

Captura e Visualização das Trajetórias de Aprendizagem como Ferramentas para a Análise do Comportamento dos Estudantes em um Ambiente Adaptativo Educacional

Êrica Peters do Carmo¹, Isabela Gasparini¹, Elaine Harada Teixeira de Oliveira²

¹Depto de Ciência da Computação - Universidade do Estado de Santa Catarina (UDESC)

²Instituto de Computação - Universidade Federal do Amazonas (UFAM)

ericapetersc@gmail.com, isabela.gasparini@udesc.br, elaine@icompu.ufam.edu.br

Abstract. *Adaptive educational environments collect users data to adapt to their characteristics. One of these data represents the users' interaction with educational resources and it is related to the concept of learning trajectories. This work aims to use students' trajectories of a mini-course of algorithms and programming logic to analyze their navigational pattern. Thus, from the data of the students, their trajectories were captured and represented visually. The results show that students prefer to perform linear navigation based on concepts. However, it has not yet been possible to draw a relationship between the educational resources accessed by students and their performance.*

Resumo. *Ambientes adaptativos educacionais coletam dados dos usuários para se adaptarem de acordo com suas características. Um desses dados representa a interação dos usuários com os recursos educacionais e está relacionado ao conceito de trajetórias de aprendizagem. Este trabalho tem como objetivo utilizar as trajetórias dos estudantes de um minicurso de algoritmos e lógica de programação para analisar o seu padrão navegacional. Assim, a partir dos dados dos estudantes, suas trajetórias foram capturadas e representadas visualmente. Os resultados obtidos mostram que os estudantes preferem realizar uma navegação linear baseada em conceitos. Contudo, ainda não foi possível traçar uma relação entre os recursos educacionais acessados pelos estudantes e seu desempenho.*

1. Introdução

A partir da popularização da Internet como ferramenta de comunicação e compartilhamento de conteúdo, tornou-se necessário o desenvolvimento de sistemas virtuais capazes de se adaptar às necessidades e preferências dos usuários. Nesse cenário, surgiram os Sistemas Adaptativos, ambientes virtuais que constroem um modelo baseado em objetivos, preferências e conhecimentos do usuário através da sua interação e utilizam-no para se adaptar às suas características individuais [Brusilovsky 1996].

Quando aplicados à Educação, esses sistemas procuram adaptar-se ao perfil de cada estudante e têm como objetivo auxiliá-lo na aquisição de conhecimento sobre determinado assunto ou disciplina. Para tornar possível essa adaptação, os sistemas coletam diversos dados a partir da interação do estudante com o ambiente, como por exemplo, a maneira com que ele navega pelos recursos educacionais disponíveis.

Define-se essa navegação como o caminho percorrido pelos usuários e formado pelo conjunto de passos dados ao interagir com o ambiente. Este caminho, por sua vez, está associado ao conceito de trajetória (ou trilha) de aprendizagem [de Oliveira et al. 2014]. Nota-se ainda que a identificação de padrões relacionados a essas trajetórias pode ser aplicada na análise do comportamento dos estudantes e do ambiente educacional como um todo.

Nesse sentido, este trabalho tem como objetivo realizar a captura e visualização das trajetórias de aprendizagem de estudantes ao interagir com um minicurso de algoritmos e linguagem de programação em um sistema adaptativo na Web, de modo a analisar os tipos de recursos educacionais mais acessados, o tipo de caminho mais percorrido (linear ou não linear), as trajetórias mais frequentes e a relação entre o comportamento navegacional dos estudantes e seus desempenhos na avaliação final. Com esse intuito, foram coletados dados de diversas edições do minicurso (2015, 2016, 2017 e 2018) e dos estudantes envolvidos (com diferentes formações). A partir desses dados foram utilizados o algoritmo *Generalized Sequential Pattern* de *Sequential Pattern Mining* (SPM) para a mineração dos padrões de navegação e o modelo proposto por [Ramos et al. 2017a] para a representação visual das trajetórias de aprendizagem na forma de grafos direcionados.

Quanto à estrutura deste artigo, a seção 2 apresenta a fundamentação de trajetórias de aprendizagem e trabalhos relacionados que as utilizaram no meio educacional. A seção 3 detalha a metodologia aplicada no desenvolvimento do trabalho e a seção 4 explora os resultados obtidos. Na seção 5, encontram-se as considerações finais.

