



Recibido: 25 outubro 2022

Revisto: 10 junho 2024

Aceite: 1 julho 2024

Endereço dos autores:

<sup>1</sup> Instituto Federal de Educação, Ciência e Tecnologia Farroupilha - Campus Alegrete - RS-377 - Km 27 - Passo Novo - Alegrete/- Rio Grande do Sul, CEP: 97555-000 (Brasil)

<sup>2,3 y 4</sup> Universidade Federal do Rio Grande do Sul. Av. Paulo Gama, 110 - Bairro Farroupilha - Porto Alegre - Rio Grande do Sul, CEP: 90040-060 (Brasil)

E-mail / ORCID

[andrea.sachete@iffarroupilha.edu.br](mailto:andrea.sachete@iffarroupilha.edu.br)

 <https://orcid.org/0000-0003-2226-3322>


[raquel.salcedo@ufrgs.br](mailto:raquel.salcedo@ufrgs.br)

 <https://orcid.org/0000-0001-9497-513X>

[alberto.canto@ufrgs.br](mailto:alberto.canto@ufrgs.br)

 <https://orcid.org/0000-0003-0822-3797>

[valdenilima@gmail.com](mailto:valdenilima@gmail.com)

 <https://orcid.org/0000-0002-7266-4856>

## ARTIGO / ARTICLE

# Indicadores da aprendizagem adaptativa em ambientes virtuais de aprendizagem: Revisão Sistemática da Literatura

## Indicators of adaptive learning in virtual learning environments: Systematic Literature Review

Andréia dos Santos Sachete<sup>1</sup>, Raquel Salcedo Gomes<sup>2</sup>, Alberto Bastos Canto Filho<sup>3</sup> e José Valdeni de Lima<sup>4</sup>

**Resumo:** As Tecnologias Digitais da Informação e Comunicação atuam como aliadas ao contexto educacional, tornando-o mais dinâmico por meio dos Ambientes Virtuais de Aprendizagem. O sistema adaptativo baseia-se em soluções/ferramentas tecnológicas, que permitem customizar os processos de ensino de acordo com as singularidades do estudante. Diante disso, realizamos uma Revisão Sistemática da Literatura (RSL) para elucidar quais indicadores de desempenho educacionais são mais utilizados para guiar a aprendizagem adaptativa em ambientes virtuais de aprendizagem. Para tanto, adotamos os princípios do Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) como protocolo de revisão sistemática, e como suporte operacional utilizamos a ferramenta online Parsifal. A busca inicial nas bases de dados - IEEE, ACM e Scopus - retornou 276 artigos. Após a filtragem baseada no protocolo, restaram 16 artigos que fazem parte do corpus de análise e discussão. Os resultados da RSL indicam que a maioria dos indicadores utilizados para direcionamento das atividades se baseia no acerto e no erro das questões. Isso mostra que ainda há muito a ser implantado no que tange a adaptabilidades de aprendizagem em ambientes virtuais, pois para uma avaliação da aprendizagem mais holística, é necessário considerar um conjunto integrado desses indicadores, e não apenas análises individualizadas.

**Palavras-Chave:** Aprendizagem Adaptativa, Indicadores de Aprendizagem, Ambientes Virtuais de Aprendizagem, Ensino Personalizado, Ambientes Adaptativos.

**Abstract:** Digital Information and Communication Technologies act as partners in the educational context, making it more dynamic through Virtual Learning Environments (VLEs). The adaptive system is based on technological solutions/tools, which allow the customization of teaching processes according to the student's singularities. Therefore, we conducted a systematic literature review (SLR) to elucidate which educational performance indicators best guide adaptive learning in virtual learning environments. To this end, we adopted the principles of Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) as a systematic review protocol, and as operational support, we used the online tool Parsifal. The initial database search - IEEE, ACM, and Scopus - returned 276 articles. After filtering based on the protocol, 16 articles remained part of the analysis and discussion corpus. The RSL results indicate that most of the indicators used to guide activities are based on the correctness and error of the questions. This shows that there is still much to be implemented in learning adaptability in virtual environments; for a more holistic assessment of learning, it is necessary to consider an integrated set of these indicators and not just individualized analyses.

