

Um Modelo baseado em Trilhas de Aprendizagem para a Representação de Alunos de Ambientes Virtuais de Aprendizagem

David Brito Ramos¹, Elaine Harada Teixeira de Oliveira²

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

² Instituto de Computação – Universidade Federal do Amazonas (UFAM) – Manaus – AM – Brasil.

david@ifam.edu.br, elaine@icomp.ufam.edu.br

Abstract. *This work describes a model based on Learning Paths for the representation of students in Virtual Learning Environments. It can help to identify the student's motivational profile, based on the Achievement Goals Theory. As additional results of the research there is a taxonomy for the learning strategies, the relationship between the achievement goals and the learning strategies, the relationship between the achievement goals and the proposed taxonomy, a software registry. From the experiments, it was confirmed that it is possible to suggest learning strategies according to the goal orientation and to classify the goal orientations of students with F1-Score above 80%.*

Resumo. *Este trabalho descreve um modelo baseado em Trilhas de Aprendizagem para a representação de alunos de Ambientes Virtuais de Aprendizagem. Ele é capaz de auxiliar da identificação do perfil motivacional do aluno, fundamentado na Teoria de Metas de Realização. Como resultados adicionais da pesquisa tem-se uma taxonomia para as estratégias de aprendizagem, a relação entre as metas de realização e as estratégias de aprendizagem, a relação entre as metas de realização e a taxonomia proposta, e um registro de software. Dos experimentos, confirmou-se que é possível sugerir estratégias de aprendizagem de acordo com a orientação de metas e classificar as orientações de metas dos alunos com F1-Score acima dos 80%.*

1. Introdução

Este artigo (resumo da tese de mesmo nome, defendida e aprovada no dia 21 de outubro de 2022 perante o Instituto de Computação da Universidade Federal do Amazonas) apresenta um modelo de representação de alunos por meio de identificação das trilhas de aprendizagem (TA). As TA foram utilizadas para identificação do comportamento, em específico a orientação de metas/motivação, abordagem fundamentada na Teoria de Metas de Realização [Ames 1984; Dweck 1986; Dweck e Elliott 1983], desenvolvida na área da psicologia educacional. As TA estão fundamentadas nas ações de interação de alunos utilizando um ambiente virtual de ensino-aprendizagem (AVA), registradas no banco de dados, não sendo necessária uma coleta de dados mais direta, como o preenchimento de pesquisas e questionários. As TA representam de forma natural o

comportamento do aluno, pois são criadas sem interferências diretas do professor [Gutiérrez et al. 2006; Ramos et al. 2015].

É possível ainda auxiliar recomendações de grupos de aluno para a realização de atividades colaborativas [Ramos et al. 2017], acompanhar a evolução de um aluno ao longo do tempo [Ramos et al. 2016], verificar a influência dos recursos disponibilizados com as taxas de aprovação e reprovação, associar o comportamento do aluno a tendências de evasão, verificar quais tipos de trilhas estão correlacionadas ao desempenho positivo do aluno, e também contribuir para a criação de AVAs adaptativos.

2. Trabalhos Relacionados

Os artigos a seguir foram extraídos de uma Revisão Sistemática da Literatura (RSL) que buscou identificar como as TA são representadas pelos diferentes trabalhos da literatura [Ramos et al. 2015].

O artigo de Sitthisak, Gilbert e Albert [2013], apresenta a implementação da Teoria de Espaço de Conhecimento por Competência. O modelo adota a ideia de que as questões/problemas estão ligadas formando um grafo de dependência ou uma rede. Os problemas podem ser associados com objetos de aprendizagem (OA), criando também relação entre os problemas/questões e os OA necessários. O trabalho de [Marquez et al. 2008] apresenta o uso de Otimização de Colônia de Formiga e Redes Bayesianas para adaptar as TA. O trabalho considera que um LMS inteligente poderia recomendar ou impor o próximo curso baseado nos resultados recentes do usuário em cursos passados e na trilha de aprendizagem (do professor) de maior sucesso tomado pela maioria dos usuários (alunos). COW é um sistema de *workflow* para o ensino aberto e à distância que utiliza o *Educational Modeling Languages* (EML) que expressa link de atividades e recursos utilizados por elas e é usado para criar as TA. O COW apresenta as TA utilizando a ideia de processos e subprocessos [Vantroys e Peter 2003].

Os trabalhos a seguir utilizaram de alguma forma o comportamento dos alunos em AVAs em suas pesquisas. Kadoic e Oreski [2018] compararam os dados dos logs com a notas finais e encontram correlação estatística relevante entre a abertura de arquivos e as notas. Concluíram também que alunos ativos nos fóruns tendem a utilizar mais os arquivos, os períodos de maior atividade são nas vésperas dos testes e nos períodos da tarde e noite. O trabalho de Auvinen, Hakulinen e Malmi [2015] utilizam mapas de calor e emblemas de conquista para aumentar o entendimento do aluno sobre o próprio comportamento. Alunos que buscam mostrar que são mais capazes tiveram interesse maior nos emblemas, alunos que tentam evitar situações em que possam parecer incapazes se identificaram mais com os mapas de calor.

