

Desenvolvimento e avaliação de um dashboard para visualização de padrões sequenciais de aprendizagem.

José Thiago Torres da Silva, Samuel Henrique Santos Silva,
Raphael A. Dourado

¹Universidade de Pernambuco (UPE), campus Caruaru, 55.014-908 – Caruaru, PE

{thiago.torress, samuel.henrique, raphael.dourado}@upe.br

Abstract. *The research focuses on the challenges faced by distance education teachers, such as limited communication and the lack of visual tools to track student progress. The system uses Sequential Pattern Mining (SPM) to identify student behaviors on learning platforms, with the results being visualized in an interactive dashboard that allows for tracking metrics such as participation, interaction time, and grades, aiding in educational decision-making. The results were obtained through a usability evaluation, which pointed out necessary improvements in the system, such as better visual clarity and organization of functionalities. The article concludes that while the system is valuable, adjustments are still needed to enhance the user experience.*

Resumo. *A pesquisa foca nas dificuldades enfrentadas por professores de ensino a distância, como comunicação limitada e falta de ferramentas visuais para acompanhar o progresso dos alunos. O sistema utiliza mineração de padrões sequenciais (SPM) para identificar comportamentos dos alunos em plataformas de ensino, com os resultados sendo visualizados em um dashboard interativo que permite o acompanhamento de métricas como participação, tempo de interação e notas, auxiliando na tomada de decisões educacionais. Os resultados foram obtidos através de uma avaliação de usabilidade, que apontou melhorias necessárias no sistema, como maior clareza visual e organização das funcionalidades. O artigo conclui que, embora o sistema seja valioso, ainda precisa de ajustes para melhorar a experiência do usuário.*

1. Introdução

O avanço das tecnologias aplicadas à educação tem permitido a criação de novas ferramentas para o monitoramento do desempenho acadêmico em ambientes de ensino à distância [Nguyen et al. 2022]. Com o aumento da adoção de modalidades de ensino remoto, surgem desafios significativos para professores que precisam acompanhar de forma eficaz o progresso dos alunos. Dentre os principais obstáculos estão a comunicação limitada entre alunos e professores, a dificuldade em identificar rapidamente estudantes com baixo desempenho e a necessidade de ferramentas visuais que permitam um acompanhamento granular e em tempo real [Li et al. 2021].

Com a maior disponibilidade de dados relativos aos processos de ensino-aprendizagem, especialmente no ensino à distância, vem se desenvolvendo a área de pesquisa em Mineração de Dados Educacionais [Baker and Inventado 2014]. Esta área preocupa-se principalmente em desenvolver métodos para explorar as características

únicas dos dados coletados em ambientes educacionais e utilizar métodos de mineração de dados para entender o comportamento dos estudantes e as circunstâncias em que ocorre a aprendizagem.

Uma das tarefas analíticas que podem ser utilizadas na Mineração de Dados Educacionais é a Mineração de Padrões Sequenciais, ou SPM (do inglês *Sequential Pattern Mining*) [Zhang and Paquette 2023, Fournier-Viger et al. 2017]. Este tipo de análise tem por objetivo identificar padrões temporais comuns nas trajetórias de aprendizagem dos estudantes, o que podem revelar estratégias desejáveis ou indesejáveis, auxiliando professores a compreender melhor o processo de aprendizagem de seus alunos e intervir para aprimorar este processo [Zhang and Paquette 2023].

No entanto, uma vez minerados, é preciso que estes padrões sejam apresentados aos professores de forma simples e intuitiva, de modo a auxiliá-los na sua compreensão e no processo de tomada de decisão. Para isso, uma das alternativas é o uso de visualizações de dados agrupadas no formato de *Learning Analytics Dashboards* (LADs) [Verbert et al. 2020, Schwendimann et al. 2017], que são painéis interativos para exploração de dados educacionais que podem auxiliar professores, alunos e gestores na análise e compreensão destes dados.