**Keywords:** Adaptive Learning, Learning Indicators, Virtual Learning Environments, Personalized teaching, Adaptive environment


## 1. Introdução

O avanço tecnológico proporcionou novas possibilidades de comunicação que minimizam barreiras geográficas e passam a integrar o cotidiano. Assim, as Tecnologias Digitais da Informação e Comunicação (TDICs) estão presentes em todas as áreas de conhecimento, passando a atuar como aliadas ao contexto educacional, tornando-o mais dinâmico por meio dos Ambientes Virtuais de Aprendizagem (AVAs). Para Moresco e Behar (2003), os AVAs são ambientes computacionais com recursos tecnológicos, que proporcionam um lugar de troca de informações, reflexão, estabelecimento de relações, elaboração de projetos e pesquisa aos estudantes. Estes espaços devem ser providos “de uma estrutura composta de funcionalidades, interface e proposta pedagógica, enriquecida de códigos simbólicos, por representações, imagens, sons, movimentos e dispositivos de comunicação síncrona e/ou assíncrona” (Moresco e Behar, 2003).

Dessa maneira, um ambiente de aprendizagem virtual é uma plataforma on-line usada para fins educacionais, que englobam os ambientes que atuam como suplementares ao curso, sejam eles recursos de leitura, sites informativos com avaliações de habilidades autônomas ou outras formas de aprendizagem virtual centradas no estudante. Na aprendizagem centrada no estudante, o professor dá ao aluno mais controle sobre o que, como e quando aprende um determinado tópico. Esse grau de interação pessoal torna os alunos mais ativos em seu próprio processo de aprendizagem e tem demonstrado resultados significativos (Behar, 2013).

No entanto, a utilização de recursos tecnológicos não necessariamente efetiva a aprendizagem com maestria. Para tanto, além dos componentes do sistema de Ensino (currículo e seus resultados pretendidos, métodos de ensino usados, tarefas de avaliação) estarem alinhados entre si, faz-se necessário refletir acerca de metodologias que ultrapassem fórmulas prontas, numa perspectiva em que os métodos de ensino e aprendizagem estejam alinhados às necessidades dos alunos.

Tradicionalmente, a maioria dos AVAs oferecem a postagem de atividades de avaliação aos estudantes de forma sequencial, como demonstra o fluxo de conteúdos e atividades de um módulo de ensino, na Figura 1. Esse módulo é percorrido com a finalidade de cumprir um objetivo educacional, e para tanto, conta com material instrucional (que pode ser hipertexto, mídias, documentos, entre outros) e de atividades para avaliação do conhecimento.