Os trabalhos a seguir utilizam perfil e/ou comportamento dos estudantes para realizar a geração de TA personalizadas. O estudo de Morozevich, Korotkikh e Kuznetsova [2022] apresenta a construção de um modelo para a personalização de TA baseado em perfil e reações ao material didático, no contexto organizacional. Para a realização das recomendações, o sistema coleta o perfil do funcionário, o perfil organizacional e dados dos treinamentos. Essas informações são utilizadas pelo módulo de recomendações para apresentar uma nova atividade/material didático. O trabalho de [He et al. 2022], apresenta uma proposta de classificação de estilos de aprendizagem de forma não supervisionada, para analisar os padrões comportamentais de aprendizagem. Baseado nisso, são geradas TAs que são fornecidas aos usuários. Para a modelagem eles

usam logs de comportamento que incluem eventos tais como, clicar, criar, ler e escrever. Um modelo treinado é criado e utilizado para fazer a predição de estilos de aprendizagem. O estilo predito, juntamente com o material de aprendizagem, serve de entrada de dados para a geração de TA. O estudo de [Jiang et al. 2022] propõe um algoritmo de geração e recomendação de TA baseado nos seguintes estados de aprendizagem: não aprendido, não dominado, insuficientemente dominado e dominado. Os comportamentos de aprendizagem são obtidos quando os alunos assistem às videoaulas, tais como: repetir, acelerar ou pular partes do vídeo. O algoritmo proposto gera caminhos de aprendizagem personalizados aos estudantes. Os autores concluem que a abordagem é capaz de melhorar as taxas de conclusão de curso, de comportamento e eficiência de aprendizado.

Conclui-se que os trabalhos relacionados mostram que a grande parte das aplicações das pesquisas buscam primeiro projetar os AVAs de forma a coletar dados previamente estabelecidos, entretanto quando os propósitos desses ambientes são muito específicos, fica mais difícil de aplicar a mesma abordagem dos trabalhos em um outro cenário. Além disso, as ações de mapear, catalogar e organizar materiais de aprendizagem não são triviais e nem são realizadas em todos os AVAs. Dessa forma, nossa principal contribuição, com este trabalho, é a criação de um modelo de representação de aluno baseado em TA independente de catalogação de recursos e atividades, e de coleta de dados explícita, com abordagem flexível que pode ser aplicada a diferentes AVAs.

3. Métodos

Primeiramente, foram realizadas pesquisas na literatura sobre TA, modelos de comportamento de estudante e outros assuntos relacionados com esta pesquisa. Também foi realizada uma pesquisa de campo, onde foram coletados dados reais de um AVA. Um modelo, baseado em grafos, para a representação das TA foi criado. A partir dele foram criadas métricas como a medida de dispersão. Também é possível utilizar medidas estatísticas como média, desvio padrão e variância sobre os dados de acesso dos vértices.

Para elaboração dos experimentos, foi selecionado um instrumento para a identificação da orientação de metas em alunos, que tivesse como público-alvo estudantes do ensino superior e fosse validado em língua portuguesa. Assim, para os experimentos, foi aplicado o instrumento Escala de Motivação para a Aprendizagem de Universitários (EMAPRE-U) [Santos et al. 2013; Zenorini e Santos 2010], para identificar a motivação de aprendizagem de cada participante e utilizar essa informação para classificar a sua trilha de aprendizagem.

Posteriormente foi elaborado um conjunto de estratégias de aprendizagem (EA) a serem tomadas, a partir de trabalhos da literatura. Com o auxílio de duas pesquisadores da psicologia educacional foi elaborada uma taxonomia com a qual classificou-se cada estratégia do conjunto previamente proposto. As EA foram associadas às orientações de metas da escala EMAPRE-U. A associação serviu para auxiliar o participante (aluno) na escolha de uma estratégia de aprendizagem [Beluce e Oliveira 2016; Boruchovitch et al. 2006; Martins e Zerbini 2014], por meio de um sistema de recomendações de EA.

De posse desse conjunto de informações, foram aplicadas técnicas de mineração de dados e aprendizagem de máquina [Artero 2009], para encontrar padrões de TA para cada meta de realização (modelo de comportamento), com os quais também é possível realizar predições de orientação a partir de novas entradas de dados. Nesse ponto, os dados das TA foram organizados de forma a servirem de entrada para os algoritmos de

mineração de dados e aprendizagem de máquina. Foi implementada uma ferramenta para o AVA Moodle, no formato de plugin, que posteriormente foi adaptado para o ambiente CodeBench [CodeBench 2020], onde o modelo proposto foi utilizado nos experimentos. Foi implementado um Sistema de Recomendação de Estratégias de Aprendizagem (SisREA) baseadas na orientação de metas do aluno. Nele, foi possível coletar a opinião dos alunos a respeito das recomendações. Também foi avaliado o percentual de acertos de classificação das metas de realização.

