

UNIVERSIDADE FEDERAL DE ALAGOAS  
CAMPUS A. C. SIMÕES  
INSTITUTO DE COMPUTAÇÃO  
CIÊNCIA DA COMPUTAÇÃO - BACHARELADO

MICHAEL MILLER RODRIGUES CARDOSO

Análise do desempenho de estudantes no ensino híbrido com base nas interações

Maceió, Alagoas

2023

MICHAEL MILLER RODRIGUES CARDOSO

Análise do desempenho de estudantes no ensino híbrido com base nas interações

Trabalho de Conclusão de Curso apresentado ao curso de Ciência da Computação da Universidade Federal de Alagoas, como requisito parcial à obtenção do título de Bacharelado em Ciência da Computação.

Orientador: Prof. Dr. Ranilson Paiva.

Maceió, Alagoas

2023

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**  
**Divisão de Tratamento Técnico**

Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

C268a Cardoso, Michael Miller Rodrigues.  
Análise do desempenho de estudantes no ensino híbrido com base nas interações / Michael Miller Rodrigues Cardoso. – 2023.  
63 f. : il. color.

Orientador: Ranilson Oscar Araújo Paiva.  
Monografia (Trabalho de Conclusão de Curso em Ciência da Computação) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2023.

Bibliografia: f. 60-62.  
Apêndice: f. 63.

1. Ensino híbrido. 2. Desempenho acadêmico. 3. Interação aluno – ensino híbrido. I. Título.

CDU: 378.147

## **AGRADECIMENTOS**

Agradeço a Deus por me abençoar imensamente em todos os momentos da minha vida, sempre me guiando e dando sabedoria para continuar minha trajetória.

Agradeço aos meus pais, Marcos e Pauliana, por terem me educado e me dado amor durante toda a minha vida e por sempre me apoiarem nas escolhas que fiz para minha carreira profissional e durante a graduação, sendo minhas principais referências e minha motivação para nunca desistir.

Agradeço ao meu orientador, Ranilson Paiva, por ter me acompanhado não só no desenvolvimento deste trabalho, mas em toda a graduação, sempre me incentivando a entregar o meu melhor em todos os projetos e produções acadêmicas.

Agradeço aos meus companheiros e amigos de graduação que estão comigo desde o tempo do ensino médio, Márcio Henrique, João Falcão, Rodrigo Santos. Vocês sempre me apoiaram em todos os momentos dessa jornada e seguiremos juntos.

Também agradeço aos amigos Gabriel, Fernanda, Lucas, Kalline, Matheus, Priscila, Wagner e Antero, pela amizade e por estarem sempre ao meu lado, me motivando e apoiando para chegar neste momento da minha caminhada.

Agradeço ao professor Chico Rosário, por ter aceitado a realização do estudo de caso em sua disciplina, e também a todos que se envolveram no experimento realizado.

Agradeço, por fim, a todos aqueles que contribuíram para a realização deste trabalho e aos que estiveram comigo e me apoiaram durante a graduação.

## RESUMO

O ensino híbrido é uma modalidade de ensino que integra abordagens do ensino presencial e online, que tem despertado interesse na área da educação por trazer maior flexibilidade para os alunos e professores, tendo sua definição básica mais recente dada por Garrison & Vaughan, em 2008. Dessa forma, é crucial explorar mais a fundo as interações e características gerais dessa modalidade de ensino, a fim de compreender seu impacto no desempenho acadêmico dos estudantes. Portanto, no presente trabalho, foi conduzido um estudo de caso em uma disciplina, ofertada no modelo híbrido de ensino, da Faculdade de Economia, Administração e Contabilidade (FEAC) da Universidade Federal de Alagoas (UFAL). Para tanto, foram analisados os dados referentes às interações dos estudantes com o ambiente de aprendizagem online utilizado e acerca das aulas e atividades presenciais. Foram realizadas transformações nos dados e aplicados algoritmos de aprendizagem de máquina não-supervisionados, para gerar um agrupamento dos estudantes em diferentes perfis de aprendizado, permitindo a identificação das características de cada tipo de aluno. Com isso, foram criadas visualizações das interações que tiveram maior influência nas notas dos alunos, foram identificados os perfis com diferentes níveis de desempenho e foram criadas recomendações personalizadas, a depender de como se deram as interações em cada grupo definido. Para validar os resultados da análise e o *feedback* gerado, foi conduzido um formulário de autoavaliação do desempenho, onde coletamos as percepções dos alunos e algumas sugestões de melhorias a serem aplicadas em futuros cursos no modelo híbrido. Portanto, o presente estudo gera informações relevantes acerca das interações e do desempenho dos estudantes em cursos híbridos. Conclui-se que o curso analisado teve pouca variedade de conteúdos na parte *online*, recomendando que sejam acrescentadas atividades com pontuação dentro do ambiente virtual de aprendizagem (AVA) e momentos no curso que pontuem a participação do aluno nas aulas, visando aprimorar futuras análises na identificação dos perfis de desempenho e no fornecimento de *feedback* aos alunos.

**Palavras-chave:** ensino híbrido; desempenho dos estudantes; interações dos estudantes; análise da aprendizagem;

## ABSTRACT

Blended learning is a mode of education that integrates aspects of both face-to-face and online teaching. It has garnered significant interest in the field of education due to the increased flexibility it offers to both students and educators. Its most recent fundamental definition was provided by Garrison & Vaughan in 2008. Thus, it is crucial to delve deeper into the interactions and general characteristics of this mode of education to comprehend its impact on students' academic performance. Consequently, in the present study, a case study was conducted in a course offered in the blended learning model at the Faculty of Economics, Administration, and Accounting (FEAC) at the Federal University of Alagoas (UFAL). To achieve this, data regarding student interactions with the online learning environment and in-person classes and activities were analyzed. Data transformations were applied, and unsupervised machine learning algorithms were utilized to cluster students into different learning profiles, enabling the identification of characteristics for each type of student. Subsequently, visualizations of interactions that had the most influence on students' grades were generated, profiles with different levels of performance were identified, and personalized recommendations were created depending on how interactions occurred in each defined group. To validate the analysis results and the generated feedback, a self-assessment performance form was administered, collecting students' perceptions and suggestions for improvements to be applied in future courses following the blended learning model. Consequently, this study generates valuable insights into student interactions and performance in blended courses. It is concluded that the analyzed course had limited online content variety, recommending the addition of activities with scoring within the virtual learning environment (VLE) and moments in the course that assess student participation in classes, aiming to enhance future analyses in identifying performance profiles and providing feedback to students.

**Keywords:** blended learning; student performance; student interactions; learning analysis.

## LISTA DE FIGURAS

- Figura 1** - Processo de condução do estudo
- Figura 2** - Médias das frequências gerais da turma
- Figura 3** - Mapa de correlação das variáveis do dataset
- Figura 4** - Gráfico do método Elbow
- Figura 5** - Gráfico do método Silhouette Score
- Figura 6** - Representação dos clusters com as médias das variáveis-alvo
- Figura 7** - Médias das variáveis-alvo do grupo 1 (evasão)
- Figura 8** - Médias das variáveis-alvo do grupo 2 (desempenho muito baixo)
- Figura 9** - Médias das variáveis-alvo do grupo 3 (desempenho baixo)
- Figura 10** - Médias das variáveis-alvo do grupo 4 (desempenho regular/bom)
- Figura 11** - Médias das variáveis-alvo do grupo 5 (desempenho alto)
- Figura 12** - Médias das variáveis-alvo do grupo 6 (desempenho excelente)
- Figura 13** - Respostas da autoavaliação do desempenho
- Figura 14** - Respostas da autoavaliação do engajamento
- Figura 15** - Respostas acerca da frequência presencial
- Figura 16** - Respostas acerca da frequência de acesso ao AVA
- Figura 17** - Respostas acerca da importância das videoaulas
- Figura 18** - Respostas acerca da importância dos conteúdos de texto
- Figura 19** - Respostas acerca da importância dos fóruns de discussão
- Figura 20** - Respostas acerca da metodologia utilizada

## **LISTA DE TABELAS**

**Tabela 1** - Critérios para o trabalho proposto

**Tabela 2** - Comparação do cumprimento dos critérios (proposta - trabalhos relacionados)

**Tabela 3** - Exemplo de base de dados mínima

**Tabela 4** - Exemplo de base de dados ideal

**Tabela 5** - Variáveis coletadas nos logs do AVA

**Tabela 6** - Variáveis coletadas pelo professor no painel do AVA

**Tabela 7** - Variáveis utilizadas para a análise

**Tabela 8** - Desvio padrão das colunas do dataset

**Tabela 9** - Agrupamento dos estudantes pelo desempenho (notas na prova)

**Tabela 10** - Recomendações para os estudantes

## **LISTA DE ABREVIATURAS E SIGLAS**

**LMS** - Sistema de Gestão da Aprendizagem

**UCI** - UC Irvine Machine Learning Repository

**AVA RIEH** - Ambiente Virtual de Aprendizagem da Rede de Inovação para Educação Híbrida

**TAM** - Techonology Acceptance Model

## SUMÁRIO

<b>RESUMO</b>	<b>4</b>
<b>ABSTRACT</b>	<b>5</b>
<b>LISTA DE FIGURAS</b>	<b>6</b>
<b>LISTA DE TABELAS</b>	<b>7</b>
<b>LISTA DE ABREVIATURAS E SIGLAS</b>	<b>8</b>
<b>SUMÁRIO</b>	<b>9</b>
<b>1. INTRODUÇÃO</b>	<b>11</b>
1.1. Contextualização	11
1.2. Motivação	12
1.3. Proposta	12
1.4. Objetivos	13
1.5. Hipóteses	13
1.6. Metodologia de avaliação da proposta	14
1.7. Resultados	14
1.8. Conclusões	15
1.9. Estrutura do trabalho	15
<b>2. FUNDAMENTAÇÃO TEÓRICA</b>	<b>16</b>
2.1. Ensino Híbrido	16
2.2. Interações	17
2.3. Análise e Previsão do Desempenho	18
2.4. Feedback	19
<b>3. TRABALHOS RELACIONADOS</b>	<b>20</b>
3.1. A multivariate approach to predicting student outcomes in web-enabled blended learning courses	20
3.2. Effect of blended learning to academic achievement	21
3.3. Effects of a blended learning approach on student outcomes in a graduate-level public health course	21
3.4. Machine Learning Based Classification Approach for Predicting Students Performance in Blended Learning	22
3.5. Predicting student performance in a blended learning environment using learning management system interaction data	23
3.6. The Impact of Online Learning Activities on Student Learning Outcome in Blended Learning Course	24
3.7. Predictors of Student Performance in a Blended-Learning Environment: An Empirical Investigation	24
3.8. Comparação dos estudos selecionados com a proposta do trabalho	25
<b>4. PROPOSTA</b>	<b>27</b>
4.1. Entendimento do ambiente e definição do objetivo	28
4.2. Coleta e tratamento dos dados	29
4.3. Análise da relação das interações com o desempenho	31

4.4. Agrupamento dos estudantes	31
4.5. Análise por grupo	32
4.6. Recomendações personalizadas	32
<b>5. METODOLOGIA</b>	<b>33</b>
5.1. Método de coleta e tratamento dos dados	33
5.2. Definição do questionário de autoavaliação	35
5.3. Validação do processo proposto	37
<b>6. RESULTADOS E DISCUSSÕES</b>	<b>38</b>
6.1. Estudo do ambiente e a definição do objetivo	38
6.2. Análise, discussão e agrupamento dos dados	38
6.3. Análise individual dos perfis de desempenho	43
6.4. Recomendações personalizadas	49
6.5. Análise dos resultados do questionário	51
<b>7. CONCLUSÃO</b>	<b>58</b>
7.1. Limitações	59
7.2. Trabalhos futuros	59
<b>8. REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>60</b>
<b>APÊNDICE A - QUESTIONÁRIO DE AUTOAVALIAÇÃO DOS ESTUDANTES</b>	<b>63</b>

## 1. INTRODUÇÃO

### 1.1. Contextualização

A aprendizagem *online* é uma modalidade de ensino que utiliza tecnologias digitais para conduzir cursos e/ou disciplinas, independente do nível e tipo de ensino, com o apoio de um sistema que habilita a comunicação do aluno com o professor/tutor e que é capaz de transferir, gerenciar, apoiar e supervisionar materiais de aprendizagem (Sun et. al, 2008). Nos últimos anos, tem sido observado um crescimento no uso de métodos de ensino online, que se tornou possível devido à disponibilidade de canais digitais e à redução de custos (Paudel, 2020). Entre as principais vantagens da aprendizagem online, temos: diversidade de plataformas de ensino à distância, redução de custos relacionados à mobilidade dos estudantes, ausência de restrições (em termos de espaço, data, duração do curso/treinamento), disponibilidade de professores e eficiência na entrega e gerenciamento dos cursos, que levaram inúmeras instituições educacionais a adotarem o ensino online como principal modelo (Hu et. al, 2012).

Devido ao surto da pandemia de COVID-19 em todo o mundo no ano de 2020, a educação, no mundo todo, foi forçada a mudar dos modelos de ensino tradicionais para modelos de ensino à distância, que se tornaram cada vez mais populares ao ponto da aprendizagem online ser considerada o meio mais acessível para a educação (Kaup et. al, 2020). No entanto, essas novidades vieram com alguns desafios, referentes à transmissão e entrega de conteúdo, taxa de evasão, engajamento, *feedback*, entre outros fatores que passaram a ser foco de pesquisas para melhorar a qualidade do ensino online (Hebebcı et. al, 2020).

Com os diversos desafios presentes nos modelos de ensino a distância, uma nova modalidade passou a ser adotada nas instituições, para flexibilizar a aprendizagem e buscar uma junção dos métodos tradicionais com a tendência do uso da tecnologia na área da educação, o modelo de ensino híbrido (Anthony et. al, 2022).

O ensino híbrido é uma abordagem educacional que combina os elementos da aprendizagem online com o ensino tradicional. Atualmente, o ensino híbrido é o método mais popular adotado pelas instituições educacionais devido à sua capacidade de fornecer aprendizado flexível, oportuno e contínuo. Além disso, a aprendizagem híbrida aumenta a interação entre professores e alunos (Aristika et. al, 2021). A importância e os benefícios de uma abordagem híbrida para melhorar o ensino e a aprendizagem são demonstrados em diversos estudos, e muitos pesquisadores consideram isso como a "nova normalidade" da educação como um todo (Rasheed et. al, 2020). A crescente popularidade do ensino híbrido criou uma demanda por melhorar a eficiência desse tipo de aprendizado.

## 1.2. Motivação

O ensino híbrido é uma abordagem que combina elementos do ensino presencial e online, que tem despertado interesse na área da educação (Garrison & Vaughan, 2008). Essa modalidade oferece benefícios significativos, como maior flexibilidade e acessibilidade para os alunos, permitindo-lhes adaptar seus horários de estudo e acessar o conteúdo de aprendizagem de forma conveniente (Tayebinik & Marlia, 2013). No entanto, apesar dessas vantagens, têm surgido preocupações em relação ao desempenho dos alunos nos cursos que adotam o modelo de ensino híbrido. Uma possível razão para isso pode ser a falta de interações efetivas entre os alunos e os professores e entre os alunos e o conteúdo, por conta dos desafios do estudante na autorregulação e do professor no uso da tecnologia para o ensino (Rasheed et. al, 2020).

Dessa forma, é pertinente explorar mais a fundo as interações no contexto do ensino híbrido, a fim de compreender seu impacto no desempenho acadêmico dos estudantes. A partir da investigação e análise das interações online e presenciais, podem ser geradas estratégias e recomendações para aprimorar os resultados de aprendizagem dos alunos e outros aspectos relacionados à qualidade dos cursos que seguem o modelo híbrido.

Nesse sentido, a análise do desempenho dos estudantes no ensino híbrido se apresenta como uma tarefa necessária para a evolução contínua da educação. Ao promovermos o aprimoramento dos processos de ensino e aprendizagem e ao desenvolvermos práticas inovadoras, estaremos capacitando educadores e instituições a fornecer um ambiente educacional mais inclusivo, dinâmico e alinhado aos desafios e oportunidades da atualidade.

## 1.3. Proposta

Neste contexto de pesquisa, concentramos nossa atenção na análise do desempenho dos estudantes em cursos de ensino híbrido na área de informática para educação. Embora estudos prévios já tenham explorado a previsão de desempenho e os fatores que afetam a aprendizagem dos alunos nesse cenário, uma lacuna persiste na identificação de perfis de aprendizagem específicos e na compreensão das interações que afetam diretamente o desempenho. Portanto, este estudo visa preencher essa lacuna, conduzindo uma análise abrangente das interações dos alunos com o conteúdo e o sistema, identificando as variáveis e tipos de interação que mais impactam o desempenho dos alunos.

Ao longo do estudo, iremos coletar dados, analisar a relação entre variáveis e desempenho, agrupar os estudantes em perfis de aprendizagem e gerar recomendações personalizadas para cada grupo. Para validar nossas descobertas, vamos conduzir um questionário de satisfação e autoavaliação com os alunos, comparando suas respostas com o feedback fornecido através das recomendações.

## 1.4. Objetivos

O presente trabalho tem como objetivo principal, definir as interações que influenciam no desempenho dos estudantes no contexto do ensino híbrido, ou seja, cursos que combinam momentos presenciais com o uso de plataformas de aprendizagem *online*. Portanto, partindo da pergunta que motivou esta pesquisa, temos alguns objetivos específicos a serem considerados no presente estudo:

- **Pergunta da pesquisa:** “O quanto cada interação online e presencial influencia no desempenho do estudante em cursos híbridos?”
- **Objetivo específico 1:** Agrupar os alunos de acordo com o desempenho;
- **Objetivo específico 2:** Entender o comportamento dos diferentes grupos de estudantes;
- **Objetivo específico 3:** Avaliar quais as possíveis melhorias na criação de futuros cursos, com base na análise das interações que influenciam no desempenho dos alunos.
- **Objetivo específico 4:** Gerar recomendações para os estudantes.

Ao investigar o impacto de cada interação no desempenho dos estudantes e validar esses resultados por meio das recomendações, este estudo pode contribuir na melhoria dos resultados de aprendizagem no contexto dos cursos híbridos. Além disso, ao fornecer informações sobre as interações e os conteúdos utilizados na disciplina a ser analisada, o trabalho também busca permitir que os professores visualizem o comportamento dos alunos em futuros cursos.

## 1.5. Hipóteses

No presente estudo, formulamos algumas hipóteses para investigar a relação entre as interações dos alunos em cursos que seguem a modalidade de ensino híbrido com o desempenho acadêmico. Essas hipóteses representam as suposições centrais da nossa pesquisa, ajudando-nos a compreender melhor como as interações online e presenciais impactam os resultados de aprendizagem dos estudantes.

- **Hipótese 1:** No contexto de cursos híbridos, diferentes tipos de interação, tanto online como presencial, possuem impacto significativo no desempenho dos alunos.
- **Hipótese 2:** É possível agrupar os estudantes em diferentes perfis de aprendizagem com base em seu desempenho, e esses perfis revelarão padrões distintos de interações que influenciam o desempenho.
- **Hipótese 3:** As recomendações personalizadas geradas com base nas análises das interações dos alunos com o conteúdo e o sistema podem auxiliar os professores e melhorar o desempenho dos estudantes ao longo da disciplina ou em futuros cursos.