2. Trajetórias de Aprendizagem

Diversos termos são utilizados em trabalhos relacionados para referirem-se às trajetórias de aprendizagem, sendo esses os mais frequentes: padrões de navegação, comportamentos navegacionais ou trilhas de aprendizagem. Contudo, todos esses termos dizem respeito ao mesmo conceito, o caminho formado pelo conjunto de passos que um estudante realiza ao interagir com um ambiente virtual de ensino [de Oliveira et al. 2014].

Cada um desses passos representa a interação do estudante com algum dos recursos educacionais presentes no ambiente. Assim, a captura das trajetórias de aprendizagem normalmente é realizada através de técnicas de *Web Analytics* capazes de extrair, medir e monitorar os acessos dos estudantes aos recursos disponíveis.

Uma vez extraídos, esses dados podem ser submetidos a diferentes técnicas de análise, sendo a *Sequential Pattern Mining* a mais comum [de Borba et al. 2016]. Essa técnica é utilizada para minerar padrões sequenciais e torna possível, por exemplo, encontrar quais são as trajetórias mais percorridas por estudantes em um determinado ambiente.

A partir disso, entende-se que as trajetórias de aprendizagem podem ser utilizadas como forma de auxiliar diversos aspectos no processo de ensino-aprendizagem. No que diz respeito aos estudantes, a obtenção das trajetórias mais percorridas pode ser utilizada na recomendação de recursos educacionais e no entendimento do seu comportamento [de Borba e Gasparini 2015]. Já em relação aos professores, a visualização das trajetórias pode auxiliar na compreensão do processo de aprendizagem da turma ou de cada estudante individualmente, e na identificação de possíveis dificuldades neste processo [Moissa et al. 2014]. Assim, destaca-se a importância da utilização das trajetórias de aprendizagem como ferramenta de análise e apoio no âmbito educacional.

Nesse cenário, diversas pesquisas têm sido realizadas com o objetivo de identificar e analisar os padrões de trajetórias de aprendizagem formadas por estudantes dentro de ambientes virtuais de ensino.

O trabalho de Romero et al. [2008], por exemplo, descreve uma ferramenta desenvolvida para a captura e visualização das trajetórias de aprendizagem percorridas pelos estudantes em um sistema educacional na Web. Para sua utilização, o usuário deve fornecer os dados do log dos estudantes que interagiram com a plataforma de ensino, e a partir disso torna-se possível utilizar os algoritmos de *Web Data Mining* implementados na ferramenta para gerar os padrões de navegação. Após a mineração desses padrões, eles são apresentados como um grafo direcionado onde os vértices representam as páginas hipertexto e as arestas representam os links entre elas. Como resultado, os professores podem visualizar e compreender as trajetórias percorridas por seus estudantes em um ambiente virtual de ensino.

Já o trabalho de Poon et al. [2017], propõe a utilização de *Data Mining* e técnicas de visualização para tornar os padrões de navegação mais compreensíveis e mostrar como estes podem ser utilizados na área de *Learning Analytics*. Com este intuito, os autores aplicaram SPM nos dados de log de estudantes matriculados em um curso do Moodle e a partir disto, obtiveram as trajetórias de aprendizagem mais frequentes. Para facilitar o entendimento desses dados, foram realizadas as representações visuais dos padrões em forma de clusterização hierárquica e gráfico de explosão solar. Como resultado, Poon et al. [2017] apresentam uma maneira efetiva de capturar e representar os dados relacionados aos padrões de comportamento navegacional dentro de um ambiente virtual de ensino e mostram como esses dados podem ser melhor utilizados para a compreensão e otimização destes ambientes.

Assim como o trabalho anterior, Ramos et al. [2017a] também abordam a representação visual das trajetórias de aprendizagem. Os autores apresentam um novo modelo de visualização no formato de um grafo direcionado, onde os vértices representam os recursos e as atividades educacionais presentes no ambiente, e as arestas representam a navegação dos estudantes ao percorrerem estes recursos. Para a análise dos dados obtidos a partir do modelo, foram utilizadas teoria dos grafos, técnicas de mineração de dados e aprendizagem de máquina. Os autores também mencionam duas ferramentas utilizadas no trabalho: Learning Path Graph de [Ramos et al. 2016] que gera o modelo de visualização proposto e Moodle Cluster de [Ramos et al. 2017b] que utiliza os dados deste modelo para sugerir grupos de estudantes para atividades colaborativas. Assim, o experimento realizado pelos autores com uma turma de um curso à distância de Informática Aplicada mostra que é possível utilizar o modelo de visualização apresentado para análises de comportamento dos estudantes, predição de reprovação escolar e formação de grupos.