Embora existam na literatura diversas propostas de *dashboards* educacionais [Schwendimann et al. 2017], há uma carência de trabalhos focados na visualização de padrões sequenciais, que possuem características especiais [Guo et al. 2020]. Assim, este trabalho apresenta o processo de especificação, prototipação, implementação e avaliação de um *dashboard* para visualização de padrões de aprendizagem detectados por algoritmos de Mineração de Padrões Sequenciais. A base de dados utilizada neste trabalho é proveniente de pesquisas anteriores dos mesmos autores, cujos detalhes estão descritos em [referência omitida para revisão].

O restante do texto está organizado da seguinte forma: a Seção 2 descreve o método utilizado para concepção, desenvolvimento e avaliação da ferramenta; a Seção 3 apresenta os resultados obtidos; e por fim a Seção 4 reporta as conclusões, limitações e trabalhos futuros.

2. Metodologia

O presente capítulo de Metodologia descreve em detalhes o processo adotado para a concepção, desenvolvimento e avaliação de um *dashboard* para visualização de padrões sequenciais de aprendizagem de alunos em ambientes de ensino à distância. A metodologia aqui apresentada foi desenhada para garantir que as necessidades e desafios identificados pelos professores fossem analisados e considerados no projeto do protótipo.

2.1. Identificação de Requisitos de Usuário, Dados e Tarefas

Para identificar as necessidades e requisitos para a ferramenta a ser desenvolvida, foi adotado o método de entrevistas semi-estruturadas com as partes interessadas. Essa escolha foi motivada pela necessidade de explorar as percepções e desafios enfrentados pelos professores universitários em relação ao acompanhamento de alunos em modalidades online. O público-alvo das entrevistas incluiu cinco professores universitários, todos com grau de doutor ou mestre e que atualmente dão aula em um curso de Sistemas de

Informação, e com experiência em ensino remoto, especialmente em disciplinas práticas, como programação.

As entrevistas seguiram um formato semi-estruturado, de modo a permitir aos entrevistados fornecerem respostas ricas e detalhadas. Durante as conversas, foram abordados os principais desafios na análise do desempenho acadêmico dos alunos, focando principalmente nas limitações das ferramentas atuais, dificuldades de comunicação e identificação de estudantes com desempenho abaixo do esperado.

O roteiro das perguntas foi:

1. Você tem alguma experiência com ensino a distância?
2. Ao aplicar aulas remotas, você tinha alguma forma de acompanhar o desempenho da turma?
3. E para o desempenho individual de cada aluno, tinha como acompanhar ao longo das aulas?
4. Você tinha alguma forma de saber se existiam alunos com dificuldades para entender as aulas?
5. De que forma você acompanhava a frequência dos alunos em suas aulas?
6. Você tinha alguma forma de garantir que os alunos não faziam uso de recursos externos durante avaliações que valiam pontuação?

Os dados coletados foram registrados em formato de notas de campo e gravações de áudio, mediante consentimento dos entrevistados. Após a coleta, os dados foram transcritos e analisados qualitativamente com o intuito de identificar padrões comuns nas respostas e demandas mais citadas pelos professores.

Para a análise dos dados, foi utilizada a técnica de análise temática [Braun and Clarke 2012], que visa identificar temas recorrentes nas respostas dos entrevistados. A partir dessas entrevistas, foram determinados os requisitos iniciais do sistema a ser desenvolvido, conforme será descrito na Seção 3.

Com base nas necessidades identificadas e estudo da base de dados utilizada no projeto, foi elaborada uma lista de atributos que compõem os dados necessários para a análise do desempenho dos alunos, bem como uma lista de tarefas analíticas que deveriam ser suportadas pelo *dashboard*. Para esta etapa, os dados e tarefas de domínio foram mapeados a descrições abstratas, conforme recomendado por Munzner [Munzner 2009].

2.2. Prototipagem de Baixo Nível

Nesta etapa, foram desenvolvidos os protótipos de baixo nível (Figura 1), ou seja, representações visuais preliminares para avaliar as interações e funcionalidades propostas. Na Tabela 1 estão detalhadas as representações visuais escolhidas para serem implementadas.

Esse protótipo foi projetado com o intuito de verificar se os gráficos pensados poderiam ser visualizados de maneira eficaz junto aos dados coletados para atender às tarefas analíticas delineadas anteriormente. Eles foram avaliados por um professor com experiência em ensino à distância, o qual sugeriu alterações que levaram os autores a pensar em novas formas de adaptar o protótipo para atender de melhor forma os requisitos identificados.

