

Uso de Trajetórias de Aprendizagem para a Identificação da Orientação de Metas de Estudantes em Disciplinas Introdutórias de Programação

David Brito Ramos¹, Ilmara Monteverde Martins Ramos¹, Elaine Harada²

¹Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM)
Manaus – AM – Brasil

²Instituto de Computação
Universidade Federal do Amazonas (UFAM) – Manaus, AM – Brasil
{david.brito,ilmara.martins}@ifam.edu.br, elaine@icomp.ifam.edu.br

Abstract. *This work presents an approach to using learning trajectories for identification of goal orientation, based on the Achievement Goals Theory, of students of introductory programming disciplines. Two experiments were conducted with data from higher education students in Introduction to Programming disciplines for three years, to obtain results from the classification of the goals, based on the analysis of the learning paths. In all, 232 students participated in the experiments. Nine classifiers were used, with tree-based classifiers achieving the best results in both experiments, reaching an f-1 score of 0.90.*

Resumo. *O objetivo deste trabalho é apresentar uma abordagem que permite utilizar as trajetórias de aprendizagem para a identificação de orientação de metas, fundamentada na Teoria de Metas de Realização, de estudantes de disciplinas introdutórias de programação. Foram conduzidos dois experimentos com dados de alunos do ensino superior em disciplinas de Introdução à Programação durante três anos, para obter resultados da classificação das metas, com base na análise das trajetórias de aprendizagem. Ao todo participaram dos experimentos 232 alunos. Foram utilizados nove classificadores, onde aqueles do tipo árvore obtiveram melhores resultados, em ambos os experimentos, sendo o melhor resultado para f-1 score o valor 0.90.*

1. Introdução

A Psicologia Educacional, subárea da Psicologia, tem por objeto de pesquisa os processos psicológicos relacionados às ações de ensino-aprendizagem e ao desenvolvimento humano [Tibúrcio e Fonseca 2021], buscando entender como os indivíduos aprendem, sendo considerado um elo entre Psicologia e Pedagogia [Araújo, Lopes e Carneiro 2018].

Diversos estudos em psicologia educacional buscam entender a motivação dos alunos para aprender. A motivação pode ser considerada como a razão de ação ou o fator pelo qual as pessoas tomam decisões para alcançar seus objetivos. Uma das teorias da motivação com base sólida e amplamente aceita é a Teoria de Metas de Realização [Ames 1984, Dweck 1986, Dweck e Elliott 1983].

Dentro da Teoria de Metas de Realização existem orientações de objetivos, também conhecida como orientação de metas, que são definidas pelas preferências particulares de cada pessoa, estabelecendo-se assim ao como ela almeja alcançar o estado final desejado [Niemivirta 2002].

A motivação está relacionada ao envolvimento dos alunos no processo de aprendizagem [Santos, Alcará e Zenorini 2013] e este envolvimento correlaciona-se com a sua orientação de meta predominante [Zenorini e Santos 2010]. Assim, existe, por exemplo, uma relação entre motivação e as estratégias de aprendizagem que os alunos usam para alcançar seus objetivos. Segundo trabalhos na literatura [Dweck e Elliott 1983, Niemivirta 2002, Elliott e Dweck 1988], motivação e aprendizagem autorregulada são os fatores que mais contribuem para o aprendizado. Nesta pesquisa, a motivação é definida pela classificação obtida de acordo com a Teoria de Metas de Realização.

Em geral, a identificação da orientação de metas é obtida por meio da aplicação de um questionário, exceto por um trabalho que apresenta uma opção diferente, na qual os autores propõem uma ferramenta computacional (programa de computador) para identificar o tipo de motivação do estudante [Romero et al. 2019].

Sabe-se que novas informações geradas a partir dos dados do Ambientes Virtuais de Aprendizagem (AVA) podem facilitar o processo de ensino e aprendizagem. O AVA coleta dados sobre usuários que podem ajudar a definir o perfil do estudante, seu comportamento e identificar suas dificuldades e necessidades. Uma forma de acompanhar os aprendizes é observar as ações que eles realizam no ambiente de aprendizagem, e essas ações podem resultar em caminhos conhecidos como trilhas de aprendizagem.