3.1 Arquitetura e questão de pesquisa

Como a proposta é um novo modelo baseado em TA, foi necessário buscar informações sobre os alunos dentro de um AVA. Para o estudo de caso dessa pesquisa foi selecionado o AVA CodeBench, que é um juiz online para programação utilizado pelo Instituto de Computação (IComp) da Universidade Federal do Amazonas (UFAM) nas disciplinas introdutórias de programação, onde foi possível aplicar o modelo na prática. A arquitetura proposta considera a implementação da prova de conceito para o CodeBench, mas pode ser aplicada a outros ambientes com as devidas adaptações. A Figura 1 representa a arquitetura de trabalho utilizada. Os estudantes interagem com o LMS que faz os registros das ações no banco de dados, na sequência, os dados de logs são analisados para extrair as trilhas de aprendizagem seguindo o modelo apresentado. Via questionário validado [Santos et al. 2013], são coletados os dados necessários para a identificação da meta do aluno. A arquitetura é formada pelo: modelo do estudante, que é composto pelas TAs e as orientações de metas de realização (MR) de cada estudante; EA; Módulo de classificação do estudante; e módulo de recomendação das EA. Pretende-se, por meio desse modelo, possibilitar a criação de ferramentas de apoio ao docente. Byun et al. [2014] afirmam que a diferença nos hábitos de estudos faz a diferença no desempenho acadêmico. Seria relevante identificar o comportamento do aluno, e baseado nesse conhecimento, tomar decisões que melhorem o processo de ensino-aprendizado. Assim, a seguinte questão de pesquisa foi formulada: É possível utilizar as trilhas de aprendizagem para a identificação de comportamento de alunos?

Assim, busca-se a partir das informações disponíveis no próprio AVA e utilizando as TA, criar um modelo que permita ao professor obter o comportamento de seus alunos.

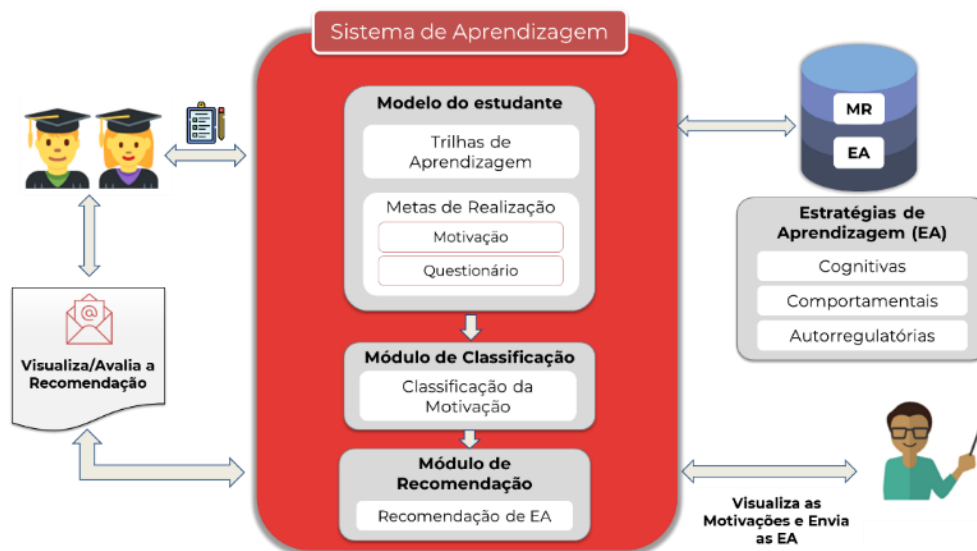


Figura 1. Arquitetura de trabalho.

4. Resultados

Como resultados da pesquisa temos o modelo de representação de TA, a taxonomia das EA, a relação entre as metas de realização e as EA, a relação entre as metas de realização e a taxonomia. Dos experimentos, confirmou-se que é possível sugerir EA de acordo com a orientação de metas e também usar as TA para classificar as orientações de metas dos alunos. Para coletar as orientações de metas dos alunos, foi utilizado um instrumento validado por pesquisadores da área de psicologia educacional chamado Escala de Motivação de Aprendizes Universitários. A partir de estudos anteriores e participação de duas psicólogas, foi elaborada uma taxonomia para a classificação das EA e um conjunto de EA classificadas de acordo a taxonomia proposta.

4.1 Modelo de trilhas de aprendizagem

As TA do modelo são formadas a partir do histórico de acesso do aluno, que fica armazenado em banco de dados. O histórico é construído com base no cruzamento de dados de diversas tabelas, tendo como ponto central os registros de histórico de acesso que indicam quando e quais recursos e atividades foram acessados pelos alunos. Dessa forma, é possível ordenar cronologicamente os eventos ocorridos durante a interação do aluno com o AVA.