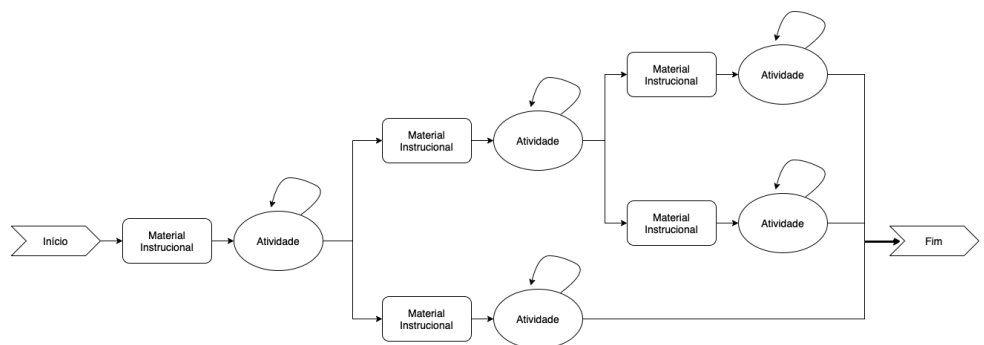


**Figura 1.** Fluxo de um curso com configuração padrão no Moodle.  
Fonte: Dados da pesquisa elaborados pelos autores.

Na Figura 2, demonstra-se uma trajetória de aprendizagem, que se adaptaria às dificuldades dos estudantes e poderia ser integrada aos AVAs. Nesse mesmo sentido, existem propostas desenvolvidas que permitem a implementação da aprendizagem adaptativa (Maravanyika, Dlodlo e Jere, 2017). A aprendizagem adaptativa (Zhao & Wang, 2019) se utiliza de modelos adaptativos, que vão desde artefatos tecnológicos até sistemas inteligentes, podendo ser utilizados em colaboração com ambientes tradicionais de ensino.

A aprendizagem adaptativa é uma forma de personalização do ensino, que compreende a elaboração de métodos de aprendizagem que consideram as singularidades e preferências dos estudantes, para atribuir mais sentido à construção de conhecimentos. De acordo com Despotovic-Zrakic (2012) a aprendizagem adaptativa também pode ser chamada de plataformas orientadas para o aluno, ambientes adaptativos, sistemas adaptativos ou sistemas personalizados.

Os materiais didáticos com foco na aprendizagem adaptativa são elaborados para se adaptar aos níveis de conhecimento e às necessidades dos educandos, buscando elevar seus níveis de aprendizagem, e permitindo que cada aluno trilhe seu próprio caminho para alcançar os objetivos do curso ou da disciplina, criando, dessa forma, várias trajetórias dentro do mesmo conteúdo ou curso.



**Figura 2.** Exemplo de Fluxo de aprendizagem adaptativa.  
Fonte: Dados da pesquisa elaborados pelos autores.

Algumas propostas de aprendizagem adaptativa podem ser observadas na literatura. Por exemplo, o Moodle<sup>1</sup> oferece suporte à inserção de plugins que podem ofertar atividades condicionais<sup>2</sup> implementadas no formato de questionários<sup>3</sup>, e usa o acerto ou o erro das questões<sup>4</sup> como indicador de aprendizagem para definir se o estudante pode avançar no nível de aprendizado. Hasibuan, Nugroho e Santosa (2018) propõem prever o aprendizado dos estudantes através de um questionário paralelo à

<sup>1</sup> O Moodle é um dos ambientes virtuais de aprendizagem (AVAs) (Behar, 2013) mais utilizados (Gomes e Pimentel, 2021), pois oferece uma gama de possibilidades em termos de exibição de conteúdos (como hipertextos, links, documentos, etc.), e uma variada quantidade de diferentes tipos de avaliações (fóruns, envio de arquivos, questionários, etc.). A sua expansão se deve a vários motivos, entre eles, ser de código aberto, escalável e flexível em termos de configuração. Além disso, obedece a padrões de interoperabilidade (Sharable Content Object Reference Model - SCORM) que facilita a transferência de conteúdo entre diferentes plataformas (Yan et al., 2010).

<sup>2</sup> [https://docs.moodle.org/22/en/Conditional\\_activities\\_settings](https://docs.moodle.org/22/en/Conditional_activities_settings)

<sup>3</sup> [https://moodle.org/plugins/availability\\_quizquestion](https://moodle.org/plugins/availability_quizquestion)

<sup>4</sup> <https://www.rasch.org/rmt/rmt22g.htm>

atividade e realizar um mapeamento das respostas baseadas no modelo VARK (*Visual, Auditory, Read/Write, Kinesthetic*), com objetivo de desvelar as fortalezas e fraquezas de aprendizado. Da mesma forma, Pitigala, Gunawardena; Hirakawa e Liyanage (2013) utilizam um questionário em paralelo às atividades, e sobre as respostas, aplicam um modelo FLSM (*Felder-Silverman Learning Style Model*) que dimensiona o estudante entre visual ou verbal, ativo ou reflexivo, sequencial ou global. Esse modelo permite avaliar a relação do estudante com os objetos de aprendizagem, e qual a melhor forma para esse estudante processar a informação.