Dentro do contexto de educação a distância, nos trabalhos da literatura, trilhas de aprendizagem eram consideradas de dois pontos de vista:

1. Uma sequência de recursos e atividades (material didático, objetos de aprendizagem, atividade, fórum, chat, ...) definidos pelo professor, ao planejar a disciplina, e disponibilizados no ambiente virtual de aprendizagem; ou
2. O caminho seguido pelo estudante durante sua interação com os recursos e atividades disponibilizados no ambiente virtual de aprendizagem.

Neste artigo, será adotado o termo Trajetórias de Aprendizagem (TA), pois se refere aos caminhos percorridos pelo aluno, enquanto, atualmente, o termo trilhas de aprendizagem passou a ser referir apenas ao primeiro ponto de vista citado acima.

Assim, a lacuna de pesquisa é que ainda não foram encontrados estudos na literatura que aproveitem as informações já existentes e armazenadas nos AVAs, principalmente trajetórias de aprendizagem, para classificar os alunos de acordo com a orientação das metas de realização. Dessa forma, medir a motivação do aluno e identificar sua orientação de metas de realização é um trabalho relevante no campo da educação.

Portanto, o objetivo deste trabalho é identificar a motivação dos alunos, sob a perspectiva da teoria das metas de realização, analisando as trajetórias de aprendizagem baseadas nos logs. A motivação dos estudantes, neste caso, é definida pela classificação obtida segundo a Teoria de Metas de Realização [Ames 1984, Dweck 1986, Dweck e Elliott 1983], na qual o estudante pode ser classificado em orientações de metas. As trajetórias de aprendizagem são baseadas em ações de interação dos alunos usando um

ambiente virtual de ensino-aprendizagem. Assim esta pesquisa está mais alinhada com Mineração de Dados Educacionais (EDM).

2. Fundamentos

4.1. Teoria de Metas de Realização

A Psicologia Educacional busca entender o comportamento dos alunos, por exemplo, com base em suas motivações e em como esse comportamento influencia a aprendizagem. A motivação é considerada um construto multidimensional e complexo [Bzuneck e Boruchovitch 2016], permitindo que seja estudada sob várias perspectivas. Uma das teorias da motivação amplamente aceita é a Teoria de Metas de Realização [Ames 1984, Dweck 1986, Dweck e Elliott 1983], onde existem orientações de metas. A orientação de metas representa disposições e preferências pessoais que contribuem para a seleção de metas (objetivos estabelecidos). Pode ser definido como a preferência de uma pessoa por classes específicas de estados finais desejados [Niemi-virta 2002]. Diversos estudos [Elliott e McGregor 2001, Elliot e Murayama 2008, Elliot, Murayama e Pekrun 2011, Elliot e Church 1997, Harackiewicz et al. 2000, Hayamizu e Weiner 1991, Pulkka e Niemi-virta 2013, Romero et al. 2019] mostraram ao longo dos anos que a teoria da motivação pode ser usada, apenas para citar alguns exemplos, para entender a estratégia de aprendizagem adotada pelo estudante, desempenho (nota), reação ao falhar, medo do fracasso e relacionamento com os colegas.

A orientação de metas indica a atitude adotada pelo aluno ao definir o motivo pelo qual ele realizará uma determinada tarefa. O conjunto de orientação de metas varia de acordo com as obras na literatura.

Zenorini e Santos [2010] adotam três orientações de metas de realização: meta Aprender, meta Performance-aproximação e meta Performance-evitação. Alunos orientados à meta Aprender caracterizam-se pela busca do crescimento intelectual e o uso de estratégias de aprendizagem mais efetivas [Zenorini e Santos 2010]. Alunos com meta de aprendizagem ou de domínio buscam aumentar sua competência. Estudantes com esse perfil buscam aprender e desenvolver suas habilidades, focando mais no progresso pessoal do que em tentar ser melhores que os outros [Romero et al. 2019]. Pesquisas também têm buscado a relação entre orientação de metas e outros fatores. Por exemplo, a meta Aprender está positivamente relacionada à extroversão, abertura, persistência, consciência e afeto positivo, e inversamente relacionado ao neuroticismo, ansiedade e raiva [Romero et al. 2019]. Pessoas com esse perfil tendem a ser organizadas e persistentes diante das dificuldades.