- **Hipótese 4:** A coleta de feedback dos estudantes por meio de um questionário de satisfação e autoavaliação ajudará a validar as descobertas sobre a importância das interações e fornecerá *insights* adicionais sobre como melhorar os cursos híbridos.

A justificativa para essas hipóteses reside na importância de identificar estratégias para melhorar os resultados de aprendizagem dos estudantes. Ao testar e validar essas hipóteses, estamos contribuindo para futuras melhorias em cursos que seguem a modalidade de ensino híbrido e fornecendo *insights* práticos que podem beneficiar tanto alunos quanto professores.

## 1.6. Metodologia de avaliação da proposta

Neste estudo, empregamos um estudo de caso para avaliar as interações dos estudantes em um curso que segue a modalidade de ensino híbrido. A pesquisa foi conduzida na disciplina "Modelagem de Negócios Inovadores" na Universidade Federal de Alagoas (UFAL), que seguiu o modelo híbrido, combinando aulas presenciais e atividades online. Coletamos dados das interações dos alunos com o Ambiente Virtual de Aprendizagem da Rede de Inovação para Educação Híbrida (AVA RIEH), bem como informações relacionadas às notas, tempo gasto na avaliação e frequência dos alunos em aulas presenciais.

O processo metodológico envolveu a coleta de dados brutos, tratamento e transformação desses dados para criar uma base de dados que registra as frequências das interações dos alunos. Em seguida, utilizamos o algoritmo de aprendizagem não-supervisionada *K-Means* para agrupar os estudantes com base em seus níveis de desempenho nas avaliações. Para determinar o número ideal de grupos, aplicamos dois métodos de validação: *Elbow Method* e *Silhouette Score*.

Além disso, para enriquecer nossa análise, desenvolvemos questionários de autoavaliação para os estudantes, abordando seu desempenho, o uso de recursos de aprendizagem e a avaliação da metodologia de ensino híbrido. Esses questionários fornecerão percepções subjetivas dos alunos e *insights* valiosos para o aprimoramento contínuo dos cursos híbridos.

## 1.7. Resultados

Os resultados do presente estudo fornecem uma análise detalhada do desempenho dos alunos em um curso híbrido, bem como suas percepções sobre a metodologia de ensino. Ao identificar perfis distintos de estudantes com diferentes níveis de desempenho acadêmico, as interações tanto online quanto presenciais foram analisadas em cada grupo

identificado, extraindo informações úteis acerca do comportamento dos alunos ao longo do curso e detalhando as semelhanças e diferenças entre os perfis.

Para cada perfil de estudantes, este estudo gera recomendações personalizadas, sugerindo melhorias a serem adotadas em futuros cursos e apontando os pontos fortes e fracos dos alunos pertencentes ao grupo. Além disso, a coleta de percepções dos alunos revelou valiosos *insights* sobre como o ensino híbrido é percebido, destacando a necessidade de equilibrar as atividades presenciais e online, bem como de fornecer recursos de aprendizagem variados e eficazes.

## 1.8. Conclusões

A análise realizada neste estudo proporciona uma visão abrangente da forma que interações influenciam no desempenho no contexto de cursos híbridos. As descobertas revelam uma variedade de perfis de estudantes com diferentes níveis de interação com os recursos disponíveis, além de sugerir recomendações práticas para futuros cursos, incluindo a incorporação de atividades pontuadas no AVA e checkpoints para avaliar a participação dos alunos, a fim de aprimorar a qualidade das interações e oferecer suporte personalizado para melhorar o desempenho e evitar evasões durante o curso.

## 1.9. Estrutura do trabalho

Os próximos capítulos são: fundamentação teórica, trabalhos relacionados, proposta, metodologia, resultados e discussões e, por fim, conclusão. No capítulo de **fundamentação teórica**, os principais conceitos deste estudo são apresentados, para criar um embasamento teórico a ser consultado. No capítulo de **trabalhos relacionados**, listam-se estudos que, de alguma forma, se relacionam com o presente trabalho. No capítulo de **proposta**, a forma com que o processo de análise dos dados do curso híbrido será conduzido é detalhado, fornecendo informações sobre a criação de visualizações estatísticas com base nos resultados a serem obtidos e como será feita a validação do estudo. No capítulo de **metodologia**, os objetivos do estudo são detalhados, bem como a estrutura do curso a ser analisado, público-alvo dos participantes, o instrumento para a coleta dos dados e quais informações foram utilizadas na análise. No capítulo de **resultados e discussões**, os dados obtidos a partir do processo conduzido são analisados através de visualizações estatísticas, além de apresentar como foi dada a validação das informações obtidas através de experimento com os participantes. Por fim, no último capítulo, são apresentadas as **conclusões** alcançadas pelo presente trabalho, bem como suas limitações, além de indicar possíveis trabalhos futuros.

## 2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo de fundamentação teórica, serão abordados os principais conceitos relacionados com o assunto do trabalho em questão, possibilitando a consulta facilitada de informações acerca desses temas para complementar quaisquer lacunas que possam existir por parte do leitor.

### 2.1. Ensino Híbrido

Uma definição básica do ensino híbrido é dada por (Garrison & Vaughan, 2008, p.148, tradução nossa) como “a integração orgânica de abordagens presenciais e online cuidadosamente selecionadas e complementares”. De acordo com os autores, o ensino híbrido visa integrar o melhor dos dois mundos, combinando a interatividade e a imersão do ensino presencial com a flexibilidade e acessibilidade do ensino online. Através dele, os estudantes podem participar em atividades presenciais em sala de aula e também acessar conteúdos e recursos online, incluindo atividades de aprendizado, colaboração com outros estudantes e professores, e receber feedback personalizado.

Existem diferentes formas de aplicar o ensino híbrido, a depender das necessidades e objetivos da instituição de ensino. Alguns dos principais tipos de ensino híbrido incluem (Bokolo Anthony Jr. et al, 2022):

- Rotação de estações: Nesse modelo, os estudantes são divididos em grupos e alternam entre atividades presenciais e online, trabalhando em diferentes estações com diferentes tipos de atividades.
- Laboratório rotacional: Nesse modelo, os estudantes participam de aulas presenciais e online em diferentes momentos, trabalhando em tarefas específicas ou projetos individuais.
- Sala de aula invertida: Nesse modelo, os estudantes são solicitados a assistir a palestras ou ler materiais online antes de uma aula presencial, permitindo que o tempo em sala de aula seja usado para atividades mais interativas, como discussões em grupo e resolução de problemas.
- Aprendizagem por projeto: Nesse modelo, os estudantes trabalham em projetos individuais ou em grupo, utilizando recursos online e presenciais para coletar informações e concluir as tarefas do projeto.
- Aprendizagem mista: Nesse modelo, o ensino é projetado de forma a integrar atividades presenciais e online em um plano de aprendizagem unificado, onde as atividades em sala de aula são complementadas e ampliadas por atividades online.

O ensino híbrido pode ser aplicado em diversos contextos educacionais, desde o ensino fundamental até o ensino superior, incluindo treinamentos profissionais, sendo especialmente útil para cursos em que os estudantes precisam de apoio adicional ou onde o acesso à tecnologia é limitado (Robin Castro, 2019). Além disso, o ensino híbrido também

pode ser aplicado em situações de emergência, como em epidemias e catástrofes naturais, onde as restrições de distanciamento social impedem o ensino presencial tradicional.

O modelo de ensino híbrido é aplicado por diversos motivos e em diversos cenários, incluindo a necessidade de adaptar o ensino às necessidades dos estudantes e às demandas da sociedade, como a crescente importância da tecnologia na educação e no trabalho. Algumas razões para aplicar o ensino híbrido incluem a flexibilidade, a personalização dos recursos e conteúdos e, além disso, tem sido demonstrado como uma estratégia efetiva para melhorar o desempenho acadêmico dos estudantes (Garrison & Vaughan, 2008).

## 2.2. Interações

(Michael G. Moore, 1989) definiu as interações como sendo as trocas entre estudantes, estudantes e professores, e estudantes e o conteúdo do curso. Essas interações podem ocorrer de várias maneiras, como através de discussões em grupo, e-mails, chats, feedbacks, atividades colaborativas e outras (Bouhnik & Marcus, 2006).

Segundo (Michael G. Moore, 1989), as interações são essenciais para o sucesso da educação a distância, uma vez que elas proporcionam a oportunidade para o desenvolvimento da compreensão do conteúdo, a construção do conhecimento em colaboração com outros estudantes e também a construção de relacionamentos significativos com professores e colegas. Além disso, as interações são fundamentais para manter a motivação dos estudantes e ajudá-los a superar os desafios que enfrentam durante o processo de aprendizagem.

Inicialmente, foram definidos três tipos de interação: aluno x conteúdo, aluno x professor e aluno x aluno, descritos por (Michael G. Moore, 1989). No entanto, com o avanço da tecnologia no processo de ensino-aprendizagem, foi definida uma quarta dimensão, explorada por (Bouhnik & Marcus, 2006), denominada de interação aluno x sistema. Abaixo temos a definição de cada tipo:

- (1) Aluno x Conteúdo: esse tipo de interação se refere ao processo do aluno receber informações e conhecimento por meio de materiais de estudo, como textos, vídeos, áudios, entre outros. Essa interação também pode ocorrer por meio de outras tecnologias que permitem ao aluno experimentar e praticar habilidades.
- (2) Aluno x Professor: essa interação se refere ao processo de o aluno receber orientação, feedback e suporte do professor. Isso pode incluir comunicações por e-mail, fóruns de discussão, videoconferências ou outras formas de comunicação síncrona ou assíncrona.
- (3) Aluno x Aluno: esse tipo de interação se refere à colaboração e troca de ideias entre os alunos. Isso pode ocorrer em fóruns de discussão, salas de bate-papo, atividades colaborativas ou em outras formas de comunicação entre alunos.

- (4) Aluno x Sistema: essa interação se refere ao processo do aluno interagir com a plataforma tecnológica utilizada para o curso, como o ambiente virtual de aprendizagem. Isso pode incluir o tempo de navegação pelo curso, a submissão de atividades, frequência de acesso à plataforma, entre outras formas de interação.

### 2.3. Análise e Previsão do Desempenho

O objetivo da análise e previsão do desempenho dos estudantes é fornecer *insights* para educadores e profissionais de ensino sobre como os alunos estão progredindo em seus estudos, identificando padrões e tendências que podem ajudar a melhorar o desempenho dos alunos (Amirah Mohamed, 2015). A análise e previsão do desempenho dos alunos também podem ajudar a identificar quais alunos estão em risco de baixo desempenho acadêmico e fornecer intervenções precoces para ajudá-los a melhorar. Além disso, pode ser usada para ajudar a desenvolver programas de ensino personalizados e estratégias de ensino para melhorar o desempenho dos alunos (Arto Hellas, et. al, 2018).

(Amirah Mohamed, 2015) destaca que a análise e previsão do desempenho pode ser realizada usando técnicas de mineração de dados, que envolvem a análise de grandes quantidades de dados para encontrar padrões e relacionamentos significativos. As técnicas de mineração de dados podem ser usadas para prever o desempenho futuro dos alunos com base em seus dados históricos e outras variáveis relevantes.

Os artigos de (Dorina Kabakchieva, 2013) e (Amirah Mohamed, 2015) mencionam diversas técnicas e algoritmos que podem ser utilizados para analisar e prever o desempenho dos alunos. Algumas dessas técnicas e algoritmos incluem:

- Regressão Linear e Logística: são técnicas de análise que permitem modelar a relação entre uma variável dependente (desempenho dos alunos) e uma ou mais variáveis independentes (por exemplo, frequência de estudo, idade, nível socioeconômico) para prever o desempenho dos alunos.
- Árvores de Decisão: são algoritmos de aprendizagem supervisionada que permitem representar graficamente possíveis decisões e resultados com base em diferentes variáveis e regras de decisão, ajudando a identificar as principais variáveis que afetam o desempenho dos alunos.
- Redes Neurais: são modelos matemáticos inspirados no cérebro humano, que podem ser treinados para prever o desempenho dos alunos com base em um grande número de variáveis e padrões complexos.
- Algoritmos de Mineração de Regras de Associação: são algoritmos de aprendizado de máquina que identificam padrões frequentes e regras de associação entre variáveis, ajudando a identificar relações entre o desempenho dos alunos e variáveis como tempo de estudo, assiduidade, resultados de testes anteriores, entre outros.

- Algoritmos de Agrupamento: são algoritmos que permitem agrupar alunos com base em padrões semelhantes de desempenho e características pessoais, auxiliando na criação de estratégias de ensino personalizadas.

Em resumo, a análise e previsão do desempenho dos estudantes podem ser aplicadas em diversas situações e com diferentes técnicas e algoritmos, visando melhorar o desempenho acadêmico dos alunos e a qualidade do ensino oferecido.

## 2.4. Feedback

O feedback é essencial no processo de aprendizagem, pois ajuda os alunos a entenderem como estão progredindo e onde precisam melhorar. Ele pode ser fornecido por professores, colegas ou por meio de sistemas automatizados. Quando bem estruturado e entregue de forma efetiva, o feedback pode incentivar os alunos a se engajarem mais com o material de aprendizagem, a corrigir seus erros e a alcançar um desempenho melhor (Susan M. Brookhart, 2017).

O feedback automatizado é uma forma de feedback gerado automaticamente por algoritmos ou programas de computador que fornecem aos alunos informações sobre seu desempenho em tarefas de aprendizagem (Anderson P. Cavalcanti, Dragan Gašević, et al, 2021). Ele pode ser fornecido em tempo real ou de forma assíncrona e pode incluir pontuações, feedback positivo e negativo, sugestões para melhorar o desempenho, entre outras informações. O feedback automatizado pode ser adaptado às necessidades individuais do aluno e pode ser usado em uma variedade de ambientes de aprendizagem online, como plataformas de aprendizagem digital, jogos educacionais e sistemas de treinamento online.

(Susan M. Brookhart, 2017) menciona que o uso de tecnologia pode ajudar a fornecer feedback mais rápido e mais personalizado aos alunos. Isso pode incluir o uso de sistemas de feedback automatizado em ambientes de aprendizagem online, para fornecer feedback aos alunos sobre seu desempenho. O feedback automatizado pode ser usado para fornecer respostas imediatas aos alunos e ajudá-los a identificar seus erros e acertos, bem como fornecer sugestões para melhorar seu desempenho.

No entanto, o livro (Susan M. Brookhart, 2017) também enfatiza que o feedback automatizado deve ser complementado pelo feedback personalizado e específico do professor. Embora o feedback automatizado possa ser útil para fornecer feedback rápido e genérico, o feedback personalizado do professor (manual) é importante para ajudar os alunos a entender como aplicar o feedback em seu trabalho e desenvolver habilidades de autoavaliação.

### 3. TRABALHOS RELACIONADOS

Nesta seção de trabalhos relacionados, listam-se 7 trabalhos obtidos através de consultas ao Google Scholar e ao Portal de Periódicos da CAPES, seguindo os critérios de: (1) abordar a, análise do desempenho no ensino híbrido com base nas interações dos estudantes, ou (2) abordar a análise do desempenho no ensino híbrido e (3) ter sido publicado nos últimos 10 anos.

Para conduzir a busca, foram utilizadas os seguintes termos: “student performance blended learning”, “blended learning student interactions”, “blended learning impact student performance” e “students performance based interactions blended learning”.

Para cada trabalho listado, apresenta-se um resumo do mesmo, descrevendo os objetivos, proposta e método utilizado, encerrando com os resultados que foram obtidos, limitações e trabalhos futuros. No final da seção, apresenta-se uma comparação dos trabalhos relacionados com o presente estudo.

#### 3.1. A multivariate approach to predicting student outcomes in web-enabled blended learning courses

Neste artigo, (Nick Z. Zacharis, 2015) apresenta um modelo prático para previsão dos alunos que correm o risco de ter um desempenho ruim em cursos de aprendizagem híbrida, que combinam ensino presencial e *online*, com o objetivo de fornecer intervenções oportunas para apoiar os estudantes em risco. O estudo propõe um modelo matemático que usa variáveis dos dados de rastreamento de atividades (*logs*) do Sistema de Gerenciamento de Aprendizagem (Moodle LMS) para identificar alunos em risco.

A metodologia da pesquisa consistiu em três fases: correlação bivariada, análise de regressão e análise de regressão por etapas. O estudo utiliza uma base de dados de alunos matriculados em um curso de contabilidade de nível superior, oferecido em uma universidade grega. Com a condução das três etapas definidas, diversas variáveis que não tinham efeito significativo no desempenho dos alunos foram excluídas do desenvolvimento do modelo de previsão.

Os resultados mostraram que apenas quatro variáveis contribuíram para a previsão da nota final do aluno, mensagens lidas, número de arquivos visualizados, número de questionários resolvidos e acessos ao ambiente online, que conseguiram prever 52% da variância das notas. (Nick Z. Zacharis, 2015) reconhece algumas limitações, como a generalização dos resultados para outros cursos ou contextos e a necessidade de considerar outros fatores que podem afetar o desempenho dos alunos.

Trabalhos futuros poderiam explorar o uso de técnicas mais avançadas de aprendizado de máquina para desenvolver modelos preditivos mais precisos, investigar a eficácia de diferentes tipos de intervenções para estudantes em risco e examinar o impacto dos diferentes recursos do Moodle LMS no desempenho dos alunos.

### **3.2. Effect of blended learning to academic achievement**

Neste artigo, (Veysel Karani Ceylan, Ayşe Elitok Kesici, 2017) investigam os efeitos do ensino híbrido no desempenho acadêmico e nas notas dos alunos do ensino médio. O objetivo do estudo é avaliar a eficácia do ensino híbrido em relação ao ensino tradicional, ao analisar a diferença entre os grupos de estudantes em um curso de informática em uma universidade da Turquia.

Uma pesquisa quantitativa foi realizada com um grupo de 53 alunos que estavam participando de uma unidade do curso (programação em Java), através de um experimento controlado, separando-os em grupos de aprendizagem híbrida e de aprendizagem tradicional. Os dados foram coletados através de testes de múltipla escolha e avaliações do curso, sendo analisados através de testes t independentes para comparação dos grupos e análises de variância.

Os resultados mostraram que o grupo de alunos do ensino híbrido tiveram um desempenho significativamente melhor nas avaliações em relação ao grupo de ensino tradicional, mostrando que a aplicação de exercícios e avaliações *online* pode melhorar os resultados de aprendizagem dos alunos.

As limitações do estudo incluem a falta de uma divisão dos grupos de alunos de acordo com as diferenças individuais e também a limitada generalização do estudo, por ser conduzido em uma única unidade de um único curso. Pesquisas futuras poderiam investigar o desempenho no ensino híbrido em outros cenários com cursos maiores e analisar outros dados de diferentes tipos de interação, além das notas em avaliações.