No que diz respeito à relação entre o comportamento navegacional dos estudantes e seu processo de aprendizagem, o trabalho de de Souza et al. [2018] destaca-se. Os autores investigam o comportamento de estudantes dentro de um *Massive Open Online Course* e destacam dois tipos de trajetórias: a linear, uma navegação que segue a sequência projetada pelo curso, e a não linear, uma navegação que não segue essa mesma sequência. Assim, o trabalho tem como objetivo verificar se a trajetória (linear ou não linear) percorrida pelos estudantes tem relação com o seu desempenho ao concluir o curso. Através da manipulação do registro de log dos estudantes, conclui-se que a maior parte

deles segue uma trajetória não linear. Porém, essa análise não considera a conclusão das atividades complementares no caminho navegado. Outro resultado também mostra que o grupo de estudantes que seguiu uma trajetória linear obteve um melhor desempenho em relação ao grupo não linear.

É possível fazer um comparativo entre este trabalho e os trabalhos citados anteriormente. Nota-se que o presente trabalho tem semelhanças com os trabalhos relacionados na utilização de SPM como técnica de análise e na representação visual das trajetórias em formato de grafo. Entretanto, este trabalho difere-se dos demais ao utilizar dados coletados tanto a partir da captura quanto da representação visual das trajetórias de aprendizagem de estudantes de diferentes cursos matriculados em um minicurso de algoritmos e linguagem de programação em diferentes semestres. Entre as análises realizadas neste trabalho estão: a identificação dos tipos de recursos educacionais mais acessados, o tipo de caminho mais percorrido (linear ou não linear), a obtenção das trajetórias mais frequentes e a relação entre o comportamento navegacional dos estudantes e o seu desempenho.

3. Metodologia

O ambiente virtual de aprendizagem utilizado neste trabalho para a extração dos dados referente às trajetórias dos estudantes foi o AdaptWeb, um ambiente adaptativo de ensino na Web capaz de adaptar seu conteúdo, apresentação e navegação de acordo com as preferências e características do usuário.

A obtenção dos dados consistiu na extração dos registros log de estudantes concluintes (estudantes que realizaram a avaliação final) de turmas já encerradas que participaram de um minicurso de algoritmos e linguagem de programação em cinco semestres diferentes. Em todos os semestres, esse minicurso foi disponibilizado para estudantes dos seguintes cursos de graduação: Ciência da Computação, Tecnologia em Análise e Desenvolvimento de Sistemas (TADS), Engenharia Elétrica, Engenharia Civil, Engenharia Mecânica, Engenharia da Produção, Matemática e Física.

A estrutura do AdaptWeb é formado por quatro tipos de recursos educacionais. O recurso principal, formado por explicações textuais, é do tipo conceito. Cada conceito pode estar ou não ligado a três outros tipos de recursos: exercício, exemplo e material complementar, que caracterizam-se como recursos extras.

Tabela 1. Dados do minicurso aplicado em cada semestre

Semestre	2015/2	2016/1	2016/2	2017/1	2018/1
Data de início	27/11/2015	02/05/16	01/09/2016	29/05/2017	16/04/2018
Data de término	07/12/2015	28/05/2016	31/10/2016	04/06/2017	10/05/2018
Quantidade de dias	11	27	61	7	25
Estudantes matriculados	114	105	139	77	218
Estudantes Concluintes	74	45	58	53	81

A Tabela 1 apresenta os dados do minicurso de algoritmos e linguagem de programação aplicados em cada um dos semestres analisados. Esses dados referem-se ao número de estudantes matriculados e concluintes, a duração e às datas de início e término do minicurso. Em 2016/2 (segundo semestre de 2016) novos recursos extras foram adi-

cionados ocasionando uma mudança na estrutura do minicurso em relação ao semestre anterior.

3.1. Técnica de captura

Conforme o mapeamento sistemático de [de Borba et al. 2016] a técnica mais utilizada na captura das trajetórias de aprendizagem são as de log, enquanto a técnica de *Sequential Pattern Mining* destaca-se na análise dessas trajetórias.