Li e Abdul Rahman (2018), Azzi e Radouane (2020), e Sheeba e Krishnan (2018) propõem o uso de modelos probabilísticos baseados na interação do estudante com o sistema, que após treinamento, recomendam personalizações de atividades mais adaptadas aos estudantes.

A relevância desta RSL está em considerar a multidimensionalidade da condição humana, afirmando que a aprendizagem é algo muito mais complexo de ser apreendido e avaliado, não podendo ser captado apenas pela verificação de uma métrica booleana. Diante disso, levantamos a seguinte questão de pesquisa: Quais indicadores de desempenho educacionais são mais utilizados na literatura para direcionar o ensino e a aprendizagem de forma personalizada e adaptativa em ambientes virtuais de aprendizagem?

As revisões sistemáticas que relacionam ambientes virtuais de aprendizagem e aprendizagem adaptativa têm uma preocupação maior em descrever as ferramentas utilizadas para realizar a adaptação da aprendizagem (Fontaine et al., 2017; Zawacki - Richter et al., 2019; Martin et al., 2020; Li et al., 2021; Shemshack e Spector, 2020), do que desvendar o conjunto de indicadores de aprendizagem necessários para que a aprendizagem adaptativa ocorra. No entanto, atualmente, a bibliografia tem discutido uma série de indicadores de desempenho educacionais que também deveriam ser levados em consideração (Camillo & Raymundo, 2019; Miquelante et al., 2017; Moraes, 2014). Com o intuito de fomentar uma discussão acerca do tema abordado, que é relevante tanto para os processos tecnológicos quanto pedagógicos no contexto de ensino e aprendizagem on-line, esta RSL pretende elucidar a questão de pesquisa descrita anteriormente. Esta RSL se diferencia das anteriores ao buscar apresentar e discutir métricas de desempenho educacional que ainda não foram abordadas em revisões anteriores. Além disso, esta revisão pretende integrar perspectivas multidimensionais, considerando a complexidade da condição humana e a necessidade de uma abordagem mais personalizada e adaptativa no ensino on-line. Dessa forma, esperamos contribuir para um avanço significativo na compreensão e aplicação de métricas educacionais em plataformas virtuais, promovendo um ensino mais eficaz e centrado no aluno.

## 2. Metodologia

A RSL é um mecanismo de identificação, avaliação e interpretação de todas as pesquisas disponíveis e relevantes para um determinado fenômeno de interesse. Uma parte essencial que a compõe é o protocolo, pois serve como base para o planejamento e a condução da revisão. Assim, adotamos os princípios do Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) como protocolo de revisão sistemática (Page et al., 2021).

O protocolo PRISMA inicia pela busca de artigos usando strings de busca em bases de dados e/ou em outras fontes de dados. No caso dessa revisão sistemática de literatura, optou-se por buscar artigos apenas em bases de dados científicas. Após o retorno das buscas, os artigos são filtrados baseados em duplicidade, critérios de inclusão e exclusão, análise de qualidade, e por fim, os artigos restantes são aqueles que farão parte do corpus de discussão que irão sustentar as respostas às perguntas de pesquisa investigadas.