### **3.3. Effects of a blended learning approach on student outcomes in a graduate-level public health course**

(Marc T. Kiviniemi, 2014) discute em seu artigo sobre a tendência crescente das abordagens de aprendizagem híbrida no ensino de ciências da saúde, propondo um estudo para comparar os resultados finais de um curso híbrido com um curso tradicional, para estimar a eficácia do ensino híbrido no desempenho dos estudantes.

A metodologia do estudo envolve comparar os resultados finais dos alunos a partir da coleta dos dados das notas nos exames e da pontuação total nas atividades do curso. (Marc T. Kiviniemi, 2014) propôs utilizar medidas simples como média, desvio-padrão,

variância e outros, para avaliar a diferença do desempenho final dos alunos do ensino híbrido e do ensino tradicional.

Os resultados do estudo mostraram que a mudança da apresentação do conteúdo do curso de uma abordagem tradicional para uma abordagem de aprendizado híbrido levou a um aumento no desempenho, conforme avaliado através dos dados obtidos. Além disso, foi aplicado um questionário para coletar o *feedback* dos estudantes sobre a abordagem de ensino utilizada, e os estudantes preferiram, predominantemente, o modelo híbrido a uma estrutura de curso mais tradicional.

Portanto, a conclusão do artigo é que abordagens de aprendizagem híbrida bem implementadas podem ter um forte potencial para melhorar o desempenho dos alunos nos cursos de ciências da saúde. Apesar dos resultados obtidos, o estudo de (Marc T. Kiviniemi, 2014) não foi verdadeiramente experimental, pois as medidas para avaliar o desempenho foram unicamente por meio das notas e através de questionários dos alunos. É necessário que pesquisas futuras avaliem as diferentes variáveis do curso, que podem ou não influenciar diretamente nos resultados finais.

### **3.4. Machine Learning Based Classification Approach for Predicting Students**

#### **Performance in Blended Learning**

Neste artigo, (Célia González Nespereira et al., 2015) apresenta uma abordagem baseada em aprendizado de máquina para prever o desempenho dos estudantes em um ambiente de ensino híbrido, utilizando dados de um Sistema de Gestão de Aprendizagem (Moodle LMS). O objetivo do estudo é desenvolver um modelo de previsão do desempenho de aprendizagem dos alunos com base em sua interação com os diferentes módulos no Moodle LMS. A proposta envolve identificar os alunos com risco de insucesso e permitir que intervenções sejam realizadas de forma antecipada.

A metodologia do estudo envolve a coleta dos dados de interações do aluno com o conteúdo e com o sistema, o que inclui variáveis como tempo de acesso, número de acessos, atividades realizadas, entre outras. Os dados foram pré-processados e, em seguida, usados em algoritmos de classificação, como *Naive Bayes*, *Árvore de Decisão*, *KNN* e também em *Redes Neurais Artificiais*, para prever o desempenho dos alunos.

Os resultados apresentados por (Célia González Nespereira et al., 2015) mostraram que a melhor performance em termos de precisão na predição do desempenho dos alunos foi obtida através das *Redes Neurais Artificiais*, podendo ser efetiva para identificar os estudantes com maior risco de insucesso em um ambiente de aprendizagem híbrida. Além disso, os resultados mostraram que as variáveis mais importantes para a previsão foram as atividades realizadas pelos alunos no LMS e o número de acessos ao sistema.

Os autores não apresentam as limitações, no entanto, vale ressaltar que o estudo foca na obtenção do melhor algoritmo de previsão do desempenho, mas não aborda a identificação de grupos de estudantes com diferentes níveis de desempenho e de acesso aos conteúdos do curso, que poderia ajudar a entender como é a interação de cada tipo de aluno no ambiente de aprendizagem. Em trabalhos futuros, (Célia González Nespereira et al., 2015) pretende explorar técnicas de otimização, para melhorar a precisão da previsão do algoritmo.

### **3.5. Predicting student performance in a blended learning environment using learning management system interaction data**

Neste artigo, (Kiran Fahd et al., 2021) explora o uso de algoritmos de aprendizado de máquina para prever o desempenho acadêmico dos estudantes no contexto do ensino híbrido, utilizando dados de interação de um Sistema de Gestão de Aprendizagem (LMS). Portanto, o estudo propõe identificar quais variáveis de interação têm maior impacto na previsão do desempenho dos alunos, a fim de criar um modelo com boa taxa de predição.

A metodologia envolve a obtenção de dados de interação de um LMS disponíveis gratuitamente no repositório aberto UCI, o pré-processamento e transformação dos dados e o uso de algoritmos classificadores baseados em árvores. Os dados da UCI tinham inicialmente 230.318 instâncias de dados, baseados nas interações de 112 estudantes com o ambiente online de aprendizagem (LMS) em seis módulos. Essas informações contêm diversos atributos de logs que foram utilizados na construção do modelo de previsão, como número de logins, tempo ativo no sistema, tempo de inatividade, quantidade de cliques do *mouse* e o número de interações com o conteúdo do curso. A análise dos resultados incluiu a comparação do desempenho dos diferentes algoritmos de aprendizado de máquina utilizados e a identificação das variáveis de interação do LMS mais importantes para a previsão do desempenho dos alunos.

Os resultados do estudo mostraram que o melhor algoritmo de aprendizado de máquina foi a floresta aleatória (*Random Forest*), com precisão de 85%, portanto, (Kiran Fahd et al., 2021) mostrou que as informações sobre a interação do aluno com o sistema, como o tempo ativo e o número de interações com o conteúdo, podem ser usadas tanto para previsão como para apoiar educadores na implementação de estratégias pedagógicas personalizadas que ajudem os alunos a ter sucesso no curso.

As limitações do estudo incluem o uso unicamente de dados gerados pela interação do aluno com o sistema, desconsiderando outros fatores que podem contribuir para o insucesso dos alunos. Pesquisas poderiam considerar o uso de conjuntos de dados aprimorados que incorporam outros tipos de interações, como do aluno com os conteúdos em si, interação com outros alunos e outros atributos, para melhorar a aplicação de um modelo de previsão e/ou classificação do desempenho dos estudantes no ensino híbrido.

### **3.6. The Impact of Online Learning Activities on Student Learning Outcome in Blended Learning Course**

Neste artigo, (Nguyen Viet Anh, 2017) conduz uma avaliação do impacto das atividades de aprendizagem online no desempenho acadêmico dos alunos em um curso híbrido. O estudo realiza uma análise do desempenho dos estudantes a partir de dados provenientes de interações com o ambiente Moodle LMS e interações dos alunos com os professores, além de explorar outros tipos de interação.

Foi conduzido um experimento controlado, separando os alunos em um grupo que utilizou o Moodle LMS e o outro grupo que ficou com o método tradicional de ensino. Diversos dados foram coletados para posterior análise estatística, como: mensagens enviadas para os professores, comentários nas atividades enviadas, notas em avaliações e também questionários de percepção, para avaliar a diferença de desempenho entre os métodos de ensino.

(Nguyen Viet Anh, 2017) também faz uma análise comparativa dos tipos de interação, a partir das diferentes variáveis que foram coletadas. O estudo explora dados sobre as interações dos alunos com diferentes atividades de aprendizagem, como interação professor-aluno, interação aluno-aluno, interação aluno-conteúdo e interação aluno-sistema. Os dados foram analisados usando análise de regressão para determinar o impacto dessas interações nos resultados de aprendizagem dos alunos.

Os alunos que participaram do grupo experimental, que incluiu atividades de aprendizagem online, obtiveram notas mais altas em comparação com os alunos do grupo de controle que não participaram dessas atividades online. Com base nesses resultados, o estudo conclui que a inclusão de atividades de aprendizagem online pode melhorar significativamente o desempenho acadêmico dos alunos em um curso híbrido.

Apesar dos resultados obtidos, o artigo tem algumas limitações, entre elas, o fato dele conduzir o experimento controlado analisando somente as interações do aluno com o LMS e com o professor. Pesquisas futuras poderiam abordar o impacto dos outros tipos de interação mencionados no estudo em um experimento mais aprimorado e, além disso, identificar os diferentes perfis de aprendizagem (grupos de estudantes com diferentes níveis de desempenho) a partir dessas interações.

### **3.7. Predictors of Student Performance in a Blended-Learning Environment: An Empirical Investigation**

Neste artigo, (Lan Umek et al, 2017) tem como objetivos identificar quais aspectos do ensino híbrido aumentam o nível de conhecimento dos alunos e quais estão mais fortemente ligados às melhores notas finais nos cursos. A proposta do estudo é usar uma

abordagem baseada em pesquisas, para investigar o impacto dos diferentes aspectos que influenciam no desempenho final dos alunos.

O artigo coletou dados das notas finais dos alunos e conduziu um questionário com 23 afirmações relacionadas ao ensino híbrido, para ajudar a identificar as diferenças entre os perfis de desempenho dos estudantes. O estudo então usa a análise de componentes principais e a regressão linear múltipla para identificar quais aspectos do aprendizado híbrido estão mais fortemente ligados às melhores notas.

Os resultados mostraram que seis dimensões do ensino híbrido influenciam nas notas finais, que inclui aspectos relacionados ao conteúdo utilizado no curso (exercícios, textos, vídeos), interação com o LMS (número de acessos, tempo de acesso) e o feedback do curso. O estudo também constatou que um alto nível de satisfação dos estudantes de administração com o uso do Moodle LMS.

O artigo de (Lan Umek et al, 2017) apresenta resultados limitados que não podem ser generalizados para outros cenários de ensino híbrido, pois analisa somente as notas e conduz questionários baseados no modelo TAM (*Technology Acceptance Model*) como forma de validação. Estudos futuros poderiam analisar as interações do aluno com o ambiente *online* e com os conteúdos através de algoritmos estatísticos e de aprendizado de máquina, para obter resultados mais precisos acerca do desempenho dos estudantes no contexto do ensino híbrido.

### 3.8. Comparação dos estudos selecionados com a proposta do trabalho

De forma a posicionar o presente trabalho aos estudos relacionados, definimos os quatro critérios do estudo proposto, tendo como base as informações obtidas a partir da fundamentação teórica e dos objetivos definidos, conforme a tabela abaixo:

Tabela 1 - Critérios para o trabalho proposto

CRITÉRIOS	
Critério 1	Explorar mais de um tipo de interação (Rossi et. al, 2013) - O trabalho aborda a análise de mais de um tipo de interação, por exemplo: interações do aluno com o professor e com o conteúdo do curso.
Critério 2	Analisar a relação entre as diferentes variáveis coletadas - O trabalho analisa a relação entre os dados coletados, provenientes das interações abordadas.
Critério 3	Identificar os diferentes perfis de desempenho - O trabalho realiza o agrupamento dos alunos de acordo com o nível de desempenho, para entender as diferenças nas interações de cada perfil ao longo do

	curso.
Critério 4	<p>Comparar variáveis de interação com o desempenho final</p> <ul style="list-style-type: none"> <li>- As variáveis obtidas no trabalho são comparadas com os resultados finais do aluno, de forma a entender o que influencia no desempenho.</li> </ul>

Fonte: Autor

Vale ressaltar que, os critérios definidos compreendem o cenário ideal para a proposta do presente trabalho, de forma a conduzir uma análise que se diferencie dos estudos existentes na literatura, trazendo resultados precisos acerca do desempenho em cursos que seguem a modalidade de ensino híbrido.

A partir da tabela 2, podemos visualizar os critérios que cada trabalho relacionado não explora e que fazem parte da proposta do presente trabalho:

Tabela 2 - Comparação do cumprimento dos critérios (proposta - trabalhos relacionados)

	<b>Critério 1</b>	<b>Critério 2</b>	<b>Critério 3</b>	<b>Critério 4</b>
<b>3.1</b>				
<b>3.2</b>				
<b>3.3</b>				
<b>3.4</b>				
<b>3.5</b>				
<b>3.6</b>				
<b>3.7</b>				
<b>Proposta</b>				

Fonte: Autor

#### 4. PROPOSTA

A pesquisa na área de informática na educação voltada à análise do desempenho dos estudantes no contexto do ensino híbrido não é inédita, tendo alguns estudos que já desenvolveram bons modelos para prever o desempenho e para identificar os fatores que influenciam os resultados de aprendizagem do aluno, incluindo alguns dos trabalhos relacionados. Os artigos de (Nespereira et. al, 2016) e (Nguyen, 2017) exploram a relação entre diferentes variáveis dos ambientes online e abordam mais de um tipo de interação, obtendo resultados úteis acerca do desempenho final dos estudantes, no entanto, conforme apresentado na seção anterior, não realizam a identificação dos diferentes perfis de desempenho, que seria útil para entender quais interações tiveram maior e menor impacto no desempenho de cada grupo de alunos.

Portanto, uma pesquisa analítica será conduzida no âmbito de cursos que seguem o modelo de ensino híbrido no contexto nacional, fazendo o uso de uma plataforma de aprendizagem Moodle, sendo o LMS mais difundido no Brasil (Murillo et. al, 2021). As interações aluno x conteúdo, aluno x ambiente, aluno x professor e aluno x aluno serão avaliadas, incluindo as informações dos momentos presenciais do curso, para possibilitar uma análise no contexto híbrido. Especificamente, iremos coletar dados de frequência e tempo de acesso aos conteúdos disponibilizados pelo professor, trocas de mensagens, participação em sala de aula e as notas nas avaliações da disciplina.

A relevância dos dados obtidos será avaliada ao verificar a relação das variáveis com o desempenho final na disciplina, para ajudar os professores na condução de futuros cursos e os estudantes no entendimento de quais recursos e conteúdos devem ser priorizados para que tenham melhores resultados.

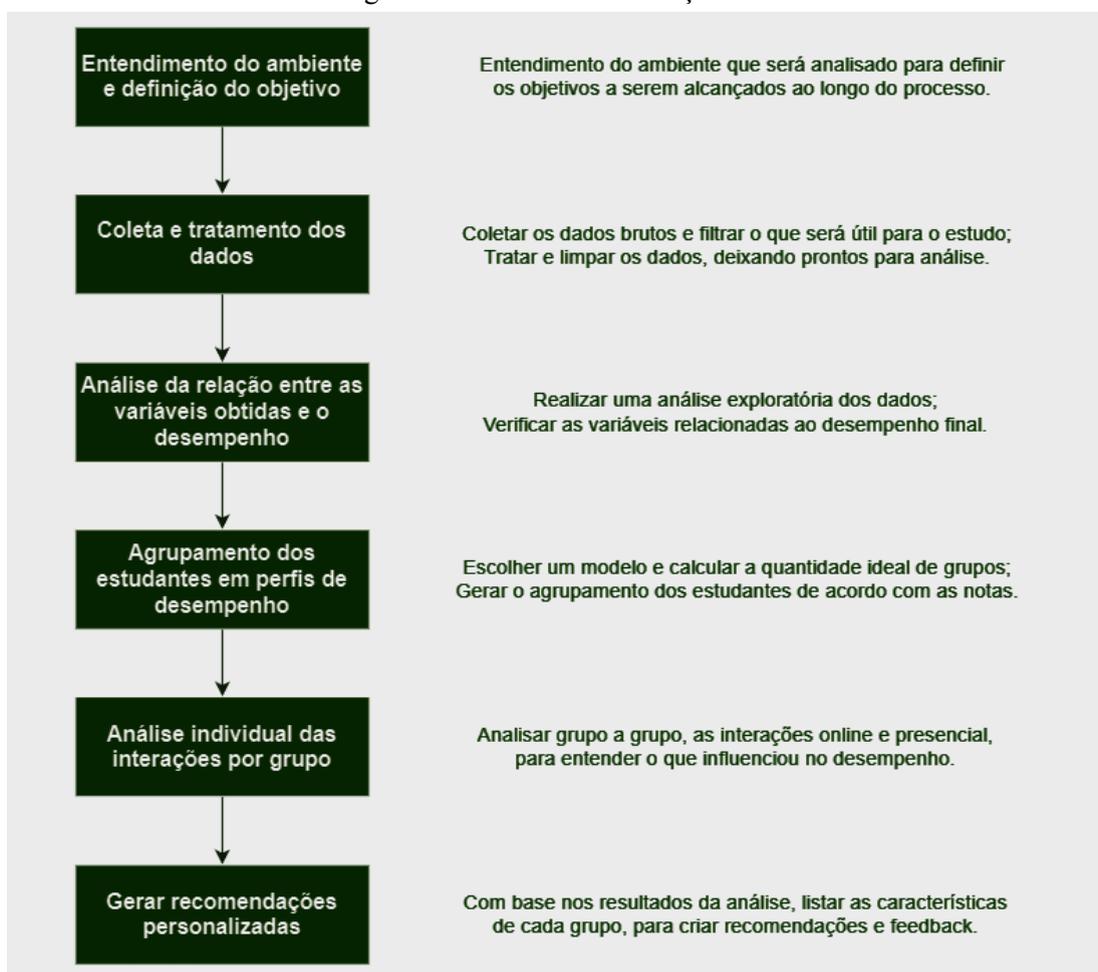
Será feita uma análise da relação entre as diferentes variáveis provenientes de interações do aluno com o conteúdo, aluno com o sistema, aluno com professor e aluno com aluno, de modo a selecionar quais dados serão comparados com os resultados finais dos estudantes. Além disso, será elaborado um agrupamento dos estudantes em diferentes perfis de desempenho, de acordo com as suas notas nas avaliações da disciplina, para identificar quem teve baixo, médio ou alto desempenho no curso.

Tendo os perfis de aprendizagem definidos, será possível identificar como as interações influenciam no desempenho dos estudantes de cada grupo, e, além disso, entender quais recursos são mais utilizados e quais tipos de interação tem maior frequência em cada grupo. Portanto, o estudo proposto conta com as seguintes etapas (conforme a Figura 1, apresentada em seguida):

- **(1)** Entendimento do problema e definição do objetivo;
- **(2)** Coleta e tratamento dos dados;
- **(3)** Análise da relação entre as variáveis obtidas e o desempenho;

- (4) Agrupamento dos estudantes em perfis de desempenho;
- (5) Análise das interações por grupo;
- (6) Gerar recomendações personalizadas.

Figura 1 - Processo de condução do estudo



Fonte: Autor

#### 4.1. Entendimento do ambiente e definição do objetivo

Inicialmente, como parte do processo para conduzir a análise de dados, é essencial estabelecer um entendimento sólido dos problemas a serem abordados e definir os objetivos do estudo. Nossa abordagem, baseada no modelo CRISP-DM (Cross-Industry Standard Process for Data Mining), concentra-se na análise de cursos híbridos que utilizam a plataforma Moodle.

Dentro desse contexto, a definição de um objetivo principal é crucial e depende das particularidades do ambiente e dos desafios que pretendemos enfrentar. Em um ambiente Moodle, alguns exemplos de possíveis objetivos incluem a análise de conteúdos com baixa interação, a investigação de conteúdos com alta interação, e/ou a avaliação do desempenho dos alunos com base em suas notas em avaliações. Tendo um objetivo claramente definido para o ambiente que estamos lidando, podemos continuar nas etapas seguintes do processo.

## 4.2. Coleta e tratamento dos dados

No contexto do ensino híbrido, para conduzir um estudo analítico, é necessário que no momento da coleta sejam obtidos dados tanto das interações *online* como dos momentos presenciais, para garantir que todo o contexto seja analisado. Dessa forma, sabendo que estamos utilizando a plataforma Moodle, podemos considerar dois cenários para a coleta e tratamento dos dados. O primeiro é o cenário mínimo, caracterizado por uma baixa diversidade de tipos de interação. O segundo é o cenário ideal, no qual encontramos uma maior variedade de tipos de interação.