Uma vez ordenados, os registros apresentam a sequência de navegação do aluno pelos recursos e atividades do AVA. A partir da observação dessa estrutura e dos estudos realizados anteriormente, em [Ramos et al. 2015; Ramos e Oliveira 2015], conclui-se que era possível a utilização da estrutura de grafos para a representação das TA. Para o conteúdo de um curso, podem ser adicionados recursos e atividades. Os recursos são conteúdos, em geral, estáticos, também chamados de materiais didáticos. As atividades são conteúdos que requerem uma participação mais ativa dos aprendizes, permitindo a interação entre eles e que podem ser utilizadas como ferramenta de avaliação pelo docente. Tarefas, chats, fóruns e questionários são exemplos de atividades. O modelo de TA proposto utiliza o grafo dirigido como forma de representação. Os vértices representam os recursos e atividades do AVA. A navegação (caminho) do aluno entre os vértices formam as arestas. O caminho do aluno é obtido por meio da sequência ordenada pelo tempo do registro do AVA. Mais detalhes sobre o modelo podem ser obtidos em [Ramos et al. 2021]. Como o modelo baseia-se nos dados gerados e armazenados pelo AVA, é possível acompanhar a evolução da TA do aluno ao longo do tempo. O modelo pode ser utilizado analisar dados de uma turma já encerrada, ou durante o decorrer das aulas. Isso porque o modelo é flexível e permite a representação de dados que podem ser delimitados por um intervalo de tempo.

4.2 Taxonomia para estratégias de aprendizagem

A partir dos trabalhos sobre escalas de estratégias de aprendizagem: EAEF [Boruchovitch et al. 2006], Martins-Zerbini [Martins e Zerbini 2014], EEAM-AVA [Beluce e Oliveira 2016] e EEA-U [Boruchovitch e Santos 2015], foi iniciada uma pesquisa sobre os tipos de EA. Buscando uma harmonização das terminologias e o agrupamento de itens semelhantes, elencou-se os fatores apresentados em cada trabalho e verificou-se uma possível disposição destes fatores dentro de uma estrutura hierárquica (taxonomia).

Estabeleceu-se como base da taxonomia a separação entre estratégias primárias e autorregulatórias, esta que este estudo considera ser termo equivalente para metacognitivas, e a Ausência de utilização de estratégia/Desmotivação em um mesmo

tipo. Em seguida, buscou-se estabelecer uma relação com os fatores apresentados nas escalas estudadas. Dessa forma, chegou-se a primeira versão da taxonomia. Para testar sua validade, realizou-se um teste piloto no qual dois pesquisadores, a orientadora e o orientando, aplicaram a taxonomia, a um conjunto de 110 itens extraídos dos trabalhos listados no início da seção. Foi dada também a opção de marcar “em dúvida”, caso o pesquisador não tivesse certeza em qual fator classificar o item analisado. Após a criação da versão preliminar da taxonomia, entrou-se em contato com as autoras do EMAPRE-U, onde foi pedido uma colaboração para verificar se a taxonomia proposta era válida. Uma das autoras respondeu indicando duas doutorandas suas, pesquisadoras especialistas em psicologia educacional. Em um primeiro momento, elas receberam as orientações para realizar as seguintes tarefas: 1) Validação da taxonomia sobre tipos de EA – foi solicitado às pesquisadoras que avaliassem se havia inconsistências na taxonomia proposta, bem como se elas acrescentariam mais tipos, ou os distribuiriam de forma diferente, ou se os conceitos precisariam ser melhorados. 2) Classificação dos itens das escalas – foi solicitado às pesquisadoras que classificassem, cada item de um conjunto de itens de escalas de EA utilizando a taxonomia proposta. Em seguida, as pesquisadoras enviaram suas considerações sobre a taxonomia e a classificação dos itens das escalas. Levando em consideração todas as contribuições das pesquisadoras especialistas, foi possível chegar a uma versão final para a taxonomia de EA nesta pesquisa, conforme a Figura 2 a seguir.