Esta revisão sistemática da literatura apresenta algumas limitações, que são listadas a seguir: (1) A busca foi realizada apenas em artigos escritos em língua inglesa, por ser uma língua franca em termos de pesquisa científica. (2) Somente foram pesquisados artigos mantidos pelas três bibliotecas digitais mais comumente citadas em outras RSLs, a saber: *ACM Digital Library*, *IEEE Xplore* e *Scopus*. (3) Não adotamos Snowballing (Wohlin, 2014), que é uma técnica que permite a inclusão no corpus de pesquisa de referências dos artigos aceitos, que atendam os critérios de inclusão e exclusão. (4) Como suporte operacional, utilizamos a ferramenta online *Parsifal*. A seguir, descrevemos os critérios de elegibilidade, fontes de informação, estratégia de pesquisa, registros de estudo e síntese de dados recomendados na parte de métodos da lista de verificação PRISMA. Usando a estratégia PICO (*Population, Intervention, Comparison, Outcomes*), especificamos as características dos estudos a serem incluídos em nossa revisão: (a) População: virtual learning environment; (b) Intervenção: adaptive learning; (c) Resultados: indicator, metric, criterion, index. Criamos os critérios de inclusão e exclusão para definir a qualidade dos artigos que seriam extraídos das bases. Os critérios de inclusão escolhidos foram: (1) Artigos escritos em língua inglesa. (2) Artigos publicados a partir do ano de 2016 ao ano de 2023. (3) Artigos que sejam estudos primários e (4) Estudos relacionando AVAs e aprendizagem adaptativa. Os critérios de exclusão. Como escolhidos foram: (1) Artigos que não são relacionados com pesquisas. (2) Artigos que são de revisão ou meta-revisão. (3) Artigo que seja versão mais antiga de outro artigo já considerado nesta RSL.

Os critérios de inclusão foram estabelecidos para garantir que os artigos selecionados estejam alinhados com os objetivos e escopo da pesquisa, sendo escritos em inglês para facilitar a compreensão e acesso global, publicados nos últimos cinco anos para assegurar a atualidade das informações, sendo estudos primários para fornecer informações originais e relevantes, e relacionando AVAs e aprendizagem adaptativa para atender ao foco específico da pesquisa. Por outro lado, os critérios de exclusão foram estabelecidos para remover artigos que não contribuam diretamente para a pesquisa, como aqueles que não são estudos primários, e artigos que são versões mais antigas de artigos já considerados, garantindo assim a relevância e eficácia da RSL.

Realizamos uma busca automática nas fontes de informação utilizando uma string de pesquisa que combina palavras-chave e sinônimos relacionados a dois domínios principais: ambientes virtuais de aprendizagem, aprendizagem adaptativa e seus indicadores, que se traduz na seguinte forma:

("virtual learning environment" OR "VLE" or "distance education" OR "virtual education" OR "e-learning") AND ("adaptive learning" OR "adaptive teaching" OR "adaptive system" OR "adaptive educational learning") AND (metric OR criterion OR index OR indicator)

Depois de termos todos os arquivos de exportação da pesquisa, os incluímos na ferramenta digital de gerenciamento de dados Parsifal, que oferece opções de importação e suporta as próximas etapas, como verificação automática de estudos duplicados e a possibilidade de rotular manualmente cada artigo como aceito ou rejeitado.

A combinação dos arquivos exportados criou uma base com todos os documentos candidatos. Primeiro, excluímos duplicatas em um processo automático pela ferramenta Parsifal. Em seguida, analisamos os títulos e excluímos todos os artigos que incluíam a palavra "revisão" para limitá-los aos estudos primários. Após, examinamos manualmente os nomes dos periódicos, porque alguns resultados do Scopus não estavam relacionados ao contexto educacional e excluímos artigos das áreas de saúde, veterinária e outras áreas. Assim, lemos o título e o resumo dos demais candidatos seguindo os critérios de inclusão e exclusão definidos para refinar os resultados. Não consideramos artigos que atendessem a pelo menos um critério de exclusão. Por outro lado, um artigo a ser incluído na lista final precisa contemplar todos os critérios de inclusão.

Após a aplicação dos critérios de inclusão e exclusão, lemos os artigos e aplicamos uma lista de verificação de avaliação de qualidade nesta seleção restante. O formulário de avaliação da qualidade tinha cinco questões e respostas com pesos específicos: sim (2,0), parcialmente (1,0), não especificado (0,0) e não (-0,5). As questões utilizadas podem ser vistas abaixo:

- Q1. O artigo descreve como são mensuradas as dificuldades dos estudantes?
- Q2. A aprendizagem adaptativa é guiada por alguma métrica?
- Q3. A proposta foi implementada na forma de um artefato digital? (ou é só uma proposta?)
- Q4. A aprendizagem adaptativa está implementada sobre um AVA?
- Q5. Os resultados oferecem dados de avaliação qualitativa ou quantitativa?

