

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**O Papel da Polaridade e do Tópico em
Mensagens Privadas na Análise de
Trajetórias Acadêmicas:
Um Estudo de Caso**

Gabriella Carvalho

JUIZ DE FORA
JUNHO, 2026

O Papel da Polaridade e do Tópico em Mensagens Privadas na Análise de Trajetórias Acadêmicas: Um Estudo de Caso

GABRIELLA CARVALHO

Universidade Federal de Juiz de Fora
Instituto de Ciências Exatas
Departamento de Ciência da Computação
Bacharelado em Ciência da Computação

Orientador: Jairo Francisco de Souza

JUIZ DE FORA
JUNHO, 2026

O PAPEL DA POLARIDADE E DO TÓPICO EM MENSAGENS
PRIVADAS NA ANÁLISE DE TRAJETÓRIAS ACADÊMICAS:

Um Estudo de Caso

Gabriella Carvalho

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA , COMO PARTE INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Jairo Francisco de Souza
Doutor em Informática - PUC-Rio

Renê Rodrigues Veloso
Doutor de Ciência da Computação - UFMG

Pedro Henrique Gasparetto Lugão
Doutor em Modelagem Computacional - LNCC

JUIZ DE FORA
25 DE JUNHO, 2026

*Ao meu pai, Paulo, ao meu irmão, Mattheus,
à minha mãe, Alexandra, às minhas tias, Glauce
e Elaine, ao meu tio, Márcio, e aos meus ami-
gos pelo apoio, carinho, inspiração e força ao
longo desta caminhada.*

Resumo

Este estudo de caso investiga as mensagens privadas do Moodle como fonte complementar para o monitoramento de trajetórias acadêmicas em cursos de educação a distância. Foram analisadas mensagens de estudantes classificados como *Formados* e *Evadidos*, combinando análise de sentimentos e modelagem de tópicos. Os resultados indicam baixa concordância entre os métodos de análise de sentimentos e associações fracas entre as classificações agregadas por estudante e os indicadores educacionais. A modelagem de tópicos mostrou que as mensagens tratam principalmente de demandas acadêmico-administrativas, como notas, prazos e dificuldades técnicas. O principal achado é que medidas genéricas de sentimento possuem utilidade limitada quando empregadas isoladamente, enquanto a identificação dos temas contribui para contextualizar dificuldades e demandas dos estudantes. Por se tratar de um estudo de caso, os resultados não permitem generalizações amplas, mas evidenciam seu potencial como fonte complementar para o acompanhamento pedagógico e reforçam a importância de centralizar e qualificar os registros de comunicação no AVA, de modo que possam apoiar estratégias institucionais de monitoramento, permanência e suporte aos estudantes.

Palavras-chave: Moodle; análise de sentimentos; educação a distância; Learning Analytics.

Abstract

This case study investigates Moodle private messages as a complementary source for monitoring academic trajectories in distance education courses. Messages from students classified as *Graduated* and *Dropout* were analyzed using a combination of sentiment analysis and topic modeling. The results indicate low agreement among the sentiment analysis methods and weak associations between student-level aggregated classifications and educational indicators. Topic modeling showed that the messages mainly address academic and administrative demands, such as grades, deadlines, and technical difficulties. The main finding is that generic sentiment measures have limited usefulness when used in isolation, whereas topic identification helps contextualize students' difficulties and demands. As this is a case study, the results do not support broad generalizations, but they highlight the potential of these messages as a complementary source for pedagogical monitoring and reinforce the importance of centralizing and improving the quality of communication records in the VLE so that they can support institutional strategies for monitoring, student retention, and student support.

Keywords: Moodle; sentiment analysis; distance education; Learning Analytics.

Agradecimentos

Agradeço, primeiramente, a Deus, pela força concedida ao longo desta caminhada.

Ao meu pai, Paulo, por todos os dias e noites em que esteve ao meu lado, fazendo tudo o que estava ao seu alcance para que eu pudesse me dedicar aos estudos. Ao meu irmão, Mattheus, pela inspiração e pelo apoio para seguir na área. À minha mãe, Alexandra, pelas constantes orações e pelo apoio. Às minhas tias, Glauce e Elaine, e ao meu tio, Márcio, pelo cuidado, carinho e pelas oportunidades que me proporcionaram.

Agradeço também ao meu professor Jairo, por lidar com meus momentos de dificuldade com paciência e por sempre me incentivar a continuar. Aos meus amigos e, em especial, ao LApIC, por tornarem os dias mais leves e alegres, mesmo nos momentos mais difíceis.

Aos professores do Departamento de Ciência da Computação pelos seus ensinamentos e aos funcionários do curso, que durante esses anos, contribuíram de algum modo para o nosso enriquecimento pessoal e profissional.

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo apoio e incentivo à pesquisa, no âmbito do projeto APQ-04805-24, e ao Centro de Educação a Distância da Universidade Estadual de Montes Claros (CEAD/Unimontes), pelo apoio institucional e pela disponibilização dos dados necessários ao desenvolvimento deste estudo.

Por fim, e não menos importante, agradeço ao Clube de Regatas do Flamengo, pela alegria, pela emoção e pelo constante divertimento ao longo desta trajetória.

*“Omnia in bonum! Tudo é para bem!
Senhor, que outra vez e sempre se cum-
pra a tua sapientíssima Vontade!”*

Via Sacra (IX Estação)

Conteúdo

Lista de Figuras	8
Lista de Tabelas	9
Lista de Abreviações	10
1 Introdução	11
1.1 Problema de Pesquisa	12
1.2 Objetivos	14
1.2.1 Objetivo Geral	14
1.2.2 Objetivos Específicos	14
1.3 Justificativa	15
1.4 Organização do Trabalho	16
2 Trabalhos Relacionados	17
2.1 Ambientes Virtuais de Aprendizagem e acompanhamento estudantil	17
2.2 Análise de Aprendizagem em AVAs	18
2.3 Indicadores educacionais em AVAs	19
2.4 Análise de sentimentos em AVAs	20
2.4.1 Técnicas para análise de sentimentos	22
2.5 Síntese dos trabalhos relacionados e lacuna de pesquisa	24
3 Materiais e métodos	26
3.1 Contexto do estudo	26
3.2 Base de Dados	27
3.3 Definição dos grupos de análise	28
3.4 Indicadores educacionais previamente desenvolvidos	30
3.5 Mensagens textuais no Moodle	32
3.5.1 Seleção do corpus textual	33
3.5.2 Preparação das mensagens	34
3.5.3 Análise exploratória das mensagens privadas	35
3.6 Estratégias de análise de sentimentos	36
3.6.1 Abordagens lexicais para análise de sentimentos	36
3.6.2 Abordagem baseada em modelo pré-treinado para classificação de sentimentos	38
3.6.3 Análise de associação com os indicadores educacionais	39
3.7 BERTopic	39
4 Resultados	42
4.1 Caracterização dos indicadores educacionais por grupo	42
4.2 Análise de sentimentos	45
4.2.1 Impacto de alterações nas mensagens	48
4.3 Correlação entre Análise de Sentimentos e Indicadores Educacionais	49
4.4 Agrupamento de Mensagens por Tópico	50
4.5 Discussão de resultados	52

5 Conclusão	56
Bibliografia	59

Lista de Figuras

2.1	Técnicas de classificação de sentimentos. Fonte: (MEDHAT; HASSAN; KORASHY, 2014)	23
3.1	Visão geral das etapas metodológicas adotadas no estudo.	27
3.2	Heurística utilizada para a definição dos grupos de análise a partir do histórico acadêmico dos estudantes.	29
4.1	Distribuição dos rótulos de sentimento por método e grupo nas mensagens privadas.	45
4.2	Correlações de Spearman entre as medidas agregadas de sentimento e os indicadores educacionais por estudante.	50

Lista de Tabelas

2.1	Síntese dos corpora textuais utilizados em estudos relacionados	22
2.2	Estudos e principais técnicas utilizadas na análise de sentimentos	24
3.1	Síntese dos indicadores educacionais utilizados no estudo	31
3.2	Presença comunicacional por grupo nas mensagens privadas	35
4.1	Estatísticas descritivas das métricas associadas aos indicadores educacionais por grupo	43
4.2	Exemplos representativos de divergência e consenso entre métodos de análise de sentimentos S=Sentilex-PT, O=OpLexicon, T=TextBlob, V=VADER, X=XML-RoBERTa, e m=mBert.	47
4.3	Nível de divergência entre métodos de análise de sentimentos por grupo . .	47
4.4	Síntese e dimensão dos principais tópicos identificados pelo BERTopic . . .	51

Lista de Abreviações

AVA	Ambiente Virtual de Aprendizagem
BERT	<i>Bidirectional Encoder Representations from Transformers</i>
c-TF-IDF	<i>class-based Term Frequency-Inverse Document Frequency</i>
DCC	Departamento de Ciência da Computação
EaD	Educação a Distância
HDBSCAN	<i>Hierarchical Density-Based Spatial Clustering of Applications with Noise</i>
LA	<i>Learning Analytics</i>
MOOCs	<i>Massive Open Online Courses</i>
mBERT	<i>Multilingual Bidirectional Encoder Representations from Transformers</i>
PLN	Processamento de Linguagem Natural
SVM	<i>Support Vector Machine</i>
TF-IDF	<i>Term Frequency-Inverse Document Frequency</i>
UAB	Universidade Aberta do Brasil
UFJF	Universidade Federal de Juiz de Fora
UMAP	<i>Uniform Manifold Approximation and Projection</i>
Unimontes	Universidade Estadual de Montes Claros
VADER	<i>Valence Aware Dictionary and sEntiment Reasoner</i>
XLM-RoBERTa	<i>Cross-lingual Language Model RoBERTa</i>

1 Introdução

O avanço das tecnologias digitais transformou diferentes dimensões da vida social, incluindo os processos de ensino e aprendizagem. No contexto educacional, a incorporação de recursos digitais favoreceu a consolidação da aprendizagem eletrônica, ou *e-learning*, entendida como parte das novas dinâmicas dos sistemas educacionais contemporâneos (SANGRÀ; VLACHOPOULOS; CABRERA, 2012), bem como o fortalecimento dos Ambientes Virtuais de Aprendizagem (AVAs), concebidos como espaços digitais estruturados para apoiar interações e atividades educacionais (DILLENBOURG; SCHNEIDER; SYNTETA, 2002).

Esses ambientes passaram a mediar atividades acadêmicas por meio da disponibilização de materiais, da submissão e devolução de atividades avaliativas e da comunicação on-line entre alunos e professores (LONN; TEASLEY, 2009). Esse movimento foi intensificado após a pandemia de covid-19, período em que o uso de plataformas digitais para atividades de ensino e aprendizagem em escolas urbanas aumentou de 22%, em 2016, para 66%, em 2020 (NITAHARA, 2021).

Embora os AVAs ampliem as possibilidades de organização e acompanhamento das atividades educacionais, eles também modificam a forma como a interação pedagógica ocorre. No ensino presencial, docentes e gestores podem observar sinais de desinteresse, dificuldade ou desengajamento a partir de interações diretas em sala de aula (MEHALL, 2020). Em AVAs, esse acompanhamento torna-se mais difícil, sobretudo pela ausência de pistas não verbais e comportamentais típicas da presencialidade (van Leeuwen, 2023).

Nesse contexto, o grande volume de interações e trocas de mensagens demanda estratégias analíticas capazes de extrair informações relevantes sobre a qualidade do ensino (MARTIN; NDOYE, 2016; QUEIROGA et al., 2021). Assim, a análise das interações dos estudantes no AVA e dos conteúdos textuais provenientes das mensagens apresenta-se como uma abordagem promissora para compreender suas experiências e trajetórias acadêmicas.

Nesse cenário, a área de Análise de Aprendizagem (*Learning Analytics* – LA) ofe-

rece estratégias para coletar, analisar e interpretar dados educacionais com o objetivo de apoiar a compreensão dos processos de aprendizagem (MARTIN; NDOYE, 2016; QUEIROGA et al., 2021). Entre os registros disponíveis nos AVAs, destacam-se tanto dados estruturados, como notas e acessos, quanto dados textuais, como mensagens privadas e outras interações escritas. Esses registros textuais podem fornecer indícios qualitativos sobre a forma como os estudantes interagem com o curso, com os docentes e com o próprio ambiente virtual.

Para investigar esses registros, a análise de sentimentos e a modelagem de tópicos apresentam-se como abordagens complementares. A análise de sentimentos permite identificar sinais afetivos, opiniões e atitudes expressas nos textos (LIU, 2012), tendo sido utilizada em fóruns educacionais para examinar percepções dos estudantes e suas relações com a permanência e a evasão em cursos on-line (WEN; YANG; ROSÉ, 2014). Por sua vez, a modelagem de tópicos permite identificar, de forma não supervisionada, temas recorrentes em grandes coleções textuais (BLEI, 2012), contribuindo para reconhecer demandas, dúvidas e assuntos discutidos em contextos educacionais (MORA et al., 2017).

Diante dessas possibilidades, este trabalho investiga de que modo a análise de sentimentos e a modelagem de tópicos aplicadas às mensagens privadas do Moodle podem complementar a interpretação de indicadores educacionais relacionados às trajetórias acadêmicas de estudantes classificados como *Formados* e *Evadidos* em cursos ofertados na modalidade a distância.

1.1 Problema de Pesquisa

As interações textuais realizadas por estudantes em AVAs constituem uma fonte potencial para o acompanhamento pedagógico. Mensagens, fóruns e outros registros escritos podem revelar dúvidas, dificuldades de compreensão, percepções sobre a disciplina, solicitações de apoio, frustrações e possíveis sinais de desconexão em relação ao curso (CLEVELAND-INNES; CAMPBELL, 2012; YANG et al., 2015; ANWAR et al., 2023). Além disso, esses registros podem complementar indicadores educacionais quantitativos previamente desenvolvidos (CARVALHO et al., 2025), uma vez que permitem observar aspectos qualitativos da experiência estudantil que nem sempre são capturados por medidas numéricas.

Entretanto, o uso desses dados textuais não é trivial e envolve limitações metodológicas. Em primeiro lugar, as interações registradas no AVA dependem das práticas institucionais, da cultura de uso da plataforma e da centralidade atribuída ao ambiente como canal de comunicação entre estudantes, professores e tutores (SINCLAIR; AHO, 2018). Quando parte dessas interações ocorre fora do Moodle, seja por outros canais digitais, como e-mail, redes sociais e aplicativos de mensagens, seja em atividades presenciais ou atendimentos institucionais, os registros disponíveis no AVA podem representar apenas uma parcela das situações vivenciadas pelos estudantes ao longo de suas trajetórias acadêmicas (SIEMENS; LONG, 2011; DRINGUS, 2012).