Alunos orientados à meta Performance-aproximação buscam demonstrar inteligência [Zenorini e Santos 2010]. Comparar desempenho com colegas também é uma atitude comum dos estudantes com essa meta. Eles buscam demonstrar mais competência em relação a outros estudantes. Eles também tendem a buscar vantagens, obter pontuações altas e alcançar objetivos o mais rápido possível, sem necessariamente adquirir conhecimento ou desenvolver habilidades para isso [Romero et al. 2019]. Alunos com meta Performance-aproximação tendem a usar estratégias de aprendizagem mais rasas, como atalhos e macetes, em comparação com alunos orientados para aprendizagem [Romero et al. 2019]. Eles, por exemplo, respondem melhor aos distintivos de conquista como *feedback*, pois são um indicador de alto desempenho [Auvinen, Hakulinen e Malmi 2015].

Estudantes cuja meta é Performance-evitação buscam evitar situações em que possam demonstrar incapacidade [Zenorini e Santos 2010] ou buscam evitar demonstrar incompetência [Auvinen, Hakulinen e Malmi 2015]. Eles também tentam não passar por situações que consideram constrangedoras. Alunos com a Performance-evitação apreciam mais os mapas de calor, pois mostram um mapa que estima resultados ruins [Auvinen, Hakulinen e Malmi 2015]. Metas orientadas a performance estão positivamente relacionadas a neuroticismo, raiva, ansiedade e vergonha. Esse perfil é inversamente relacionado à persistência em tarefas, abertura, extroversão [Romero et al. 2019].

1. Dataset

O *CodeBench*, um juiz online para o ensino de programação, possui um banco de dados fornecido online onde os registros dos alunos são armazenados. Portanto, para realizar a análise dos seus dados, basta baixá-los em <https://codebench.icomp.ufam.edu.br/dataset/>. Os dados de 2016 a 2024 (*Dataset* versão 1.81) estão disponíveis, com um total de 129 turmas, 5.229 alunos, com 18.553 exercícios concluídos e 2.544 exames realizados. A organização do conjunto de dados é feita por pastas e arquivos, dos quais os principais para este trabalho são descritos a seguir. Os dados começam organizados pela pasta semestral, pastas que representam os semestres das aulas, cujo nome segue o formato "ano-semester". Dentro de cada pasta semestral estão as pastas que representam os grupos ou turmas, o nome de uma pasta de turma é um número que indica o id da turma. Cada pasta de classe possui duas subpastas: "assessments" e "users".

Dentro da pasta de avaliações (*assessments*), cada arquivo representa uma lista de exercícios de uma tarefa ou uma prova (prova prática). A diferença é que, nas provas, os exercícios que os alunos devem responder são aleatórios, os IDs de todos os exercícios do mesmo bloco aleatório de exercícios são armazenados. É nessa pasta que os dados para representar os vértices do modelo de TA são coletados. Cada vértice representa um exercício de programação. A lista de exercícios é a seção à qual os vértices pertencem. Dentro da pasta de usuários (*users*) há várias pastas, cada uma representando um estudante distinto, o nome da pasta é o id do aluno. Dentro da pasta do aluno há uma pasta chamada "codemirror" que contém todos os eventos disparados para cada exercício. É nessa pasta que os dados de acesso podem ser extraídos para compor o modelo de trajetórias de aprendizagem adotado neste trabalho. Ainda dentro da pasta do estudante, há a pasta "grades" que armazena as notas de cada lista e a nota final do curso, esta última está em "final_grade.data".

3. Trabalhos relacionados

Morozevich, Korotkikh e Kuznetsova [2022] apresentam a construção de um modelo para personalizar trilhas de aprendizagem com base no perfil e nas reações ao material de ensino, no contexto organizacional. O aprendizado visa treinar habilidades técnicas e interpessoais alinhadas aos valores da empresa e do funcionário, também buscando alcançar os objetivos organizacionais. Para fazer recomendações, o sistema coleta o perfil do funcionário, o perfil organizacional e os dados de treinamento. Essas informações são usadas pelo módulo de recomendações para apresentar uma nova atividade ou material didático.