Nesse sentido, a partir dos registros de log armazenados no AdaptWeb foi realizada a extração das sequências de recursos educacionais que representam a interação de cada estudante matriculado no minicurso. Essas sequências foram agrupadas de acordo com os semestres de aplicação do minicurso.

A Tabela 2 apresenta um exemplo do log referente ao minicurso e armazenado no AdaptWeb. A partir desse log, a sequência obtida é <9CONCEITO><9EXERCICIO><10EXERCICIO> onde os *itemsets* estão ordenados de acordo com a sua ocorrência e representam a interação do estudante com um determinado recurso educacional.

Tabela 2. Exemplo de log do AdaptWeb

id_log	id_usuario	topico	menu	data_aceso	hora_aceso	modo_navig	id_curso
122288	1901	9	conceito	2018-04-22	18:34:11	livre	483
122289	1901	9	exercicio	2018-04-22	18:34:16	livre	483
122292	1901	10	exercicio	2018-04-22	18:59:02	livre	483

Para processar os conjuntos de sequências geradas a partir dos logs de cada turma foi utilizada a ferramenta Weka onde os dados foram submetidos ao algoritmo *Generalized Sequential Pattern* (GSP). O GSP é um algoritmo de *Sequential Pattern Mining* capaz de minerar padrões de sequência de acordo com um valor mínimo de suporte [Agrawal and Srikant 1995]. Assim, adotando o suporte como 0,8 foi possível obter para cada minicurso as trajetórias de aprendizagem mais frequentes percorridas por no mínimo 80% dos estudantes matriculados.

Tabela 3. Maiores trajetórias de 2016/1 e 2017/1 com 0,8 de suporte

2016/1	2017/1
<{1.0CONCEITO}{3.1CONCEITO}{3.2CONCEITO}{3.3CONCEITO}{3.4CONCEITO}{3.5CONCEITO}{4.0CONCEITO}{4.1CONCEITO}{4.2CONCEITO}{4.3CONCEITO}{6.4CONCEITO}{7.1CONCEITO}{7.2CONCEITO}{7.3CONCEITO}> (37)	<{1CONCEITO}{1.1CONCEITO}{1.2CONCEITO}{1.3CONCEITO}{1.4CONCEITO}{2CONCEITO}{2.1CONCEITO}{2.2CONCEITO}{2.3CONCEITO}{3.1CONCEITO}{3.2CONCEITO}{4.1CONCEITO}{4.2CONCEITO}{5CONCEITO}> (42)
<{1.0CONCEITO}{3.1CONCEITO}{3.2CONCEITO}{3.3CONCEITO}{3.4CONCEITO}{3.5CONCEITO}{4.0CONCEITO}{4.1CONCEITO}{4.3CONCEITO}{5.1CONCEITO}{5.2CONCEITO}{7.1CONCEITO}{7.2CONCEITO}{7.3CONCEITO}> (37)	<{1CONCEITO}{1.1CONCEITO}{1.2CONCEITO}{1.3CONCEITO}{1.4CONCEITO}{2CONCEITO}{2.1CONCEITO}{2.2CONCEITO}{2.3CONCEITO}{3.1CONCEITO}{3.3CONCEITO}{4.1CONCEITO}{4.2CONCEITO}{5CONCEITO}> (42)


Com o intuito de exemplificar os resultados obtidos, a Tabela 3 apresenta as maiores trajetórias dos semestres 2016/1 e 2017/1. Na tabela, os números em destaque referem-se ao número de estudantes que percorreu a trajetória em questão. Nota-se ainda

que apenas as maiores sequências foram consideradas pois as demais são subsequências das mesmas. As análises retiradas dessas capturas serão explanadas na seção 4.

3.2. Visualização

Após a análise das trajetórias geradas optou-se por representá-las visualmente para auxiliar o processo de entendimento dos seus padrões e a busca por outros dados que pudessem ser extraídos. A escolha da representação baseada em grafos deu-se de acordo com o trabalho de [Ramos et al. 2015] que afirma que este é o formato mais utilizado para representar as trajetórias de aprendizagem.