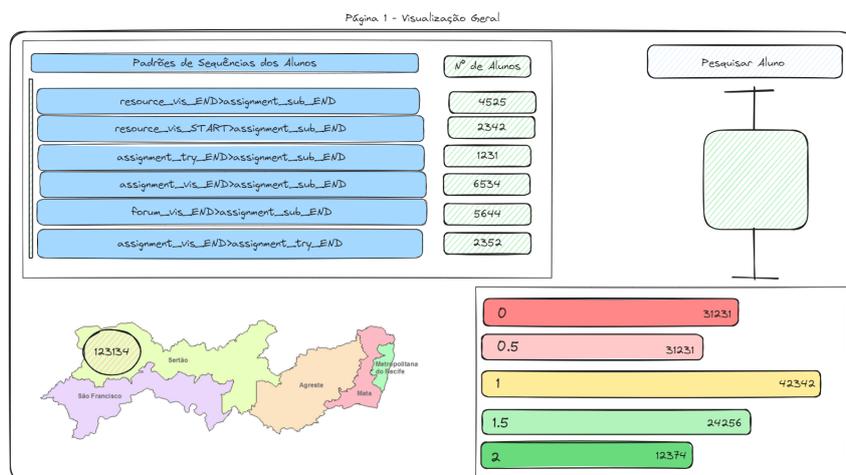


Figura 1. Protótipo de Baixo Nível

Representação Visual	Tarefa(s) associadas
Tabela demonstrando os padrões de sequências dos alunos e o número de alunos para cada padrão e poder filtrar o <i>dashboard</i> a partir dessas sequências	Avaliar impacto de intervenções educacionais, Monitorar desempenho acadêmico geral
<i>Boxplot</i> marcando onde o aluno selecionado se encontra	Detectar necessidades de suporte individualizado

Tabela 1. Representações Visuais de Baixo Nível

2.3. Prototipagem de Alto Nível

Após as fases iniciais de identificação de requisitos e prototipagem de baixo nível, a prototipagem de alto nível foi conduzida com o objetivo de refinar as representações visuais implementadas e melhorar a usabilidade do sistema. A principal finalidade desta etapa foi desenvolver visualizações que fossem intuitivas e que pudessem auxiliar os professores a realizar tarefas analíticas específicas, focando no monitoramento e análise do desempenho dos alunos em atividades a distância.

As representações visuais foram integradas em um *dashboard* interativo, implementado utilizando a plataforma PowerBi, onde os professores podem explorar os dados e aplicar filtros personalizados para realizar suas análises. Esse *dashboard* foi desenvolvido com foco na usabilidade, permitindo uma navegação simples e eficiente entre as diferentes visualizações.

2.4. Avaliação de Usabilidade

Após o desenvolvimento do protótipo de alto nível, uma rodada de avaliações de usabilidade foi conduzida. Quatro (4) usuários, professores e monitores universitários, testaram o *dashboard*, fornecendo *feedback* sobre a eficácia das representações visuais e a utilidade das funcionalidades. A avaliação teve como foco analisar os seguintes fatores:

- Facilidade de uso: Os gráficos e tabelas foram fáceis de interpretar e utilizar?
- Eficiência nas tarefas: O sistema permitiu que os professores realizassem as análises com rapidez e precisão?

- Relevância das informações: As representações visuais forneceram informações valiosas sobre o desempenho dos alunos?

Para isso, foi definido um protocolo tarefas que os usuários deveriam realizar no *dashboard* durante a avaliação. O protocolo consistiu em cinco tarefas, listadas abaixo:

1. Identificar as cinco sequências de ações mais populares entre os alunos.
2. Identificar as sequências que demandaram mais tempo para serem concluídas.
3. Visualizar as sequências de ações de alunos com notas superiores a 1,45.
4. Identificar a cidade com maior concentração de alunos, utilizando um gráfico de mapa.
5. Realizar análises de desempenho geral a partir de dados filtrados.