O trabalho de HE et al. [2022] apresenta uma proposta de um classificador de estilos de aprendizagem (LSC) de forma não supervisionada, para analisar padrões

comportamentais de aprendizagem. Com base nisso, trilhas de aprendizagem são geradas e fornecidas aos usuários. O estudo aponta que o LSC utiliza rotulagem de informações feita por especialistas, o que é inviável para aplicações em grande escala. Os *logs* incluem eventos de comportamento como clique, criação, leitura e escrita. Com os *logs* disponíveis, um modelo treinado é criado e usado para prever estilos de aprendizagem. O estilo previsto, juntamente com o material de aprendizagem, serve como entrada para a geração de trilhas de aprendizagem (*Learning Sequence*).

O estudo de Jiang et al. [2022] propõe um algoritmo para gerar e recomendar trilhas de aprendizagem com base em estados de aprendizagem. Os autores propõem primeiro um método para calcular automaticamente a dificuldade dos pontos de conhecimento e, a partir disso, construir um modelo de dificuldade de conhecimento. O estudo leva em conta comportamentos de aprendizagem e pontuações de exercícios como parâmetro para avaliar o estado de aprendizagem dos alunos e construir um modelo dinâmico do domínio do conhecimento. Os estados de aprendizagem usados no estudo são: não aprendido, não dominado, insuficientemente dominado e dominado. Os comportamentos de aprendizagem são baseados em como os alunos assistem aos vídeos das aulas, como repetir, acelerar ou pular partes do vídeo. Com o modelo de dificuldade do conhecimento e o modelo de domínio do conhecimento em mãos, o algoritmo proposto gera caminhos de aprendizagem personalizados para os alunos. Os autores concluem que a abordagem é capaz de melhorar as taxas de conclusão de cursos, o comportamento e a eficiência do aprendizado.

Os trabalhos relacionados mostram que a maioria das aplicações de pesquisa busca primeiro projetar ambientes de aprendizagem para coletar dados previamente estabelecidos, porém, quando os propósitos desses ambientes são muito específicos, torna-se mais difícil aplicar a mesma abordagem dos trabalhos em outro cenário. Além disso, as ações de mapeamento, catalogação e organização dos materiais de aprendizagem não são triviais e não são realizadas em todos os ambientes virtuais.

4. Métodos

Um modelo, baseado em grafos, para a representação de trajetórias de aprendizagem, elaborado em um trabalho anterior [Ramos et al. 2017], foi adaptado para representar dados do CodeBench, onde foram considerados apenas os eventos de acesso às listas de exercícios. Métricas como a medida de dispersão e medidas estatísticas como média, desvio padrão e variância nos dados de acesso a vértices foram estimadas a partir do modelo de trilhas utilizado [Ramos et al. 2017].

Para a elaboração dos experimentos, foi selecionado um instrumento validado para identificar a orientação de metas nos estudantes, este instrumento teve estudantes do ensino superior como público-alvo e foi validado na língua nativa. Assim, para os experimentos, o instrumento Escala de Motivação para Aprendizagem de Universitários (EMAPRE-U) [Santos, Alcará e Zenorini 2013, Zenorini e Santos 2010] foi aplicado para identificar a motivação de aprendizagem de cada participante e usar essas informações para classificar sua trajetória de aprendizagem.

De posse desse conjunto de informações, as TAs foram organizadas para servir como entrada para algoritmos de mineração de dados e aprendizado de máquina [Artero 2009], a fim de fazer previsões de orientação de metas.

4.1. Seleção de uma Escala de Metas de Realização

Para manter a confiabilidade da pesquisa, bem como sua validade, é importante que um instrumento validado seja aplicado cujas análises estatísticas e propriedades psicométricas atestem que o instrumento realmente cumpre o que propõe. Seguindo as orientações de Bittencourt e Isotani [2018], que, além de afirmar que mais instrumentos validados deveriam ser usados nas pesquisas e menos instrumentos próprios, também é necessário levar em conta o contexto ao qual são aplicados. Dito isso, também é não é razoável aplicar um instrumento que foi validado em um idioma estrangeiro, por exemplo, traduzido apenas para o idioma da pessoa que responderá ao questionário e acreditar que terá a mesma validade. Na área da psicologia educacional, esses critérios são considerados, por isso, esta pesquisa buscou selecionar um instrumento em um contexto educacional validado na língua nativa, ou seja, o português brasileiro, e adequado para os respondentes, estudantes universitários.