Além disso, nem toda mensagem textual expressa diretamente sentimentos ou apresenta indícios relacionados à evasão e ao desempenho acadêmico. Em contextos educacionais, mensagens privadas podem manter um tom formal e cordial mesmo quando relatam dificuldades, problemas técnicos, dúvidas sobre atividades ou contestações de notas (WEN; YANG; ROSÉ, 2014). Assim, a polaridade atribuída pelos métodos de análise de sentimentos pode refletir não apenas a demanda acadêmica central da mensagem, mas também elementos linguísticos e contextuais de sua redação, como expressões de polidez, negação, atenuação e intensificação. Também deve ser considerada a diferença entre a polaridade previamente atribuída a termos isolados e aquela assumida por esses termos em um contexto específico (LIU, 2012; WILSON; WIEBE; HOFFMANN, 2005).

Diante dessas limitações, torna-se necessário investigar não apenas a polaridade das mensagens, mas também os assuntos abordados e sua relação com os indicadores educacionais. Essa perspectiva orienta os objetivos apresentados a seguir.

Assim, este trabalho parte do seguinte problema de pesquisa:

De que modo a análise de sentimentos e a modelagem de tópicos aplicadas a mensagens privadas do Moodle podem complementar a interpretação de indicadores educacionais na análise das trajetórias acadêmicas de estudantes formados e evadidos em cursos de Educação a Distância (EaD)?

A investigação considera que a contribuição desses registros depende não apenas das características textuais extraídas, mas também da quantidade, da qualidade, da centralidade e da completude das interações registradas no AVA.

1.2 Objetivos

Com base no problema de pesquisa apresentado, estabelece-se um objetivo geral, desdobrado em objetivos específicos que orientam a análise das mensagens privadas do Moodle como fonte complementar para a interpretação das trajetórias acadêmicas.

1.2.1 Objetivo Geral

Investigar de que modo a análise de sentimentos e a modelagem de tópicos aplicadas às mensagens privadas do Moodle podem complementar a interpretação de indicadores educacionais relacionados às trajetórias acadêmicas de estudantes *Formados* e *Evadidos* em cursos de EaD.

1.2.2 Objetivos Específicos

1. Caracterizar a distribuição das mensagens privadas entre estudantes *Formados* e *Evadidos*;
2. Investigar como a polaridade dos sentimentos se manifesta nas mensagens privadas dos estudantes;
3. Analisar a relação entre os sinais extraídos das mensagens privadas e os indicadores educacionais previamente desenvolvidos por Carvalho et al. (2025);
4. Identificar os principais temas recorrentes nas mensagens privadas do Moodle;
5. Comparar a distribuição das classificações de sentimento e dos temas das mensagens entre estudantes *Formados* e *Evadidos*;
6. Analisar os limites e as potencialidades das mensagens privadas como fonte complementar para a interpretação das trajetórias acadêmicas e para o acompanhamento pedagógico.

1.3 Justificativa

A presente pesquisa justifica-se pela necessidade de ampliar a compreensão das trajetórias estudantis em AVAs, especialmente no contexto da EaD. Nessa modalidade, parte importante das interações entre estudantes, professores e tutores ocorre de forma mediada por tecnologias digitais, incluindo comunicações e registros textuais produzidos em ambientes virtuais de aprendizagem (ONG; QUEK, 2023). Esses registros podem conter informações relevantes sobre as experiências acadêmicas dos estudantes, mas nem sempre são explorados de forma articulada aos indicadores educacionais tradicionalmente utilizados em iniciativas de LA.

Os AVAs armazenam uma ampla quantidade de dados estruturados, como notas, acessos, frequência de participação e quantidade de postagens. Esses registros representam dimensões observáveis e quantificáveis da trajetória acadêmica e são frequentemente operacionalizados por meio de indicadores derivados de logs, como frequência de acesso, visualizações, postagens e tempo de uso da plataforma (CONIJN et al., 2017; Santos, 2024; HERNÁNDEZ-GARCÍA; ACQUILA-NATALE; CHAPARRO-PELÁEZ, 2017).

Nessa perspectiva, indicadores educacionais construídos a partir de dados do Moodle podem apoiar a análise da trajetória estudantil em múltiplas dimensões, incluindo engajamento, desempenho, motivação, relação aluno-professor, profundidade cognitiva e desistência (CARVALHO et al., 2025). No entanto, a experiência discente não se limita aos registros estruturados da plataforma, pois parte dela também pode se manifestar em dados textuais, como mensagens privadas e postagens em fóruns, nos quais os estudantes expressam dúvidas, dificuldades, solicitações de apoio, frustrações e percepções sobre o curso (CLEVELAND-INNES; CAMPBELL, 2012; YANG et al., 2015; ANWAR et al., 2023).

Apesar desse potencial, as mensagens privadas provenientes de interações reais ainda são pouco exploradas. Além disso, na literatura consultada, não foram identificados trabalhos que articulassem diretamente a análise textual dessas mensagens a indicadores educacionais. Essa lacuna justifica investigar de que modo esses registros podem complementar a interpretação das trajetórias acadêmicas.

A relevância desta pesquisa está em discutir o potencial e os limites dos registros

textuais do Moodle como fonte complementar para o acompanhamento discente. Ao analisar mensagens privadas provenientes de um contexto real de uso, o estudo permite refletir sobre a importância da centralidade, da qualidade e da completude dos registros de comunicação no AVA, bem como sobre sua possível utilização como apoio às estratégias institucionais de acompanhamento e suporte pedagógico.

1.4 Organização do Trabalho

Este trabalho está organizado em cinco capítulos. O Capítulo 1 apresenta a introdução da pesquisa, contemplando a contextualização do tema, o problema de pesquisa, os objetivos geral e específicos, a justificativa e a organização do trabalho.

O Capítulo 2 apresenta os trabalhos relacionados e a fundamentação teórica que sustenta o estudo. Nesse capítulo, são discutidos os Ambientes Virtuais de Aprendizagem (AVAs) e seu papel no acompanhamento estudantil, a área de LA, a construção de indicadores educacionais em AVAs, o uso da análise de sentimentos em contextos educacionais e, por fim, a lacuna de pesquisa que orienta esta investigação.

O Capítulo 3 descreve os materiais e métodos adotados. São apresentados o contexto do estudo, a base de dados utilizada, a definição dos grupos de análise, os indicadores educacionais previamente desenvolvidos, o processo de seleção e preparação das mensagens privadas do Moodle, bem como as estratégias empregadas para análise de sentimentos e modelagem de tópicos.

O Capítulo 4 apresenta e discute os resultados obtidos. Inicialmente, é realizada uma caracterização descritiva dos indicadores educacionais por grupo. Em seguida, são analisadas as polaridades atribuídas pelos diferentes métodos de análise de sentimentos e o nível de concordância entre eles. Posteriormente, são examinadas as relações entre os sinais extraídos das mensagens privadas e os indicadores educacionais. Por fim, são apresentados os tópicos identificados pelo BERTopic e discutidas as contribuições e limitações das mensagens privadas como fonte complementar para o monitoramento discente.

Por fim, o Capítulo 5 apresenta as considerações finais do trabalho, retomando os principais achados da pesquisa, suas limitações e possíveis direções para trabalhos futuros.

2 Trabalhos Relacionados

Para fundamentar esta pesquisa, inicialmente discute-se o conceito de AVA, seu papel na EaD e sua relevância para o acompanhamento da trajetória estudantil. Em seguida, apresenta-se o campo de LA, responsável por desenvolver abordagens voltadas à coleta, análise e interpretação de dados educacionais gerados nesses ambientes. Posteriormente, são abordados os estudos que exploram mensagens, fóruns e outras interações textuais em contextos educacionais, destacando seu potencial para revelar aspectos da experiência discente. Por fim, discutem-se as contribuições da construção de indicadores educacionais e da análise de sentimentos para o acompanhamento pedagógico e para a compreensão mais ampla da trajetória dos estudantes, e debatem-se as lacunas identificadas.

2.1 Ambientes Virtuais de Aprendizagem e acompanhamento estudantil

O avanço das tecnologias digitais tem ampliado as possibilidades de ensino e aprendizagem para além do modelo presencial tradicional, favorecendo a consolidação do *e-learning* como uma modalidade educacional mediada por tecnologias digitais (SANGRÀ; VLA-CHOPOULOS; CABRERA, 2012). Nesse cenário, os AVAs passaram a desempenhar um papel de suporte ao processo de ensino-aprendizagem, ao reunirem recursos voltados à organização de conteúdos, à realização de atividades e à promoção de interações educacionais em espaços digitais (DILLENBOURG; SCHNEIDER; SYNTETA, 2002).

Essa mediação não se limita à disponibilização de materiais ou à realização de atividades. Ao concentrar diferentes práticas educacionais em um mesmo ambiente, os AVAs também passam a registrar múltiplas dimensões da participação estudantil, como acessos, submissões de atividades, interações em fóruns e comunicações realizadas na plataforma. Esses registros podem subsidiar o acompanhamento de aspectos da trajetória discente, permitindo observar padrões de participação, engajamento e desempenho ao

longo do curso (MORA et al., 2017).

Esse acompanhamento torna-se especialmente relevante porque a educação online continua enfrentando grandes desafios. Entre eles, destacam-se a evasão, que permanece como um problema recorrente em cursos mediados por tecnologia (OLIVÉ et al., 2019), e a satisfação dos estudantes, aspecto relacionado à qualidade da experiência educacional e à permanência no curso (CHAMORRO-ATALAYA et al., 2023). Dessa forma, os dados produzidos nos AVAs podem contribuir não apenas para descrever o uso desses ambientes, mas também para apoiar a identificação de dificuldades, demandas e possíveis fatores associados à trajetória acadêmica dos estudantes.

No presente estudo, o AVA de interesse é o Moodle, uma plataforma de código aberto amplamente adotada por instituições de ensino e organizações (EINHARDT; TAVARES; CECHINEL, 2016). No contexto das universidades públicas brasileiras, esse sistema é frequentemente utilizado para apoiar a oferta de disciplinas, organizar conteúdos e atividades, registrar interações entre os participantes e armazenar dados relacionados à participação dos estudantes (FURTADO; FERNANDES, 2017; JORGE, 2020). Por essa razão, o Moodle constitui uma fonte relevante para investigações voltadas ao acompanhamento estudantil em contextos educacionais mediados por tecnologia.

Assim, compreender o papel dos AVAs no acompanhamento estudantil exige considerar não apenas sua função como espaço de mediação pedagógica, mas também o potencial analítico dos registros produzidos nesses ambientes. É a partir dessa perspectiva que se insere a LA, voltada ao uso de dados educacionais para compreender e acompanhar processos de aprendizagem em ambientes digitais.

2.2 Análise de Aprendizagem em AVAs

Diante do volume crescente de registros produzidos em AVAs e dos desafios envolvidos no acompanhamento estudantil em contextos educacionais mediados por tecnologia, a LA emerge como uma área relevante. Esse campo parte da possibilidade de transformar rastros digitais gerados em ambientes educacionais em evidências sobre participação, desempenho e necessidades dos estudantes (SIEMENS; LONG, 2011). De modo geral, a LA dedica-se ao uso sistemático desses dados para compreender e apoiar processos de apren-

dizagem, considerando tanto os estudantes quanto os contextos nos quais a aprendizagem ocorre (SIEMENS, 2013).

No contexto dos AVAs, a LA tem sido utilizada para transformar registros do ambiente em informações úteis ao acompanhamento pedagógico (SCHWENDIMANN et al., 2017). Dados de acesso, participação em atividades, interações em fóruns, submissão de tarefas e resultados em avaliações podem ser organizados e analisados de modo a oferecer evidências sobre o comportamento discente ao longo do curso (SCHWENDIMANN et al., 2017; COSTAS-JAUREGUI et al., 2021).

Assim, mais do que armazenar grandes volumes de dados, os AVAs passam a constituir fontes para a produção de conhecimento sobre a trajetória estudantil, uma vez que seus registros podem revelar padrões de participação, desempenho e interação relevantes para professores e gestores (RAMOS et al., 2020; Santos, 2024). Nesse cenário, a LA fornece a base conceitual e metodológica para a construção de indicadores orientados por dimensões recorrentes na literatura, como engajamento, desempenho, motivação, interação e evasão (Oliveira; RODRIGUES; MACIEL, 2022; RIBEIRO et al., 2013; CHANEY et al., 2009).

2.3 Indicadores educacionais em AVAs

No âmbito da LA, uma das formas mais recorrentes de operacionalizar os dados produzidos nos AVAs consiste na construção de indicadores educacionais e painéis de acompanhamento, capazes de sintetizar diferentes aspectos do processo de aprendizagem (SCHWENDIMANN et al., 2017; COSTAS-JAUREGUI et al., 2021).

Esses indicadores permitem transformar registros brutos do ambiente, como acessos, desempenho em atividades, participação e uso de recursos, em medidas mais compreensíveis e utilizáveis no acompanhamento estudantil (EINHARDT; TAVARES; CECINEL, 2016). Dessa forma, favorecem a identificação de padrões, a observação de tendências e o apoio à tomada de decisão pedagógica (Menezes, 2024; Santos, 2024).

Entretanto, embora os indicadores numéricos sejam úteis para sintetizar dimensões importantes da trajetória discente, eles nem sempre capturam aspectos qualitativos da experiência dos estudantes. Como já demonstrado em estudo anterior, é possível mo-

delar indicadores relacionados a dimensões como engajamento, desempenho, motivação, relação aluno-professor, necessidade de reforço e evasão escolar a partir de dados do Moodle (CARVALHO et al., 2025).

Ainda assim, dificuldades, frustrações, dúvidas, percepções sobre o curso e sinais de desengajamento podem se manifestar de maneira mais explícita em interações textuais, como mensagens privadas e postagens em fóruns (CLEVELAND-INNES; CAMPBELL, 2012; YANG et al., 2015; ANWAR et al., 2023). Por essa razão, a análise desses dados textuais pode complementar os indicadores educacionais tradicionais, ampliando a compreensão sobre o percurso acadêmico dos estudantes.

2.4 Análise de sentimentos em AVAs

A análise de sentimentos em AVAs tem ganhado relevância à medida que se reconhece que parte importante da experiência discente se manifesta em interações textuais produzidas em fóruns, mensagens e outros canais de comunicação mediados pela plataforma. Nesses espaços, os estudantes não apenas discutem conteúdos e atividades, mas também expressam emoções, opiniões, dúvidas, frustrações e percepções sobre o curso, o que torna esses registros uma fonte valiosa para a compreensão do comportamento estudantil em contextos digitais (CLEVELAND-INNES; CAMPBELL, 2012; ANWAR et al., 2023).