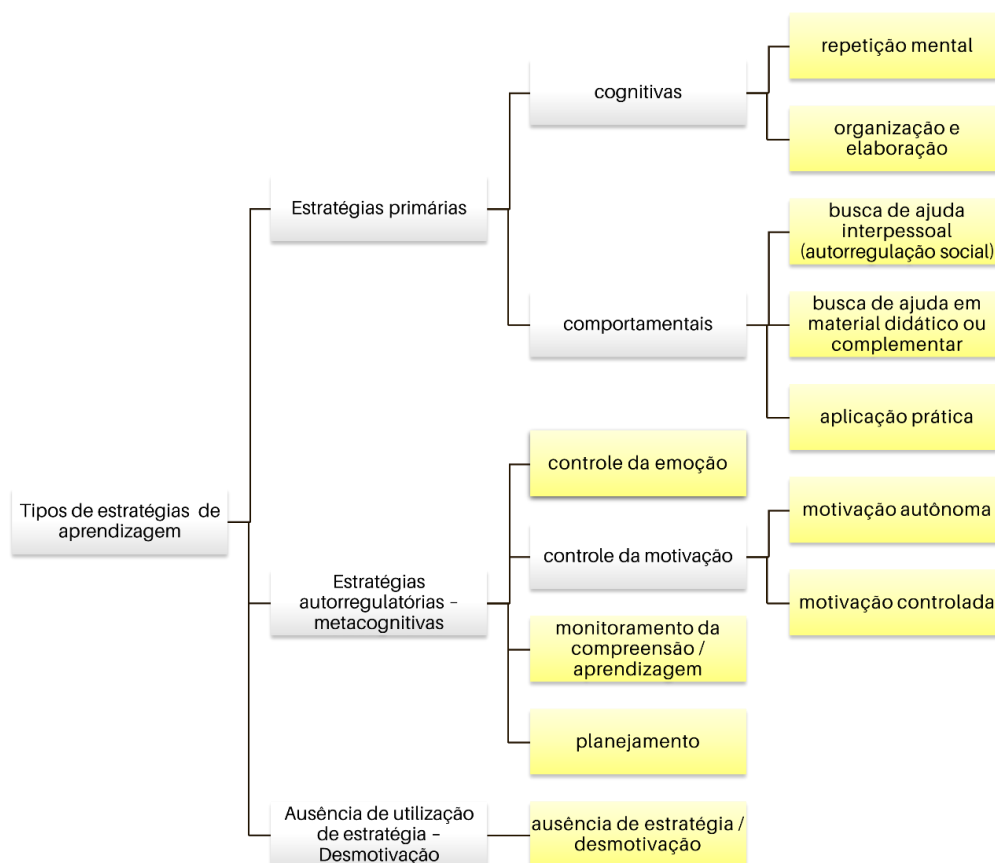


Figura 2. Taxonomia das estratégias de aprendizagem.

4.3 Relação entre as metas de realização e estratégias de aprendizagem

A busca de uma escala que possa avaliar a motivação do aluno decorre da necessidade de se utilizar instrumentos validados durante a pesquisa. Na busca pelo instrumento validado, com suas propriedades psicométricas analisadas e aceitas, e considerando os instrumentos analisados, foi selecionado o EMAPRE-U [Santos et al. 2013]. O instrumento EMAPRE-U, disponível em [Ramos 2020], é um instrumento em língua portuguesa validado ao contexto universitário, devidamente aprovado pela avaliação de suas propriedades psicométricas. O instrumento possui três metas de realização: meta Aprender, meta Performance-aproximação e a meta Performance-evitação. O instrumento é respondido em uma escala de Likert de três pontos: “Discordo”, “Não sei” e “Concordo”.

Dessa forma, outra contribuição foi apresentar um conjunto de EA relacionadas a cada uma das metas de realização do EMAPRE-U [Santos et al. 2013]. Foi realizado o levantamento de um conjunto de evidências que relacionam as metas de realização aos tipos de EA. Como a pesquisa utilizou o EMAPRE-U, buscou-se na literatura trabalhos que mencionassem as metas do instrumento e as estratégias de aprendizagem relacionadas. É possível, por exemplo, afirmar que a meta Aprender está relacionada com a EA de repetição mental [Kadioğlu e Kondakci 2014; Koopman et al. 2014; Shyr et al. 2017], que a meta Performance-aproximação está relacionada com EA do tipo organização e elaboração [Diseth 2011; Kadioğlu e Kondakci 2014; Shyr et al. 2017], ou que a meta Performance-evitação está relacionada com Motivação controlada [Beluce e Oliveira 2016]. A tabela completa está em [Ramos 2022].

Assim, seguindo as evidências levantadas, obteve-se a relação entre a taxonomia proposta, Figura 2, e as metas de realização da escala EMAPRE-U. Identificou-se que há relação positiva entre as metas Aprender e Performance-aproximação e todos os tipos de estratégia apresentados na taxonomia, enquanto a meta Performance-evitação está relacionada com alguns itens apenas.

As EA foram extraídas de escalas de EA validadas na literatura: EAEF [Boruchovitch et al. 2006], Martins-Zerbini [Martins e Zerbini 2014], EEAM-AVA [Beluce e Oliveira 2016] e EEA-U [Boruchovitch e Santos 2015]. A relação final de EA, já classificadas de acordo com a taxonomia proposta, e que compõe a base de estratégias do sistema de recomendação de EA estão listadas no Quadro 19 da tese de [Ramos 2022].

4.4 Experimento de recomendação de estratégias de aprendizagem

Esta seção descreve os experimentos e resultados decorrentes da aplicação do modelo no juiz online para aulas de programação chamado CodeBench. Foram realizados dois experimentos, um para a classificação de metas e outro para a recomendação de EA. Os participantes destes experimentos foram os alunos da disciplina Introdução a Programação de Computadores (IPC/ICC), que aceitaram participar da pesquisa. Foram coletados dados nos semestres 2019/02 e 2020/ERE (Ensino Remoto Emergencial).