Inicialmente, foi realizada uma revisão sistemática da literatura para selecionar trabalhos que apresentassem instrumentos de coleta de dados sobre a motivação dos alunos por meio da teoria da motivação de realização. Existem instrumentos para medir a motivação, por exemplo, em esportes ou no trabalho, mas esses casos não são aplicáveis a esta pesquisa. Nos estudos realizados, foram selecionados aqueles com questionários na língua nativa, em um total de seis trabalhos, dos quais três foram propostas de instrumentos e três aplicaram apenas instrumentos existentes. Usando um processo semelhante ao *snowballing*, foi verificado quais instrumentos foram aplicados nos últimos três artigos. A busca por uma escala que possa avaliar a motivação dos alunos decorre da necessidade de usar instrumentos validados durante a pesquisa. Na busca por um instrumento validado, com suas propriedades psicométricas analisadas e aceitas, e considerando os instrumentos encontrados, o EMAPRE-U foi selecionado.

O desenvolvimento do EMAPRE-U começou com o trabalho de Zenorini e Santos [2010], que visava construir uma escala de Motivação para Aprendizagem com itens baseados na Teoria de Metas de Realização. A escala, chamada EMAPRE, era aplicada aos estudantes do ensino médio com idades entre 14 e 20 anos. As autoras aplicaram a escala com 50 itens e, após análise estatística, reduziram o número de itens para 28. Assim, novos testes de validação foram necessários para ajustar e confirmar a aplicabilidade da escala para estudantes do ensino superior, o que foi realizado em uma nova pesquisa, resultando no EMAPRE-U [Santos, Alcará e Zenorini 2013]. Assim, estudos recentes confirmaram as propriedades psicométricas da escala criada e especialmente projetada para o Ensino Superior, que também é o alvo deste artigo.

O instrumento EMAPRE-U é um instrumento validado no contexto universitário na língua nativa, devidamente aprovado pela avaliação de suas propriedades psicométricas [Santos, Alcará e Zenorini 2013]. O instrumento possui 28 itens, divididos em três metas de conquista: 12 itens para a meta Aprender, 9 para a meta Performance-aproximação e 7 itens para a meta Performance-evitação. O instrumento é respondido em uma escala de *Likert* de três pontos: “Discordo”, “Não sei” e “Concordo”.

5. Experimentos e Resultados

Foram usados as TAs extraídas a partir dos arquivos de registro do *dataset* do *CodeBench*, combinados com as orientações de metas obtidas via questionário EMAPRE-U. Dois experimentos foram realizados conforme as subseções a seguir.

5.1. Experimento 1

Para este experimento, os dados analisados são de 168 alunos das turmas de Introdução à Programação de Computadores (IPC) durante o período 2020/ERE (Regime Especial por conta da pandemia de COVID-19). Devido à pandemia, as aulas foram totalmente remotas e, como eram aulas de regime especial, a participação dos alunos era opcional. Os alunos foram divididos em três grupos: Manhã, Tarde e Noite. Todos os grupos tinham o mesmo instrutor e incluíam o mesmo conjunto de recursos e atividades. As aulas, realizadas às segundas e quartas-feiras, começaram em 9 de setembro de 2020 e terminaram em 16 de dezembro de 2020, com o Exame Final. Também cabia a critério dos alunos escolher em qual grupo participar.

Para realizar a classificação, foram usados a ferramenta *Jupyter* e a linguagem de programação *Python*. Nos experimentos iniciais, a precisão foi muito alta devido ao conjunto de dados desequilibrado, já que os algoritmos tendiam a classificar os alunos na turma predominante. No conjunto de dados original, havia 140 alunos com a meta Aprender, 7 com a meta Performance-aproximação e 21 com a meta Performance-evitação ($n=168$). Como resultado, os classificadores rotularam os dados do teste como pertencentes a meta de aprendizagem. Para contornar este problema, foi aplicado um método de *oversampling*, chamado SMOTE (*Synthetic Minority Over-sampling Technique*) que gera dados sintéticos da classe minoritária de forma a equilibrar a quantidade de amostras entre as classes. A amostragem foi feita pela divisão de dados de treino e de teste na proporção 75% para 25%, respectivamente, da base de dados, de forma estratificada e com a opção *random state* ativada, para manter a reprodutibilidade dos experimentos, independentemente da quantidade de execuções. Com essas configurações, classificadores de árvore apresentaram melhores resultados.