**Cenário mínimo:** O cenário mínimo para a primeira etapa do estudo envolve a coleta de dados básicos do ambiente online, ou seja, a quantidade de acessos ao ambiente virtual de aprendizagem, a frequência de acesso aos conteúdos disponibilizados na plataforma, como videoaulas e materiais de texto, e por fim, a frequência nas aulas presenciais e as notas das avaliações da disciplina. Os dados podem ser coletados manualmente por meio de planilhas e de registros de presença nas aulas presenciais, demandando um esforço considerável na etapa de tratamento, que vai envolver a combinação das diferentes fontes de dados em um único conjunto que integre todas as informações.

Na tabela abaixo, temos um exemplo de cenário mínimo para o processo de coleta e tratamento dos dados:

Tabela 3 - Exemplo de base de dados mínima

Variável	Descrição	Tipo de interação	Tipo
acessos_ava	Total de acessos na plataforma	Aluno x Ambiente	remoto
frequencia_aulas	Frequência em aulas presenciais	Aluno x Ambiente	presencial
acessos_videos	Total de acessos às videoaulas	Aluno x Conteúdo	remoto
acessos_textos	Total de acessos aos conteúdos de texto	Aluno x Conteúdo	remoto
nota_prova	Nota obtida na avaliação	Aluno x Conteúdo	remoto ou presencial

Fonte: Autor

**Cenário recomendado:** No cenário recomendado, iremos coletar dados que rastreiam todas as interações dos alunos no ambiente online de forma precisa, incluindo registros detalhados do tempo gasto na plataforma, tempo gasto nas videoaulas, frequência de acesso aos conteúdos, participação nos fóruns de discussão, mensagens trocadas (aluno x aluno e aluno x professor) e as notas nas avaliações. Quanto aos momentos presenciais,

teremos os registros de presença, notas nas provas, notas em apresentações de trabalhos e pontuação por participação durante as aulas. Portanto, diferente do cenário mínimo que só inclui interações entre aluno x ambiente e aluno x conteúdo, nesse cenário temos os quatro tipos de interações. Além disso, teremos um ambiente que permite a coleta dos dados online por uma única fonte de dados, facilitando o tratamento dos dados, tendo que lidar somente com as inconsistências, informações duplicadas, entre outros fatores comuns em processos de coleta e tratamento.

Na tabela abaixo, temos um exemplo de cenário ideal para o processo de coleta e tratamento dos dados:

Tabela 4 - Exemplo de base de dados ideal

<b>Variável</b>	<b>Descrição</b>	<b>Tipo de interação</b>	<b>Tipo</b>
acessos_ava	Total de acessos na plataforma	Aluno x Ambiente	remoto
tempo_ava	Total de tempo gasto na plataforma	Aluno x Ambiente	remoto
frequencia_aulas	Frequência em aulas presenciais	Aluno x Ambiente	presencial
acessos_videos	Total de acessos às videoaulas	Aluno x Conteúdo	remoto
tempo_videos	Tempo total assistindo videoaulas	Aluno x Conteúdo	remoto
acessos_textos	Total de acessos aos conteúdos de texto	Aluno x Conteúdo	remoto
mensagens_professor	Quantidade de mensagens enviadas ao professor	Aluno x Professor	remoto
mensagens_aluno	Quantidade de mensagens enviadas a outro aluno	Aluno x Aluno	remoto
mensagens_grupo	Quantidade de mensagens enviadas no grupo da turma	Aluno x Aluno	remoto
nota_trabalhos	Nota média obtida nos trabalhos	Aluno x Conteúdo	remoto e/ou presencial
atividade_avaliativa_1	Nota obtida na primeira avaliação	Aluno x Conteúdo	remoto ou presencial
atividade_avaliativa_2	Nota obtida na segunda avaliação	Aluno x Conteúdo	remoto ou presencial

Fonte: Autor

### 4.3. Análise da relação das interações com o desempenho

Nesta etapa, iremos iniciar realizando uma análise exploratória dos dados, para entender o comportamento das variáveis e interpretar quais informações podem ser úteis para atingir os objetivos definidos. Portanto, iremos utilizar métodos para analisar a relação entre os dados disponibilizados e o desempenho final do aluno, tendo um cenário mínimo e um ideal para o cumprimento dessa etapa.

**Cenário mínimo:** No cenário mínimo, iremos aplicar métodos estatísticos básicos para a análise da relação entre variáveis, como correlações entre os dados coletados e o desempenho dos estudantes, representado pelas notas obtidas nas atividades avaliativas.

**Cenário recomendado:** No cenário recomendado, a análise seria conduzida utilizando técnicas de análise de dados, como regressão múltipla, análise de variância (ANOVA), ou até mesmo modelos de aprendizado de máquina para identificar correlações complexas entre as variáveis no conjunto de dados. Adicionalmente, seria possível realizar análises de causalidade para entender de que maneira as interações exercem um impacto direto sobre o desempenho dos alunos.

### 4.4. Agrupamento dos estudantes

Com base nos resultados da análise da relação entre as variáveis e o desempenho dos estudantes, iremos selecionar os campos com maior importância e aplicar um modelo de aprendizagem não-supervisionada, como o *K-Means* ou *DBSCAN*, para identificar os diferentes perfis de desempenho entre a turma. Para esta etapa, também temos um cenário mínimo e um ideal.

**Cenário mínimo:** No cenário mais básico, a categorização dos estudantes em perfis de desempenho seria executada manualmente, com base em intervalos de notas, como categorias de baixo, médio e alto desempenho. Essa abordagem demanda uma análise subjetiva de cada grupo definido pelo algoritmo de aprendizagem.

**Cenário recomendado:** No cenário recomendado, a classificação dos estudantes em diferentes perfis de desempenho ocorreria de forma automatizada, por meio de algoritmos de clusterização. Portanto, esses algoritmos considerariam múltiplas variáveis de desempenho (ex: notas em provas, trabalhos, exercícios, simulados), permitindo uma segmentação mais precisa e a identificação de perfis de desempenho mais sofisticados e detalhados.

#### 4.5. Análise por grupo

Esta etapa envolve a análise e interpretação das características das interações dos alunos em cada grupo, previamente definidos pelo algoritmo de clusterização. O objetivo é identificar os fatores preponderantes que impactaram positivamente no desempenho dos alunos e identificar áreas que podem ser aprimoradas.

**Cenário mínimo:** No cenário mínimo, a análise por grupo seria realizada manualmente, sendo necessária uma revisão detalhada das características das interações dos alunos de cada grupo. Dessa forma, podemos identificar os principais fatores que influenciaram no desempenho dos alunos, bem como as áreas que poderiam ser aprimoradas. Embora essa abordagem ofereça uma boa compreensão das interações, requer muita atenção e está sujeita a interpretações subjetivas.

**Cenário recomendado:** No cenário recomendado, a análise das interações dos alunos nos grupos seria conduzida de forma automatizada por meio de algoritmos de mineração de dados (Mueen, 2016). Esses algoritmos identificariam padrões nas interações dos alunos, destacando automaticamente os fatores que influenciaram positivamente o desempenho e áreas passíveis de melhoria. Essa abordagem automatizada economizaria tempo na interpretação dos resultados e ofereceria *insights* mais detalhados, permitindo uma compreensão completa das interações e seus efeitos no desempenho dos alunos.

#### 4.6. Recomendações personalizadas

Com os resultados da análise das interações que influenciam diretamente no desempenho dos diferentes grupos de estudantes, serão desenvolvidas recomendações personalizadas para cada grupo definido a partir da análise e modelagem dos dados. Essas recomendações indicarão os conteúdos e interações que deveriam ter sido priorizados para a obtenção de melhores resultados no curso, ajudando os alunos em futuros cursos e os professores no processo de fornecimento de *feedback*.

**Cenário mínimo:** No cenário mínimo, podemos gerar as recomendações personalizadas com base em abordagens manuais, como a análise das principais áreas de melhoria de desempenho de cada aluno, escrevendo cada sugestão de melhoria e *feedback* com base nas características identificadas em cada grupo de estudantes revelado pelo modelo de aprendizagem não-supervisionada.

**Cenário recomendado:** No cenário recomendado, sistemas de recomendação baseados em IA (Khanal, 2020) podem ser utilizados para criar recomendações altamente personalizadas para cada aluno, deixando de se limitar a um único tipo de *feedback* para cada perfil de desempenho. Essas recomendações iriam considerar as variáveis coletadas do AVA, incluindo o histórico de interações e as características individuais de aprendizagem de cada aluno, sugerindo ações específicas para melhorar o desempenho.

## 5. METODOLOGIA

O presente trabalho tem como base um estudo de caso realizado na disciplina “Modelagem de Negócios Inovadores” da Faculdade de Economia, Administração e Contabilidade (FEAC) da Universidade Federal de Alagoas (UFAL). É importante ressaltar que este curso, desde o seu início, já contava com uma sólida metodologia, cronograma e estrutura previamente definidos, dessa forma, seguimos o que foi proposto de acordo com o ambiente disponibilizado para conduzir o estudo.

No decorrer da disciplina, foram coletados dados referentes às interações dos estudantes com o Ambiente Virtual de Aprendizagem da Rede de Inovação para Educação Híbrida (AVA RIEH). A turma, composta por 32 alunos de graduação, teve o foco nas atividades e conteúdos online, porém com momentos presenciais, se encaixando no modelo de ensino híbrido.

O curso teve uma duração total de 11 semanas, seguindo a metodologia híbrida, com aulas presenciais focadas no ensino do conteúdo principal e nas apresentações de trabalhos em grupo, enquanto as aulas remotas focaram nos conteúdos complementares, discussões e na realização da avaliação da disciplina.

### 5.1. Método de coleta e tratamento dos dados

Inicialmente, foram coletadas 7 variáveis de um total de 4605 registros do AVA RIEH, conforme a tabela 5:

Tabela 5 - Variáveis coletadas nos logs do AVA

Variável	Descrição	Exemplo
Hora	Data e Hora do evento	“22/06/23, 01:51:55”
Nome completo	Nome completo do aluno	“JOÃO SILVA”
Usuário afetado	Nome completo do aluno	“JOÃO SILVA”
Contexto do evento	Título do conteúdo acessado	“URL: Construindo a confiança para inovar 1/2”
Componente	Tipo do conteúdo acessado	“Sistema”, “URL”, “Questionário”
Nome do evento	Nome do evento de forma específica	“Módulo do curso visualizado”
Descrição	Descrição específica da interação realizada	“The user with id '24' viewed the 'quiz' activity with course module id '41'.”

Fonte: Autor

Em seguida, foram coletados diretamente com o professor, os dados referentes aos resultados da primeira avaliação da disciplina, que incluiu as notas e o total de minutos que o aluno gastou para finalizá-la, obtidos pelo professor através do seu painel de tutor dentro do AVA RIEH, além da frequência dos alunos nas aulas presenciais, obtidas de forma manual através do sistema acadêmico geral da UFAL (SIE WEB).

O *dataset* que o professor exportou através do seu painel de tutor dentro da plataforma AVA RIEH, segue um padrão parecido com o *dataset* dos dados históricos, contendo as seguintes informações (Tabela 6):

Tabela 6 - Variáveis coletadas pelo professor no painel do AVA

<b>Variável</b>	<b>Descrição</b>	<b>Exemplo</b>
Sobrenome	sobrenome do aluno	SANTOS
Nome	primeiro nome do aluno	LUCAS
Endereço de email	email do aluno	lucas@gmail.com
Iniciado em	data/hora de início da prova	8 agosto 2023 09:26 AM
Completo	data/hora do final da prova	8 agosto 2023 10:04 AM
Tempo utilizado	Tempo em minutos/segundos	38 minutos
Avaliar/10,00	Nota obtida na prova	9,00

Fonte: Autor

Foi realizado um tratamento e transformação dos dados coletados, convertendo os *logs* do AVA em variáveis de frequência de acesso aos conteúdos e combinando com a obtenção das frequências nas aulas presenciais e as notas, que foram coletadas com o professor e inseridas na base de dados. Portanto, chegamos a um conjunto final contendo as seguintes variáveis para a análise (tabela 7):

Tabela 7 - Variáveis utilizadas para a análise

<b>Variável</b>	<b>Descrição</b>	<b>Tipo de interação</b>	<b>Tipo</b>
Nome completo	Nome completo do aluno	-	-
Acesso_Plataforma	Frequência de acesso à plataforma	Aluno x Ambiente	remoto
Video_Visualizado	Quantidade de visualizações nos vídeos	Aluno x Conteúdo	remoto
Texto_Visualizado	Quantidade de visualizações nos textos	Aluno x Conteúdo	remoto
Acesso_Forum	Frequência de acesso ao fórum de discussão	Aluno x Professor / Aluno x Aluno	remoto

Visualizacao_Prova	Quantidade de visualizações nas questões da prova	Aluno x Conteúdo	remoto
Tempo_Prova	Tempo para realizar a prova, em minutos	Aluno x Ambiente	remoto
Nota_Prova	Nota do aluno na prova	Aluno x Conteúdo	remoto
FreqPresencial	Frequência nas aulas presenciais	Aluno x Ambiente	presencial
Quantidade_dias	Total de horas de acesso ao AVA, formatado em dias	Aluno x Ambiente	remoto

Fonte: Autor

Vale ressaltar que a variável “**Quantidade\_dias**” é uma estimativa de tempo gasto na plataforma em dias, que foi criada de forma manual, coletando a data/hora de cada *log* de acesso e fazendo a soma do tempo. Já a variável “**Tempo\_Prova**”, foi criada pela soma do tempo utilizado nas duas tentativas de realização da prova. As demais variáveis do AVA, do acesso à plataforma e aos conteúdos, foram geradas através do cálculo das frequências dos logs para cada aluno.

Em seguida, será realizada a modelagem desses dados, utilizando o algoritmo de aprendizagem não supervisionada *K-Means* para agrupar os estudantes em perfis de desempenho de acordo com a variável “**Nota\_Prova**”, revelando alunos com características diferentes na interação com os recursos e conteúdos disponibilizados durante a disciplina.

## 5.2. Definição do questionário de autoavaliação

Conforme proposto para o presente trabalho, iremos gerar recomendações com base nos resultados da análise dos dados e compará-las com as respostas de um questionário de autoavaliação com os estudantes, para entender quais as interações que influenciam diretamente no desempenho final, validar as recomendações criadas para os estudantes e, conseqüentemente, auxiliar professores na criação e condução de futuros cursos que sigam o modelo híbrido e por fim, sugerir possíveis melhorias no AVA RIEH.

O questionário foi dividido em 3 blocos: autoavaliação do desempenho, utilização dos recursos de aprendizagem e avaliação da metodologia. As questões foram definidas com base no modelo TAM (*Technology Acceptance Model*), por seguir o padrão de utilidade percebida, uma das formas de avaliação do modelo. A seguir, temos as perguntas do questionário de autoavaliação:

Autoavaliação do desempenho:

- Questão 1:
  - Avalie numa faixa de 0 a 10, como foi seu desempenho na disciplina.

- Tipo: Escala linear.
- Questão 2:
  - Avalie numa faixa de 0 a 10, como foi seu engajamento com a disciplina.
  - Tipo: Escala linear.
- Questão 3:
  - Avalie numa faixa de 0 a 10, o nível da sua frequência nas aulas presenciais.
  - Tipo: Escala linear.
- Questão 4:
  - Avalie numa faixa de 0 a 10, o nível da sua frequência de acesso à plataforma (AVA).
  - Tipo: Escala linear.
- Questão 5:
  - Você se considera em qual faixa de desempenho entre os alunos da turma?
  - Tipo: Múltipla escolha.
  - Alternativas: Baixo Desempenho, Regular, Alto Desempenho.

#### Utilização dos recursos de aprendizagem:

- Questão 6:
  - Numa escala de 0 a 10, o quanto você considera as videoaulas importantes para o seu desempenho?
  - Tipo: Escala linear.
- Questão 7:
  - Numa escala de 0 a 10, o quanto você considera os conteúdos de texto importantes para o seu desempenho?
  - Tipo: Escala linear.
- Questão 8:
  - Numa escala de 0 a 10, o quanto você considera os fóruns de discussão (módulos e avisos), importantes para o seu desempenho?
  - Tipo: Escala linear.

#### Avaliação da metodologia:

- Questão 9:
  - Numa escala de 0 a 10, avalie o uso da metodologia de ensino híbrido na disciplina.
  - Tipo: Escala linear.
- Questão 10:
  - Dê alguma sugestão de melhoria para a condução de disciplinas que seguem o modelo de ensino híbrido.
  - Tipo: Aberta (Parágrafo).
- Questão 11:
  - Sinta-se livre para deixar qualquer observação e/ou comentário acerca da disciplina, do uso do AVA ou da metodologia adotada. (opcional)
  - Tipo: Aberta (Parágrafo).

As questões relacionadas à autoavaliação do desempenho e ao uso dos recursos de aprendizagem podem ser consideradas como partes do componente de "Utilidade Percebida" do Modelo TAM, uma vez que os respondentes estão avaliando a utilidade percebida dos elementos da disciplina. No terceiro bloco, a questão 9 avalia a utilidade percebida da metodologia de ensino, enquanto as questões de sugestões e comentários servem para coletar informações adicionais que podem não ser facilmente categorizadas no Modelo TAM, mas são igualmente importantes para obter feedback dos alunos.

Portanto, o presente trabalho se concentra em um estudo de caso combinado com a análise dos resultados do questionário mencionado acima, que tem como objetivo compreender o quanto cada conteúdo/recurso utilizado durante a disciplina (momentos remotos e presenciais) influencia no desempenho dos estudantes.

### **5.3. Validação do processo proposto**

Para validar o processo de análise e as recomendações, será conduzido um questionário de satisfação e autoavaliação com os estudantes (Apêndice A), seguindo o TAM (*Technology Acceptance Model*). Esse questionário tem como objetivo avaliar a percepção dos próprios alunos em relação aos conteúdos/recursos que ele deveria ter priorizado, seu nível de desempenho e também para coletar a avaliação que eles dão para a metodologia que o professor utilizou no curso de modo geral.

Através das informações obtidas por meio do questionário, será possível validar os resultados da análise realizada, comparando as respostas com as recomendações sugeridas, além de levantar questões relevantes sobre as medidas que podem ser tomadas para melhorar o desempenho dos estudantes no contexto geral dos cursos híbridos e para aprimorar o ambiente de aprendizagem analisado.

É importante destacar que o objetivo deste trabalho não é fornecer previsões antecipadas de risco de insucesso para os alunos. Em vez disso, busca-se apresentar uma análise focada na identificação das interações que mais influenciaram nos resultados finais dos estudantes, de acordo com seus diferentes níveis de desempenho. Essa análise servirá como base para recomendações personalizadas, visando auxiliá-los na escolha das interações com a maior chance de otimizar o desempenho desses estudantes. Além disso, as recomendações também funcionarão como um *feedback* valioso para os estudantes com baixa interação nos principais recursos da disciplina. Ao mesmo tempo, essa análise contribuirá para que os professores compreendam melhor como os alunos interagem ao longo do curso, e como essas interações afetam o desempenho acadêmico de seus estudantes. Com isso, poderão ajustar suas abordagens de ensino de acordo com as necessidades identificadas.