Nesse cenário, diferentes estudos têm buscado compreender padrões de comportamento em AVAs a partir da linguagem utilizada pelos estudantes. Wen et al. (WEN; YANG; ROSÉ, 2014) analisaram sentimentos em fóruns de MOOCs com o objetivo de monitorar opiniões dos estudantes sobre o curso e sobre seus principais recursos, observando associação entre a variação dos sentimentos expressos nas postagens e os índices de evasão. Yang et al. (YANG et al., 2015) investigaram a confusão manifestada em mensagens de fóruns e mostraram que esse tipo de sinal pode ser utilizado para identificar estudantes com maior risco de desengajamento, sobretudo quando a confusão não é resolvida. Já Kagklis et al. (KAGKLIS et al., 2015) exploraram dados de fóruns em educação a distância por meio da combinação entre mineração de texto, análise de sentimentos e análise de redes sociais, evidenciando que os conteúdos textuais também podem contribuir para caracterizar formas de participação e desempenho entre estudantes.

Essa linha de investigação também aparece em estudos que articulam dados textuais com outros registros de interação para identificar perfis, riscos ou situações sensíveis no contexto educacional. Bobó et al. (BOBÓ et al., 2019), por exemplo, propõem a arquitetura SASys, aplicada ao Moodle, para identificar perfis emocionais a partir de mensagens publicadas em fóruns de perguntas e respostas e combiná-los com dados de interação, a fim de reconhecer estudantes potencialmente em risco de evasão. De modo semelhante, Pfitscher et al. (PFITSCHER et al., 2023) analisam respostas textuais de estudantes de programação para apoiar ações de retenção estudantil. Em um contexto mais amplo de comunicação digital educacional, Pereira et al. (PEREIRA; ALVES; PADILHA, 2024) investigam mensagens de grupos escolares no WhatsApp para identificar sinais de bullying, mostrando que registros textuais produzidos em canais mediados por tecnologia podem revelar aspectos relevantes da experiência estudantil.

Além da identificação de padrões de comportamento, a análise de sentimentos pode apoiar intervenções pedagógicas mais direcionadas. Ao detectar manifestações de insatisfação, confusão, frustração ou afastamento progressivo, torna-se possível fornecer aos docentes e tutores informações adicionais sobre a experiência dos estudantes, complementando indicadores numéricos tradicionalmente utilizados em LA. No caso específico do Moodle, Dake e Bada (DAKE; BADA, 2023) exploraram sentimentos de estudantes relacionados ao uso do módulo de avaliação da plataforma e construíram um classificador para prever polaridades futuras, o que é especialmente útil para possibilitar essas intervenções pedagógicas antecipadas.

A síntese apresentada na Tabela 2.1 indica que a análise de textos educacionais tem sido aplicada em diferentes contextos, especialmente em fóruns e respostas abertas. Entretanto, alguns estudos se baseiam em conjuntos reduzidos de mensagens, enquanto aqueles com corpora maiores tendem a se concentrar em interações públicas, como postagens em fóruns. Esse recorte pode limitar a análise de contextos institucionais nos quais a comunicação entre estudantes e instrutores não ocorre prioritariamente nesses espaços. Este estudo diferencia-se dos trabalhos anteriores ao analisar mensagens privadas reais do Moodle, escritas em português, e ao discutir seu potencial e suas limitações como fonte complementar aos indicadores educacionais para compreender as trajetórias de estudantes

Tabela 2.1: Síntese dos corpora textuais utilizados em estudos relacionados

Estudo	Ambiente	Corpus textual analisado
Bobó et. al (2019)	AVA (Moodle)	27 mensagens de estudantes provenientes de 10 fóruns de perguntas e respostas em um curso a distância.
Kagklis et al. (2015)	Fórum de curso EaD	198 mensagens de 34 estudantes e 173 mensagens de 4 tutores publicadas em fóruns de discussão.
Wen, Yang e Rosé (2014)	MOOC (Coursera)	36.590 postagens de fóruns de discussão provenientes de três MOOCs.
Yang et al. (2015)	MOOC (Coursera)	12.434 postagens de 4.281 estudantes em dois cursos, combinadas com dados de interação na plataforma.
Cleveland-Innes e Campbell (2012)	AVA	Transcrições de discussões online e respostas abertas de 217 estudantes em 19 cursos de dois programas de pós-graduação.
Dake e Bada (2023)	AVA (Moodle)	300 respostas abertas de estudantes, coletadas por meio de formulário, sobre sua experiência com avaliações online no Moodle.
Lundqvist, Liyanagunawardena e Starkey (2020)	MOOC (FutureLearn)	25.000 postagens online e 337 declarações de feedback produzidas por 264 participantes em um MOOC de programação.

classificados como *Evadidos* e *Formados*.

2.4.1 Técnicas para análise de sentimentos

Do ponto de vista tecnológico, a literatura mostra que a análise de sentimentos não se restringe a uma única técnica. De modo geral, as abordagens podem ser organizadas em dois grandes grupos: métodos baseados em aprendizado de máquina e métodos baseados em léxicos (MEDHAT; HASSAN; KORASHY, 2014), como nota-se na Figura 2.1.

O primeiro grupo inclui classificadores tradicionais, como Naive Bayes, *Support Vector Machines* (SVM), árvores de decisão, máxima entropia e redes neurais, além de modelos mais recentes baseados em arquiteturas *Transformers* (MEDHAT; HASSAN; KORASHY, 2014; DALIPI; ZDRAVKOVA; AHLGREN, 2021; ANWAR et al., 2023). Já o segundo grupo atribui polaridade aos textos a partir de dicionários ou recursos lexicais previamente associados a valores sentimentais (MEDHAT; HASSAN; KORASHY, 2014).

A Tabela 2.2 sintetiza algumas técnicas e ferramentas identificadas na literatura,




Figura 2.1: Técnicas de classificação de sentimentos. Fonte: (MEDHAT; HASSAN; KORASHY, 2014)

evidenciando a diversidade de estratégias utilizadas para a análise de sentimentos em textos educacionais e em língua portuguesa.

Essa diversidade metodológica indica que não há uma única técnica predominante para a análise de sentimentos em contextos educacionais. Abordagens baseadas em léxicos podem ser úteis em cenários sem corpora rotulados, por serem mais simples de aplicar e menos dependentes de treinamento prévio. Por outro lado, métodos de aprendizado de máquina e modelos *Transformers* tendem a capturar melhor o contexto das mensagens, embora possam exigir bases anotadas, maior custo computacional ou ajustes ao domínio analisado.

Além disso, estudos em português mostram que o desempenho das técnicas depende do tipo de texto, do domínio, da granularidade da tarefa e dos recursos linguísticos empregados (SOUZA; VIEIRA, 2012; FREITAS, 2013). Assim, os resultados obtidos por uma abordagem não podem ser generalizados automaticamente para todos os contextos educacionais. Por esse motivo, o presente estudo compara diferentes métodos de análise de sentimentos, observando como eles se comportam quando aplicados a mensagens privadas do Moodle.

Tabela 2.2: Estudos e principais técnicas utilizadas na análise de sentimentos

Estudo	Principal técnica ou ferramenta
Ibnu et al. (2024)	Modelos <i>Transformers</i> , com destaque para o mBERT na classificação de sentimentos em feedbacks estudantis.
Koufakou (2023)	Comparação entre abordagens tradicionais, <i>deep learning</i> e modelos <i>Transformers</i> , com destaque para o RoBERTa na extração de polaridade.
Souza e Vieira (2012)	Avaliação de léxicos em português, com melhor desempenho do OpLexicon no cenário analisado.
Freitas (2013)	Comparação entre léxicos de opinião em português, com destaque para o uso de adjetivos do SentiLex em resenhas de filmes.
Lundqvist, Liyanagunawardena e Starkey (2020)	Uso do VADER para análise de sentimentos em postagens de um MOOC, sem necessidade de treinamento prévio.
Bobó et al. (2019)	Uso de Semântica de Frames, com base na FrameNet Brasil, para identificação de perfis emocionais em fóruns do Moodle.
Pereira, Alves e Padilha (2024)	Uso de TextBlob e BERT para identificação de sinais de bullying em mensagens de grupos escolares no WhatsApp.
Cobos, Jurado e Blázquez-Herranz (2019)	Desenvolvimento do edX-CAS, ferramenta baseada em PLN para análise de subjetividade e polaridade em conteúdos e interações de cursos online.

2.5 Síntese dos trabalhos relacionados e lacuna de pesquisa

Os trabalhos apresentados neste capítulo evidenciam que os AVAs constituem fontes relevantes para o acompanhamento estudantil, uma vez que registram dados de acesso, participação, desempenho e interação. No campo da LA, esses registros têm sido utilizados para a construção de indicadores educacionais capazes de sintetizar dimensões da trajetória discente, como engajamento, desempenho, motivação, interação e desistência (CARVALHO et al., 2025; SIEMENS; LONG, 2011; SIEMENS, 2013; SCHWENDIMANN et al., 2017; COSTAS-JAUREGUI et al., 2021).

Entretanto, embora esses indicadores contribuam para o acompanhamento pedagógico, eles tendem a representar aspectos mais observáveis e quantitativos da participação dos estudantes enquanto elementos como dúvidas, dificuldades e frustrações aparecem de forma mais explícita em interações textuais. Nesse sentido, estudos relacionados têm explorado fóruns, respostas abertas e outros registros escritos por meio de técnicas de análise de sentimentos e PLN, demonstrando o potencial desses dados para complemen-

tar a compreensão da experiência discente (WEN; YANG; ROSÉ, 2014; YANG et al., 2015; KAGKLIS et al., 2015; BOBó et al., 2019; DAKE; BADA, 2023).

Apesar dessas contribuições, observa-se que a maior parte dos trabalhos se concentra em fóruns de discussão ou respostas abertas, enquanto mensagens privadas provenientes de interações reais ainda são pouco exploradas. Essa menor presença pode estar relacionada às dificuldades de acesso a esse tipo de dado, que envolve questões éticas, de privacidade, consentimento e proteção de informações pessoais. Em determinadas plataformas, mecanismos de segurança, como a criptografia de ponta a ponta, também podem limitar a disponibilidade das mensagens para fins de pesquisa. Além disso, não foram encontrados trabalhos que articulassem diretamente a análise textual com indicadores educacionais. Assim, a lacuna identificada refere-se à necessidade de investigar como mensagens privadas, escritas em português, podem complementar a análise da trajetória acadêmica dos estudantes.

Diante desse cenário, este estudo de caso examina o potencial e as limitações das mensagens privadas do Moodle como fonte complementar a indicadores educacionais previamente modelados, considerando estudantes classificados como *Evadidos* e *Formados*. Para isso, é conduzida uma análise comparativa entre diferentes técnicas de análise de sentimentos, incluindo abordagens baseadas em léxicos e modelos *Transformers*, com o objetivo de examinar como esses métodos classificam as mensagens e em que medida os sinais extraídos se relacionam com os indicadores educacionais e com a situação acadêmica dos estudantes.

3 Materiais e métodos

Este capítulo apresenta a metodologia adotada no estudo, contemplando a caracterização e a integração das bases de dados, a definição dos grupos de análise, a descrição dos indicadores educacionais, a seleção e o pré-processamento das mensagens privadas e as técnicas empregadas na análise textual. Também são apresentadas as estratégias de análise de sentimentos, modelagem de tópicos, associação com os indicadores educacionais e interpretação dos resultados.

A Figura 3.1 apresenta uma visão geral das etapas metodológicas do estudo. O processo iniciou-se com a integração dos registros provenientes do Moodle e do WebGiz, seguida pela definição dos grupos de trajetória acadêmica e pela organização dos indicadores educacionais. Posteriormente, foram selecionadas e pré-processadas as mensagens privadas atribuídas aos estudantes. Sobre esse corpus, aplicaram-se diferentes métodos de análise de sentimentos e o BERTopic, enquanto as classificações de sentimento agregadas por estudante foram relacionadas aos indicadores educacionais. Por fim, os resultados foram interpretados de forma conjunta, considerando as características e as limitações dos registros disponíveis.

3.1 Contexto do estudo

O estudo foi realizado no contexto da Universidade Estadual de Montes Claros (Unimontes), instituição integrante do sistema da Universidade Aberta do Brasil (UAB). Nesse modelo, a organização didático-pedagógica dos cursos de EaD combina atividades mediadas pelo AVA, como questionários, tarefas e fóruns, com avaliações presenciais. Há dados históricos produzidos entre 2017 e 2025, abrangendo cursos de diferentes áreas do conhecimento.

No caso das atividades realizadas diretamente no Moodle, os registros disponíveis permitem acompanhar tanto a participação dos estudantes quanto os resultados obtidos nas atividades. Já as avaliações presenciais são observadas de forma indireta, por meio




Figura 3.1: Visão geral das etapas metodológicas adotadas no estudo.

das notas posteriormente lançadas na plataforma. Assim, a base analisada reúne registros produzidos no AVA e informações acadêmicas consolidadas no Moodle, possibilitando a investigação da trajetória estudantil a partir de diferentes dimensões da experiência educacional.

3.2 Base de Dados

A base de dados utilizada neste estudo foi composta a partir da integração de registros provenientes do Moodle e do sistema de gestão acadêmica da instituição. O Moodle constitui a principal fonte de dados do trabalho, pois registra o desenvolvimento das atividades no AVA, incluindo acessos, interações, submissões, participação em fóruns, mensagens privadas e parte dos resultados acadêmicos dos estudantes. Complementarmente, foram utilizadas informações do sistema acadêmico WebGiz, especialmente aquelas relacionadas às notas finais e à situação acadêmica dos estudantes nas disciplinas.

A utilização conjunta dessas duas fontes decorre da natureza complementar dos dados. Enquanto o Moodle permite observar aspectos do processo de aprendizagem e da participação dos estudantes no ambiente virtual, o WebGiz concentra registros administrativos e formais da trajetória acadêmica. Assim, a integração entre as bases possibilitou

compor uma visão mais consistente da experiência estudantil, articulando registros de interação no AVA, dados textuais e informações acadêmicas consolidadas.

A base analisada reúne dados históricos de 20 cursos de EaD ofertados pela Unimontes nos anos de 2018, 2020 e 2023, todos mediados pelo Moodle¹. Os registros disponíveis abrangem o período de setembro de 2017 a fevereiro de 2025, permitindo observar interações e informações acadêmicas produzidas ao longo de diferentes ofertas e períodos letivos.

Além disso, foram consideradas duas vertentes principais de informação. A primeira corresponde aos indicadores educacionais previamente calculados a partir de registros do Moodle, contemplando dimensões como engajamento, desempenho, motivação, relação aluno-professor, profundidade cognitiva e desistência. A segunda é composta por dados textuais produzidos pelos estudantes na plataforma por meio das mensagens privadas. A articulação entre essas duas vertentes permite investigar em que medida os registros textuais podem complementar a interpretação dos indicadores educacionais na análise das trajetórias acadêmicas.

3.3 Definição dos grupos de análise

A definição dos grupos de trajetória acadêmica não foi obtida diretamente a partir de uma única variável da base institucional. Em vez disso, foi construída a partir do histórico acadêmico dos estudantes ao longo dos períodos letivos. No WebGiz, cada matrícula em disciplina é acompanhada por um código de situação, representado por letras, que indica diferentes desfechos acadêmicos. Como esses registros estão organizados em nível de disciplina, foi necessário elaborar um procedimento de classificação que permitisse inferir a trajetória global de cada estudante em nível individual.