Ao final da pesquisa, os dados coletados foram analisados em intervalos distintos. O objetivo dessa forma de análise era determinar em que momento os algoritmos apresentariam melhores resultados e/ou se haveria uma melhora gradual ao longo do tempo. O estabelecimento dos intervalos de dados levou em consideração o cronograma de ensino do componente curricular, que já havia sido apresentado aos alunos e fazia parte da rotina diária do instrutor.

Embora o início oficial das aulas fosse em 9 de setembro, já que 7 de setembro, uma segunda-feira, era feriado nacional, os recursos e atividades do *CodeBench* já estavam disponíveis desde o dia 3 de setembro. Portanto, essa foi a data de referência para o início da coleta de dados. As datas finais para coleta de dados que formam os intervalos de dados foram selecionadas com base no prazo final para submissão de atividades, que são divididas por assunto de acordo com o planejamento do componente curricular. Exceto pelas duas primeiras datas finais de coleta de dados (16 e 30 de setembro), pois também foi verificado se uma classificação satisfatória ($F-1 \geq 0,8$) poderia ser alcançada com dados iniciais dos alunos.

Os algoritmos baseados em árvores, Random Forest e Decision Tree, renderam melhores resultados. Os resultados também indicam que, três semanas após o início oficial das aulas (09/09), há uma melhora nos resultados dos algoritmos iniciais, e essa melhora é mantida até o intervalo mais longo de coleta de dados, conforme apresentado na Figura 1.




Figura 1. Resultados de classificação do Experimento 1.

5.2. Experimento 2

Neste segundo experimento, coletamos dados de todos os estudantes que concordaram em participar da pesquisa do ano de 2020 (incluindo os dados do período do regime especial) até o ano de 2022. O objetivo do experimento era verificar se dados de diferentes turmas e períodos também poderiam ser usados para classificar orientações de metas.

Assim, foram unificados os dados de 23 turmas distintas, totalizando 232 alunos, sendo 198 da meta Aprender, 10 da meta Performance-aproximação e 24 da meta Performance-evitação. Como no experimento anterior, a orientação para metas de aprendizagem permaneceu predominante em relação às outras metas de desempenho. Com isso, novamente usamos o método SMOTE para balancear os dados. Os resultados deste experimento são apresentados na Figura 2.




Figura 2. Resultados de classificação do Experimento 2.

6. Conclusões

Este artigo mostrou a identificação da orientação de metas por meio de um modelo de representação do aluno, trajetórias de aprendizagem em um AVA, com o objetivo de ajudar os professores a identificar a motivação de seus alunos.

Nos experimentos de classificação, um F1-score acima de 80% foi obtido para os algoritmos da *Decision Tree* e da *Random Forest* ao classificar a motivação dos alunos de acordo com as TAs, mesmo menos de um mês após o início das aulas.

Com o tempo, os resultados do ranking praticamente permanecem os mesmos. Isso pode indicar que a motivação do aluno permaneceu a mesma durante todo o curso e que é possível identificá-la nas primeiras semanas de aula. No segundo experimento, mostramos que é possível classificar a motivação do aluno até mesmo juntando dados de turmas distintas.

Como limitação do trabalho, foi identificado que a maioria dos alunos que participaram até o final da pesquisa pertencia a meta de aprendizagem, gerando uma base de dados desequilibrada. Para contornar essa situação, foi usada uma técnica de *oversampling* conhecida como SMOTE. O método cria instâncias sintéticas da classe minoritária com base nas instâncias reais, apesar de ser uma solução para bases desbalanceadas, pode gerar ruído e instâncias em regiões onde dificulte a separação de classes.

