quanto por ferramenta automatizada com inteligência artificial.

As principais conclusões deste trabalho foram: *i*) os estudantes apresentam maior adesão para expressar seus sentimentos sobre a disciplina quando são periodicamente instigados a fazê-lo; *ii*) existe baixo engajamento dos estudantes, mesmo eles sendo instigados a responder a taxa de respostas foi em torno de 50% em cada turma; *iii*) a análise psicopedagógica dos sentimentos mostrou resultados similares entre a instituição pública e a instituição comunitária, e; *iv*) a análise automatizada pode auxiliar a apontar possíveis problemas ou dificuldades na turma, uma vez que mostrou acurácia de 68% para uma classificação binária dos sentimentos (positivo ou negativo), com baixa quantidade de falsos positivos (11%).

Quanto aos trabalhos futuros, propõe-se duas frentes: aprimorar a coleta de sentimentos com vistas a melhorar o engajamento e investigar as possíveis correlações entre as desistências e suas razões com os sentimentos respondidos nos questionários. No segundo contexto, espera-se combinar dados coletados passivamente, como frequência, acesso a materiais, notas com os sentimentos extraídos automaticamente para desenvolver ou aprimorar modelos que estimam o risco da desistência estudantil.

Referências

- Akçapınar, G., Altun, A., and Aşkar, P. (2019). Using learning analytics to develop early-warning system for at-risk students. *International Journal of Educational Technology in Higher Education*, 16(1):1–20.
- Alec Go, R. B. and Huang, L. Sentiment140 - a twitter sentiment analysis tool. url=<http://help.sentiment140.com/for-students>. [Online, acessado em Julho de 2023].
- Atiq, Z. and Loui, M. C. (2022). A qualitative study of emotions experienced by first-year engineering students during programming tasks. *ACM Transactions on Computing Education (TOCE)*, 22(3):1–26.
- Balage Filho, P., Pardo, T. A. S., and Aluísio, S. (2013). An evaluation of the brazilian portuguese liwc dictionary for sentiment analysis. In *Proceedings of the 9th Brazilian Symposium in Information and Human Language Technology*.
- Bardin, L. (1977). *Análise de conteúdo*. Lisboa: edições 70.
- Bóbob, M. L., Campos, F., Stroele, V., David, J. M. N., Braga, R., and Torrent, T. T. (2022). Using sentiment analysis to identify student emotional state to avoid dropout in e-learning. *International Journal of Distance Education Technologies (IJDET)*, 20(1):1–24.
- Brar, A. Student feedback dataset. url=<https://www.kaggle.com/datasets/brarajit18/student-feedback-dataset>. [Online, acessado em Julho de 2023].
- Bridle, J. S. (1990). Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In Soulié, F. F. and Héroult, J., editors, *Neurocomputing*, pages 227–236, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Buschetto Macarini, L. A., Cechinel, C., Batista Machado, M. F., Faria Culmant Ramos, V., and Munoz, R. (2019). Predicting students success in blended learning—evaluating different interactions inside learning management systems. *Applied Sciences*, 9(24):5523.