A coleta de dados durante a avaliação foi realizada através de gravação de tela e áudio, registrando as interações dos participantes com o sistema, capturando tanto a navegação quanto os comentários em tempo real. Ao final de cada sessão, foi solicitado aos participantes que expressem verbalmente sua opinião sobre a experiência de uso, com foco na facilidade de uso, clareza das informações e satisfação geral com a ferramenta.

3. Resultados

Nesta seção, são apresentados os resultados obtidos neste estudo, incluindo os requisitos de usuário, dados e tarefas identificados, a ferramenta desenvolvida, e os resultados da avaliação do protótipo de alto nível.

3.1. Requisitos identificados

A partir das entrevistas com os professores, foram identificados três requisitos principais:

1. Falta de comunicação eficaz: um dos principais desafios relatados foi a dificuldade que muitos alunos têm em solicitar ajuda ou acessar os canais de apoio disponíveis nas plataformas de ensino a distância. A ausência de interação face a face dificulta ainda mais a identificação de alunos que se mostram hesitantes em participar ativamente, sobretudo os mais tímidos.
2. Dificuldade em identificar alunos com baixo desempenho: os professores relataram que, em disciplinas como programação, há uma maior complexidade em acompanhar o progresso individual dos alunos. Isso se agrava pela falta de indicadores claros e em tempo real que permitam identificar rapidamente os alunos que estão tendo dificuldades.
3. Necessidade de visualização do desempenho por atividade: os professores expressaram o desejo de ter ferramentas que lhes permitissem visualizar o desempenho dos alunos de forma granular, identificando quais tópicos ou atividades apresentam maior dificuldade para a turma. Isso permitiria a realização de aulas de revisão focadas e a alocação de recursos de monitoria de maneira mais eficaz.

A partir destes requisitos de usuário, foram definidos que atributos da base poderiam ser utilizados para a construção das visualizações. A Tabela 2 lista os atributos escolhidos e suas respectivas descrições, além de sua classificação em termos de tipo abstrato de dados, conforme recomendado em [Munzner 2014].

A partir da definição desses atributos, foram delineadas as principais tarefas analíticas que o sistema deverá permitir, conforme detalhado na Tabela 3. Essas tarefas visam cobrir os principais desafios relatados pelos professores e fornecer soluções que melhorem a comunicação e a identificação de dificuldades durante o ensino à distância.

Nome do Atributo	Descrição	Tipo Abstrato	Domínio
NOME_ALUNO	Nome do aluno	Catagórico	[Strings]
NOTA	Nota do aluno na disciplina	Quantitativo	[0, 10]
LOCAL	Cidade do aluno	Catagórico	[Strings]
PARTICIPACAO	Frequência de participação em atividades	Quantitativo	[0, 100]
TEMP_OCORR	Tempo decorrido até a realização da atividade	Quantitativo	[Inteiros, Dias]

Tabela 2. Atributos Identificados

Tarefa	Atributo(s) envolvido(s)
Monitorar desempenho acadêmico geral	NOME_ALUNO, NOTA, PARTICIPACAO, LOCAL
Identificar alunos com desempenho abaixo do esperado	NOME_ALUNO, NOTA
Avaliar impacto de intervenções educacionais	NOME_ALUNO, NOTA, PARTICIPACAO
Detectar necessidades de suporte individualizado	NOME_ALUNO, NOTA, PARTICIPACAO, LOCAL
Visualizar desempenho por atividade	NOME_ALUNO, NOTA, PARTICIPACAO

Tabela 3. Tarefas Analíticas Identificadas

3.2. Ferramenta desenvolvida

A Figura 2 apresenta a versão final da ferramenta desenvolvida. Foram selecionadas e desenvolvidas três representações visuais com o objetivo oferecer uma visão clara e acessível sobre os padrões de comportamento dos alunos e seu desempenho em diversas atividades. A Tabela 3 descreve as representações visuais escolhidas e as tarefas analíticas associadas a cada uma delas.

Nas subseções a seguir, cada uma das representações visuais é apresentada em detalhes.

3.2.1. Gráfico de bolhas

A primeira representação visual desenvolvida é o Gráfico de Bolhas que tem por objetivo permitir avaliar a correlação entre o tempo que os alunos gastam no sistema e suas notas em atividades específicas. Cada bolha reflete um grupo de alunos que teve resultados similares, sendo seu eixo x a nota média dos alunos e o eixo y o total de tempo despendido pelos alunos.