Por fim, foi possível identificar e extrair os dados de acesso dos alunos da base de dados do *CodeBench*, e a partir deles gerar o modelo de estudante identificando as trajetórias de aprendizagem. Com o uso do questionário EMAPRE-U, foi possível usar a teoria de metas de realização para identificar a motivação dos alunos, o que, junto com as trajetórias de aprendizagem, formou o modelo comportamental. Por meio de

experimentos práticos, utilizando algoritmos de classificação, foi possível identificar os alvos com boa precisão.

Para trabalhos futuros, a intenção é modelar a relação entre TAs e metas de realização em tempo real, utilizando técnicas de aprendizado de máquina e mineração de dados.

Agradecimentos

Ao Instituto Federal de Educação, Ciência e Tecnologia do Estado do Amazonas –IFAM Campus Manaus Zona Leste, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- Brasil (AUXPE-CAPES-PROEX), Código de Financiamento 001, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Processo 308513/2020-7. Além disso, esta pesquisa, realizada no âmbito do Projeto Samsung - UFAM de Ensino e Pesquisa (SUPER), de acordo com o Artigo 39 do Decreto nº10.521/2020, foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº8.387/1991, através do convênio 001/2020 firmado com a UFAM e FAEPI, Brasil e este projeto foi parcialmente financiado pela Fundação de Amparo à pesquisa do Estado do Amazonas - FAPEAM por meio dos projetos PDPG-CAPES e POSGRAD 2025-2026 e POSGRAD 2026-2027.

Declaração sobre uso de Inteligência Artificial

Os autores declaram que houve uso de IA apenas para a sugestão de melhorias textuais do artigo. Não houve uso de IA nos demais procedimentos, tais como levantamento bibliográfico dos fundamentos ou trabalhos relacionados, criação de imagens, aplicação da metodologia, execução, análise ou síntese dos experimentos, elaboração das conclusões.

Referências

- Ames, C. (1984) “Competitive, cooperative and individualistic goal structures: A motivational analysis”. *Research on Motivation in Education*, Vol. 1: Student Motivation, 1, 177–207.
- Araújo, Roberta Maria Monteiro; Lopes, Lilian Thalia Siqueira; Carneiro, Fábio Delano Vidal (2018) “A Psicologia Educacional e o Vínculo Afetivo na Mídia Educacional”. *Encontros de Iniciação Científica UNI7*, v. 8, n. 1, 2018.
- Artero, A. O. (2009) *Inteligência Artificial: Teoria e Prática*. Livraria da Física, São Paulo.
- Auvinen, T., Hakulinen, L. e Malmi, L. (2015) “Increasing Students’ Awareness of Their Behavior in Online Learning Environments with Visualizations and Achievement Badges”. *IEEE Transactions on Learning Technologies*, 8, 261–273. DOI: <https://doi.org/10.1109/TLT.2015.2441718>
- Bittencourt, I.I. e Isotani, S. (2018) “Informática na Educação baseada em Evidências: Um Manifesto”. *Revista Brasileira de Informática na Educação*, 26, 108. DOI: <https://doi.org/10.5753/rbie.2018.26.03.108>