## 6. RESULTADOS E DISCUSSÕES

Neste capítulo de resultados e discussões é apresentada a análise do desempenho dos estudantes, baseada em suas interações e notas. Identificamos seis perfis de desempenho e geramos recomendações personalizadas para cada grupo. As percepções dos alunos também foram coletadas, fornecendo *insights* valiosos sobre a importância de atividades online e conteúdos objetivos, contribuindo para a melhoria contínua do ensino híbrido.

### 6.1. Estudo do ambiente e a definição do objetivo

Inicialmente, analisamos o ambiente no qual o curso foi ministrado (vide Capítulo 5), composto pelo AVA RIEH e momentos de interação presencial. No ambiente online, não havia ferramentas disponíveis para ajudar os professores a monitorar as interações dos alunos e nem mecanismos de recomendação e feedback para auxiliar os estudantes no entendimento dos pontos fortes e fracos de seu desempenho ao longo da disciplina. Quanto ao ambiente presencial, nenhum tipo de dado estava sendo coletado nem analisado.

A constatação desses pontos nos levou a reconhecer a necessidade de conduzir uma análise que combinasse dados online e presenciais para compreender as dinâmicas das interações e o impacto no desempenho dos estudantes. O estudo surge como resposta a essa necessidade e tem o propósito de não apenas preencher as lacunas identificadas, mas também de contribuir para a melhoria contínua do ensino híbrido.

Portanto, o objetivo central do estudo é entender o quanto cada interação online e presencial pode influenciar no desempenho dos estudantes. Para cumprir tal objetivo, agrupamos os alunos de acordo com os resultados nas avaliações, analisamos as interações que influenciaram no desempenho e geramos recomendações personalizadas e feedback para cada grupo definido.

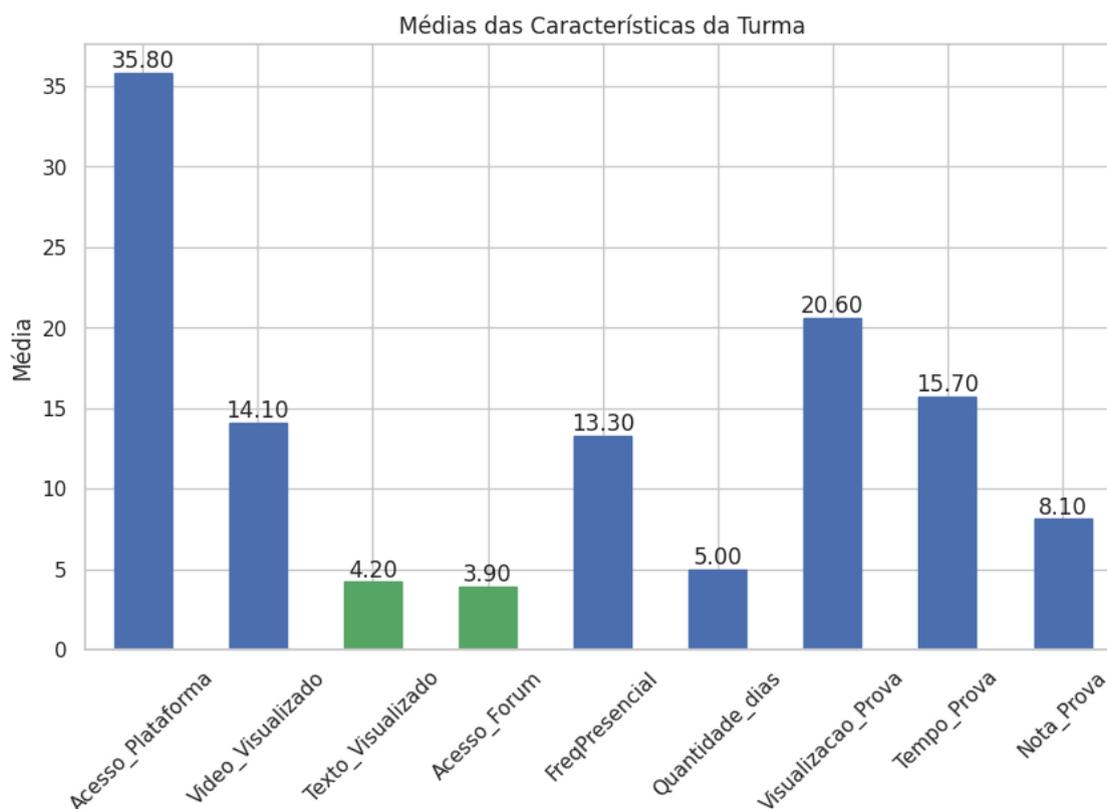
### 6.2. Análise, discussão e agrupamento dos dados

Feita a construção do *dataset* (vide Capítulo 5), foi realizada uma análise exploratória, para entender as características dos dados, as correlações com as notas e descartar informações que não sejam relevantes para agrupar os estudantes em diferentes perfis de desempenho. Na figura a seguir (Figura 2), podemos observar as médias das características da turma<sup>1</sup>, tendo como destaque a baixa frequência de acesso aos conteúdos de texto e aos fóruns de discussão:

---

<sup>1</sup> Para quaisquer dúvidas acerca das variáveis, consultar a seção 5.1 do capítulo de metodologia.

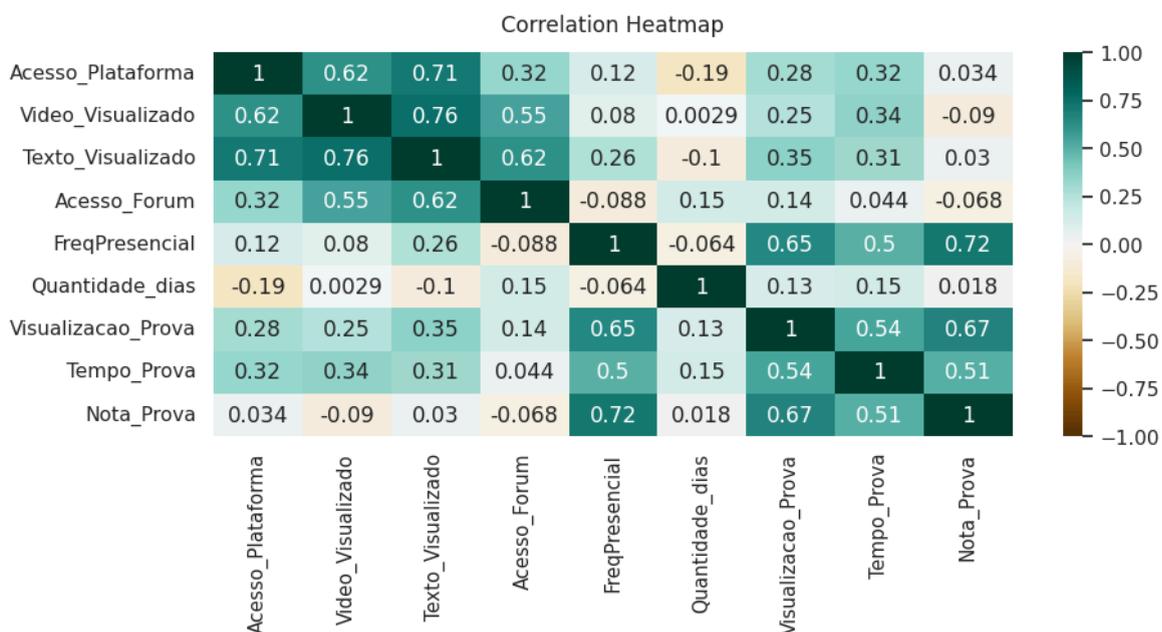
Figura 2 - Médias das frequências gerais da turma



Fonte: Autor

Em seguida, construímos uma representação do mapa de correlação, conforme a Figura 3, para entender quais dos dados obtidos possuem relação com a variável **Nota\_Prova**, além de observar outras possíveis correlações entre os dados obtidos:

Figura 3 - Mapa de correlação das variáveis do dataset



Fonte: Autor

Na tabela a seguir (Tabela 8), temos o desvio padrão das colunas do *dataset*, com exceção da variável **Nota\_Prova**, que será utilizada para o modelo de agrupamento:

Tabela 8 - Desvio padrão das colunas do dataset

<b>Variável</b>	<b>Desvio Padrão</b>
Acesso_Plataforma	18.74
Video_Visualizado	11.85
Visualizacao_Prova	10.86
Tempo_Prova	6.78
FreqPresencial	5.76
Acesso_Forum	3.76
Texto_Visualizado	3.69
Quantidade_dias	1.98

Fonte: Autor

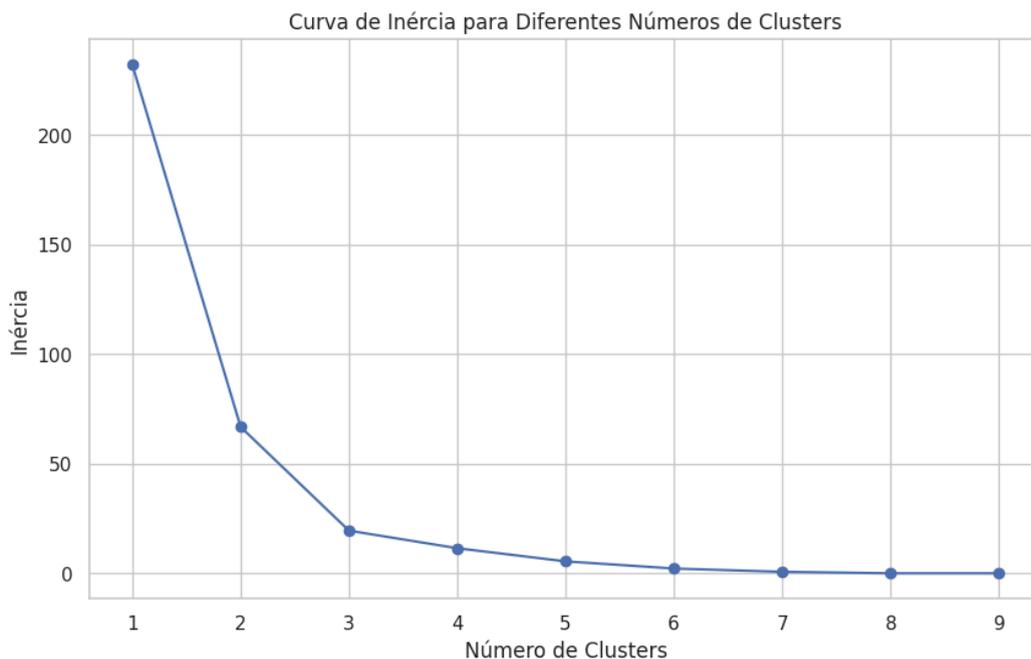
Ao analisar as médias das características da turma, o mapa de correlação e a tabela de desvio padrão, foi possível notar que a turma teve uma baixa interação com as videoaulas. Ao observar as variáveis de visualizações nos textos e os acessos ao fórum, a situação é mais crítica, tendo uma quantidade de interações muito baixa. Quando comparamos com os acessos ao AVA, o tempo de prova, a quantidade de visualizações nas questões e a frequência nas aulas presenciais, notamos claramente essa diferença.

Portanto, descartamos variáveis que possuem tanto baixa correlação com as notas como um baixo desvio padrão, pois não irão ajudar na identificação dos diferentes perfis de desempenho entre os estudantes. As variáveis **Texto\_Visualizado**, **Acesso\_Forum** e **Quantidade\_dias** foram removidas do modelo.

Tendo os campos definidos para construir o modelo, utilizamos o algoritmo de aprendizagem não-supervisionada *K-Means*, para montar o agrupamento dos estudantes de acordo com o nível de desempenho (notas na avaliação), para conduzir a investigação das variáveis que mais influenciaram nos resultados de aprendizagem dos estudantes em cada cluster (grupo ou agrupamento). Para definir a quantidade ideal de *clusters* para o contexto da identificação de diferentes perfis de desempenho entre os alunos, utilizamos 2 métodos de validação: *Elbow Method* e *Silhouette Score*.

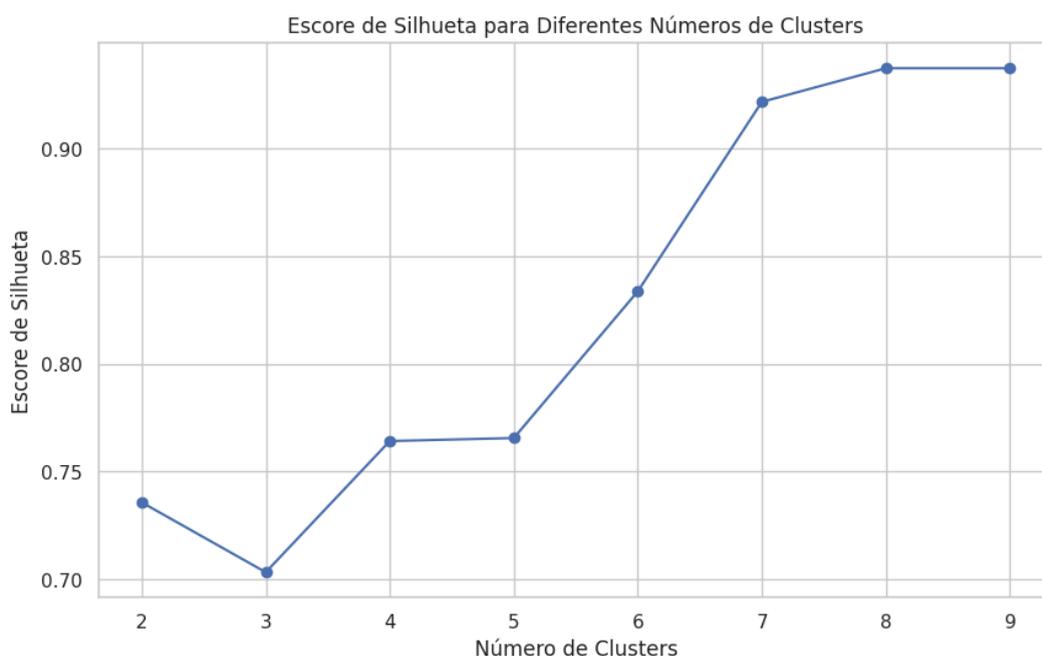
O método *Elbow* envolve plotar a variação explicada (ou inércia) em relação ao número de *clusters*. O ponto "cotovelo" no gráfico é onde a adição de mais *clusters* não melhora significativamente a variação explicada (Yellowbrick v1.3 documentation, 2023). Na figura abaixo (Figura 4) temos a representação desse método para o presente trabalho:

Figura 4 - Gráfico do método Elbow



Fonte: Autor

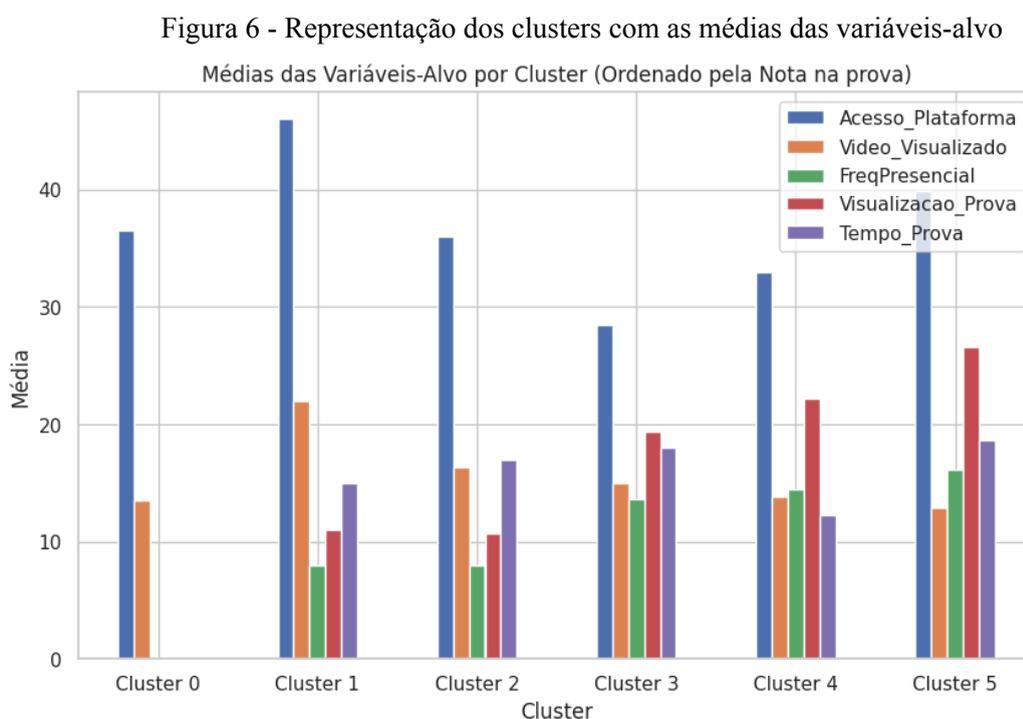
O *Silhouette Score* mede quão semelhantes são as amostras de um *cluster* em comparação com os *clusters* vizinhos mais próximos (scikit-learn 0.24.1 documentation, 2023). Valores mais altos indicam que os *clusters* estão bem separados e que as amostras estão mais próximas de seu próprio *cluster* do que de outros *clusters*. Um *Silhouette Score* alto é indicativo de *clusters* bem definidos. Na figura abaixo (Figura 5) temos o resultado da aplicação desse método:

Figura 5 - Gráfico do método *Silhouette Score*

Fonte: Autor

Através dos resultados do método do cotovelo (*Elbow*), notamos que a partir de 3 *clusters* a curva de inércia se estabiliza, ou seja, interpretamos que o recomendado seria de 3 a 5 *clusters*. Já no algoritmo de *Silhouette*, o índice/score apresenta como ideal de 7 a 9 *clusters*. Após verificarmos e testar a diferença das características dos grupos com os valores recomendados pela interpretação dos algoritmos, consideramos mais adequado o valor que fica entre os intervalos do *Elbow* e o *Silhouette*, optando pelo uso de 6 *clusters* no *K-means*. Ao definir entre 7 e 9 grupos, como foi recomendado pelo *Silhouette Score*, apareceram perfis com níveis de desempenho muito próximos, o que foge da proposta do estudo, que tem como um dos objetivos identificar estudantes com perfis mais distintos de aprendizagem. Ao testar entre 3 e 5 grupos, encontramos estudantes muito diferentes num mesmo *cluster*, o que também foge da proposta do trabalho.