Inicialmente, os códigos de situação foram agrupados em categorias mais amplas, correspondentes a situações de aprovação, andamento, reprovação e condição neutra. Em seguida, os dados foram sintetizados por estudante e por período letivo, permitindo identificar, em cada etapa da trajetória, a quantidade de disciplinas aprovadas, em andamento

¹O estudo foi aprovado pelo Comitê de Ética, sob o registro CAAE/UNIMONTES 94419625.8.0000.5146

e reprovadas, bem como a presença de componentes curriculares associados à conclusão do curso, como o Trabalho de Conclusão de Curso (TCC). Também foi incorporada uma medida de inatividade acadêmica, calculada a partir da distância, em semestres, entre o último período cursado pelo estudante e o período mais recente observado na base.

A Figura 3.2 apresenta uma visão geral da heurística utilizada para atribuir o *status* acadêmico final de cada estudante a partir do histórico por disciplina e de sua organização por período letivo.




Figura 3.2: Heurística utilizada para a definição dos grupos de análise a partir do histórico acadêmico dos estudantes.

Com base nessas informações, foi definido um conjunto de regras de decisão para atribuir o *status* final de cada estudante. De modo geral, estudantes com disciplinas ainda em andamento no último período observado foram classificados como *Cursandos*. Estudantes com indícios de encerramento bem-sucedido da trajetória, especialmente associados à aprovação em disciplinas de TCC e à posterior inatividade acadêmica, foram classificados como *Formados*. Por sua vez, estudantes com predominância de situações negativas no último período, sem matrícula posterior ou com inatividade prolongada, foram classificados como *Evadidos*. A classificação também considerou situações específicas registradas no histórico acadêmico, quando presentes, como falecimento.

Como o objetivo deste trabalho é comparar trajetórias acadêmicas já consolidadas, optou-se por desconsiderar os estudantes classificados como *Cursandos*. A partir dessa delimitação, os dados textuais e os indicadores educacionais foram vinculados ao respectivo grupo de cada estudante, possibilitando análises comparativas entre *Formados* e *Evadidos*. Nota-se, portanto, que os indicadores e as mensagens privadas foram organizados em nível individual em relação a cada estudante.

Ao todo, foram identificados cerca de 4.500 usuários vinculados ao ambiente, dos quais 3.763 foram classificados como estudantes. Entre esses estudantes, 39,5% possuíam *status* de *Cursando*, 29,7% de *Formado* e 30,8% de *Evadido*. Como o objetivo deste estudo é analisar trajetórias acadêmicas já definidas, os estudantes classificados como *Cursando* foram excluídos do recorte analítico. Dessa forma, a base passou a contemplar 2.278 estudantes, dos quais 50,9% eram *Evadidos* e 49,1% eram *Formados*. Observa-se, portanto, uma distribuição equilibrada entre as duas categorias consideradas.

3.4 Indicadores educacionais previamente desenvolvidos

Este estudo utiliza indicadores educacionais previamente desenvolvidos por Carvalho et al. (2025) a partir de registros do Moodle. Esses indicadores representam diferentes dimensões da trajetória acadêmica dos estudantes no AVA, incluindo participação, desempenho, interação com docentes, envolvimento com atividades e possíveis sinais de vulnerabilidade acadêmica.

A utilização desses indicadores oferece uma referência quantitativa para caracterizar a trajetória dos estudantes em múltiplos aspectos. Em vez de restringir a análise a uma única medida, como nota final ou frequência de acesso, os indicadores permitem observar diferentes dimensões do percurso acadêmico no Moodle. Dessa forma, eles funcionam como uma base de comparação para investigar se os dados textuais extraídos das mensagens privadas apenas reforçam padrões já observados nos registros estruturados ou se acrescentam elementos complementares à interpretação da experiência estudantil.

De modo geral, os indicadores de engajamento, motivação, desempenho, relação

aluno-professor e profundidade cognitiva sintetizam dimensões primárias da experiência estudantil no AVA. Além desses, considera-se também o indicador de desistência, construído a partir da combinação de baixos níveis em outros indicadores educacionais. Diferentemente das métricas primárias, esse indicador não corresponde a uma contagem direta de eventos no ambiente, mas a uma sinalização derivada do comportamento observado em múltiplas dimensões da trajetória estudantil.

A Tabela 3.1 sintetiza os indicadores utilizados neste estudo, suas respectivas fontes ou métricas numéricas e sua interpretação geral.

Tabela 3.1: Síntese dos indicadores educacionais utilizados no estudo

Indicador	Fonte / métrica numérica	Interpretação geral
Engajamento	Contagem de postagens em fóruns avaliativos	Representa a participação do estudante em atividades avaliativas no AVA
Motivação	Contagem de postagens em fóruns não avaliativos	Indica participação em espaços não diretamente vinculados à avaliação formal
Desempenho	<i>Score</i> composto pela nota obtida e pela posição relativa do estudante na turma	Representa o rendimento acadêmico considerando desempenho absoluto e comparativo
Relação aluno-professor	Contagem de interações entre estudante e docente em fóruns	Reflete a intensidade da interação acadêmica entre discente e professor
Profundidade Cognitiva	<i>Score</i> derivado dos rastros de interação em fóruns, tarefas e questionários	Busca representar o nível de envolvimento do estudante com as atividades do AVA
Desistência	Sinalização construída a partir de baixos níveis em outros indicadores	Indica possível vulnerabilidade à evasão ou necessidade de acompanhamento mais próximo

No trabalho de (CARVALHO et al., 2025), cada indicador foi operacionalizado por meio de uma medida numérica e de uma classificação em faixas interpretativas. Neste estudo, foram utilizadas apenas as medidas numéricas, pois o objetivo é examinar sua relação com as características extraídas das mensagens privadas dos estudantes. Como os indicadores foram originalmente calculados para cada combinação entre estudante e disciplina, foi necessário obter um único valor por estudante. Para isso, calculou-se, para cada indicador, a média dos valores registrados nas disciplinas cursadas pelo estudante. Essa agregação produz uma síntese de sua trajetória acadêmica, que pode ser comparada às características textuais das mensagens privadas, como a polaridade dos sentimentos e os temas recorrentes.

Além de servirem como base para a análise de correlação com os sinais extraídos das mensagens privadas, os indicadores educacionais também foram caracterizados de forma descritiva. Para isso, foram comparadas as distribuições dos indicadores entre estudantes *Formados* e *Evadidos* com o objetivo de contextualizar o comportamento dos indicadores nos grupos analisados antes da interpretação conjunta com as polaridades e os tópicos extraídos das mensagens.

Essa escolha decorre da própria organização dos registros no Moodle. As mensagens privadas possuem contexto global no sistema e não apresentam, necessariamente, vínculo explícito com uma disciplina específica. Por isso, não é possível associar diretamente cada mensagem aos indicadores do estudante em uma disciplina particular. Por exemplo, uma mensagem com polaridade negativa pode estar relacionada a uma dificuldade pontual em determinada disciplina, enquanto a média geral dos indicadores do estudante pode indicar um comportamento acadêmico satisfatório ao longo de sua trajetória. Considerando essa característica da base, este estudo adota uma aproximação em nível individual, tomando como referência o comportamento médio do estudante nas disciplinas cursadas.

Dessa forma, as relações entre mensagens privadas e indicadores educacionais são interpretadas em nível agregado, considerando o comportamento médio do estudante ao longo de sua trajetória. Essa organização permite articular duas perspectivas complementares: de um lado, os indicadores oferecem uma representação estruturada de participação, desempenho e interação no AVA; de outro, as mensagens privadas podem revelar aspectos qualitativos da experiência discente, como dúvidas, dificuldades, solicitações de apoio e percepções expressas nas interações escritas.

3.5 Mensagens textuais no Moodle

Neste estudo, os registros textuais analisados correspondem às mensagens privadas trocadas entre usuários no Moodle. Esse tipo de interação foi priorizado por favorecer comunicações mais diretas, nas quais os estudantes podem apresentar pedidos de ajuda, solicitar esclarecimentos e relatar dificuldades.

Inicialmente, considerou-se também a incorporação de postagens em fóruns. No

entanto, verificou-se que os fóruns disponíveis estavam majoritariamente associados a discussões coletivas, vinculadas diretamente às atividades e aos conteúdos das disciplinas. Por essa razão, optou-se por concentrar a análise nas mensagens privadas, por apresentarem maior aderência ao objetivo deste estudo: investigar registros textuais mais próximos da experiência individual dos estudantes e de suas demandas de acompanhamento.

3.5.1 Seleção do corpus textual

Inicialmente, foram realizadas consultas à base de dados do Moodle com o objetivo de recuperar mensagens privadas (`mdl_message`) que não correspondessem a notificações automáticas e que apresentassem conteúdo textual não vazio. Como esse tipo de mensagem possui escopo global no sistema, e não está restrito a uma disciplina específica, foi necessário adotar uma estratégia de aproximação para identificar aquelas potencialmente associadas a estudantes. Para isso, selecionaram-se mensagens enviadas por usuários que possuíam papel de aluno em ao menos uma disciplina no Moodle.

Essa estratégia, embora adequada como ponto de partida, ainda incluía mensagens de usuários cuja atuação no ambiente não se alinhava de forma predominante ao papel discente. Por essa razão, a base resultante foi posteriormente confrontada com a base de estudantes proveniente do WebGiz, adotada como referência confiável para a identificação dos alunos. Para isso, preservaram-se todos os registros dessa base e associaram-se a eles apenas as mensagens que apresentaram correspondência por CPF. Como resultado, foram desconsideradas cerca de 2 mil mensagens sem vínculo com estudantes confirmados, as quais, após inspeção em blocos, de fato revelaram características típicas de comunicações produzidas por professores e tutores.

Além disso, identificaram-se casos de usuários que, embora registrados em algum momento como alunos, passaram posteriormente a atuar como tutores ou professores. Nesses casos, grande parte das mensagens privadas refletia interações associadas a esse segundo papel, o que poderia contaminar o corpus com comunicações não representativas da experiência discente. Assim, tais ocorrências foram analisadas individualmente e removidas da base final.

Desse modo, a constituição do corpus textual não se restringiu à extração inicial

dos registros disponíveis no ambiente, mas envolveu sucessivas etapas de refinamento, com o objetivo de preservar interações efetivamente atribuíveis aos estudantes e coerentes com o foco analítico da pesquisa.

3.5.2 Preparação das mensagens

O pré-processamento das mensagens privadas teve como objetivo padronizar os registros textuais e reduzir ruídos que pudessem comprometer as etapas posteriores de análise. Inicialmente, foram removidas duplicatas previamente identificadas na base, correspondentes a registros em que uma mesma mensagem havia sido enviada mais de uma vez pelo mesmo estudante.

Em seguida, o conteúdo textual das mensagens foi normalizado por meio da decodificação de entidades HTML, remoção de tags HTML, conversão para letras minúsculas e padronização de espaços em branco. Também foram removidos elementos pouco informativos para a análise textual, como links, endereços de e-mail e sequências numéricas longas, que poderiam corresponder a matrículas, telefones, códigos ou outros identificadores.

Após essa etapa de limpeza, mensagens que se tornaram vazias foram descartadas. Também foram removidos registros que não puderam ser vinculados a um estudante identificado no WebGiz, bem como mensagens sem data válida, uma vez que essas informações eram necessárias para organizar os registros por estudante e por momento de envio.

Além da limpeza textual, foi realizado um procedimento de agrupamento de mensagens curtas. Mensagens consecutivas enviadas pelo mesmo estudante ao mesmo destinatário e no mesmo dia foram unificadas quando pelo menos uma delas possuía até três palavras. Essa estratégia foi adotada porque mensagens muito curtas, quando analisadas isoladamente, tendem a carregar pouco conteúdo semântico, mas podem fazer sentido quando lidas em conjunto com mensagens próximas da mesma conversa.

Após a junção, os blocos textuais resultantes com menos de três palavras foram removidos por apresentarem conteúdo insuficiente para as análises propostas. Por fim, foi realizada uma nova verificação de duplicatas exatas sobre os textos já limpos e agrupados, garantindo que a base final não mantivesse repetições idênticas.

3.5.3 Análise exploratória das mensagens privadas

Antes da análise textual propriamente dita, foi realizada uma caracterização da presença comunicacional dos estudantes nas mensagens privadas do Moodle. Conforme apresentado na Seção 3.3, quando considerada a base acadêmica geral, observa-se uma distribuição equilibrada entre *Formado* e *Evadido*.

No entanto, esse equilíbrio não se mantém quando se considera apenas o subconjunto de estudantes que enviaram mensagens privadas registradas no Moodle. Dos 2.278 estudantes do recorte analítico, apenas 604 possuem mensagens privadas disponíveis após as etapas de seleção e pré-processamento textual. Esse subconjunto representa, portanto, uma parcela reduzida da base total (aproximadamente 27%) e evidencia que o uso das mensagens privadas não ocorreu de forma homogênea entre os estudantes.

A distribuição final dos registros textuais por grupo é apresentada na Tabela 3.2. Observa-se que, entre os estudantes com mensagens privadas, há predominância do grupo *Formado*, que corresponde a 79,97% dos estudantes com mensagens e a 87,01% das mensagens analisadas. Em contraste, os estudantes *Evadidos* representam 20,03% dos estudantes com mensagens e 12,99% dos registros textuais. Então, a média de mensagens por estudante é maior entre os *Formados* (5,35) do que entre os *Evadidos* (3,19).

Tabela 3.2: Presença comunicacional por grupo nas mensagens privadas

Grupo	Quantidade de estudantes com mensagens	Quantidade de mensagens privadas	Média de mensagens por estudante
<i>Evadido</i>	121 (20,03%)	386 (12,99%)	3,19
<i>Formado</i>	483 (79,97%)	2585 (87,01%)	5,35

Esses resultados indicam que, embora os grupos de *Formados* e *Evadidos* sejam equilibrados na base acadêmica geral, a presença comunicacional nas mensagens privadas é desigual. No contexto analisado, os estudantes que concluíram o curso aparecem com maior frequência no corpus textual e também produziram, em média, mais mensagens. Assim, as análises baseadas em mensagens privadas devem considerar que esses registros representam apenas parte da trajetória estudantil observável no Moodle, com maior presença relativa de estudantes formados.

3.6 Estratégias de análise de sentimentos

Conforme discutido na Seção 2.4, as estratégias mais recorrentes para análise de sentimentos podem ser agrupadas, de modo geral, em abordagens baseadas em léxicos e abordagens baseadas em aprendizado de máquina. Considerando esse panorama, optou-se, neste trabalho, por explorar inicialmente métodos lexicais, com o objetivo de comparar diferentes recursos amplamente utilizados na literatura. Para isso, foram empregados os léxicos SentiLex-PT e OpLexicon, bem como as ferramentas VADER e TextBlob, cujos resultados foram posteriormente comparados entre si.