- Cafardo, R. (2023). Mais da metade dos alunos desistem da faculdade no brasil, por que ti tem um dos maiores abandonos?
- Cambria, E., Liu, Q., Decherchi, S., Xing, F., and Kwok, K. (2022). Senticnet 7: A commonsense-based neurosymbolic ai framework for explainable sentiment analysis. In *Proceedings of the Language Resources and Evaluation Conference*, pages 3829–3839, Marseille, France. European Language Resources Association.
- Carvalho, P. and Silva, M. J. (2015). Sentilex-pt: Principais características e potencialidades. *Oslo Studies in Language*, 7(1).
- Christo, M. M. S., de Resende, L. M. M., and Kuhn, T. d. C. G. (2018). Por que os alunos de engenharia desistem de seus cursos—um estudo de caso. *Nuances: estudos sobre Educação*, 29(1).
- Coto, M., Mora, S., Grass, B., and Murillo-Morera, J. (2022). Emotions and programming learning: systematic mapping. *Computer Science Education*, 32(1):30–65.
- Da Silva, C. L. (2002). Emoções e sentimentos na escola: uma certa dimensão do domínio afetivo. Master's thesis, Universidade Federal da Bahia.
- da Silva Garcia, L. M. L., Lara, D. F., and Antunes, F. (2020). Análise da retenção no ensino superior: um estudo de caso em um curso de sistemas de informação. *Revista da Faculdade de Educação*, 34(2):15–38.
- de Oliveira, C. F., Sobral, S. R., Ferreira, M. J., and Moreira, F. (2021). How does learning analytics contribute to prevent students' dropout in higher education: a systematic literature review. *Big Data and Cognitive Computing*, 5(4):64.
- Elisa G, P. (2017). *O universo das emoções: uma introdução*. Libellus, 1 ed. edition.
- Fialho, M. D. and Prestes, E. M. d. T. (2014). Evasão escolar no curso de pedagogia da ufpb: na compreensão dos gestores educacionais. *Gestão & Aprendizagem*, 3(1):42–63.
- Freitas, C., Motta, E., Milidiú, R., and César, J. (2012). Vampiro que brilha... rá! desafios na anotação de opiniao em um corpus de resenhas de livros. *Encontro de Linguística de Corpus*, 11:22.
- Gaioso, N. P. d. L. (2005). O fenômeno da evasão escolar na educação superior no brasil. *Brasília, DF: Universidade Católica de Brasília*, page 20.
- Gonçalves, L. (2018). Imdb pt-br. url=<https://www.kaggle.com/datasets/luisfredgs/imdb-ptbr>. [Online, acessado em Junho de 2023].
- Hochreiter, S. and Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8):1735–1780.
- Maas, A. L., Daly, R. E., Pham, P. T., Huang, D., Ng, A. Y., and Potts, C. (2011). Learning word vectors for sentiment analysis. In *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*, pages 142–150, Portland, Oregon, USA. Association for Computational Linguistics.
- Mallada, F. J. R. (2011). La gestión del absentismo escolar. *Anuario Jurídico y Económico Escurialense*, (44):579–596.

- Manhães, L. M. B., Da Cruz, S. M. S., Costa, R. J. M., Zavaleta, J., and Zimbrão, G. (2012). Previsão de estudantes com risco de evasão utilizando técnicas de mineração de dados. In *Brazilian symposium on computers in education (simpósio brasileiro de informática na educação-sbie)*, volume 1.
- Morais, A. M. d. et al. (2018). Abordagem avaliativa multidimensional para previsão da evasão do discente em cursos on-line.
- Nagai, N. P. and Cardoso, A. L. J. (2017). A evasão universitária: Uma análise além dos números. *Revista Estudo & Debate*, 24(1).
- Pennebaker Conglomerates, I. (2023). Liwc-22. url=<https://www.liwc.app/>. [Online, acessado em Julho de 2023].
- Poria, S., Cambria, E., Winterstein, G., and Huang, G.-B. (2014). Sentic patterns: Dependency-based rules for concept-level sentiment analysis. *Knowledge-Based Systems*, 69:45–63.
- Queiroga, E. M., Lopes, J. L., Kappel, K., Aguiar, M., Araújo, R. M., Munoz, R., Villarroel, R., and Cechinel, C. (2020). A learning analytics approach to identify students at risk of dropout: A case study with a technical distance education course. *Applied Sciences*, 10(11):3998.
- Queiroga, E. M., Lopes, J. L. B., de Araújo, R. M., and Cechinel, C. (2018). Modelo de predição da evasão de estudantes em cursos técnicos a distância a partir da contagem de interações. *Revista Thema*, 15(2):425–438.
- SEMESP (2023). Mapa do ensino superior - 13ª edição.
- Souza, M. and Vieira, R. (2012). Sentiment analysis on twitter data for portuguese language. In *Computational Processing of the Portuguese Language: 10th International Conference, PROPOR 2012, Coimbra, Portugal, April 17-20, 2012. Proceedings 10*, pages 241–247. Springer.
- Vinodhini, G. and Chandrasekaran, R. (2012). Sentiment analysis and opinion mining: a survey. *International Journal*, 2(6):282–292.