Este gráfico foi pensado para permitir uma análise mais detalhada do compor-

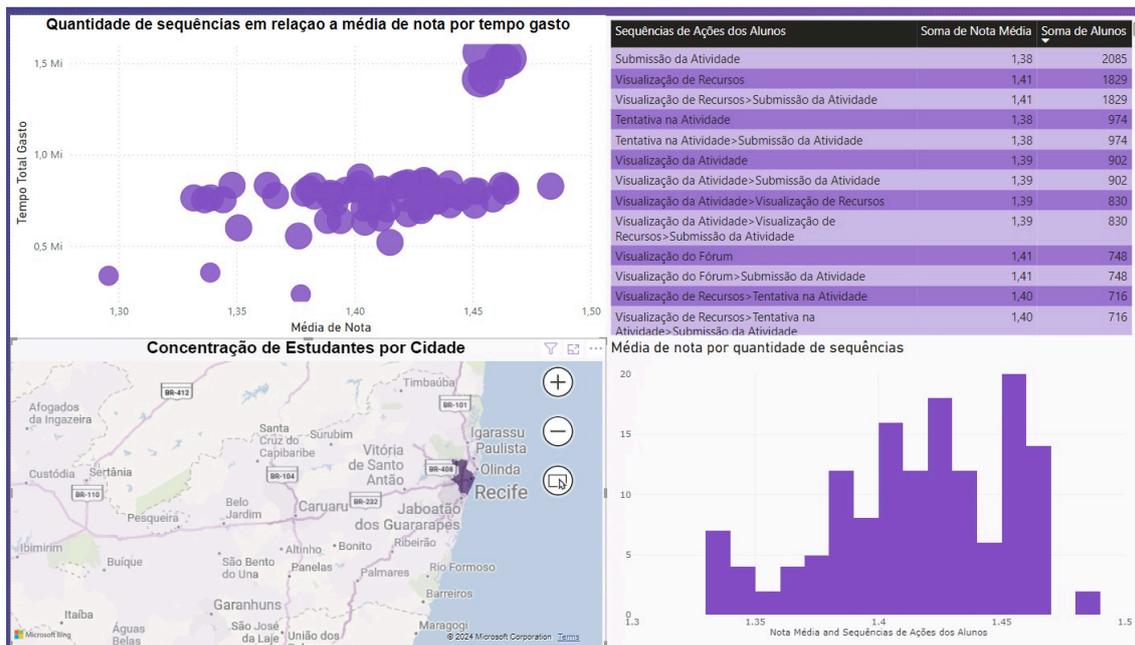


Figura 2. Protótipo de Alto Nível

tamento dos alunos em relação ao desempenho acadêmico, atendendo a duas tarefas analíticas principais: monitorar o desempenho acadêmico geral e avaliar o impacto de intervenções educacionais.

3.2.2. Tabela de Padrões de Sequência de Ações dos Alunos

Outra representação visual importante é uma tabela que mostra os padrões de sequência de ações realizadas pelos alunos ao longo de suas atividades, conforme identificado por um algoritmo de SPM. Essa tabela permite que os professores filtrem os dados de acordo com diferentes sequências de ações, possibilitando uma visão clara de como os alunos estão se comportando em relação ao tempo de realização das atividades, participação, e

Representação Visual	Tarefa(s) associadas
Tabela demonstrando os padrões de sequências dos alunos e o número de alunos para cada padrão e poder filtrar o <i>dashboard</i> a partir dessas sequências	Avaliar impacto de intervenções educacionais, Monitorar desempenho acadêmico geral
Histograma demonstrando a quantidade de sequências para cada nota	Monitorar desempenho acadêmico geral, identificar alunos com desempenho abaixo do esperado
Mapa de calor dos alunos por cidade	Monitorar desempenho acadêmico geral
Gráfico de bolhas demonstrando o tempo desempenhado dos alunos no sistema em relação a nota na atividade	Avaliar impacto de intervenções educacionais, Monitorar desempenho acadêmico geral

Tabela 4. Representações Visuais de Alto Nível

notas obtidas.