Figura 1. Trajetórias de aprendizagem dos estudantes de 2016/1



Com esse intuito, foi utilizado o modelo de representação proposto por [Ramos et al. 2017a]. Este modelo representa a trajetória de aprendizagem no formato de um grafo direcionado onde os vértices representam recursos educacionais e as arestas representam os caminhos percorridos por um estudante de um recurso até o outro. O grafo apresenta quatro tipos diferentes de arestas: **sequencial** (chamada por [Ramos et al. 2017a] de aresta padrão), que representa o caminho feito de um recurso até seu sucessor imediato; **de avanço**, que representa o caminho feito de um recurso até um recurso além do seu sucessor imediato; **de retorno**, que representa o caminho feito de


um recurso até um recurso anterior ao primeiro; e **de refresh** que representa o caminho de um recurso para ele mesmo, ou seja, a atualização da página.

Ainda de acordo com Ramos et al. [2017a] o tamanho dos vértices está relacionado à quantidade de acessos dos recursos, assim, o tamanho de cada vértice é proporcional ao seu grau de entrada. Já as arestas têm espessura proporcional ao número de estudantes que percorreram o caminho por elas indicado, denota-se esse número como o peso de cada aresta. Assim, as trilhas de aprendizagem foram reescritas de modo a representarem as arestas e os nós conforme o modelo proposto e foram importadas para a ferramenta Gephi, um software livre para manipulação de grafos, utilizado para gerar a representação visual dessas trilhas. Na Figura 1, é possível visualizar as trajetórias de aprendizagem percorridas pelos estudantes do semestre 2016/1. Nota-se uma preferência pelas trajetórias lineares, ou seja, caminhos que vão de um conceito para o seu sucessor imediato, denotados pelas arestas azuis. Também é possível observar que os recursos mais acessados são, na sua grande maioria, os conceitos. Em relação aos recursos extras, observa-se que existem arestas ligando-os a outros recursos do mesmo tipo, isso significa que alguns alunos preferem fazer uma navegação baseada no tipo do recurso. Um exemplo deste tipo de navegação são os alunos que percorrem linearmente todos os exercícios.

4. Resultados e Análises

Em relação às trajetórias de aprendizagem dos semestres 2016/1 e 2017/1 destacadas na seção 3.1, torna-se possível observar semelhanças na maneira com que os estudantes de diferentes turmas navegam pelo AdaptWeb. Primeiramente, é possível observar que apesar de existirem alguns avanços entre os tópicos, as trajetórias seguem majoritariamente um caminho linear passando de cada recurso para o seu sucessor imediato ou outro recurso próximo.

Figura 2. Porcentagem de arestas por semestres



Nota-se que nenhum recurso extra (exemplo, exercício ou material complementar) apareceu como *itemset* de nenhuma das trajetórias geradas. Isso demonstra que, entre a grande maioria dos estudantes, há uma preferência pela navegação por conceitos. Apesar dos semestres cujas trajetórias foram analisadas terem diferenças estruturais, os padrões de navegação obtidos em ambos mostram que 80% dos estudantes faz um caminho similar

na parte introdutória do curso (parte anterior às explicações sobre operadores lógicos e aritméticos, laços de repetição, vetores e matrizes).

Já em relação à representação visual das trajetórias explanadas na seção 3.2, outros dados podem ser obtidos e analisados. Um deles diz respeito à porcentagem de cada tipo de aresta em cada um dos semestres analisados. Esse dado foi obtido a partir da soma dos pesos de arestas de cada tipo e da porcentagem que essa soma representa em relação ao peso total de todas as arestas. Conforme apresentado na Figura 2, as arestas sequenciais estão presentes em maior número nos caminhos trilhados pelos estudantes, seguidas pelas arestas de retorno e por fim pelas arestas de avanço. Reforçando o resultado obtido na captura das trajetórias, as turmas de todos os semestres optaram por uma navegação predominantemente linear.

Uma análise com base nos dados dos estudantes matriculados em 2018/1 separados por curso foi realizada, observando a porcentagem de recursos acessados por estudante em cada curso. Essa análise pode ser observada na Figura 3 que apresenta a relação entre a quantidade de recursos de cada tipo acessada pelos estudantes de cada curso. É possível verificar que nenhum curso acessou mais de 75% dos recursos disponíveis. Para investigar o impacto da interação com os recursos no desempenho final dos estudantes, foi feita uma comparação entre os dados da Figura 3 e a média das notas na avaliação final do minicurso apresentada na Tabela 4.