Para a recomendação de EA, o SisREA (registro de software, processo N°: BR512023001731-0) foi a ferramenta criada a partir do modelo de TA. Os estudantes responderam ao EMAPRE-U [Santos et al. 2013; Zenorini e Santos 2010], para identificar a motivação de aprendizagem e utilizar essa informação para classificar as TA. O SisREA foi aplicado junto a um sistema de aprendizagem, no formato de juiz online [CodeBench 2020], no qual os estudantes, de cursos superiores de diversas áreas, aprendem conceitos

de programação, nos semestres 2019/2 (152 estudantes) e 2020/1 (152 estudantes), ao todo, 304 estudantes. Com os estudantes já classificados, o docente pode acessar o SisREA para fazer as recomendações de EA, conforme a Figura 3.

| Aluno | ID Triha | Motivacao | Nível de Aprender | Nível de Aproximação | Nível de Evitação | Estratégias |
|----------|----------|---------------|-------------------|----------------------|-------------------|---|
| Aluno 01 | 599 | meta aprender | 87.98 | 5.29 | 6.73 | Ler textos complementares, além dos indicados pelo professor. ▾ |

[Enviar Recomendação](#)

Figura 3. Enviando recomendação para uma turma.

O estudante recebe a recomendação em seu e-mail, no qual aparecem a EA e uma classificação na escala de Likert, em formato cinco estrelas. As avaliações dos estudantes ficam então armazenadas e podem ser utilizadas para identificar as melhores recomendações. Como a participação na pesquisa foi voluntária, nem todos os alunos que concordaram em participar da pesquisa responderam às recomendações de EA. Ao todo, 41 alunos avaliaram a recomendações recebidas. Desse total, 20 são do sexo masculino, 21 do feminino e a média de idade dos participantes foi de 24,7 anos. Assim, os alunos receberam sugestões de EA de acordo com suas orientações de motivação.

Foram obtidas 60 avaliações de recomendação, que classificaram ao todo 22 EA das 70 fornecidas no SisREA. A média geral das recomendações foi de 4,3 em uma escala de Likert de 5 pontos. Estratégias do tipo “Busca de Ajuda em Material Didático ou Complementar” foram as que obtiveram as melhores avaliações.

4.5 Experimento de classificação de metas de realização

Para o experimento de classificação de metas, os dados analisados são de alunos das turmas de Introdução a Programação de Computadores (IPC), do período 2020/ERE (Ensino Remoto Emergencial). Em decorrência da Pandemia, as aulas foram totalmente remotas, e como eram turmas de regime especial, a participação dos alunos era optativa. Os alunos foram divididos em três turmas, a saber: Manhã, Tarde e Noite. Todas as turmas possuíam o mesmo docente e continham o mesmo conjunto de recursos e atividades. As aulas, que eram sempre às segundas e quartas-feiras, iniciaram em 09 de setembro de 2020 e encerram em 16 de dezembro de 2020, com a Prova Final. Também ficou a critério dos alunos em qual das turmas participar.

Nos experimentos iniciais de classificação a acurácia era muito alta devido a base estar desbalanceada, uma vez que os algoritmos tendiam a classificar os estudantes como da base predominante. Na base original, havia 140 estudantes da meta Aprender, 7 da meta Performance-aproximação e 21 da meta Performance-evitação (n=168). Assim os classificadores rotulavam os dados de testes como da meta Aprender. 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.

Ao fim da pesquisa, os dados coletados foram analisados em intervalos de dados distintos. O objetivo dessa forma de análise foi verificar a partir de quanto tempo os algoritmos apresentariam melhores resultados e/ou se haveria uma crescente na melhora

nos resultados com o passar do tempo. Para o estabelecimento dos intervalos de dados, levou-se em consideração o planejamento de ensino da disciplina, esta foi apresentada aos alunos e já era do cotidiano do docente. O início da coleta de dados se deu em 03 de setembro, que foi o dia em que o curso ficou disponível. As datas de fim de coleta que compõe os intervalos de dados correspondem ao prazo final de entrega das atividades, que são divididas por assunto, conforme plano de ensino da disciplina. Exceto pelas duas primeiras datas de fim de coleta (16/09 e 30/09), isso porque também seria verificado se com dados iniciais dos alunos seria possível realizar uma classificação satisfatória ($f-1 \geq 0.8$).

A Figura 4 apresenta os resultados de classificação para cada algoritmo aplicado. Os algoritmos baseados em árvores, Random Forest e Árvore de decisão, obtiveram resultados melhores. Os resultados também mostram que três semanas após o início oficial das aulas (09/09), há uma melhora nos resultados dos primeiros algoritmos e mantém-se assim até o intervalo mais longo de coleta de dados.