Na figura abaixo (Figura 6), temos a representação das médias das variáveis no agrupamento *K-Means* com 6 *clusters* (ordenado por nota, ou seja, o primeiro grupo obteve as menores notas enquanto o último obteve as maiores):



Fonte: Autor

Portanto, separamos a variável **Nota\_Prova** dos demais dados, pois ela corresponde ao resultado final do estudante no curso, sendo a única variável de desempenho disponibilizada através do AVA. Dessa forma, aplicamos o algoritmo *K-Means* de aprendizagem não-supervisionada para separar os estudantes em *clusters* seguindo a quantidade ideal definida anteriormente. Por fim, a partir dos resultados do agrupamento gerado pelo modelo, identificamos seis perfis de alunos com diferentes níveis de desempenho. Esses perfis estão nomeados e caracterizados na Tabela 9:

Tabela 9 - Agrupamento dos estudantes pelo desempenho (notas na prova)

<b>Desempenho</b>	<b>Quantidade de alunos</b>	<b>%</b>	<b>Nota na prova</b>
Evasão	2	6.25	x = 0
Muito Baixo	1	3.13	x = 3
Baixo	3	9.37	x = 5 ou x = 6
Regular/bom	6	18.75	x = 7 ou x = 8
Alto	7	21.87	x = 9
Excelente	13	40.63	x = 10

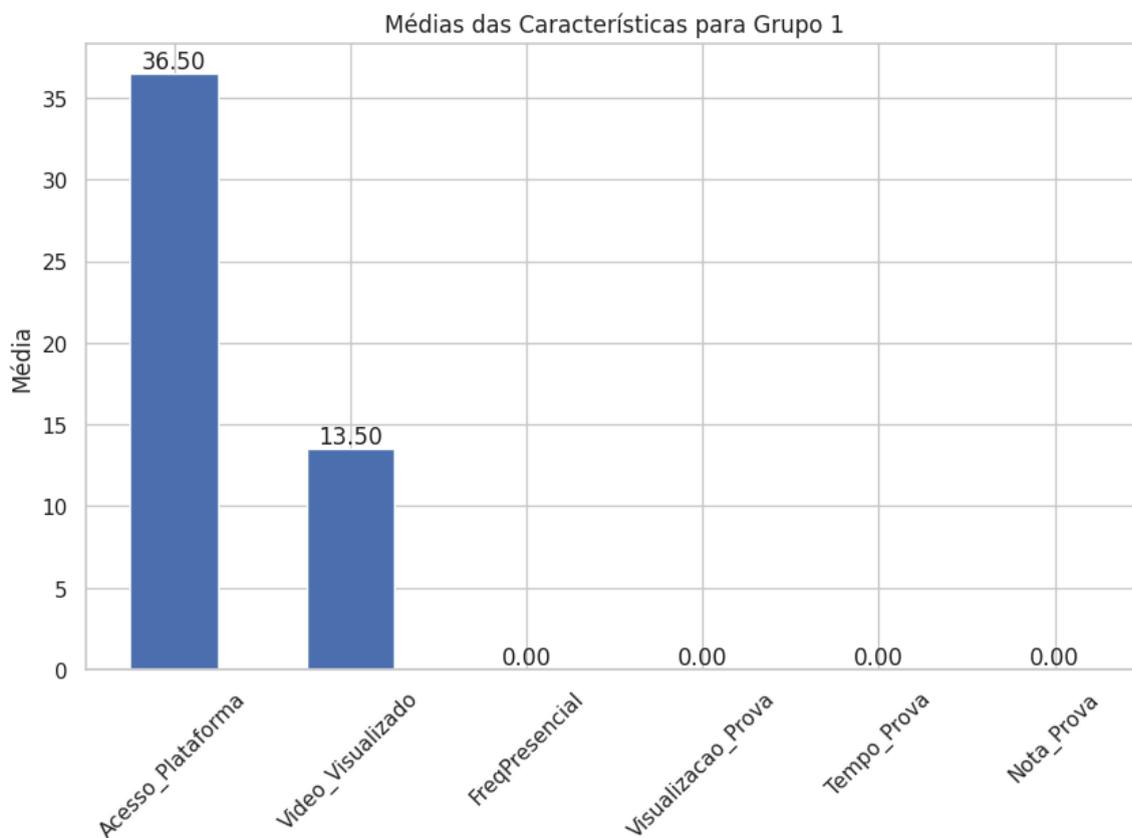
Fonte: Autor

Feito isso, analisamos individualmente cada grupo de estudantes (de acordo com o algoritmo de aprendizagem de não-supervisionada escolhido) e geramos representações das médias das características de cada grupo definido pelo modelo.

### 6.3. Análise individual dos perfis de desempenho

O grupo 1 (evasão) é composto por alunos que nunca compareceram às aulas presenciais e nem fizeram a prova, então, consideramos que evadiram do curso, mas também há a possibilidade de serem ouvintes que estavam apenas acompanhando os conteúdos do AVA, independente de estarem devidamente matriculados na disciplina. Na Figura 7, temos a representação das médias das características desse grupo:

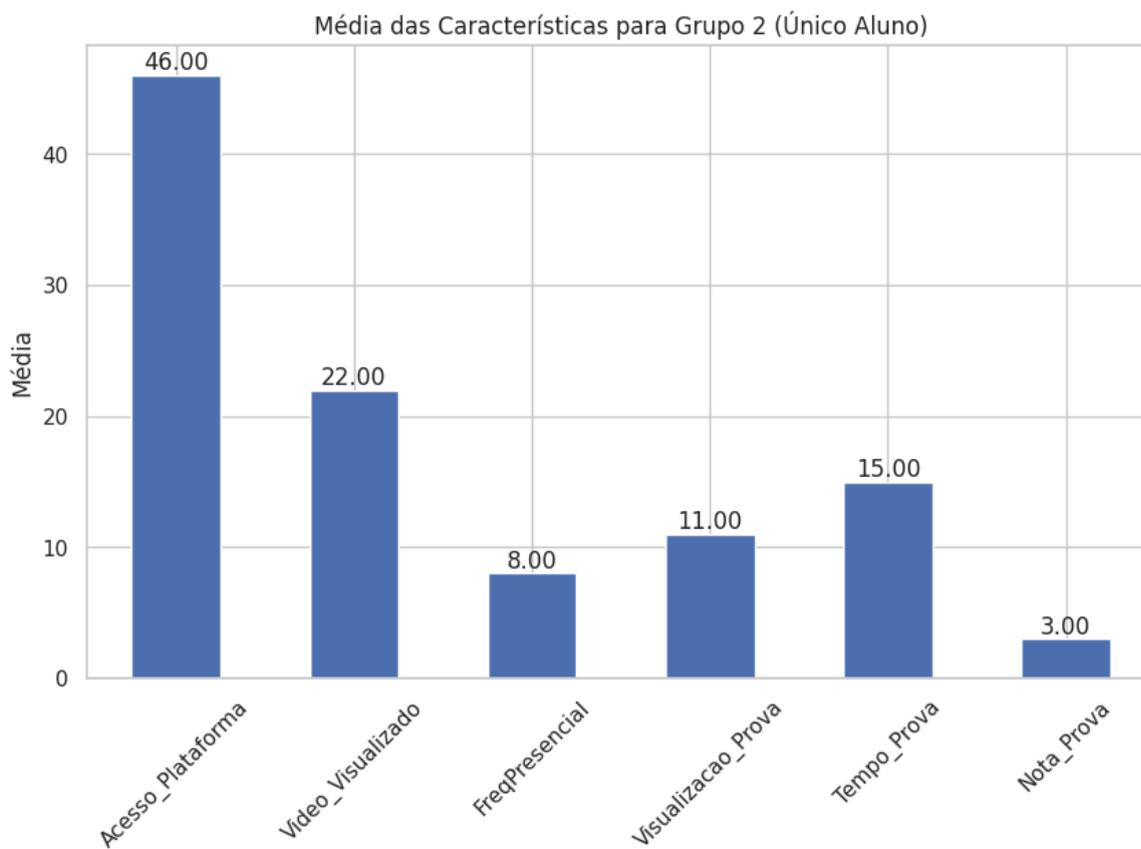
Figura 7 - Médias das variáveis-alvo do grupo 1 (evasão)



Fonte: Autor

O grupo 2 (desempenho muito baixo) é composto por apenas um aluno, que teve participação ativa no AVA, com a quantidade de acessos à plataforma e o número de visualizações nas videoaulas acima da média da turma, no entanto, o aluno obteve nota 3 (de 10) na prova, teve poucas visualizações nas questões e teve baixa frequência nas aulas presenciais, assistiu apenas 8 de 20 aulas ministradas. Na Figura 8, temos a representação das médias das características do grupo de desempenho muito baixo:

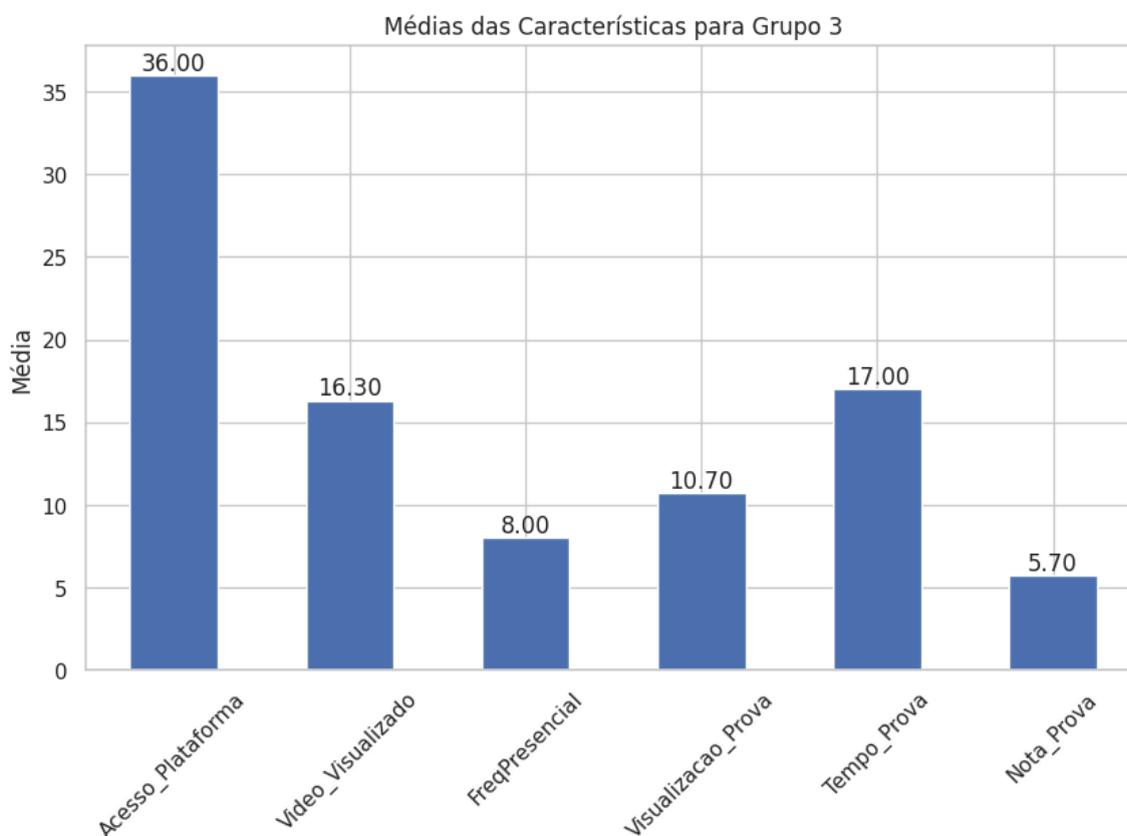
Figura 8 - Médias das variáveis-alvo do grupo 2 (desempenho muito baixo)



Fonte: Autor

O grupo 3 (desempenho baixo) teve um comportamento semelhante ao grupo anterior, os alunos tiveram uma interação no AVA inferior ao grupo 2, a mesma frequência média nas aulas presenciais e a única diferença notada foi a média de tempo de prova um pouco superior. As notas obtidas foram 5 ou 6 de 10, sendo considerado o grupo de desempenho baixo. Portanto, no grupo 2 (desempenho muito baixo) e no grupo 3, os alunos tiveram notas abaixo da média, que pode ser explicado pela baixa frequência nas aulas presenciais e pela quantidade de visualizações durante a realização da prova, 50% menor em relação à média da turma. Na Figura 9, temos a representação das médias das características do grupo de desempenho baixo:

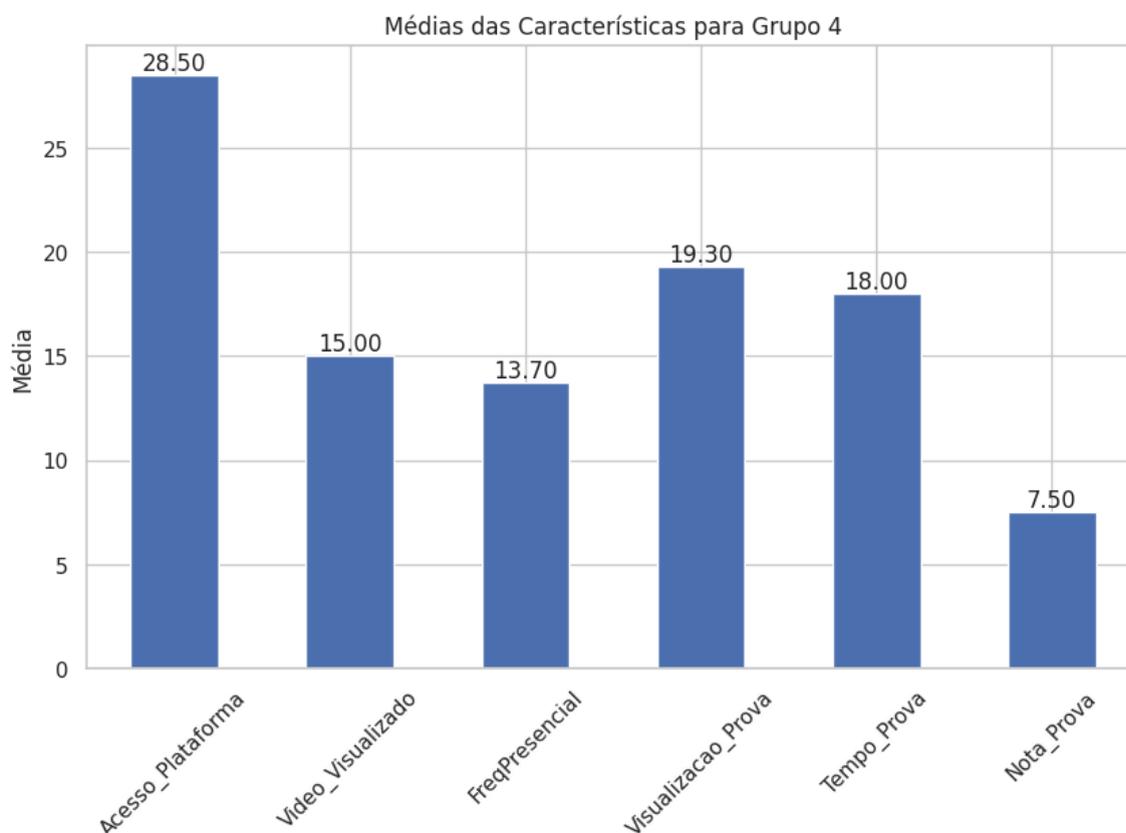
Figura 9 - Médias das variáveis-alvo do grupo 3 (desempenho baixo)



Fonte: Autor

O grupo 4 (desempenho regular/bom) é composto por alunos que alcançaram notas suficientes para serem aprovados na disciplina, especificamente 7 ou 8 de 10. Os estudantes desse grupo tiveram uma quantidade de interações no AVA (acessos à plataforma e visualizações nas videoaulas) levemente abaixo da média geral da turma, e quando comparamos com os grupos anteriores, observamos que na realização da prova, estes alunos tiveram mais visualizações nas questões e dedicaram mais tempo para realizá-las. Além disso, a frequência nas aulas presenciais seguiu praticamente a média geral da turma, comparecendo em cerca de 13 das 20 aulas. Abaixo, na Figura 10, temos a representação do grupo 4 de desempenho regular/bom:

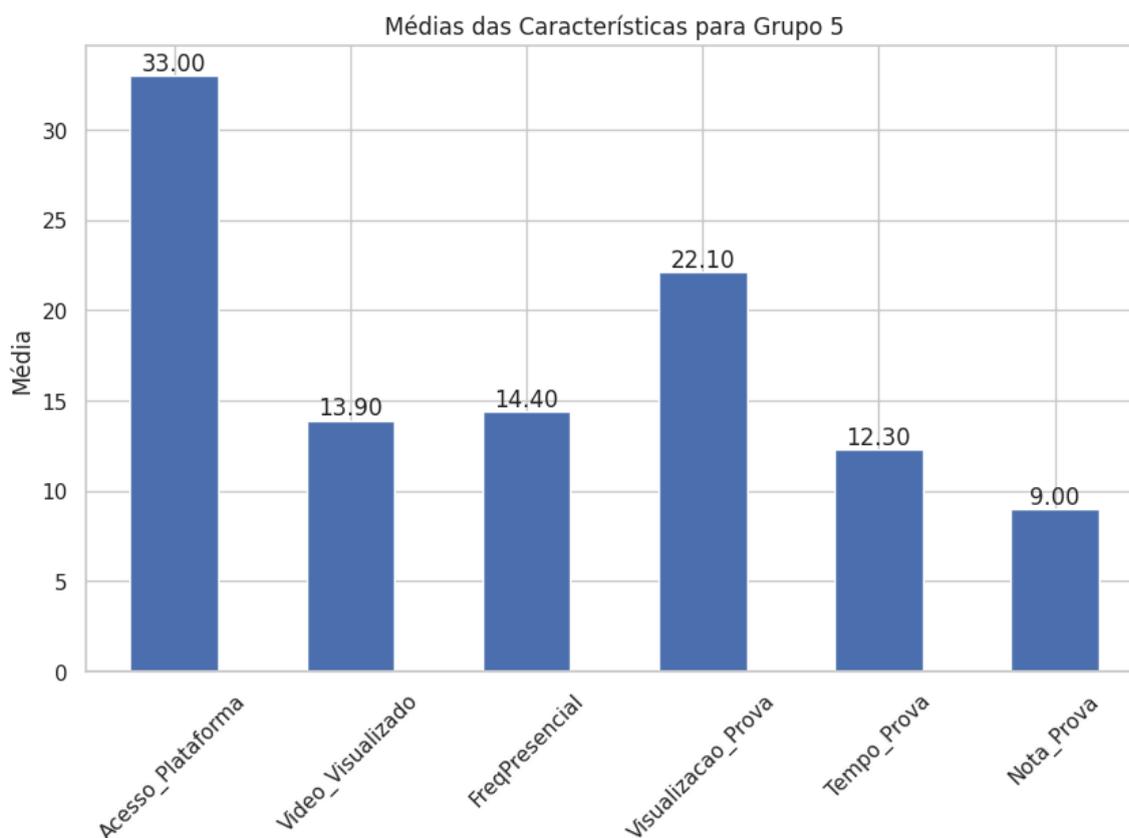
Figura 10 - Médias das variáveis-alvo do grupo 4 (desempenho regular/bom)