Figura 3. Recursos utilizados por estudante em cada curso de 2018/1

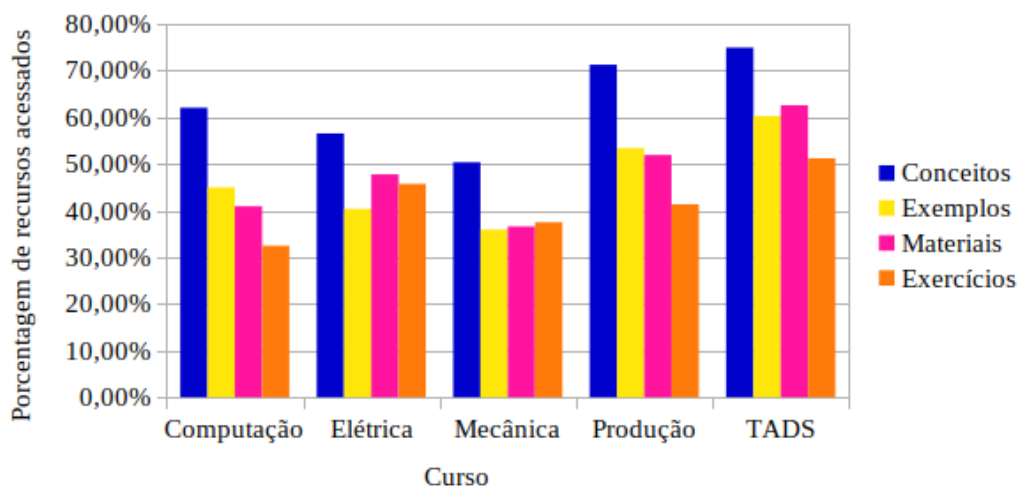


Tabela 4. Média das notas por curso na avaliação final no semestre 2018/1

Curso	Elétrica	Mecânica	Produção	TADS
Computação	80,67	72,50	78,18	71,76

Destacam-se as seguintes relações: TADS é o curso com maior interação por estudante com todos os tipos de recurso, porém é também o curso que apresenta a menor média de notas final. Diferentemente, Mecânica que apresenta uma média de notas igualmente baixa, é o curso com menor interação por estudante, quando considerados todos os tipos de recursos. Já Elétrica e Computação, que possuem interação relativamente baixas quando comparadas às demais, são os cursos que apresentam as maiores médias de notas.

A partir destes resultados entende-se que ainda não é possível traçar um padrão entre os recursos com que os estudantes interagiram e o seu desempenho no minicurso.

Outro resultado obtido a partir dos dados apresentados na Figura 3 é o fato de que os recursos mais acessados pelos estudantes de todos os cursos são do tipo conceito, reforçando o que foi observado na captura das trajetórias. Observa-se que foi possível realizar diferentes análises a partir da captura e visualização das trajetórias de aprendizagem. Entre essas análises encontram-se as trajetórias mais frequentes em diferentes semestres, o tipo de recurso educacional mais acessado e o tipo de caminho (linear ou não linear) de preferência dos estudantes. Contudo, não foi possível observar um padrão entre os recursos com os quais o estudante interagiu durante sua trajetória e o seu desempenho ao final do minicurso.

5. Considerações finais

Neste trabalho foram realizadas a captura e visualização das trajetórias de aprendizagem de um minicurso de algoritmos e linguagem de programação em um ambiente educacional na Web. As turmas foram formadas por estudantes de diversos cursos de graduação que realizaram o minicurso em diferentes semestres. A partir das trajetórias geradas foi possível realizar análises abrangendo o tipo de recurso educacional mais acessado, o tipo de caminho (linear ou não linear) mais percorrido, as trajetórias mais frequentes e a relação entre os recursos acessados pelos estudantes e seus desempenhos.

Como resultados finais, observou-se que os recursos educacionais mais acessados são do tipo conceito e a maior parte dos estudantes prefere seguir um caminho linear ao navegar pelo ambiente. Esse mesmo padrão foi observado nas trajetórias de aprendizagem mais frequentes que mostram uma navegação pela parte introdutória do minicurso sem retornos e sem acessos aos recursos extras. Contudo, apesar dos resultados obtidos, não foi possível encontrar um padrão entre os recursos educacionais acessados pelos estudantes e seus desempenhos no minicurso.