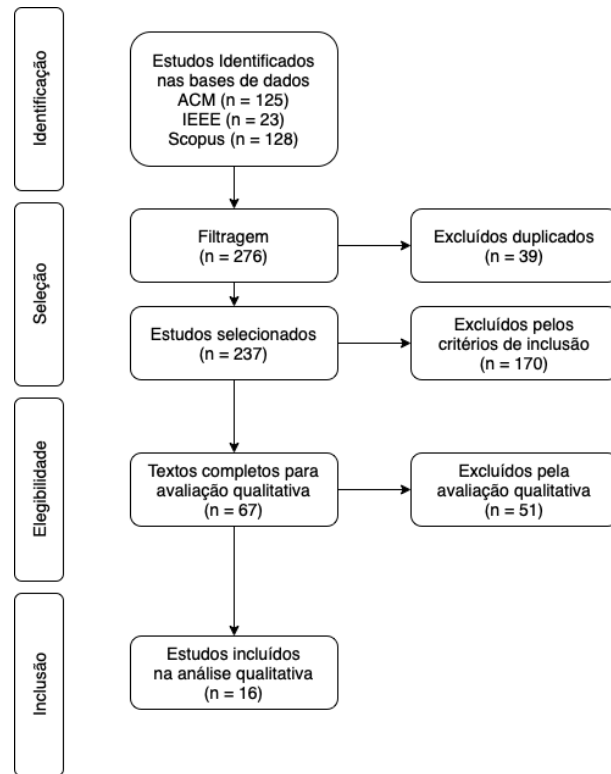
A pontuação máxima foi de 10,0, calculada a partir do número de questões e da resposta de maior peso. Portanto, aceitamos 4,9 como pontuação de corte. Consequentemente, após a leitura do conteúdo, foram excluídos os artigos com pontuação inferior à pontuação de corte.

Após a leitura integral dos estudos, extraímos metadados e demais informações relevantes à nossa pesquisa. Dentre esses dados, incluem-se o país, o ano, as métricas utilizadas para orientar a aprendizagem adaptativa, a implementação de ferramentas de aprendizagem adaptativa em Ambientes Virtuais de Aprendizagem, e quais AVAs são empregados para tal fim.

### **3. Resultados**


Esta revisão sistemática da literatura foi realizada em conformidade com o protocolo descrito na seção anterior. A Figura 3 ilustra o processo detalhado das fases da revisão. Inicialmente, a seleção automatizada retornou 276 registros ao aplicar a string de pesquisa nas bases de dados previamente mencionadas. Desses, 39 artigos duplicados foram removidos. A análise dos títulos e resumos permitiu a pré-seleção de 67 estudos,

que atendiam aos critérios de inclusão e exclusão estabelecidos. Por fim, aplicou-se a lista de verificação de qualidade para analisar os 67 trabalhos elegíveis, a qual resultou em 16 artigos selecionados.




**Figura 3.** Protocolo da revisão sistemática baseada no PRISMA.  
Fonte: Dados da pesquisa extraídos pelos autores.

A Figura 4 apresenta a porcentagem de artigos que foram recuperados pela string de busca em cada uma das três bases de dados utilizadas neste estudo. Percebe-se que, a maioria dos artigos encontrados sobre o tema foram retornados pela Scopus, possivelmente devido ao fato de que muitos artigos indexados em outras bases também estão presentes na Scopus.