Fonte: Autor

O grupo 5 (grupo muito bom) é composto pelos alunos que alcançaram uma nota 9 de 10 na avaliação. Os estudantes foram bem frequentes nas aulas presenciais, em média 14 de 20, acessaram o AVA com uma frequência próxima da média da turma e tiveram uma quantidade de visualizações durante a prova um pouco acima da turma em geral. Porém, os alunos dos grupos de desempenho baixo e regular/bom acessaram os conteúdos do AVA mais que os estudantes desse grupo, que também tiveram um tempo de prova reduzido, finalizando a avaliação numa média de 12 minutos. Abaixo, na Figura 11, temos as médias das características do grupo 5 de desempenho alto:

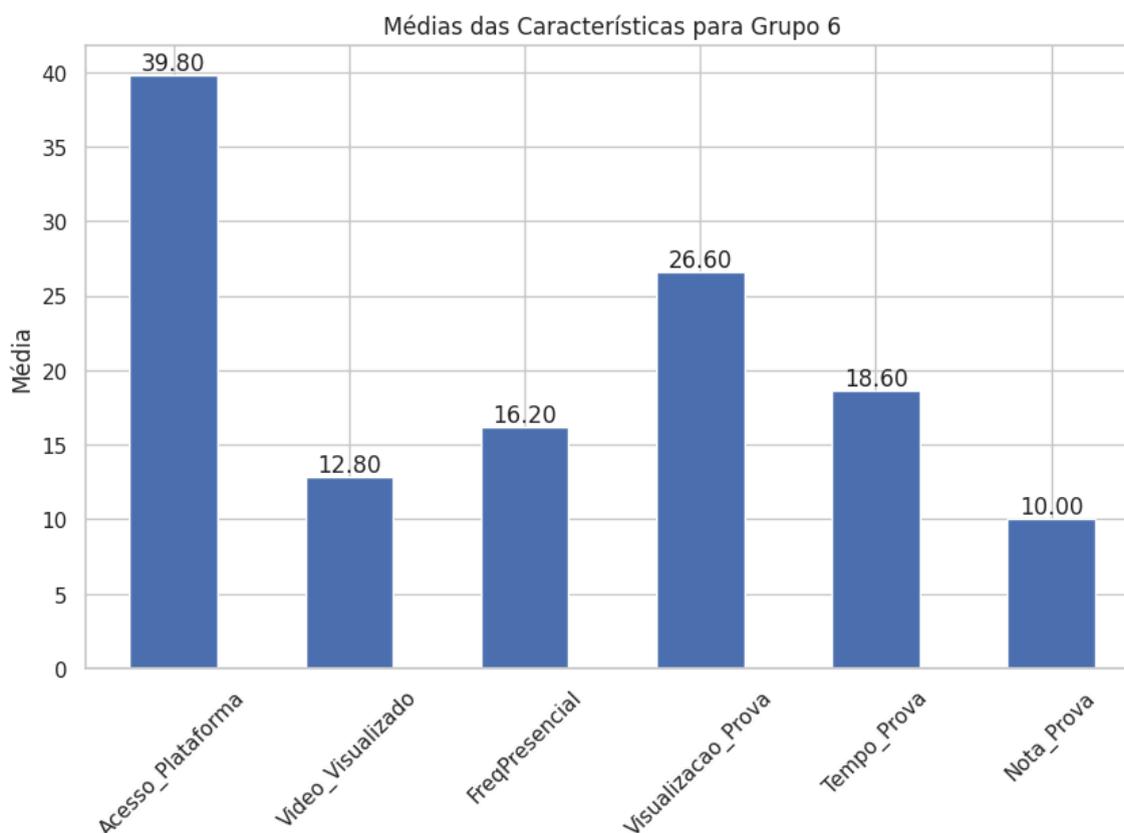
Figura 11 - Médias das variáveis-alvo do grupo 5 (desempenho alto)



Fonte: Autor

No grupo 6, todos os alunos conseguiram nota máxima 10 de 10 na avaliação, alcançando um desempenho excelente. Foram os alunos que mais compareceram às aulas presenciais, que tiveram a maior frequência média de visualizações nas questões e também com maior tempo de prova. Porém, os alunos de desempenho excelente foram os que menos visualizaram as videoaulas disponibilizadas no AVA, o que pode gerar discussões acerca da importância do conteúdo disponibilizado *online* em relação ao que foi passado nas aulas presenciais. É, também, o grupo com maior número de alunos (13) o que pode sugerir que o curso teve uma metodologia apropriada ou que são estudantes com aptidões ao uso de tecnologia no processo de aprendizagem. Na Figura 12, podemos observar as médias das características do grupo 6 (desempenho excelente):

Figura 12 - Médias das variáveis-alvo do grupo 6 (desempenho excelente)



Fonte: Autor

Quando comparamos os alunos do grupo 6 (desempenho excelente) com aqueles do grupo anterior (desempenho alto), percebemos que os dados estão com médias bem próximas. A maior diferença está no tempo médio de prova, então, há a possibilidade de que os alunos que tiveram alto desempenho poderiam ter alcançado a excelência (nota 10), caso tivessem dedicado mais tempo na prova, revisando as questões respondidas com mais calma e atenção. No entanto, outros fatores fora do alcance da nossa análise podem ter sido os responsáveis por “impedir” os alunos de obterem a nota máxima na prova.

#### 6.4. Recomendações personalizadas

Para validar os resultados da análise, geramos recomendações e/ou feedback acerca do desempenho ao longo do curso, sugerindo melhorias e os recursos que deveriam ser priorizados no curso, para cada perfil de estudantes. Na tabela a seguir (Tabela 10), temos a listagem das recomendações criadas para cada grupo:

Tabela 10 - Recomendações para os estudantes

Grupo	Contexto	Feedback
Evasão	Nunca foi às aulas presenciais;	Matricule-se na disciplina no próximo período e participe ativamente das aulas

	<p>Não realizou a avaliação da disciplina. Tempo de prova: Não realizou; Acesso online razoável (AVA + videoaulas).</p>	<p>presenciais, pois os conteúdos do AVA são complementos do que é dado em sala de aula. Dê atenção aos prazos das avaliações. Caso tenha tido problemas externos que o levaram a desistir da disciplina, busque ajuda, conversando com o professor, coordenador ou outro responsável do seu curso.</p>
Desempenho muito baixo	<p>Frequência baixa nas aulas presenciais; Nota muito baixa na avaliação da disciplina (3/10); Tempo de prova: Um pouco abaixo do normal; Acesso online frequente (AVA + videoaulas).</p>	<p>Infelizmente você não obteve nota suficiente para aprovação na disciplina. Na próxima vez, recomendamos que você sempre que possível frequente as aulas presenciais e utilize os conteúdos do AVA ao seu favor, como complemento do que foi dado em sala de aula. Além disso, ao realizar uma prova, também utilize o tempo a seu favor, fazendo as questões com calma e revisando as respostas antes de submeter no AVA.</p>
Desempenho baixo	<p>Frequência baixa nas aulas presenciais; Nota baixa na avaliação da disciplina (5/10 ou 6/10); Tempo de prova: Normal; Acesso online razoável (AVA + videoaulas).</p>	<p>Infelizmente você não obteve nota suficiente para aprovação na disciplina. Na próxima vez ou em outros cursos que sigam a mesma metodologia híbrida, recomendamos que você sempre que possível frequente as aulas presenciais e utilize os conteúdos do AVA ao seu favor, como complemento do que foi dado em sala de aula. Além disso, antes de submeter as respostas de uma prova, revise atentamente cada questão respondida.</p>
Desempenho regular	<p>Frequência razoável nas aulas presenciais; Nota regular/boa na avaliação da disciplina (7/10 ou 8/10); Tempo de prova: Normal; Acesso online baixo (AVA + videoaulas).</p>	<p>Você foi aprovado na disciplina e seguiu a média geral de desempenho da turma, no entanto, poderia frequentar mais aulas presenciais para absorver conteúdos importantes para as avaliações. Além disso, você também teve um baixo acesso aos conteúdos complementares do AVA, que poderiam dar suporte aos seus estudos. Dessa forma, você conseguirá elevar seu desempenho, alcançando melhores notas.</p>
Desempenho alto	<p>Frequência alta nas aulas presenciais; Nota alta na avaliação da disciplina (9/10); Tempo de prova: Baixo; Acesso online baixo (AVA + videoaulas).</p>	<p>Parabéns pelo alto desempenho na disciplina, você participou ativamente das aulas presenciais, alcançou uma boa nota na prova e fez um bom uso do AVA, mesmo com um baixo acesso aos conteúdos disponibilizados. Você terminou a prova em poucos minutos, tente dedicar mais tempo nas avaliações dos próximos cursos revisando bem as respostas, isso poderá ajudá-lo a elevar seu desempenho.</p>
Desempenho excelente	<p>Frequência alta nas aulas presenciais;</p>	<p>Parabéns pelo excelente desempenho na disciplina, você participou ativamente das</p>

	Nota 10/10 na avaliação da disciplina; Tempo de prova: Normal; Acesso online razoável (AVA + videoaulas)	aulas presenciais, alcançou nota máxima na prova e fez um bom uso do AVA, mesmo não consumindo tanto os conteúdos complementares como a média geral da turma. Continue aprimorando seu conhecimento nos próximos cursos.
--	--	--

Fonte: Autor

Portanto, a partir do método adotado para conduzir a análise dos dados, foi possível gerar visualizações acerca das interações que tiveram maior influência nas notas dos alunos, identificar os grupos com diferentes níveis de desempenho, analisar como se deram as interações em cada grupo definido e gerar feedback personalizado.

### 6.5. Análise dos resultados do questionário

Em seguida, o questionário de autoavaliação foi enviado para os estudantes (definido anteriormente no capítulo de metodologia), para que auto indiquem seu nível de desempenho na disciplina, os recursos/conteúdos que mais utilizou e quais deveriam ser priorizados para melhorar suas notas de modo geral. 23 dos 32 alunos que participaram da disciplina responderam ao formulário.

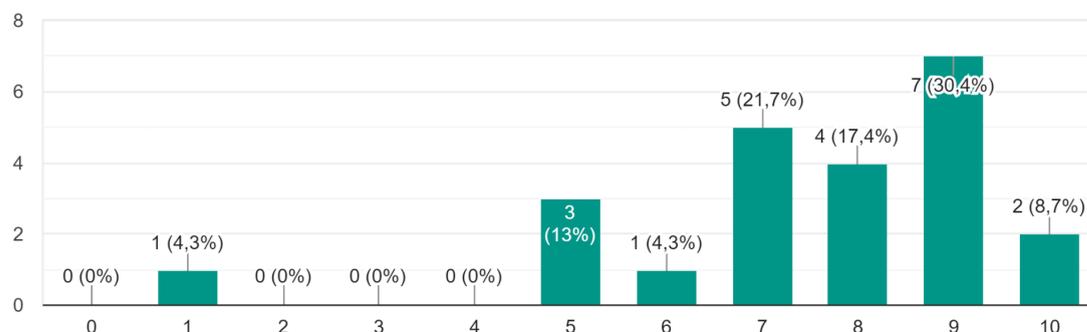
Vale ressaltar que nem todas as perguntas do questionário serão abordadas, pois em algumas delas não foi possível extrair informações úteis para a análise do desempenho e comparação com os resultados do modelo.

Na figura abaixo (Figura 13), podemos observar que, 13 dos 23 alunos que responderam o questionário se auto avaliaram com um nível de desempenho entre 8 e 10. A informação está de acordo com o que foi concluído a partir da análise dos dados, em que 20 dos 32 alunos matriculados tiveram um desempenho classificado como alto ou excelente. Vale ressaltar que, ao responder essa pergunta acerca do desempenho (questão 1 do formulário), o aluno pode ter levado em conta outros fatores externos ou pessoais, diferente do modelo implementado, que analisa as notas e os logs do AVA.

Figura 13 - Respostas da autoavaliação do desempenho

Avalie numa faixa de 0 a 10, como foi seu desempenho na disciplina.

23 respostas



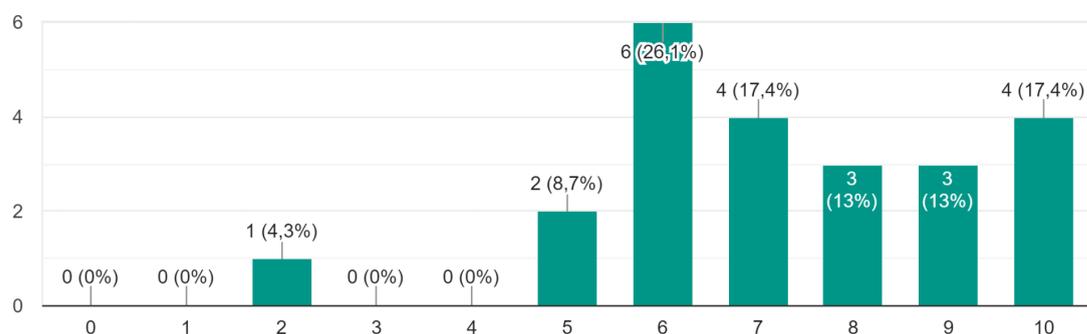
Fonte: Autor

A segunda pergunta do questionário foi acerca do nível de engajamento com a disciplina, dessa vez, os alunos tiveram respostas mais dispersas, com 12 das 23 respostas entre os níveis 5 e 7 da escala de 0 a 10, o que mostra que grande parte da turma considera que poderia ter participado e se dedicado mais ao longo da disciplina. Esses fatores podem ter influenciado na baixa interação com os fóruns de discussão, constatada anteriormente na análise dos dados e construção do modelo. Na figura 14, temos a representação da autoavaliação do engajamento:

Figura 14 - Respostas da autoavaliação do engajamento

Avalie numa faixa de 0 a 10, como foi seu engajamento com a disciplina.

23 respostas



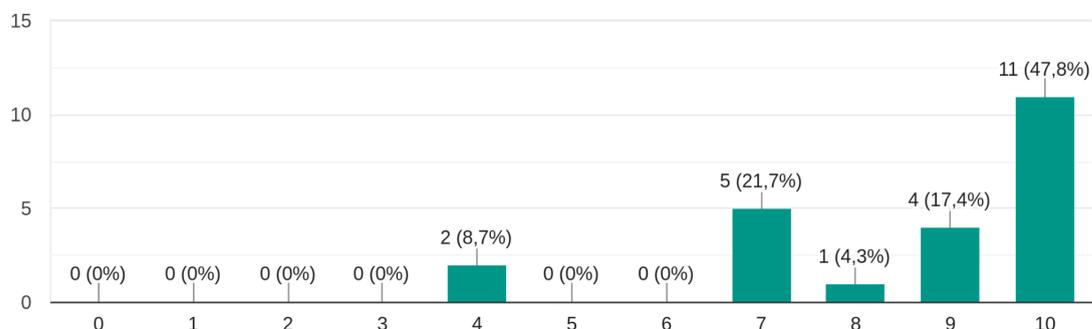
Fonte: Autor

Na figura abaixo (Figura 15), temos as respostas acerca da frequência nas aulas presenciais (questão 3), com 11 dos 23 alunos (47,8%) avaliando com 10/10, o que mostra a importância que eles deram para os momentos presenciais ao longo da disciplina.

Figura 15 - Respostas acerca da frequência presencial

Avalie numa faixa de 0 a 10, o nível da sua frequência nas aulas presenciais.

23 respostas



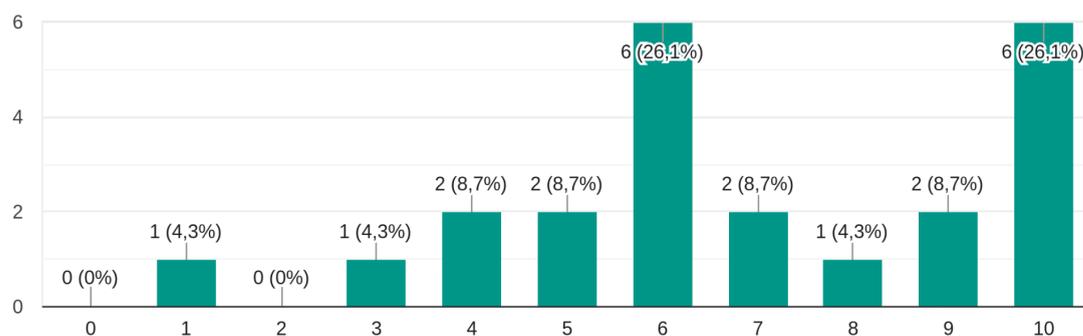
Fonte: Autor

Na figura a seguir (Figura 11), temos as respostas acerca da frequência de acesso à plataforma AVA RIEH (questão 4), com respostas bem mais dispersas, destacando que apenas 6 dos 23 alunos avaliaram com 10/10, sendo a mesma quantidade que avaliou a frequência de acesso com uma nota 6/10.

Figura 16 - Respostas acerca da frequência de acesso ao AVA

Avalie numa faixa de 0 a 10, o nível da sua frequência de acesso à plataforma (AVA).

23 respostas



Fonte: Autor

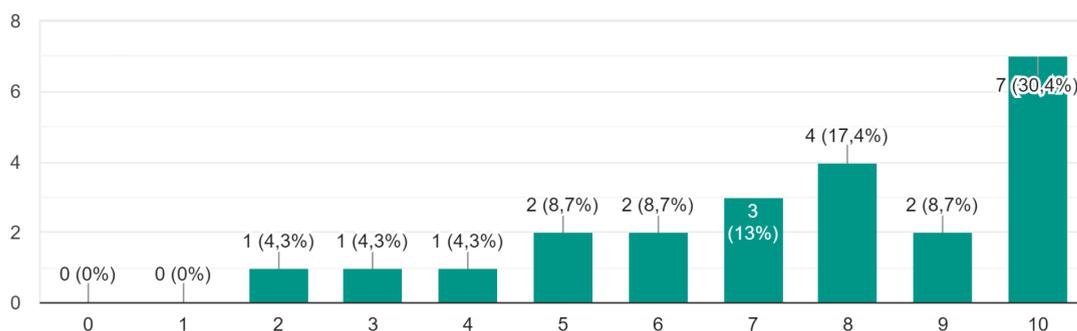
Quando comparamos com as respostas da pergunta anterior (questão 3), notamos que os alunos preocuparam-se mais em frequentar as aulas presenciais em relação à parte remota, já que os conteúdos do AVA foram complementos ao que era dado em sala de aula. No entanto, quando voltamos para os logs analisados no início da seção, percebemos que isso se refletiu na baixa interação com os recursos fornecidos pelo professor através do ambiente de aprendizagem online.

Nas figuras a seguir (Figura 17, 18 e 19), temos a distribuição das respostas dos alunos para as perguntas acerca do uso dos recursos de aprendizagem disponibilizados no AVA, que coletou numa faixa de 0 a 10, o nível de importância das vídeo aulas, conteúdos de texto e os fóruns de discussão, respectivamente.

Figura 17 - Respostas acerca da importância das videoaulas

Numa escala de 0 a 10, o quanto você considera as videoaulas importantes para o seu desempenho?