Entre as limitações deste trabalho encontram-se as diferentes variáveis que podem agir sobre o comportamento das turmas matriculadas no minicurso de algoritmos e linguagem de programação. Entre elas estão o tempo que cada turma teve para realizar o minicurso, as datas de início e término do minicurso bem como a fase do curso em que os estudantes estão, que influenciam diretamente no nível de conhecimento que eles já possuem sobre o conteúdo. Nesse sentido, propõe-se como trabalhos futuros a investigação da relação entre os recursos educacionais acessados e o desempenho dos estudantes levando em consideração as variáveis mencionadas como limitações deste trabalho, e a utilização das trajetórias de aprendizagem como ferramenta para auxiliar o processo de análise da evasão do minicurso.

Agradecimentos

Este trabalho foi realizado com apoio da bolsa de iniciação científica PIBIC/CNPq e da UDESC e apoio da FAPESC, Edital FAPESC/CNPQ Nº06/2016, T.O. Nº:2017TR1755 -Ambientes Inteligentes Educacionais com Integração de Técnicas Learning Analytics e Gamificação e FAPESC EDITAL Nº 01/2016 – T.O. nº 2017TR649 – Processo 531/2017 - Apoio a Grupos de Pesquisa da Universidade do Estado de Santa Catarina (UDESC).

Referências

- Agrawal, R. and Srikant, R. (1995). Mining sequential patterns: Generalizations and performance improvements. In *International Conference on Data Engineering*, pages 3–14, Taipei, Taiwan.
- Brusilovsky, P. (1996). Methods and techniques of adaptive hypermedia. In *UMUAI*, volume 6, pages 87–129. Kluwer.
- de Borba, E. J. and Gasparini, I. (2015). O uso da trajetória de aprendizagem do aluno em ambientes virtuais de aprendizagem. *RENOTE*, 13(1).
- de Borba, E. J., Gasparini, I., Lichtnow, D., Pimenta, M. S., and de Oliveira, J. P. M. (2016). Captura e visualização da trajetória de aprendizagem do aluno: um mapeamento sistemático. *TISE*, 12:105–111.
- de Oliveira, J. P. M., de Lima, J. V., Wives, L. K., Pernas, A. M., Gasparini, I., Fernandez, A., and Diaz, A. (2014). Adaptatividade geocultural em ambientes virtuais de aprendizagem. *RIED*, 17(1):83–109.
- de Souza, N. S., Santiago, G., de Lima, J. V., do Canto Filho, A. B., and Perry, G. T. (2018). Análise das trajetórias de aprendizagem de estudantes inscritos em um mooc. *RENOTE*, 16(1).
- Moissa, B., de Borba, E. J., Kemczinski, A., and Gasparini, I. (2014). Uma ferramenta de visualização da informação para analisar o comportamento do aluno em um ambiente e-learning e sua trajetória de aprendizagem. *InfoDesign*, 11(3):337–351.
- Poon, L. K. M., Kong, S.-C., Yau, T. S. H., Wong, M., and Ling, M. H. (2017). Learning analytics for monitoring students participation online: Visualizing navigational patterns on learning management system. In *International Conference on Blended Learning*, pages 166–176, Hong Kong, China.
- Ramos, D. B., de Oliveira, E. H. T., Ramos, I. M. M., and Oliveira, K. M. T. (2015). Trilhas de aprendizagem em ambientes virtuais de ensino-aprendizagem: Uma revisão sistemática da literatura. In *Simpósio Brasileiro de Informática na Educação*, pages 338–347.
- Ramos, D. B., Ramos, I. M. M., do Nascimento, P. B., and de Oliveira, E. H. T. (2016). Uma ferramenta baseada em grafo para identificação e visualização de trilhas de aprendizagem. *TISE*, 12:237 – 343.
- Ramos, D. B., Ramos, I. M. M., do Nascimento, P. B., de Souza Amaral, G., and de Oliveira, E. H. T. (2017a). Um modelo para trilhas de aprendizagem em um ambiente virtual de aprendizagem. In *Simpósio Brasileiro de Informática na Educação*, pages 1407–1416.
- Ramos, I. M. M., Ramos, D. B., do Nascimento, P. B., de Souza Amaral, G., Gadelha, B., and de Oliveira, E. H. T. (2017b). M-cluster: Uma ferramenta de recomendação para formação de grupos em ambientes virtuais de aprendizagem. In *Simpósio Brasileiro de Informática na Educação*, page 1657–1666.
- Romero, C., Gutierrez-Santos, S., Freire, M., and Ventura, S. (2008). Mining and visualizing visited trails in web-based educational systems. In *Educational Data Mining*.