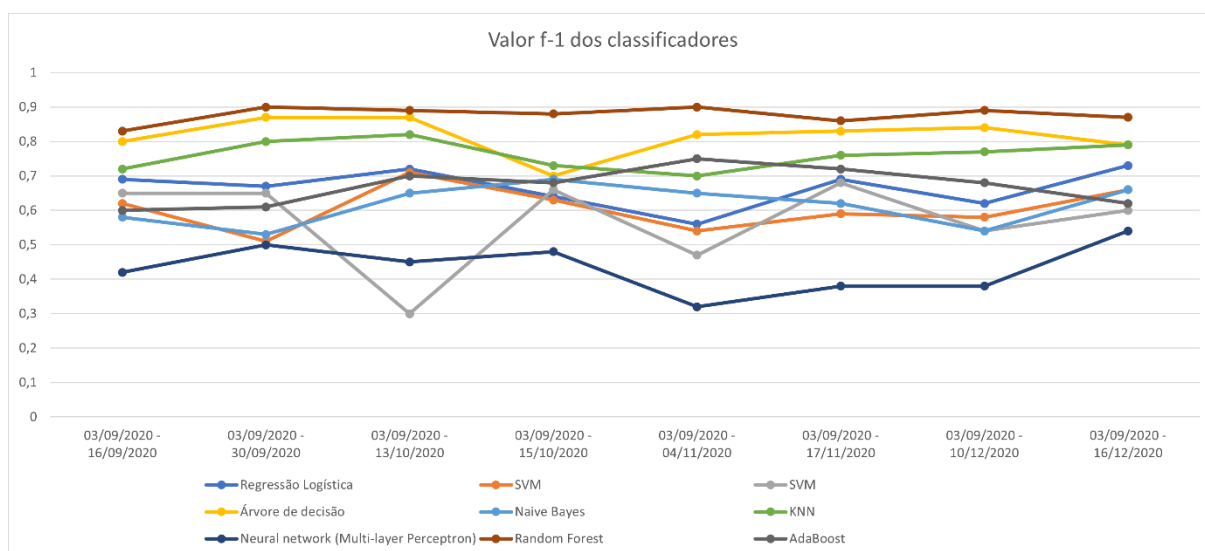


Figura 4. Resultados da classificação.

5. Conclusão

Este trabalho apresentou um modelo de representação de alunos baseado nas TA em AVAs. A arquitetura geral foi projetada pensando na flexibilidade, tais como a utilização de outros instrumentos que avaliam as metas de realização, bem como inclusão de novas EA.

Para as recomendações de EA, obteve-se a média 4,3 na escala de Likert de cinco pontos. Isso é um indicativo de que as EA recomendadas estavam, em sua maioria, de acordo com as metas de realização dos alunos. No experimento de classificação, obteve-se F1-Score acima dos 80% para os algoritmos Árvore de decisão e Random Forest ao classificar a motivação/meta de realização dos estudantes de acordo com as TAs. Inclusive com menos de um mês do início das aulas. Com o passar do tempo, os resultados de classificação praticamente se mantêm o mesmo. Isso pode indicar que a motivação do aluno se manteve igual ao longo da disciplina.

Por fim, foi possível identificar e extrair os dados de acessos dos alunos da base de dados do CodeBench, e a partir deles gerar o modelo do aluno identificando as TA. Com o uso do questionário EMAPRE-U, foi possível utilizar a teoria das metas de realização, para identificar o comportamento dos alunos que juntamente com as TA formaram o modelo de comportamento.

Por meio de experimentos práticos, usando algoritmos de classificação, foi possível identificar as metas com uma boa precisão. Além disso, de posse da identificação das metas de realização, foi possível recomendar EA aos alunos.

Com isso, todos os objetivos do trabalho foram alcançados e se conclui que é possível utilizar TA para identificar o comportamento dos alunos, respondendo à questão de pesquisa.

Agradecimentos

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e do Instituto Federal de Educação, Ciência e Tecnologia do Estado do Amazonas – IFAM Campus Parintins. O primeiro autor também agradece a Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) pela bolsa de pesquisa concedida por meio do Programa PROINT/AM (Edital N° 003/2018).

References

Ames, C. (1984). Competitive, cooperative and individualistic goal structures: A motivational analysis. *Research on motivation in education. Vol. 1: Student motivation*, v. 1, p. 177–207.

Artero, A. O. (2009). *Inteligência Artificial: Teoria e Prática*. 1. ed. São Paulo: Livraria da Física.

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*, v. 8, n. 3, p. 261–273.

Beluce, A. C. e Oliveira, K. L. De (2016). “Escala de estratégias e motivação para aprendizagem em ambientes virtuais”. *Revista Brasileira de Educação*, v. 21, n. 66, p. 593–610.

Boruchovitch, E. e Santos, A. A. A. Dos (2015). “Psychometric studies of the learning strategies scale for university students”. *Paideia*, v. 25, n. 60, p. 19–27.

Boruchovitch, E., Santos, A. A. A. Dos, Da Costa, E. R., et al. (2006). “A construção de uma escala de estratégias de aprendizagem para alunos do ensino fundamental”. *Psicologia: Teoria e Pesquisa*, v. 22, n. 3, p. 297–304.

Byun, J., Pennington, D., Cardenas, J., Dutta, S. e Kirwan, J. (2014). “Understanding student behaviors in online classroom: Data scientific approach”. *Proceedings - 2014 IEEE International Congress on Big Data, BigData Congress 2014*, p. 802–803.

CodeBench (2020). CodeBench. <http://codebench.icomp.ufam.edu.br/>.

Diseth, Å. (2011). “Self-efficacy, goal orientations and learning strategies as mediators between preceding and subsequent academic achievement”. *Learning and Individual Differences*, v. 21, n. 2, p. 191–195.