23 respostas

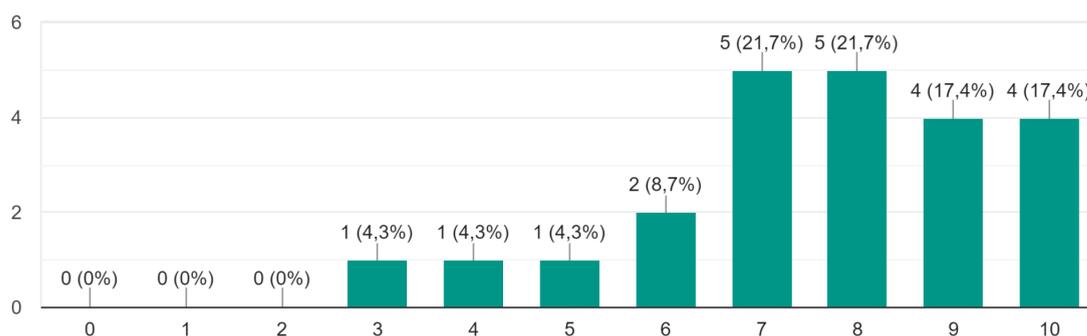


Fonte: Autor

Figura 18 - Respostas acerca da importância dos conteúdos de texto

Numa escala de 0 a 10, o quanto você considera os conteúdos de texto importantes para o seu desempenho?

23 respostas

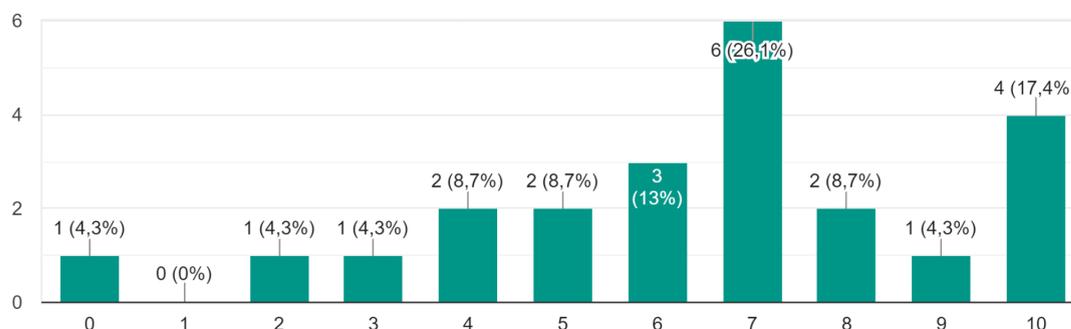


Fonte: Autor

Figura 19 - Respostas acerca da importância dos fóruns de discussão

Numa escala de 0 a 10, o quanto você considera os fóruns de discussão (módulos e avisos), importantes para o seu desempenho?

23 respostas



Fonte: Autor

Ao analisar a diferença entre as três representações, podemos perceber que 13 dos 23 alunos entrevistados deram um nível de importância de 8 a 10 para as vídeo aulas e os conteúdos de texto, enquanto que na avaliação dos fóruns de discussão apenas 7 dos 23 alunos avaliaram na mesma faixa. Dessa forma, tendo em vista também a dispersão dos dados e a quantidade elevada de avaliações abaixo de 8, os estudantes consideram que os fóruns de discussão são menos importantes para o desempenho do que os conteúdos de vídeo e texto.

Ao longo da análise dos dados e construção do agrupamento de estudantes, para cada tipo de conteúdo foi apresentado o desvio padrão, a correlação com as notas e por fim, através do questionário, o nível de importância dado pelos próprios alunos. Com isso, podemos ranquear os três tipos de conteúdos utilizados na disciplina na seguinte ordem:

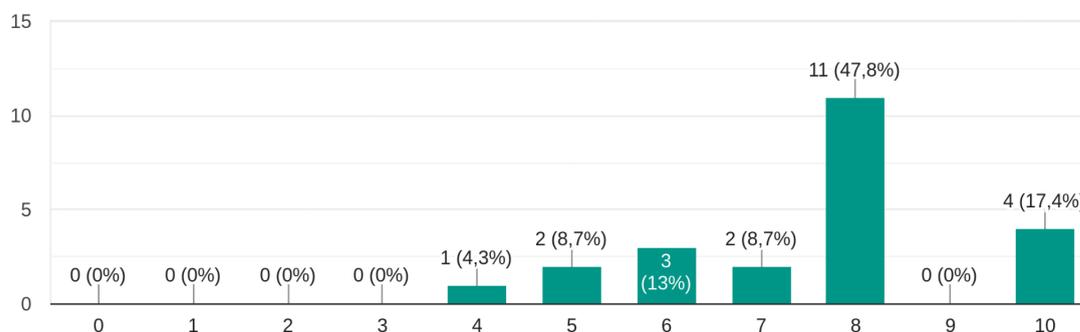
- (1) Vídeo aulas: alto desvio padrão, baixa correlação com as notas, importância alta (nota entre 8 e 10) para 13 de 23 alunos;
- (2) Conteúdos de texto: baixo desvio padrão, baixa correlação com as notas, importância alta (nota 8 a 10) para 13 dos 23 alunos;
- (3) Fóruns de discussão: baixo desvio padrão, baixa correlação com as notas, importância alta (nota 8 a 10) para apenas 7 dos 23 alunos.

Por fim, temos a distribuição das percepções dos alunos acerca do uso da metodologia de ensino híbrido na disciplina, com 11 dos 23 alunos respondendo com uma nota 8 de 10, conforme a figura a seguir (Figura 20):

Figura 20 - Respostas acerca da metodologia utilizada

Numa escala de 0 a 10, avalie o uso da metodologia de ensino híbrido na disciplina.

23 respostas



Fonte: Autor

A fim de compreender a autoavaliação em relação ao uso da metodologia de ensino híbrido, foi deixado um espaço em aberto no formulário destinado aos estudantes, proporcionando-lhes a oportunidade de expressar suas opiniões, sugerir melhorias e recomendar possíveis mudanças nos próximos cursos, com base em suas experiências ao longo da disciplina.

Abaixo, temos algumas sugestões apresentadas pelos alunos, que estão de acordo com os resultados encontrados ao longo do presente trabalho:

- *"Achei que neste semestre tiveram poucas atividades obrigatórias no AVA, acredito ser necessário mais atividades para melhor aprendizado da matéria."*
- *"Menos aulas presenciais, mais aulas online, mais aulas online gravadas."*
- *"Além dos materiais de leitura e vídeo-aulas, é interessante que haja exercícios propostos. É interessante que haja esses exercícios pois somente a leitura e assistir vídeos não consolidam tanto o conhecimento. A prática solidifica muito mais."*
- *"Conteúdos curtos e objetivos na parte online para a melhor fixação. Algumas matérias que adotam esse modelo acabam pecando muito nesse sentido, colocando atividades muito extensas por serem "online". Além disso, os prazos de entrega poderiam ser mais flexíveis, já que muitos alunos possuem problemas inesperados durante a entrega online, mas não tão flexíveis a ponto do aluno não fazer por "esquecer"."*

As percepções dos alunos revelam alguns pontos que estão em concordância com os resultados da análise. Por exemplo, quando os estudantes mencionam a necessidade de mais atividades no ambiente virtual de aprendizagem (AVA) para melhorar a compreensão da matéria, isso ressoa com a constatação de que a interação dos alunos no AVA estava abaixo da média em relação a outras variáveis.

Da mesma forma, a sugestão de mais aulas online gravadas reflete o desejo por conteúdos online mais curtos e objetivos, que foi destacado como benéfico no estudo. A ênfase na importância de exercícios propostos também se alinha com a descoberta de que o desempenho dos alunos nas questões da prova estava diretamente relacionado ao tempo investido na resolução dessas questões. No entanto, a sugestão de prazos de entrega mais flexíveis, embora compreensível, não foi abordada diretamente nos resultados da análise. Em resumo, as percepções dos alunos corroboram as descobertas do estudo, destacando áreas em que melhorias podem ser implementadas para aprimorar o processo de ensino-aprendizagem no contexto do curso híbrido.

Resumidamente, para uma análise abrangente do desempenho dos estudantes com base nas interações no curso híbrido, procedemos à coleta de dados provenientes dos logs do AVA RIEH, dados presenciais e as notas das provas fornecidas pelo professor. Após a coleta, esses dados foram submetidos a um processo de tratamento, resultando na construção de uma base de dados que registra as frequências das interações. Em seguida, empregamos métodos analíticos para determinar o número ideal de grupos e utilizamos o algoritmo K-Means para realizar um agrupamento dos alunos, levando em consideração suas notas como critério de diferenciação. Paralelamente a esses procedimentos, aplicamos um formulário de autoavaliação destinado aos estudantes, a fim de enriquecer os resultados da análise com percepções e sugestões valiosas para o aprimoramento contínuo de cursos híbridos.

## 7. CONCLUSÃO

A análise dos dados do AVA e das percepções dos estudantes ao longo deste estudo proporcionou uma visão abrangente das dinâmicas de ensino-aprendizagem no contexto do curso híbrido. As evidências revelaram uma variedade de perfis de estudantes com diferentes níveis de interação com os recursos disponíveis, frequência nas aulas presenciais e desempenho na avaliação da disciplina.

Ao comparar a diferença entre a frequência de interações com os conteúdos do AVA e a participação em sala de aula, foi possível constatar que os conteúdos do AVA foram pouco acessados pelos estudantes, principalmente os materiais de texto e o fórum de discussão. Diversos fatores podem ter influenciado tal comportamento, desde falta de incentivo ao uso do AVA, quantidade de conteúdos fornecidos por módulo, duração das videoaulas, entre outros. É necessário que os professores avaliem criteriosamente a maneira pela qual os recursos de aprendizagem são disponibilizados aos alunos e que cultivem uma comunicação contínua durante todo o período da disciplina, a fim de estimular ativamente o engajamento dos estudantes com esses materiais.

Com base nos *insights* obtidos através do estudo de caso, recomenda-se que nos próximos cursos sejam acrescentadas atividades com pontuação dentro do AVA e/ou checkpoints que pontuem a participação do aluno nas aulas. Dessa forma, teremos uma quantidade considerável de variáveis, aumento da quantidade e qualidade das interações dentro e fora do AVA e também será possível conduzir análises mais precisas e profundas acerca do desempenho ao longo do curso, monitorando, inclusive, em quais momentos o aluno esteve mais engajado com a disciplina, identificando possíveis evasões e permitindo também a criação de recomendações personalizadas de forma antecipada, auxiliando tanto o aluno quanto o professor.

As quatro hipóteses definidas inicialmente para o presente trabalho, puderam ser respondidas através do estudo de caso:

- **Hipótese 1:** Ao analisar a relação das variáveis com o comportamento dos estudantes entre os diferentes perfis de desempenho, notamos que tanto as interações presenciais como remotas, impactam nos resultados de aprendizagem.
- **Hipótese 2:** Foi possível gerar um agrupamento de estudantes com diferentes características e comportamentos no curso híbrido analisado.
- **Hipótese 3:** As recomendações personalizadas geradas trouxeram *insights* úteis para compreender a diferença de interações entre os tipos de estudantes e também sugestões de melhorias para construção de futuros cursos.

- **Hipótese 4:** O *feedback* obtido através do questionário de autoavaliação esteve bem alinhado com o estudo de caso, servindo como apoio aos *insights* gerados através dos dados e das recomendações personalizadas, enriquecendo os resultados do processo conduzido.

Então, os resultados obtidos no presente estudo, com destaque para o estudo de caso realizado, ampliam o debate acerca da forma que o ensino híbrido está sendo conduzido, sugerindo melhorias e adaptações na elaboração e condução dos cursos e mostrando a importância e necessidade da análise constante das características e comportamento dos estudantes, tanto nos momentos online como nos presenciais, para auxiliá-los no aprendizado e evitar possíveis evasões durante o curso/disciplina.

### 7.1. Limitações

O curso contou com apenas 3 tipos de conteúdos no AVA, as videoaulas, materiais de texto e os fóruns de discussão. Além disso, a frequência nas aulas presenciais teve um impacto bem maior no desempenho, e com isso, os alunos interagiram pouco no ambiente online, tendo uma quantidade reduzida de dados para analisar. Conforme as semanas foram avançando, as interações caíram gradativamente, principalmente após a realização da prova individual.

Além disso, o estudo teve sua análise limitada pela falta de alguns dados essenciais nos logs do AVA RIEH, como informações mais precisas do tempo gasto na plataforma e dentro de cada tipo de conteúdo, além dos dados em que foi preciso contatar o professor para realizar a coleta, pois só podiam ser acessados através do painel do tutor.

Vale ressaltar também que, após a primeira avaliação, através de uma prova dentro do AVA, o curso seguiu um outro método avaliativo, conduzindo trabalhos em grupo com apresentações e dinâmicas totalmente presenciais, impossibilitando a coleta e análise dos dados referentes à condução dessa segunda avaliação. Caso a disciplina tivesse seguido o mesmo método avaliativo para as duas notas, poderíamos gerar melhores resultados.

### 7.2. Trabalhos futuros

Em trabalhos futuros, propõe-se a coleta de dados de dois períodos seguidos de um curso que contenha mais conteúdos e métricas de acompanhamento do desempenho e também do engajamento do estudante, como o que foi sugerido anteriormente. Dessa forma, poderemos construir um algoritmo de previsão antecipada dos resultados finais dos estudantes, além de classificar os perfis de forma mais precisa com recomendações individualizadas.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Sun, P.-C.; Tsai, R.J.; Finger, G.; Chen, Y.-Y.; Yeh, D. What drives a successful e-Learning? An empirical investigation of the critical factors influencing learner satisfaction. *Comput. Educ.* 2008, 50, 1183–1202.
- [2] Hu, P.J.-H.; Hui, W. Examining the role of learning engagement in technology-mediated learning and its effects on learning effectiveness and satisfaction. *Decis. Support Syst.* 2012, 53, 782–792.
- [3] Kaup, S.; Jain, R.; Shivalli, S.; Pandey, S.; Kaup, S. Sustaining academics during COVID-19 pandemic: The role of online teaching-learning. *Indian J. Ophthalmol.* 2020, 68, 1220–1221.
- [4] Hebebcı, Mustafa & Bertiz, Yasemin & Alan, Selahattin. (2020). Investigation of Views of Students and Teachers on Distance Education Practices during the Coronavirus (COVID-19) Pandemic. *International Journal of Technology in Education and Science.* 4. 267-282. 10.46328/ijtes.v4i4.113.
- [5] Aristika, A., Darhim, Juandi, D., & Kusnandi, (2021). The Effectiveness of Hybrid Learning in Improving of Teacher-Student Relationship in Terms of Learning Motivation.
- [6] Rasheed, R.A.; Kamsin, A.; Abdullah, N.A. Challenges in the online component of blended learning: A systematic review. *Comput. Educ.* 2020, 144, 103701.
- [7] Dangwal, K.L. Blended learning: An innovative approach. *Univers. J. Educ. Res.* 2017, 5, 129–136
- [8] Garrison, D. R., & Vaughan, N. D. Blended learning in higher education: Framework, principles, and guidelines. (2008).
- [9] Tayebinik, Maryam, and Marlia Puteh. "Blended Learning or E-learning?." arXiv preprint arXiv:1306.4085 (2013).
- [10] Robin Castro. Blended learning in higher education: Trends and capabilities. *Education and Information Technologies* 24, 2523-2546 (2019).
- [11] Anthony, B., Kamaludin, A., Romli, A. et al. Blended Learning Adoption and Implementation in Higher Education: A Theoretical and Systematic Review. *Tech Know Learn* 27, 531–578 (2022).
- [12] Moore, M. G. Editorial: Three Types of Interaction. *American Journal of Distance Education*, 3, 1-7. (1989).

- [13] Bouhnik, Dan & Marcus, Tali. Interaction in distance-learning courses. *JASIST*. 57. 299-305. 10.1002/asi.20277. (2006).
- [14] Amirah Mohamed Shahiri et al. A Review on Predicting Student's Performance Using Data Mining Techniques. *Procedia Computer Science*, 72. (2015).
- [15] Dorina Kabakchieva. Predicting Student Performance by Using Data Mining Methods for Classification. *CYBERNETICS AND INFORMATION TECHNOLOGIES*, 13. (2013)
- [16] Arto Hellas, Petri Ihantola, Andrew Petersen, et al. Predicting academic performance: a systematic literature review. 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education. Association for Computing Machinery, New York, NY, USA, 175–199. (2018).
- [17] Susan M. Brookhart. *How to Give Effective Feedback to Your Students*, 2nd Edition. ASCD. (2017)
- [18] Anderson P. Cavalcanti, Arthur Barbosa, Dragan Gašević, et al. Automatic feedback in online learning environments: A systematic literature review. *Computers and Education: Artificial Intelligence*, 2. (2021)
- [19] Paudel, Pitambar. (2020). Online Education: Benefits, Challenges and Strategies During and After COVID-19 in Higher Education. *International Journal on Studies in Education*. 3. 70-85. 10.46328/ijonse.32.
- [20] Rossi, Dolene; van Rensburg, H; Beer, Colin; Clark, Damien; Danaher, Patrick; Harreveld, Roberta (2013). Learning interactions : a cross-institutional multi-disciplinary analysis of learner-learner and learner-teacher and learner-content interactions in online learning contexts. CQUniversity. Report. <https://hdl.handle.net/10018/1013373>.
- [21] Acassia dos Anjos Santos (2015). O moodle na educação superior à distância. *Anais do Congresso Nacional UEADSL*. ISSN 2317-0220
- [22] Khanal, S.S., Prasad, P., Alsadoon, A. et al. A systematic review: machine learning based recommendation systems for e-learning. *Educ Inf Technol* 25, 2635–2664 (2020). <https://doi.org/10.1007/s10639-019-10063-9>
- [23] Mueen, Ahmed & Zafar, Bassam & Manzoor, Umar. (2016). Modeling and Predicting Students' Academic Performance Using Data Mining Techniques. *International Journal of Modern Education and Computer Science*. 11. 36-42. 10.5815/ijmecs.2016.11.05.
- [24] Elbow Method - Yellowbrick v1.3.post1 documentation. (n.d.). Yellowbrick. <https://www.scikit-yb.org/en/latest/api/cluster/elbow.html>

[25] Silhouette Score - sklearn.metrics.silhouette\_score — scikit-learn 0.24.1 documentation. (n.d.). Scikit-Learn.Org.  
[https://scikit-learn.org/stable/modules/generated/sklearn.metrics.silhouette\\_score.html](https://scikit-learn.org/stable/modules/generated/sklearn.metrics.silhouette_score.html)

[26] Nespereira, Celia & El-hariri, Esraa & El-Bendary, Nashwa & Vilas, Ana & Díaz Redondo, Rebeca. (2016). Machine Learning Based Classification Approach for Predicting Students Performance in Blended Learning. 10.1007/978-3-319-26690-9\_5.

[27] Anh, Nguyen. (2017). The Impact of Online Learning Activities on Student Learning Outcome in Blended Learning Course. Journal of Information & Knowledge Management. 16. 10.1142/S021964921750040X.

## **APÊNDICE A - QUESTIONÁRIO DE AUTOAVALIAÇÃO DOS ESTUDANTES**

Cópia do formulário Google utilizado para coletar as informações de satisfação e a autoavaliação dos estudantes em relação ao curso:

- <https://forms.gle/2sJRFFnaABjmpTM5A>