Essa tabela pode ser particularmente útil para a tarefa de avaliar o impacto de intervenções educacionais, pois permite observar se os alunos alteram seus padrões de comportamento após a implementação de novas estratégias pedagógicas. Além disso, auxilia no monitoramento do desempenho acadêmico geral, oferecendo uma visão ampla sobre como as ações dos alunos se refletem em seu desempenho.

3.2.3. Mapa de calor dos alunos por cidade

O mapa de calor permite visualizar a distribuição geográfica dos alunos, representando diferentes regiões com intensidade de cores que variam de acordo com a concentração de estudantes.

Essa visualização pode ser útil para monitorar o desempenho acadêmico geral dos alunos em diferentes localidades. Por exemplo, se uma cidade apresenta um maior número de alunos com desempenho abaixo do esperado, o mapa de calor pode destacar essa região, permitindo que o professor identifique possíveis padrões geográficos que influenciam o aprendizado.

3.2.4. Histograma de Sequências por Nota

Mais uma representação visual é o histograma que mostra a quantidade de sequências de ações realizadas pelos alunos em relação às suas notas. Esse gráfico oferece uma visão agregada sobre como as ações dos alunos estão correlacionadas com as notas finais, facilitando a tarefa de monitorar o desempenho acadêmico geral.

Essa visualização permite aos professores identificar faixas de notas que estão associadas a comportamentos específicos, o que pode indicar a necessidade de intervenção em casos de baixo desempenho ou dispersão em atividades. A análise dessas informações possibilita a criação de estratégias mais direcionadas para melhorar o aprendizado.

3.3. Avaliação da ferramenta

Nesta seção são descritos os resultados da avaliação conduzida com o *dashboard* desenvolvido. Estes resultados foram divididos em desempenho nas tarefas e sugestões de melhoria, reportados nas subseções a seguir.

3.3.1. Desempenho dos Usuários nas Tarefas

Os participantes tiveram diferentes níveis de sucesso na execução das tarefas propostas. Na Tarefa 1, que envolvia a ordenação de uma tabela pela quantidade de usuários, dois dos participantes (Usuários A e B) não conseguiram completá-la corretamente. O erro foi relacionado à dificuldade em localizar a funcionalidade de ordenação na interface da tabela, o que indica uma necessidade de maior clareza nos controles de ordenação.

Na Tarefa 2, que era relacionada ao gráfico de bolhas, um dos participantes (Usuário A) relatou dificuldade em compreender as informações apresentadas.

Essa dificuldade pode estar associada à complexidade visual do gráfico ou à falta de contextualização das informações, sugerindo a necessidade de aprimoramento na apresentação dos dados.

A Tarefa 3 foi particularmente reveladora, pois nenhum dos participantes utilizou o gráfico de histograma para concluir a análise. Isso sugere que o gráfico não foi considerado útil ou não estava devidamente destacado no *layout* do *dashboard*, levando os participantes a ignorá-lo completamente.

3.3.2. Sugestões e Pontos de Melhoria

Com base nos erros cometidos e no *feedback* obtido dos participantes ao final das sessões de avaliação, foram identificados alguns pontos de melhoria para garantir uma melhor usabilidade do sistema em uma versão futura:

- Adicionar um botão para redefinir o gráfico para o estado inicial: Os usuários indicaram que seria útil ter uma funcionalidade de "reset" nos gráficos, que permitisse retornar rapidamente à visualização original após a aplicação de filtros ou interações.
- Destaque visual no gráfico de mapa: Foi sugerido que o gráfico de mapa, que mostra a distribuição de alunos por região, fosse ajustado para ser bicolor, proporcionando maior contraste e destaque nas áreas com maior concentração de alunos. Isso ajudaria a facilitar a visualização de dados mais relevantes.
- Sinalização mais clara dos controles de ordenação na tabela: Um ponto comum de dificuldade foi a localização dos controles de ordenação. Melhorar a sinalização ou adicionar indicadores mais evidentes nos cabeçalhos da tabela pode ajudar os usuários a identificar rapidamente essa funcionalidade.
- Maior destaque para o gráfico "Média de nota por quantidade de sequências": Como nenhum usuário utilizou esse gráfico, é necessário aumentar seu destaque visual ou reconsiderar seu posicionamento no *dashboard*. Isso pode ser feito melhorando seu design, ou apresentando uma breve explicação sobre sua importância no contexto da análise de desempenho.