Em um segundo momento, foram incorporadas abordagens baseadas em modelos de aprendizado de máquina, visando ampliar a análise textual para além da polaridade lexical. Nesse contexto, utilizaram-se os modelos XLM-RoBERTa e mBERT para a classificação de sentimentos. Além disso, empregou-se o BERTopic para a identificação não supervisionada de tópicos recorrentes no corpus. Com isso, buscou-se combinar estratégias distintas de análise, de modo a comparar seus comportamentos e explorar, sob diferentes perspectivas, os conteúdos produzidos pelos estudantes.

3.6.1 Abordagens lexicais para análise de sentimentos

As abordagens lexicais partem do princípio de que a polaridade de um texto pode ser inferida a partir de repertórios previamente construídos, nos quais palavras ou expressões são associadas a valores sentimentais. Em geral, essas estratégias apresentam a vantagem de serem mais simples de aplicar e mais interpretáveis, sobretudo em contextos nos quais não se dispõe de corpora extensos e anotados manualmente.

No presente trabalho, foram empregados quatro recursos dessa natureza: SentiLex-PT, OpLexicon, VADER e TextBlob. Os dois primeiros foram aplicados diretamente sobre as mensagens em língua portuguesa, por terem sido desenvolvidos com foco nesse idioma. Já os demais demandaram uma etapa prévia de tradução automática para o inglês, uma vez que seus mecanismos e recursos de polaridade foram concebidos prioritariamente para essa língua.

Todos os métodos foram aplicados sobre o corpus resultante do processo de limpeza e padronização descrito na Subseção 3.5.2. Buscou-se garantir que as diferenças

observadas entre os resultados decorressem principalmente das características de cada abordagem de análise de sentimentos, e não de variações na base de entrada utilizada por cada método.

SentiLex-PT e OpLexicon

O SentiLex-PT é um léxico de polaridade desenvolvido para a língua portuguesa, composto por 82.347 formas flexionadas. Trata-se de um recurso útil em aplicações de mineração de opinião, sobretudo para a detecção e classificação de sentimentos e opiniões em português, com ênfase no português europeu (FREITAS, 2013). De modo semelhante, o OpLexicon é um léxico de sentimentos também voltado para a língua portuguesa, construído a partir de múltiplas fontes de informação. O recurso reúne 30.322 palavras, cada uma associada à sua categoria morfológica e à respectiva polaridade, que pode ser positiva, negativa ou neutra (SOUZA; VIEIRA, 2012; FREITAS, 2013).

No presente trabalho, ambos os recursos foram aplicados às mensagens em sua forma original, com a incorporação de tratamentos linguísticos auxiliares à atribuição de polaridade, como negação, intensificação e atenuação, uma vez que esses elementos podem modificar o sentido dos termos identificados nos léxicos.

Também foram realizados testes exploratórios com lematização, mas optou-se por não incorporar essa configuração à análise principal, pois se entendeu que alterações mais substanciais poderiam deslocar o texto de sua forma original de ocorrência. Além disso, apenas a versão com remoção de expressões de polidez, como cumprimentos, agradecimentos e encerramentos formais, foi retomada na discussão dos resultados, por evidenciar o possível impacto desses marcadores sobre os métodos baseados em léxicos. Ainda assim, os resultados comparativos principais entre os métodos foram conduzidos com as mensagens originais.

VADER e TextBlob

Com os textos previamente traduzidos para o inglês por meio da biblioteca Python *deep-translator*, utilizando a classe `GoogleTranslator`, aplicaram-se também o VADER (*Valence Aware Dictionary and sEntiment Reasoner*) e o TextBlob.

O VADER é uma abordagem lexical baseada em regras, originalmente desenvolvida para a análise de sentimentos em textos curtos de mídias sociais, produzindo *scores* de positividade, negatividade, neutralidade e um *score* composto de polaridade (LUNDQVIST; LIYANAGUNAWARDENA; STARKEY, 2020). Por sua vez, o TextBlob foi empregado como um recurso de análise de sentimentos por oferecer uma interface simplificada para extração de polaridade e subjetividade em textos (ALKHNBASHI; NASSR, 2022).

3.6.2 Abordagem baseada em modelo pré-treinado para classificação de sentimentos

Além das abordagens lexicais, outra possibilidade para a identificação de sentimentos em textos consiste no uso de modelos pré-treinados baseados em arquiteturas *Transformers*. Diferentemente dos métodos baseados apenas em léxicos, esses modelos incorporam informação contextual no processo de classificação, permitindo representar palavras e expressões de acordo com o contexto em que aparecem. Essa característica permite, em tarefas de análise de sentimentos, analisar as polaridades de um enunciado com construções mais amplas, e não apenas de palavras isoladas.

Nesta etapa foram empregados dois modelos pré-treinados para classificação de sentimentos: o XLM-RoBERTa e o mBERT, por serem capazes de lidar com textos em múltiplos idiomas e por seu uso recorrente em tarefas de PLN envolvendo classificação textual (ID et al., 2024; KOUFAKOU, 2023).

XLM-RoBERTa e mBERT

O mBERT (*multilingual Bidirectional Encoder Representations from Transformers*) é uma versão multilíngue do BERT, treinada sobre textos de diversos idiomas. Sua principal característica está na capacidade de representar palavras considerando simultaneamente o contexto à esquerda e à direita, o que favorece a modelagem de relações semânticas mais complexas (ID et al., 2024). Para essa abordagem, utilizou-se o modelo `cardiffnlp/mbert-base-tweet-sentiment-pt`, versão ajustada do `bert-base-multilingual-cased` para análise de sentimentos em português.

O XLM-RoBERTa é um modelo multilíngue baseado na arquitetura RoBERTa, pré-treinado em grandes volumes de textos de diferentes idiomas (ID et al., 2024). Por operar com representações contextuais, o modelo tende a capturar nuances semânticas e relações de sentido que dificilmente seriam contempladas por abordagens puramente lexicais. Neste trabalho, utilizou-se o modelo `cardiffnlp/twitter-xlm-roberta-base-sentiment`, pré-treinado em aproximadamente 198 milhões de tweets e posteriormente ajustado para a tarefa de análise de sentimentos em oito idiomas, incluindo o português.

Como ambos os modelos foram ajustados a partir de dados provenientes de redes sociais, considera-se que há diferenças entre o domínio original de treinamento e o corpus analisado neste estudo. Essa diferença de domínio pode influenciar o comportamento dos classificadores, seja na sensibilidade a determinados marcadores linguísticos, seja na distribuição final das polaridades atribuídas às mensagens privadas do Moodle.

3.6.3 Análise de associação com os indicadores educacionais

Para examinar a associação entre as classificações de sentimento e os indicadores educacionais, adotou-se o coeficiente de correlação de Spearman, adequado à análise de relações monotônicas sem pressupor normalidade das variáveis. A unidade de análise foi o estudante e, por isso, para estudantes com mais de uma mensagem, os *scores* produzidos por cada método foram agregados por meio da média.

A análise principal considerou apenas as mensagens que receberam o mesmo rótulo de polaridade em todos os métodos, com o objetivo de restringir a comparação aos casos de maior estabilidade classificatória. Após a agregação, cada estudante contribuiu com uma única observação por método e indicador. Foram excluídos, em cada correlação, os casos com valores ausentes em qualquer uma das duas variáveis consideradas.

3.7 BERTopic

Além da análise de sentimentos, buscou-se investigar os principais temas presentes nas mensagens privadas dos estudantes. Para isso, empregou-se o BERTopic, uma abordagem não supervisionada de modelagem de tópicos baseada em representações semânticas

contextualizadas. Diferentemente de modelos tradicionais baseados predominantemente na frequência de palavras, o BERTopic parte da representação vetorial dos documentos, permitindo que textos semanticamente próximos sejam agrupados mesmo quando não compartilham exatamente o mesmo vocabulário (GROOTENDORST, 2022; REIMERS; GUREVYCH, 2019).

De forma geral, o funcionamento do BERTopic pode ser compreendido em quatro etapas principais. Primeiro, cada documento é convertido em um vetor denso por meio de um modelo de linguagem pré-treinado, capaz de capturar relações semânticas entre frases e parágrafos. Em seguida, esses vetores, originalmente em alta dimensionalidade, são projetados para um espaço reduzido por meio de técnicas de redução de dimensionalidade, comumente o UMAP (MCINNES; HEALY; MELVILLE, 2020). Essa etapa facilita a identificação de estruturas locais no espaço vetorial e torna o agrupamento dos documentos mais tratável. Posteriormente, os documentos são agrupados por meio de um algoritmo de clusterização, frequentemente o HDBSCAN, uma abordagem hierárquica baseada em densidade que permite identificar agrupamentos em regiões densas do espaço vetorial e separar documentos que não se ajustam claramente a nenhum grupo, tratados como ruído ou outliers (MCINNES; HEALY; ASTELS, 2017).

Por fim, o BERTopic gera uma representação interpretável para cada tópico utilizando uma variação do TF-IDF denominada class-based TF-IDF (c-TF-IDF), na qual os documentos de um mesmo agrupamento são tratados como uma classe e as palavras mais representativas de cada classe são usadas para descrever o tópico (GROOTENDORST, 2022). No contexto deste trabalho, essa abordagem foi utilizada para analisar quais conteúdos predominam nas mensagens privadas dos estudantes e verificar se determinados temas ocorrem com maior frequência em grupos específicos, como estudantes formados e evadidos.

Para a aplicação do BERTopic, as mensagens foram submetidas a um pré-processamento leve, voltado principalmente à normalização textual e à padronização básica do conteúdo. Optou-se por não realizar uma limpeza excessivamente agressiva antes da geração dos embeddings, a fim de preservar o contexto semântico das mensagens, já que modelos baseados em Transformers utilizam a sequência textual para produzir representações contextuali-

zadas. Em seguida, utilizou-se o modelo `paraphrase-multilingual-MiniLM-L12-v2`, pertencente à família Sentence-BERT, adequado para gerar embeddings semânticos de sentenças e parágrafos em contexto multilíngue (REIMERS; GUREVYCH, 2019; REIMERS; GUREVYCH, 2020). A escolha por um modelo baseado em MiniLM também se relaciona ao seu menor custo computacional, uma vez que essa arquitetura foi proposta como uma forma eficiente de compressão de modelos Transformers por meio de destilação de conhecimento (WANG et al., 2020).

4 Resultados

Esta seção apresenta os resultados obtidos por meio do método descrito anteriormente. Inicialmente, realiza-se uma caracterização descritiva dos indicadores educacionais por grupo, com o objetivo de observar como eles se comportam entre estudantes *Formados* e *Evadidos*. Depois, são comparadas as polaridades identificadas por cada método de análise de sentimentos. Em seguida, discute-se a relação entre essas polaridades e os indicadores educacionais considerados no estudo. Por fim, são apresentados os tópicos obtidos com o BERTopic.

4.1 Caracterização dos indicadores educacionais por grupo

Antes de analisar os sinais extraídos das mensagens privadas, realizou-se uma caracterização descritiva dos indicadores educacionais considerados no estudo. Essa análise teve como objetivo observar como as dimensões estruturadas da trajetória acadêmica se comportam entre estudantes *Formados* e *Evadidos*, oferecendo uma base de comparação para a interpretação posterior das polaridades, dos tópicos e das correlações com os dados textuais.

A Tabela 4.1 apresenta estatísticas descritivas das métricas numéricas associadas aos indicadores educacionais, considerando o subconjunto de estudantes com mensagens privadas disponíveis e com valores válidos nas métricas analisadas. De modo geral, observa-se que os estudantes *Formados* apresentam valores médios e medianos superiores em desempenho, engajamento, relação aluno-professor e algumas dimensões de profundidade cognitiva. Esse comportamento sugere que, no recorte analisado, os estudantes que concluíram o curso tendem a apresentar trajetórias mais consolidadas nos registros estruturados do AVA.

Tabela 4.1: Estatísticas descritivas das métricas associadas aos indicadores educacionais por grupo

Indicador / métrica	Evadido				Formado			
	Média	DP	Med.	IIQ	Média	DP	Med.	IIQ
Desempenho								
Nota mediana	47,38	28,72	54,00	47,50	77,03	18,63	82,35	13,50
Desempenho comparativo	-0,13	0,69	0,00	0,60	0,36	0,33	0,42	0,40
Engajamento								
Mediana de posts	2,63	2,17	2,50	3,00	4,90	2,49	4,00	2,00
Total de posts	64,52	57,07	51,00	66,50	245,64	127,77	223,00	120,50
Motivação								
Mediana de posts	0,00	0,00	0,00	0,00	0,00	0,06	0,00	0,00
Total de posts	1,64	2,67	1,00	2,00	15,73	13,56	13,00	15,00
Profundidade cognitiva								
Fórum	1,16	0,53	1,40	0,23	1,44	0,19	1,50	0,06
Questionário	0,77	0,98	0,00	2,00	0,87	1,08	0,00	2,00
Tarefa	1,27	0,55	1,45	0,43	1,67	0,24	1,67	0,23
Relação aluno-professor								
Mediana de interações	0,06	0,35	0,00	0,00	0,45	1,09	0,00	0,00
Total de interações	5,72	8,71	2,00	7,00	48,48	66,41	25,00	48,75
Trajetória acadêmica								
Número de disciplinas	21,74	13,37	18,00	21,00	47,62	8,49	48,00	10,00

Nota. DP = desvio-padrão; Med. = mediana; IIQ = intervalo interquartil. As estatísticas dos indicadores foram calculadas para os estudantes com valores disponíveis nas respectivas métricas; por isso, o número de casos pode diferir ligeiramente do total de estudantes com mensagens privadas.

A caracterização apresentada na Tabela 4.1 evidencia diferenças entre os grupos, especialmente nos indicadores associados ao desempenho e engajamento. Em relação ao desempenho, os estudantes *Formados* apresentam valores médios e medianos superiores tanto na nota mediana quanto no desempenho comparativo. Além disso, a maior dispersão observada entre os *Evadidos*, sobretudo na nota mediana, sugere trajetórias acadêmicas mais heterogêneas nesse grupo, enquanto os *Formados* tendem a se concentrar em faixas mais altas e estáveis de rendimento.

Nos indicadores de engajamento, os *Formados* também apresentam valores superiores, tanto na média quanto na mediana. Como o indicador individual corresponde à média das postagens em fóruns avaliativos ao longo das disciplinas cursadas, os resultados indicam maior nível médio de participação desse grupo nas atividades avaliativas do Moodle.

O indicador de motivação apresenta comportamento menos distintivo entre os grupos. A mediana de postagens em fóruns não avaliativos é igual a zero para *Formados* e *Evadidos*, indicando baixa participação nesse tipo de espaço para grande parte dos estudantes. Embora o total médio de postagens seja maior entre os *Formados*, esse resultado também pode estar relacionado ao maior número de disciplinas cursadas por esse grupo.