Dweck, C. S. (1986). Motivational Processes Affecting Learning. *American Psychologist*,

Dweck, C. S. e Elliott, E. S. (1983). Achievement motivation. In: Mussen, P. H.; Hetherington, E. M.[Eds.]. . *Handbook of child psychology: Socialization, personality, and social development*. New York: Wiley. p. 643–691.

Gutiérrez, S., Pardo, A. e Kloos, C. (2006). “Finding a learning path: toward a swarm intelligence approach”. *Proceedings of the 5th IASTED ...*,

He, Z., Xia, W., Dong, K., et al. (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.* , KDD '22. Association for Computing Machinery. <https://doi.org/10.1145/3534678.3539107>.

Jiang, B., Li, X., Yang, S., et al. (2022). “Data-Driven Personalized Learning Path Planning Based on Cognitive Diagnostic Assessments in MOOCs”. *Applied Sciences*, v. 12, n. 8.

Kadioğlu, C. e Kondakci, E. U. (2014). “Relationship between Learning Strategies and Goal Orientations: A Multilevel Analysis”. *Eurasian Journal of Educational Research*, v. 14, n. 56, p. 1–20.

Kadoic, N. e Oreski, D. (2018). “Analysis of student behavior and success based on logs in Moodle”. *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2018 - Proceedings*, p. 654–659.

Koopman, M., Bakx, A. e Beijgaard, D. (2014). “Students’ goal orientations and learning strategies in a powerful learning environment: A case study”. *Studies in Educational Evaluation*, v. 43, p. 186–196.

Marquez, J. M., Ortega, J. A., Gonzalez-Abril, L. e Velasco, F. (2008). “Creating adaptive learning paths using Ant Colony Optimization and Bayesian Networks”. In *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. . IEEE.

Martins, L. B. e Zerbini, T. (2014). “Escala de Estratégias de Aprendizagem: evidências de validade em contexto universitário híbrido”. *Psico-USF*, v. 19, n. 2, p. 317–328.

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*, v. 16, n. 2, p. 21–35.

Ramos, D. B. (2020). “Motivação e Estratégias de Aprendizagem”. https://1drv.ms/b/s!Ar47uyek2bmwlqBZli1JnN_ZzxnIbA?e=dHg07e.

Ramos, D. B. (2022). “Um modelo baseado em trilhas de aprendizagem para a representação de alunos de ambientes virtuais de aprendizagem”. Tese de Doutorado. Programa de Pós-Graduação em Informática da Universidade Federal do Amazonas.2022.

Ramos, D. B. e Oliveira, E. H. T. De (2015). “Relatório Técnico da Revisão Sistemática de Literatura sobre Trilhas de Aprendizagem em Ambientes Virtuais de Aprendizagem.”. <https://1drv.ms/b/s!Ar47uyek2bmwlqBtQmOITavExcXWbQ?e=mdh2fj>.

Ramos, D. B., Ramos, I. M. M., Gasparini, I. e Oliveira, E. H. T. De (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. Do e Oliveira, E. H. T. De (2016). “Uma Ferramenta Baseada em Grafo para Identificação e Visualização de Trilhas de Aprendizagem”. *Nuevas Ideas en Informática Educativa*, v. 12, p. 237–243.

Ramos, D., Oliveira, E., Monteverde, I. e Oliveira, K. (2015). “Trilhas de Aprendizagem em Ambientes Virtuais de Ensino-aprendizagem: Uma Revisão Sistemática da Literatura”. In *Anais do XXVI Simpósio Brasileiro de Informática na Educação (SBIE 2015)*. . <http://br-ie.org/pub/index.php/sbie/article/view/5182>.

Ramos, I. M. M., Ramos, D. B., Amaral, G. de S., et al. (2017). “M-Cluster: Uma ferramenta de Recomendação para Formação de Grupos em Ambientes Virtuais de Aprendizagem”. In *Simpósio Brasileiro de Informática na Educação (SBIE)*. . <http://www.br-ie.org/pub/index.php/sbie/article/view/7697>.

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*, v. 25, n. 3, p. 531–546.

Shyr, W.-J., Feng, H.-Y., Zeng, L.-W., Hsieh, Y.-M. e Shih, C.-Y. (2017). “The Relationship between Language Learning Strategies and Achievement Goal Orientations from Taiwanese Engineering Students in EFL Learning”. *EURASIA Journal of Mathematics, Science and Technology Education*, v. 13, n. 10, p. 6431–6443.

Sitthisak, O., Gilbert, L. e Albert, D. (2013). “Learning in Moodle using Competence-Based Knowledge Space Theory and IMS QTI”. In *Computer Science and Engineering Conference (ICSEC), 2013 International*.

Vantroys, T. e Peter, Y. (2003). “COW, a Flexible Platform for the Enactment of Learning Scenarios”. In: Favela, J.; Decouchant, D.[Eds.]. . *Groupware: Design, Implementation, and Use (Lecture Notes in Computer Science)*. Berlim: Springer. v. 2806p. 168–182.

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*, v. 44, n. 2, p. 291–298.