4. Conclusão e Trabalhos Futuros

Este trabalho apresentou o processo de concepção, desenvolvimento e avaliação de um dashboard para visualização de padrões sequenciais de aprendizagem. A avaliação de usabilidade do mesmo revelou que, embora o protótipo apresente funcionalidades consideradas úteis para o monitoramento do desempenho dos alunos, algumas áreas ainda precisam de ajustes para garantir que os usuários possam utilizá-lo de maneira eficiente e sem frustrações. A dificuldade de alguns usuários em completar as tarefas propostas aponta para a necessidade de melhorias na clareza visual e na disposição dos controles e gráficos. Além disso, a ausência de utilização de certas funcionalidades, como no histograma de sequências por nota, sugere que é necessário repensar a forma como essas visualizações são introduzidas e destacadas na interface, para garantir que os professores as vejam como elementos úteis no processo de análise. Essas sugestões serão consideradas nas próximas iterações do protótipo, com o objetivo de aprimorar a experiência do usuário e tornar o sistema mais intuitivo, acessível e eficaz.

5. Agradecimentos

José Thiago Torres da Silva possui bolsa de Iniciação Científica financiada pelo programa UPE-PFA (Edital ICTI 2023, processo P00226/S00226).

Referências

- Baker, R. S. and Inventado, P. S. (2014). Educational data mining and learning analytics. In Larusson, J. A. and White, B., editors, *Learning Analytics: From Research to Practice*, pages 61–75. Springer New York, New York, NY.
- Braun, V. and Clarke, V. (2012). Thematic analysis. In *APA handbook of research methods in psychology, Vol 2: Research designs: Quantitative, qualitative, neuropsychological, and biological*, APA handbooks in psychology®, pages 57–71. American Psychological Association.
- Fournier-Viger, P., Lin, J. C.-W., Kiran, R. U., and Koh, Y. S. (2017). A survey of sequential pattern mining. *Data Science and Pattern Recognition*, 1(1):54–77.
- Guo, Y., Guo, S., Jin, Z., Kaul, S., Gotz, D., and Cao, N. (2020). Survey on visual analysis of event sequence data.
- Li, Q., Jung, Y., and Friend Wise, A. (2021). Beyond first encounters with analytics: Questions, techniques and challenges in instructors’ sensemaking. In *LAK21: 11th International Learning Analytics and Knowledge Conference*, LAK21, page 344–353, New York, NY, USA. Association for Computing Machinery.
- Munzner, T. (2009). A nested model for visualization design and validation. *IEEE Transactions on Visualization and Computer Graphics*, 15(6):921–928.
- Munzner, T. (2014). *Visualization analysis & design*. AK Peters/CRC Press. OCLC: 904266418.
- Nguyen, Q., Rienties, B., and Whitelock, D. (2022). Informing learning design in online education using learning analytics of student engagement. In *Open World Learning*. Routledge. Num Pages: 19.
- Schwendimann, B. A., Rodríguez-Triana, M. J., Vozniuk, A., Prieto, L. P., Boroujeni, M. S., Holzer, A., Gillet, D., and Dillenbourg, P. (2017). Perceiving learning at a glance: A systematic literature review of learning dashboard research. *IEEE Transactions on Learning Technologies*, 10(1):30–41.
- Verbert, K., Ochoa, X., De Croon, R., Dourado, R. A., and De Laet, T. (2020). Learning analytics dashboards: the past, the present and the future. In *Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, LAK ’20, pages 35–40. Association for Computing Machinery.
- Zhang, Y. and Paquette, L. (2023). Sequential pattern mining in educational data: The application context, potential, strengths, and limitations. In Peña-Ayala, A., editor, *Educational Data Science: Essentials, Approaches, and Tendencies: Proactive Education based on Empirical Big Data Evidence*, pages 219–254. Springer Nature.