- Bzuneck, J.A. e Boruchovitch, E. (2016) “Motivação e Autorregulação da Motivação no Contexto Educativo”. *Psicologia: Ensino & Formação*, 7, 75–84. DOI: <https://doi.org/10.21826/2179-58002016727584>
- Dweck, C.S. (1986) “Motivational Processes Affecting Learning”. *American Psychologist*. DOI: <https://doi.org/10.1037/0003-066X.41.10.1040>
- Dweck, C.S. e Elliott, E.S. (1983) “Achievement motivation”. In: Mussen, P.H. e Hetherington, E.M. (eds.) *Handbook of Child Psychology: Socialization, Personality, and Social Development*. Wiley, New York, pp. 643–691.
- Elliot, A.J. e Church, M.A. (1997) “A hierarchical model of approach and avoidance achievement motivation”. *Journal of Personality and Social Psychology*, 72, 218–232.
- Elliot, A.J. e McGregor, H.A. (2001) “A 2 × 2 achievement goal framework”. *Journal of Personality and Social Psychology*, 80, 501–519. DOI: <https://doi.org/10.1037/0022-3514.80.3.501>
- Elliot, A.J. e Murayama, K. (2008) “On the Measurement of Achievement Goals: Critique, Illustration, and Application”. *Journal of Educational Psychology*, 100, 613–628. DOI: <https://doi.org/10.1037/0022-0663.100.3.613>
- Elliot, A.J., Murayama, K. e Pekrun, R. (2011) “A 3 × 2 achievement goal model”. *Journal of Educational Psychology*, 103, 632–648. DOI: <https://doi.org/10.1037/a0023952>
- Elliott, E.S. e Dweck, C.S. (1988) “Goals: An approach to motivation and achievement”. *Journal of Personality and Social Psychology*, 54, 5–12. DOI: <https://doi.org/10.1037/0022-3514.54.1.5>
- Harackiewicz, J.M., Barron, K.E., Tauer, J.M., Carter, S.M. e Elliot, A.J. (2000) “Short-term and long-term consequences of achievement goals”. *Journal of Educational Psychology*, 92, 316–330.
- Hayamizu, T. e Weiner, B. (1991) “A Test of Dweck’s Model of Achievement Goals as Related to Perceptions of Ability”. *Journal of Experimental Education*, 59, 226–234. DOI: <https://doi.org/10.1080/00220973.1991.10806562>
- He, Z., Xia, W., Dong, K., Guo, H., Tang, R., Xia, D. e Zhang, R. (2022) “Unsupervised Learning Style Classification for Learning Path Generation in Online Education Platforms”. In: *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. ACM, New York, pp. 2997–3006.
- Jiang, B., Li, X., Yang, S., Kong, Y., Cheng, W., Hao, C. e Lin, Q. (2022) “Data-Driven Personalized Learning Path Planning Based on Cognitive Diagnostic Assessments in MOOCs”. *Applied Sciences*, 12. DOI: <https://doi.org/10.3390/app12083982>
- Morozevich, E.S., Korotkikh, V.S. e Kuznetsova, Y.A. (2022) “The development of a model for a personalized learning path using machine learning methods”. *Business Informatics*, 16, 21–35. DOI: <https://doi.org/10.17323/2587-814X.2022.2.21.35>
- Niemivirta, M. (2002) “Motivation and performance in context: The influence of goal orientations and instructional setting on situational appraisals and task performance”. *Psychologia – An International Journal of Psychology in the Orient*, 45, 250–270. DOI: <https://doi.org/10.2117/psysoc.2002.250>

- Pulkka, A. e Niemivirta, M. (2013) “Predictive relationships between adult students’ achievement goal orientations, course evaluations, and performance”. *International Journal of Educational Research*, 61, 26–37. DOI: <https://doi.org/10.1016/j.ijer.2013.03.015>
- Ramos, D. B., Ramos, I. M. M., Gasparini, I. e De Oliveira, E. H. T. (2021) “A new learning path model for e-learning systems”. *International Journal of Distance Education Technologies*, v. 19, n. 2, p. 20–40.
- Ramos, D. B., Ramos, I. M. M., Nascimento, P. B.; Amaral, G. S.; Harada, Elaine. (2017) “Um Modelo para Trilhas de Aprendizagem em um Ambiente Virtual de Aprendizagem”. In: *Simpósio Brasileiro De Informática Na Educação (SBIE)*, 28., Recife/PE. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, p. 1407-1416
- Romero, M., Hernández, J.M., Juola, J. F., Casadevante, C. e Santacreu, J. (2019) “Goal Orientation Test: An Objective Behavioral Test”. *Psychological Reports*. DOI: <https://doi.org/10.1177/0033294119845847>
- Santos, A. A. A. dos, Alcará, A. R. e Zenorini, R. da P. C. (2013) “Estudos psicométricos da escala de motivação para a aprendizagem de universitários”. *Fractal: Revista de Psicologia*, 25, 531–546. DOI: <https://doi.org/10.1590/s1984-02922013000300008>
- Tibúrcio, Nadiane Maria da Silva e Fonseca, Géssica Fabiely (2021) “A relação teoria e prática no ensino de psicologia educacional na UFRN: experiências de uma monitoria”. *Revista de Casos e Consultoria*, v. 12, n. 1, p. e24516-e24516
- Zenorini, R. da P.C. e Santos, A.A.A. dos (2010) “Escala de Metas de Realização como Medida da Motivação para Aprendizagem”. *Interamerican Journal of Psychology*, 44, 291–298.