Quanto à profundidade cognitiva, observa-se um padrão mais favorável aos *Formados* nas métricas associadas a fóruns e tarefas, com valores centrais mais altos e menor dispersão. Esse comportamento sugere maior regularidade no envolvimento com atividades do AVA. Por outro lado, a profundidade cognitiva em questionários apresenta medianas iguais a zero nos dois grupos.

A relação aluno-professor apresenta concentração de valores baixos, com mediana igual a zero nos dois grupos. Esse resultado indica que muitos estudantes tiveram pouca ou nenhuma interação direta com docentes nos fóruns. Ainda assim, o total de interações é mais elevado entre os *Formados*, sugerindo que, quando ocorre, esse tipo de interação aparece de forma mais acumulada nesse grupo.

De modo geral, os resultados mostram que os estudantes *Formados* apresentam valores mais elevados em desempenho, engajamento, número de disciplinas cursadas, interação aluno-professor e parte das métricas de profundidade cognitiva. Já os *Evadidos* apresentam maior dispersão em algumas dimensões, especialmente no desempenho. Essa caracterização é importante porque mostra que os grupos já se diferenciam nos registros estruturados do AVA antes da incorporação dos sinais extraídos das mensagens privadas. Assim, as análises posteriores de sentimentos, tópicos e correlações devem ser interpretadas à luz desse comportamento prévio dos indicadores educacionais.

4.2 Análise de sentimentos

A comparação entre os métodos de análise de sentimentos mostrou que a polaridade atribuída às mensagens privadas do Moodle varia consideravelmente conforme a abordagem analítica utilizada. Como apresentado na Figura 4.1, os métodos baseados em léxicos tendem a atribuir uma proporção maior de rótulos positivos, enquanto os modelos contextuais baseados em *Transformers* produzem distribuições relativamente mais concentradas nas classes neutra e negativa.




Figura 4.1: Distribuição dos rótulos de sentimento por método e grupo nas mensagens privadas.

Esse comportamento é consistente com as características de cada abordagem. Métodos baseados em léxicos atribuem maior peso à polaridade de unidades textuais isoladas, o que pode favorecer classificações positivas em mensagens que contêm cumprimentos, expressões de agradecimento e outros marcadores de polidez. No entanto, no corpus analisado, essas expressões polidas frequentemente aparecem em mensagens cujo conteúdo principal envolve dificuldades acadêmicas, problemas técnicos, pedidos de revisão de nota, preocupações com o desempenho ou risco de reprovação em uma disciplina.

Em contraste, modelos baseados em *Transformers* analisam o enunciado de forma mais contextualizada, incorporando relações semânticas mais amplas. Como resultado, eles tendem a classificar parte dessas mensagens como neutras ou negativas, especialmente quando o conteúdo geral indica dificuldade, insatisfação ou necessidade de intervenção institucional.

A inspeção qualitativa das mensagens sugere que as classificações produzidas pelos modelos baseados em *Transformers* foram, em muitos casos, mais compatíveis com o conteúdo global dos enunciados. Ao considerar o contexto completo da mensagem, esses modelos pareceram representar de forma mais realista situações em que expressões de cordialidade coexistiam com relatos de dificuldades, reclamações ou solicitações de apoio.

Para ilustrar esse comportamento, a Tabela 4.2 apresenta exemplos representativos de divergência e concordância entre os métodos. As mensagens selecionadas referem-se a situações recorrentes no corpus, como reprovação em disciplina, contestação de nota, problemas técnicos no AVA e insatisfação com materiais didáticos ou avaliações.

Os exemplos indicam que a divergência tende a ocorrer principalmente em mensagens formalmente polidas, nas quais a linguagem institucional suaviza situações de dificuldade acadêmica ou insatisfação. Por outro lado, quando a mensagem contém marcadores negativos explícitos, como crítica direta, dificuldade de compreensão do conteúdo ou insatisfação com materiais e avaliações, observa-se maior convergência entre os métodos.

A Tabela 4.3 reforça essa interpretação ao evidenciar a baixa concordância entre os métodos. O percentual de mensagens com consenso total foi baixo em ambos os grupos,

Tabela 4.2: Exemplos representativos de divergência e consenso entre métodos de análise de sentimentos S=Sentilex-PT, O=OpLexicon, T=TextBlob, V= Vader, X=XML-RoBERTa, e m=mBert.

Trecho da mensagem	S	O	T	V	X	m	Interpretação
<i>“Bom dia professora, tudo bem? não consegui ser aprovada em sua disciplina, por 0,50 pontos. Terei que refazer a disciplina [...]? aguardo retorno. atenciosamente.”</i>	+	-	+	+	-	-	A mensagem trata de reprovação por pequena diferença de nota, mas contém saudações e fechamento cordial, o que favorece classificações positivas em alguns métodos.
<i>“Boa tarde. nota da atividade colaborativa, 0 em 10? sem justificativa, professora? não, ué. assim não tem como prosseguir, por favor me dê um retorno plausível. 0 porque?”</i>	+	+	+	+	-	-	Apesar de expressar contestação, insatisfação e cobrança por justificativa, a mensagem foi classificada como positiva por métodos lexicais.
<i>“Não estou conseguindo abrir o fórum [...] aparece erro de codificação.”</i>	-	+	+	+	-	-	O trecho representa um problema técnico no AVA. A divergência mostra que mensagens objetivas sobre falhas da plataforma podem receber polaridades distintas conforme o método.
<i>“Professora, às vésperas de sua prova eu e a maioria das alunas estamos em dúvida [...] seus vídeos são de péssima qualidade de áudio [...] o conteúdo é muito complicado de entendimento [...] queríamos muito uma webinar.”</i>	-	-	-	-	-	-	Neste caso, há consenso entre todos os métodos, pois a mensagem contém marcadores negativos explícitos, como dificuldade, crítica à qualidade do material e insatisfação com a preparação para a avaliação.
<i>“Gostaria de te agradecer pelas aulas muito bem explicadas, excelente conteúdo e uma dicção perfeita. Estou realmente encantada pelo seu trabalho. Parabéns de coração!”</i>	+	+	+	+	+	+	Neste caso, há consenso positivo entre todos os métodos, pois a mensagem apresenta marcadores afetivos explicitamente positivos, como agradecimento, elogio à qualidade das aulas e reconhecimento do trabalho docente.

correspondendo a 4,66% entre estudantes evadidos e 3,17% entre estudantes formados. Em contraste, predominaram mensagens classificadas em dois ou três rótulos distintos de polaridade, indicando que a análise de sentimentos nesse corpus é sensível ao método adotado.

Tabela 4.3: Nível de divergência entre métodos de análise de sentimentos por grupo

Grupo	Consenso total	Dois rótulos	Três rótulos
<i>Evadidos</i>	18 (4,66%)	174 (45,08%)	194 (50,26%)
<i>Formados</i>	82 (3,17%)	1007 (38,96%)	1496 (57,87%)

Observa-se também que o grupo de *Formados* apresentou uma proporção maior de mensagens classificadas em três rótulos distintos de polaridade, sugerindo maior instabilidade entre os métodos. No grupo de *Evadidos*, o percentual de mensagens com consenso total foi ligeiramente superior ao observado entre os estudantes formados.

Em ambos os grupos, contudo, a baixa convergência indica que a interpretação afetiva das mensagens privadas não pode ser tratada como independente da abordagem analítica escolhida. Assim, no contexto analisado, a polaridade das mensagens deve ser interpretada com cautela, especialmente porque interações educacionais e administrativas

podem combinar linguagem polida com situações concretas de dificuldade acadêmica, preocupação ou insatisfação.

4.2.1 Impacto de alterações nas mensagens

Como análise complementar, investigou-se o efeito de expressões de polidez sobre os métodos baseados em léxicos. Para isso, foram removidas expressões recorrentes utilizadas em cumprimentos, agradecimentos e encerramentos formais, como “bom dia”, “por favor” e “atenciosamente”.

Após essa remoção, os métodos SentiLex e OpLexicon foram reaplicados, permitindo comparar a polaridade original com a polaridade obtida sem esses marcadores. Os resultados mostram que 21,91% das mensagens mudaram de rótulo com o SentiLex e 42,21% com o OpLexicon, indicando maior sensibilidade do OpLexicon a esse tipo de expressão. A principal mudança observada foi de positivo para neutro, correspondendo a 15,42% das mensagens no SentiLex e 26,99% no OpLexicon. Além disso, no OpLexicon, 3,10% das mensagens passaram de positivo para negativo.

Esses resultados sugerem que parte da positividade inicialmente capturada pelos métodos baseados em léxicos estava associada a fórmulas de saudação, tratamento e encerramento, e não necessariamente ao conteúdo acadêmico central das mensagens. Essa interpretação dialoga com Wen et al. (2014), que observaram, em fóruns de Massive Open Online Courses (MOOCs), que mensagens classificadas como positivas frequentemente estavam associadas a agradecimentos e respostas breves, como “thank you”. Assim, no corpus analisado, a presença recorrente de marcadores de polidez pode ter contribuído para elevar a polaridade positiva atribuída por métodos lexicais.

Nesse contexto, o XLM-RoBERTa apresentou classificações qualitativamente mais compatíveis com o conteúdo global das mensagens, ao considerar simultaneamente os marcadores de polidez e a demanda acadêmica expressa pelo estudante. Diferentemente dos métodos lexicais, sua interpretação mostrou-se menos dependente de palavras positivas isoladas, produzindo resultados mais condizentes com o conteúdo observado.

4.3 Correlação entre Análise de Sentimentos e Indicadores Educacionais

Após a caracterização dos indicadores por grupo, buscou-se verificar se as polaridades expressas nas mensagens privadas se relacionam com essas dimensões estruturadas da trajetória acadêmica. Assim, a análise de correlação não teve como objetivo comparar diretamente *Formados* e *Evadidos*, mas observar se os sinais sentimentais extraídos das mensagens acompanham, em nível agregado, indicadores como desempenho, engajamento, motivação, interação aluno–professor, profundidade cognitiva e desistência.

A análise considerou apenas mensagens com consenso geral entre os métodos, visando selecionar somente mensagens cuja polaridade apresentasse maior estabilidade entre as diferentes abordagens empregadas. Em seguida, agregou os *scores* de cada estudante para correlacioná-los com os indicadores educacionais.

Os resultados dessas correlações são apresentados na Figura 4.2. De modo geral, as correlações observadas foram fracas, com valores próximos de zero na maior parte das combinações analisadas. Nenhuma associação apresentou alta magnitude, indicando que a polaridade média das mensagens privadas não está forte ou diretamente relacionada aos indicadores educacionais considerados.

Ainda assim, algumas associações específicas podem ser destacadas. Entre os indicadores avaliados, a maior correlação foi observada entre o indicador de desempenho e o método mBERT, com valor aproximado de 0,27.² Para o indicador de motivação, a associação mais forte foi observada entre o número total de postagens e o método mBERT, com correlação aproximada de 0,24. Por outro lado, para a profundidade cognitiva em fóruns, foi identificada uma correlação negativa com o método SentiLex, com valor aproximado de -0,25. Embora esses valores indiquem pequenas variações entre métodos e indicadores, eles sugerem que a análise de sentimentos, quando resumida pela polaridade média das mensagens privadas, não apresenta associação forte com os indicadores educacionais previamente calculados.

²O coeficiente de correlação de Spearman varia de -1 a 1. Em geral, valores absolutos abaixo de 0,30 são interpretados como associações fracas, embora esse limiar possa variar conforme o contexto da pesquisa.

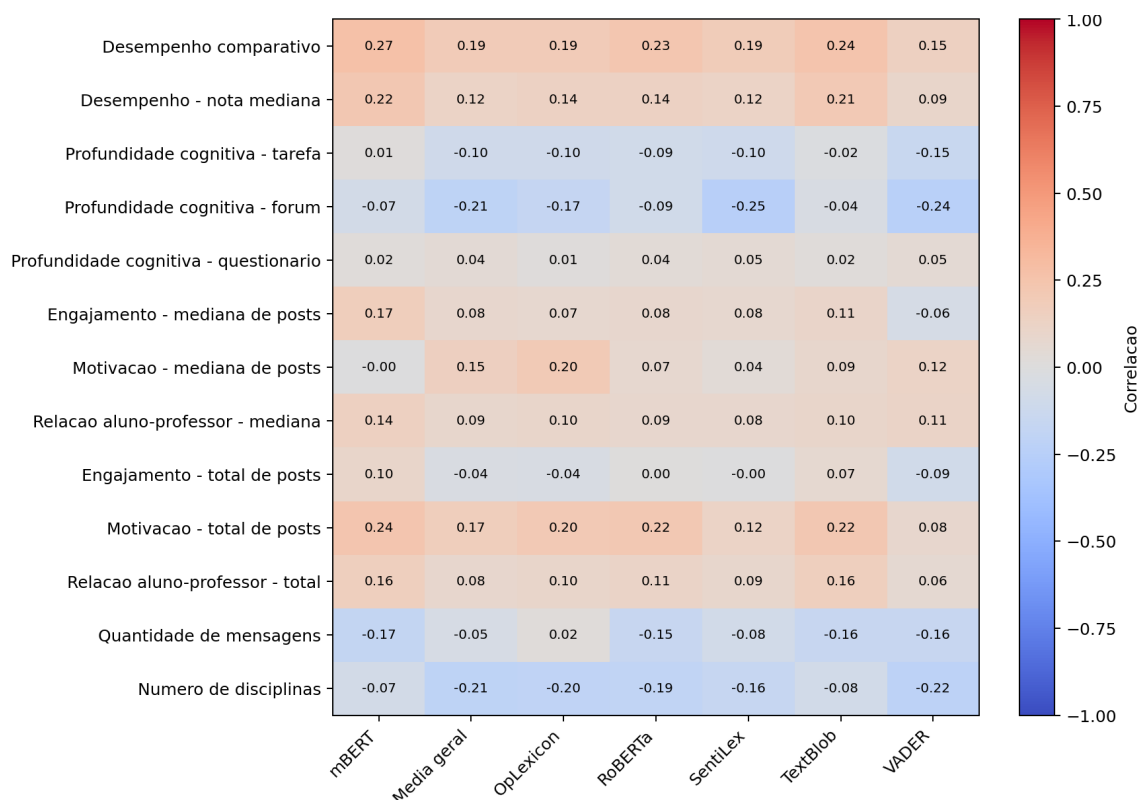


Figura 4.2: Correlações de Spearman entre as medidas agregadas de sentimento e os indicadores educacionais por estudante.

Embora as correlações tenham apresentado baixa magnitude, observou-se consistência na direção de algumas associações entre os métodos. Os indicadores de desempenho correlacionaram-se positivamente com a polaridade, sugerindo que estudantes com melhor desempenho produziram mensagens, em média, mais positivas. Em sentido oposto, a profundidade cognitiva nos fóruns e o número de disciplinas cursadas apresentaram associações negativas em todas as abordagens. Essas tendências podem refletir maior envolvimento com dúvidas, resolução de problemas e demandas acadêmicas, mas, devido à baixa magnitude das correlações, não permitem estabelecer conclusões definitivas.

4.4 Agrupamento de Mensagens por Tópico

Esta etapa teve como objetivo identificar conjuntos de mensagens semanticamente semelhantes e caracterizar os assuntos mais recorrentes nas comunicações privadas do Moodle. Para isso, utilizou-se o BERTopic, método que representa semanticamente cada mensagem e agrupa textos com conteúdos próximos.

Como resultado, o modelo atribuiu a cada agrupamento um identificador numé-

rico, denominado *topic ID*. Esses números funcionam apenas como rótulos gerados pelo algoritmo e não indicam ordem, importância ou intensidade. A interpretação de cada tópico foi realizada a partir da análise dos termos mais representativos e das mensagens associadas ao agrupamento. Posteriormente, tópicos que tratavam de assuntos semelhantes foram reunidos manualmente em categorias mais amplas, denominadas macrotópicos.

As mensagens para as quais o modelo não identificou similaridade suficiente com nenhum agrupamento receberam o identificador -1 e foram consideradas *outliers*. A Tabela 4.4 apresenta os macrotópicos construídos, os tópicos que os compõem, o número de mensagens e uma síntese de seu conteúdo.

Tabela 4.4: Síntese e dimensão dos principais tópicos identificados pelo BERTopic

Macrotópico	ID do tópico (mensagens)	Mensagens, n (%)	Síntese
Notas, avaliações e provas	3(162), 12(54), 17(42), 18(40), 21(34), 23(25)	357 (12,0)	Notas ausentes, avaliações presenciais, gabaritos, provas de recuperação e pedidos de revisão de nota.
Fóruns e atividades colaborativas	0(323), 1(247)	570 (19,2)	Participação em fóruns, notas de fórum, postagens e atividades em grupo.
Prazos, envios e problemas técnicos	4(144), 5(125), 16(42)	311 (10,5)	Datas, atrasos, envios por e-mail, postagem de atividades e dificuldades relacionadas à internet.
Conteúdo das disciplinas	6(112), 7(103), 9(92), 11(75), 22(26)	408 (13,7)	Trechos de atividades, conteúdos das disciplinas e respostas enviadas pelos estudantes.
Trabalho final, estágio e orientação	10(83), 13(51), 14(47)	181 (6,1)	Relatórios, estágios, trabalhos finais, orientação e correções acadêmicas.
Outros tópicos e <i>outliers</i>	2(183), 8(97), 15(42), 19(37), 20(37); -1 (748)	1.144 (38,5)	Tópicos adicionais não incluídos nos macrotópicos anteriores e mensagens não associadas de forma consistente a um agrupamento pelo BERTopic.

Os resultados mostram que as mensagens privadas foram utilizadas principalmente para tratar de demandas acadêmicas e administrativas. Entre os assuntos identificados estão participação em fóruns, notas, avaliações, prazos, envio de atividades, dificuldades técnicas, estágios, trabalhos finais e contato com professores ou tutores. Portanto, o corpus representa situações concretas da trajetória acadêmica dos estudantes mais frequentemente do que manifestações afetivas espontâneas.

O maior macrotópico claramente delimitado foi o de fóruns e atividades colaborativas, com 570 mensagens, seguido pelos tópicos relacionados ao conteúdo das disciplinas, com 408 mensagens, e por notas, avaliações e provas, com 357 mensagens. Além disso, 748 mensagens foram classificadas como *outliers*, indicando que parte do corpus apresentava conteúdos muito específicos, heterogêneos ou insuficientemente semelhantes para formar agrupamentos estáveis.

Embora os estudantes *Formados* predominem em números absolutos em todos os tópicos, esse resultado deve ser interpretado considerando a composição do corpus, no qual esse grupo concentra a maior parte das mensagens. Em termos relativos, alguns tópicos apresentaram participação proporcionalmente maior de estudantes *Evadidos* em comparação com sua presença geral no conjunto de mensagens, especialmente aqueles relacionados a envios por e-mail, prazos, notas ausentes e dificuldades de postagem. Esses resultados mostram que parte das mensagens dos estudantes evadidos estava relacionada a problemas de organização acadêmica, acompanhamento de avaliações e dificuldades operacionais no uso do AVA.

O agrupamento por tópicos também contribui para compreender por que a polaridade média, isoladamente, apresentou associações fracas com os indicadores educacionais: muitas mensagens não expressam estados afetivos amplos, mas solicitações específicas. Esse resultado se aproxima do observado por Yang et al. (YANG et al., 2015), que destacam que sinais textuais mais específicos, como manifestações de confusão, podem fornecer interpretações mais úteis sobre retenção e evasão.

Dessa forma, a modelagem de tópicos complementa a análise de sentimentos ao revelar quais demandas motivaram as comunicações privadas no Moodle. Os resultados indicam ainda que a interpretação da polaridade depende do conteúdo e do contexto comunicativo da mensagem, uma vez que textos classificados como negativos ou neutros podem representar pedidos de ajuda, dúvidas ou dificuldades acadêmicas específicas.

4.5 Discussão de resultados

A caracterização inicial dos indicadores educacionais mostrou que os grupos de *Formados* e *Evadidos* já apresentam diferenças nos registros estruturados do AVA. Os estudantes *Formados* tendem a apresentar valores mais elevados em desempenho, engajamento, número de disciplinas cursadas, interação aluno-professor e em parte das métricas de profundidade cognitiva. Esse resultado indica que as trajetórias acadêmicas dos grupos se distinguem nos indicadores educacionais antes mesmo da análise dos dados textuais. Portanto, a questão central das análises seguintes não se restringe a verificar se os grupos diferem, mas envolve compreender se as mensagens privadas acrescentam sinais complementares à

interpretação dessas diferenças.

Os resultados obtidos indicam que a interpretação das mensagens privadas do Moodle depende fortemente da abordagem analítica utilizada. A baixa concordância entre os métodos de análise de sentimentos mostra que a polaridade atribuída às mensagens não pode ser tratada como uma característica objetiva e independente do método empregado. Essa variação é coerente com a literatura, que aponta diferenças importantes entre abordagens baseadas em léxicos e métodos baseados em aprendizado de máquina, especialmente quanto à capacidade de considerar o contexto textual (MEDHAT; HASSAN; KORASHY, 2014).

No corpus analisado, os métodos baseados em léxicos tenderam a atribuir maior proporção de rótulos positivos, enquanto os modelos baseados em *Transformers* apresentaram distribuições mais concentradas nas classes neutra e negativa. Conforme visto na Subseção 4.2.1, esse comportamento pode ser explicado, em parte, pela natureza formal das mensagens privadas em contexto acadêmico, onde expressões de saudação, agradecimento e encerramento aparecem com frequência nas mensagens e podem influenciar a classificação realizada por métodos lexicais. Assim, mensagens que tratam de dificuldades, problemas técnicos, reprovação ou contestação de notas podem receber polaridade positiva quando contêm marcadores de polidez.

As diferenças entre os métodos também ajudam a explicar os resultados obtidos na análise de correlação com os indicadores educacionais. De modo geral, as correlações entre a polaridade média das mensagens e os indicadores foram fracas. Esse resultado sugere que a polaridade, quando resumida em uma média por estudante, não expressa de forma direta a trajetória acadêmica observada nos indicadores. Mensagens privadas podem registrar situações pontuais, como uma dúvida sobre atividade, um problema técnico ou uma contestação de nota, sem que isso se reflita necessariamente na média dos indicadores do estudante ao longo das disciplinas cursadas.

Esses resultados são consistentes com a literatura, que sugere que a relação entre sentimentos expressos em ambientes virtuais de aprendizagem e indicadores educacionais não é necessariamente direta. Wen et al. (2014), ao analisarem sentimentos em postagens de estudantes em nível individual, observaram que os efeitos não foram consistentes entre

os cursos investigados, sugerindo que, em análises individualizadas, a interpretação da polaridade depende fortemente do conteúdo das mensagens, do contexto do curso e do tipo de interação analisada.

No contexto do Moodle, Bobó et al. (2019) identificaram evidências de perfis emocionais e potencial risco de evasão com base em um pequeno número de mensagens em fóruns de perguntas e respostas. No entanto, diferentemente do presente estudo, os autores não trataram a polaridade de forma isolada, mas a combinaram com registros de interação do AVA. Assim, enquanto Bobó et al. apontam para o potencial do uso de sinais textuais em combinação com outros rastros educacionais, os resultados obtidos neste estudo indicam que a polaridade média das mensagens privadas, quando considerada isoladamente, não apresenta associação forte com os indicadores educacionais analisados.

Portanto, a ausência de correlações fortes neste estudo não implica que as mensagens privadas sejam irrelevantes para o monitoramento estudantil. Pelo contrário, sugere que a polaridade média, isoladamente, pode ser insuficiente para capturar dimensões complexas da experiência discente. Mensagens privadas podem expressar frustrações específicas que não necessariamente se refletem diretamente em indicadores de desempenho, engajamento, motivação ou desistência. Assim, os resultados reforçam a necessidade de interpretar a análise de sentimentos como uma camada complementar aos indicadores educacionais, especialmente quando combinada à análise de tópicos e ao contexto comunicativo em que as mensagens foram produzidas.

Nesse sentido, os resultados obtidos com o BERTopic ampliam a interpretação da análise de sentimentos. Os macrotópicos identificados mostram que as mensagens privadas foram utilizadas principalmente para tratar de demandas acadêmicas e administrativas, como notas, avaliações, prazos, envio de atividades, dificuldades técnicas, fóruns, estágio, orientação e trabalhos finais. Assim, o corpus analisado parece refletir mais situações concretas da trajetória acadêmica do que manifestações afetivas espontâneas. Esse resultado ajuda a compreender por que a polaridade média apresentou associação fraca com os indicadores: muitas mensagens não expressam sentimentos amplos sobre o curso, mas solicitações específicas relacionadas à organização das disciplinas e ao suporte acadêmico.

Essa interpretação se aproxima do observado por Yang et al. (2015), que mostram

que sinais textuais mais específicos, como a confusão, podem oferecer interpretações mais úteis sobre retenção e evasão do que medidas afetivas genéricas. No presente estudo, a modelagem de tópicos cumpre papel semelhante ao agrupar as mensagens segundo os problemas, as dúvidas e as demandas relatadas pelos estudantes. Esses agrupamentos podem ainda subsidiar estudos futuros voltados à classificação automática das mensagens em categorias acadêmicas e administrativas previamente definidas e validadas.

Em conjunto, os resultados reforçam que o uso de mensagens privadas em LA deve considerar tanto o potencial quanto os limites desses registros. Por um lado, as mensagens podem complementar os indicadores educacionais ao revelar demandas qualitativas que não aparecem diretamente em medidas numéricas. Por outro, sua utilidade depende da quantidade de registros disponíveis, da centralidade do Moodle como canal institucional de comunicação e da forma como estudantes e docentes utilizam a plataforma. Assim, mais do que indicar uma relação direta entre sentimento e trajetória acadêmica, este estudo evidencia que os registros textuais do Moodle podem apoiar o acompanhamento discente quando analisados em articulação com indicadores, tópicos recorrentes e contexto institucional de produção das mensagens.

5 Conclusão

Este trabalho investigou como a análise de sentimentos e a modelagem de tópicos aplicadas a mensagens privadas do Moodle podem complementar a interpretação de indicadores educacionais na análise das trajetórias acadêmicas de estudantes *Formados* e *Evadidos* em cursos de EaD. Para isso, foram analisadas mensagens privadas produzidas no Moodle em conjunto com indicadores educacionais previamente construídos, considerando dimensões como desempenho, engajamento, motivação, relação aluno-professor, profundidade cognitiva e desistência.

De modo geral, os resultados indicam que as mensagens privadas podem complementar a interpretação dos indicadores educacionais, mas essa contribuição não ocorre de forma direta pela polaridade média dos sentimentos. A análise de sentimentos mostrou baixa concordância entre os métodos empregados e correlações fracas entre a polaridade média das mensagens e os indicadores educacionais. Assim, a polaridade, quando considerada isoladamente, apresentou alcance limitado para explicar diferenças entre estudantes *Formados* e *Evadidos* ou para representar diretamente dimensões da trajetória acadêmica.

Apesar dessas limitações, os modelos contextuais baseados em *Transformers*, como o mBERT e o XLM-RoBERTa, demonstraram potencial para a análise de mensagens educacionais. A inspeção qualitativa indicou que esses modelos foram mais capazes de considerar o conteúdo global dos enunciados, evitando que cumprimentos, agradecimentos e outras expressões de polidez determinassem isoladamente a classificação. Esse comportamento foi relevante em mensagens nas quais uma formulação cordial acompanhava relatos de dificuldades, reclamações, dúvidas ou pedidos de apoio. Contudo, devido à ausência de um conjunto de referência anotado manualmente, não foi possível determinar objetivamente qual método apresentou maior acurácia.

A análise textual contribuiu para a compreensão de demandas acadêmicas e administrativas, bem como de aspectos qualitativos das trajetórias dos estudantes, especialmente quando interpretada à luz dos tópicos das mensagens e do contexto de uso do AVA. Dessa forma, a principal resposta ao problema de pesquisa é que a análise de sentimentos

e a modelagem de tópicos complementam os indicadores educacionais ao oferecer uma camada textual e qualitativa para a interpretação da trajetória estudantil. A polaridade média mostrou-se insuficiente para representar a complexidade da experiência discente, enquanto a análise dos temas recorrentes permitiu compreender melhor o conteúdo das interações e indicar que muitas mensagens refletem situações concretas de organização acadêmica, suporte institucional e dificuldades pontuais enfrentadas pelos estudantes.

Como limitação, a análise considerou a polaridade média das mensagens e os valores médios dos indicadores, o que pode diluir manifestações esporádicas relevantes ao longo da trajetória do estudante. Além disso, o volume de mensagens privadas não se distribuiu de forma uniforme entre os grupos analisados, uma vez que os estudantes formados apresentaram maior atividade comunicacional no ambiente. Também é importante considerar que as mensagens privadas possuem natureza educacional e administrativa, o que pode dificultar a identificação clara de sentimentos.

Outra limitação refere-se à própria centralidade do Moodle como canal de comunicação institucional, pois os resultados sugerem que o potencial da análise textual em LA pode ser limitado pelas práticas institucionais e organizacionais relativas ao uso do AVA. Quando parte das interações relevantes ocorre fora do Moodle, como por WhatsApp, e-mail ou atendimento presencial, os registros textuais disponíveis no ambiente podem representar apenas uma fração da experiência estudantil. Nesse sentido, a ausência de correlações fortes não implica que os dados textuais não tenham valor; ao contrário, evidencia que o potencial analítico da LA depende da qualidade, centralidade e completude dos registros produzidos no ambiente institucional.

Por fim, ao analisar um conjunto real de dados de estudantes, este estudo evidencia tanto o potencial quanto as limitações das mensagens privadas do Moodle como fonte para o monitoramento discente. Os achados sugerem que esses registros não devem ser utilizados de forma isolada ou como substitutos dos indicadores educacionais, mas como uma fonte adicional de interpretação. Esses achados podem apoiar a reflexão institucional sobre a importância de centralizar os registros de comunicação no AVA, a fim de ampliar seu uso em estratégias de acompanhamento, orientação e permanência estudantil.

Em trabalhos futuros, propõe-se aprofundar a investigação por meio de análises

temporais das mensagens, do desenvolvimento de estratégias para vincular os registros textuais a disciplinas ou períodos letivos específicos e da incorporação de abordagens voltadas à identificação de dúvidas, manifestações de confusão e pedidos de apoio. Tecnicamente, modelos baseados em BERT poderiam ser integrados ao AVA para processar mensagens em tempo próximo ao real e sinalizar situações que demandassem acompanhamento.

Além dos aspectos técnicos, esse tipo de aplicação exige cuidados éticos relacionados à privacidade, à transparência e à finalidade do tratamento das mensagens privadas. Os estudantes devem ser informados sobre a análise desses registros e sobre os objetivos do monitoramento. Nesse contexto, os modelos deveriam atuar como ferramentas de apoio à equipe pedagógica, com revisão humana das sinalizações, e não como mecanismos autônomos de vigilância, rotulação ou intervenção.

Bibliografia

ALKHNBASHI, O.; NASSR, R. Topic modelling and sentimental analysis of students' reviews. *Computers, Materials and Continua*, v. 74, p. 6835–6848, 12 2022.

ANWAR, A. et al. Emotions matter: A systematic review and meta-analysis of the detection and classification of students' emotions in stem during online learning. *Education Sciences*, v. 13, n. 9, 2023. ISSN 2227-7102. Disponível em: <<https://www.mdpi.com/2227-7102/13/9/914>>.

BLEI, D. M. Probabilistic topic models. *Commun. ACM*, Association for Computing Machinery, New York, NY, USA, v. 55, n. 4, p. 77–84, abr. 2012. ISSN 0001-0782. Disponível em: <<https://doi.org/10.1145/2133806.2133826>>.

BOBÓ, M. et al. Identificação do perfil emocional do aluno através de análise de sentimento: Combatendo a evasão escolar. In: *Anais do XXX Simpósio Brasileiro de Informática na Educação*. Porto Alegre, RS, Brasil: SBC, 2019. p. 1431–1440. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/40172>>.

CARVALHO, G. et al. Análise de aprendizagem no moodle: Construção de um painel de dados com indicadores educacionais. In: *Anais do XXXVI Simpósio Brasileiro de Informática na Educação*. Porto Alegre, RS, Brasil: SBC, 2025. p. 85–98. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/38416>>.

CHAMORRO-ATALAYA, O. et al. Student satisfaction classification algorithm using the minority synthetic oversampling technique. In: . [S.l.: s.n.], 2023. v. 13, n. 7, p. 423–430.

CHANEY, B. H. et al. A primer on quality indicators of distance education. *Health Promotion Practice*, v. 10, n. 2, p. 222–231, 2009. Disponível em: <<https://doi.org/10.1177/1524839906298498>>.

CLEVELAND-INNES, M.; CAMPBELL, P. Emotional presence, learning, and the online learning environment. *The International Review of Research in Open and Distributed Learning*, p. 269, 10 2012.

COBOS, R.; JURADO, F.; BLÁZQUEZ-HERRANZ, A. A content analysis system that supports sentiment analysis for subjectivity and polarity detection in online courses. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, v. 14, n. 4, p. 177–187, 2019.

CONIJN, R. et al. Predicting student performance from lms data: A comparison of 17 blended courses using moodle lms. *IEEE Transactions on Learning Technologies*, v. 10, n. 1, p. 17–29, 2017.

COSTAS-JAUREGUI, V. et al. Descriptive analytics dashboard for an inclusive learning environment. In: *IEEE Frontiers in Education Conference (FIE)*. [S.l.: s.n.], 2021. p. 1–9.

DAKE, D.; BADA, G. Unveiling learner emotions: Sentiment analysis of moodle-based online assessments using machine learning. *Journal of Information Technology Education: Innovations in Practice*, 07 2023.

DALIPI, F.; ZDRAVKOVA, K.; AHLGREN, F. Sentiment analysis of students' feedback in moocs: A systematic literature review. *Frontiers in Artificial Intelligence*, v. 4, 09 2021.

DILLENBOURG, P.; SCHNEIDER, D. K.; SYNTETA, P. Virtual learning environments. In: *Proceedings of the 3rd Hellenic Conference Information and Communication Technologies in Education*. [S.l.: s.n.], 2002. p. 3–18.

DRINGUS, L. Learning analytics considered harmful. *Online Learning*, v. 16, p. 87–100, 06 2012.

EINHARDT, L.; TAVARES, T. A.; CECHINEL, C. Moodle analytics dashboard: a learning analytics tool to visualize users' interactions in Moodle. In: *XI Latin American Conference on Learning Objects and Technology (LACLO)*. [S.l.: s.n.], 2016. p. 1–6.

FREITAS, L. Comparing portuguese opinion lexicons in feature-based sentiment analysis. *International Journal of Computational Linguistics and Applications*, v. 4, p. 147–158, 03 2013.

FURTADO, U. d. M.; FERNANDES, J. d. O. *Introdução à EaD: Moodle para Estudantes*. Mossoró, RN, 2017. Material didático consultado em PDF. Disponível em: <<https://ead.ufersa.edu.br/wp-content/uploads/sites/116/2020/09/Caderno-Did%C3%A1tico-Introdu%C3%A7%C3%A3o-%C3%A0-EaD-Moodle-para-estudantes-revisado-2020.pdf>>.

GROOTENDORST, M. BERTopic: Neural topic modeling with a class-based TF-IDF procedure. *arXiv preprint arXiv:2203.05794*, 2022.

HERNÁNDEZ-GARCÍA, Á.; ACQUILA-NATALE, E.; CHAPARRO-PELÁEZ, J. Current state of learning management systems' log data-based learning analytics. In: *Proceedings of the 17th Biennial EARLI Conference for Research on Learning and Instruction*. Tampere, Finland: [s.n.], 2017.

ID, I. et al. Sentiment analysis of student evaluation feedback using transformer-based language models. *Indonesian Journal of Electrical Engineering and Computer Science*, v. 36, p. 1127, 11 2024.

KAGKLIS, V. et al. A learning analytics methodology for detecting sentiment in student fora: A case study in distance education. *European Journal of Open, Distance and E-Learning*, v. 18, 12 2015.

KOUFAKOU, A. Deep learning for opinion mining and topic classification of course reviews. *Education and Information Technologies*, Kluwer Academic Publishers, USA, v. 29, n. 3, p. 2973–2997, jun. 2023. ISSN 1360-2357. Disponível em: <<https://doi.org/10.1007/s10639-023-11736-2>>.

LIU, B. *Sentiment Analysis and Opinion Mining*. [S.l.]: Morgan & Claypool Publishers, 2012. (Synthesis Lectures on Human Language Technologies).

LONN, S.; TEASLEY, S. D. Saving time or innovating practice: Investigating perceptions and uses of learning management systems. *Computers Education*, v. 53, n. 3, p. 686–694, 2009. ISSN 0360-1315. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360131509001006>>.

LUNDQVIST, K.; LIYANAGUNAWARDENA, T.; STARKEY, L. Evaluation of student feedback within a mooc using sentiment analysis and target groups. *The International Review of Research in Open and Distributed Learning*, v. 21, 05 2020.

MARTIN, F.; NDOYE, A. Using learning analytics to assess student learning in online courses. *Journal of University Teaching and Learning Practice*, v. 13, 07 2016.

MCINNES, L.; HEALY, J.; ASTELS, S. hdbscan: Hierarchical density based clustering. *Journal of Open Source Software*, The Open Journal, v. 2, n. 11, p. 205, 2017. Disponível em: <<https://doi.org/10.21105/joss.00205>>.

MCINNES, L.; HEALY, J.; MELVILLE, J. Umap: Uniform manifold approximation and projection for dimension reduction. 2020. Disponível em: <<https://arxiv.org/abs/1802.03426>>.

MEDHAT, W.; HASSAN, A.; KORASHY, H. Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, v. 5, n. 4, p. 1093–1113, 2014. ISSN 2090-4479. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2090447914000550>>.

MEHALL, S. Purposeful interpersonal interaction: What is it and how is it measured? *Online Learning*, v. 24, 03 2020.

Menezes, M. F. d. Proposta de um dashboard para análise e visualização de dados educacionais de sistemas tutores inteligentes. *Universidade Federal do Amazonas*, 2024.

MORA, H. et al. A computational method for enabling teaching-learning process in huge online courses and communities. In: . [S.l.: s.n.], 2017. v. 18, n. 1.

NITAHARA, A. *Estudo mostra que pandemia intensificou uso das tecnologias digitais*. Agência Brasil, 2021. Acesso em: 25 nov. 2021. Disponível em: <<https://agenciabrasil.ebc.com.br/geral/noticia/2021-11/estudo-mostra-que-pandemia-intensificou-uso-das-tecnologias-digitais>>.

Oliveira, P. d.; RODRIGUES, R.; MACIEL, A. Revisão sistemática da literatura sobre modelos de visualizações utilizados para analisar fenômenos educacionais em plataformas de LMS. In: *Anais do XXXIII Simpósio Brasileiro de Informática na Educação*. [s.n.], 2022. p. 1006–1015. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/22477>>.

OLIVÉ, D. M. et al. A supervised learning framework: using assessment to identify students at risk of dropping out of a mooc. In: . [S.l.]: Springer Science+Business Media, LLC, part of Springer Nature, 2019. v. 32, p. 9–26.

ONG, S.; QUEK, G. Enhancing teacher–student interactions and student online engagement in an online learning environment. *Learning Environments Research*, v. 26, p. 681–707, 01 2023.

PEREIRA, M. R.; ALVES, L.; PADILHA, T. P. Investigando o uso de análise de sentimentos para identificar comportamentos de bullying em grupo de whatsapp escolar. In: *Anais do XXXV Simpósio Brasileiro de Informática na Educação*. Porto Alegre, RS, Brasil: SBC, 2024. p. 3059–3065. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/31468>>.

PFITSCHER, R. et al. Análise de sentimentos em turmas de programação com vistas ao apoio à permanência estudantil. In: *Anais do XXXIV Simpósio Brasileiro de Informática na Educação*. Porto Alegre, RS, Brasil: SBC, 2023. p. 1329–1340. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/26758>>.

QUEIROGA, E. M. et al. Using virtual learning environment data for the development of institutional educational policies. *Applied Sciences*, v. 11, n. 15, 2021. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/11/15/6811>>.

RAMOS, J. et al. Crisp-edm: uma proposta de adaptação do modelo CRISP-DM para mineração de dados educacionais. In: *Anais do XXXI Simpósio Brasileiro de Informática na Educação*. [s.n.], 2020. p. 1092–1101. Disponível em: <<https://sol.sbc.org.br/index.php/sbie/article/view/12865>>.

REIMERS, N.; GUREVYCH, I. *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*. 2019. Disponível em: <<https://arxiv.org/abs/1908.10084>>.

REIMERS, N.; GUREVYCH, I. Making monolingual sentence embeddings multilingual using knowledge distillation. In: *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing*. [S.l.]: Association for Computational Linguistics, 2020. p. 4512–4525.

RIBEIRO, G. et al. Avaliação da efetividade do ensino em um curso de formação continuada semipresencial. *Anais do Workshop de Informática na Escola*, v. 19, n. 1, p. 369–378, 2013. Disponível em: <<http://milanesa.ime.usp.br/rbie/index.php/wie/article/view/2622>>.

SANGRÀ, A.; VLACHOPOULOS, D.; CABRERA, N. Building an inclusive definition of e-learning: An approach to the conceptual framework. *The International Review of Research in Open and Distributed Learning*, v. 13, n. 2, p. 145–159, 2012.

Santos, T. C. B. d. Lumilab: um dashboard de learning analytics para apoio a gestores e professores de moocs da plataforma lúmina. In: *Programa de Pós-Graduação em Informática na Educação (UFRGS)*. [s.n.], 2024. Disponível em: <<http://hdl.handle.net/10183/280842>>.

SCHWENDIMANN, B. A. et al. Perceiving learning at a glance: a systematic literature review of learning dashboard research. *IEEE Transactions on Learning Technologies*, v. 10, n. 1, p. 30–41, 2017.

SIEMENS, G. Learning analytics the emergence of a discipline. *American Behavioral Scientist*, v. 57, p. 1380–1400, 10 2013.

SIEMENS, G.; LONG, P. Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review*, v. 5, p. 30–32, 01 2011.

SINCLAIR, J.; AHO, A.-M. Experts on super innovators: understanding staff adoption of learning management systems. *Higher Education Research & Development*, Routledge, v. 37, n. 1, p. 158–172, 2018.

SOUZA, M.; VIEIRA, R. Sentiment analysis on twitter data for portuguese language. In: . [S.l.: s.n.], 2012. p. 241–247. ISBN 978-3-642-28884-5.

JORGE, J. (Ed.). *Ambiente Virtual de Aprendizagem: Guia Prático do Moodle para Professores*. [S.l.], 2020. Guia institucional; organizador indicado na capa. Disponível em: <<https://www.sead.ufpb.br/sead/contents/documentos/documentos-sead/manual-moodle-professor-2020.pdf>>.

van Leeuwen, A. Teachers' experiences of monitoring their students in online higher education: recommendations for course design and opportunities for learning analytics. *Technology, Pedagogy and Education*, Routledge, v. 32, n. 5, p. 589–604, 2023. ISSN 1475-939X. Publisher Copyright: © 2023 The Author(s). Published by Informa UK Limited, trading as Taylor & Francis Group.

WANG, W. et al. Minilm: deep self-attention distillation for task-agnostic compression of pre-trained transformers. In: *Proceedings of the 34th International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2020. (NIPS '20). ISBN 9781713829546.

WEN, M.; YANG, D.; ROSÉ, C. P. Sentiment analysis in mooc discussion forums: What does it tell us? In: *Proceedings of the 7th International Conference on Educational Data Mining*. London, United Kingdom: [s.n.], 2014. p. 130–137. Disponível em: <https://educationaldatamining.org/EDM2014/uploads/procs2014/long%20papers/130_EDM-2014-Full.pdf>.

WILSON, T.; WIEBE, J.; HOFFMANN, P. Recognizing contextual polarity in phrase-level sentiment analysis. In: *Proceedings of Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing*. Vancouver, British Columbia, Canada: Association for Computational Linguistics, 2005. p. 347–354. Disponível em: <<https://aclanthology.org/H05-1044/>>.

YANG, D. et al. Exploring the effect of confusion in discussion forums of massive open online courses. p. 121–130, 03 2015.