**Figura 4.** Quantidade de artigos retornados em cada base.  
 Fonte: Dados da pesquisa extraídos pelos autores.

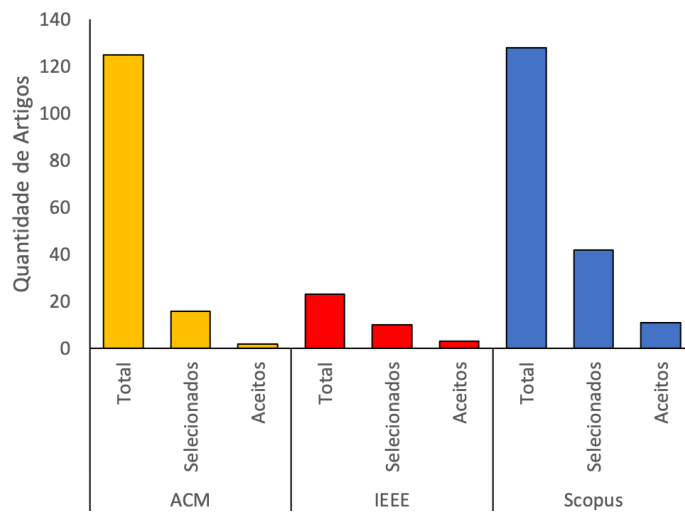
A Figura 5 apresenta uma estratificação dos resultados da busca, organizada com base no ano de publicação dos artigos retornados. Observa-se um aumento significativo no número de artigos publicados sobre esse tema em 2023, indicando um contínuo interesse e pesquisa por parte da comunidade científica em propor e desenvolver soluções nessa área.



**Figura 5.** Artigos recuperados estratificados por ano.  
 Fonte: Dados da pesquisa extraídos pelos autores.

A Figura 6 apresenta, por base de dados, a quantidade de artigos que foram selecionados na primeira fase e, após, na segunda fase.





**Figura 6.** Artigos seleccionados e aceitos pelos critérios por base de dados.  
Fonte: Dados da pesquisa extraídos pelos autores.

Nessa etapa, percebeu-se que alguns estudos não estavam alinhados com o objetivo da investigação. Apesar de 2022 e 2023 terem registrado o maior número de artigos selecionados pela string de busca, nenhum desses trabalhos discutiu as métricas utilizadas para orientar a aprendizagem adaptativa. Assim, dentre as pesquisas avaliadas, 16 obtiveram pontuação satisfatória na avaliação da qualidade, pois apresentavam e discutiam as métricas de interesse deste trabalho. Esses trabalhos são discutidos e sumarizados de maneira aprofundada para responder à questão de pesquisa dessa Revisão Sistemática de Literatura: Quais indicadores de desempenho educacionais são mais utilizados na literatura para direcionar o ensino e a aprendizagem de forma personalizada e adaptativa em ambientes virtuais de aprendizagem?

Rezaei e Montazer (2016) apresentam um sistema de aprendizagem adaptativa, que emprega uma metodologia de agrupamento para avaliar seu impacto na qualidade do ensino em um curso e-learning. Os autores se baseiam nos estilos de aprendizagem e dividem o sistema de agrupamento em quatro fases: identificação das estruturas dos grupos, classificação dos alunos nos grupos correspondentes, detecção da expiração e da modificação dos grupos. A implementação desse sistema demonstrou melhorias tanto na satisfação dos estudantes quanto no progresso acadêmico, evidenciando a eficácia do sistema de aprimorar os resultados educacionais dos estudantes.

A pesquisa de Dolores et al. (2017) propõem um modelo conceitual com seis indicadores de adaptabilidade em um MOOC, e a partir desse, elaboraram e aplicaram um questionário aos participantes. Os indicadores são: materiais didáticos acessíveis e resultados em atividades avaliadas; acesso aos conteúdos depende do ritmo de estudo; escolha entre diferentes níveis de dificuldade e métodos avaliativos; organização pela área de interesse; avaliação por pares organizada de acordo com a área de interesse/formação/nível de experiência. Dolores et al. (2017) concluíram que os participantes dão mais ênfase a dois dos indicadores: a adaptação ao ritmo de trabalho

pessoal e a diversidade nos níveis de dificuldade oferecidos para a obtenção de diferentes objetivos.

Su (2017) propõe um Sistema Híbrido de Recomendação de Caminhos de Aprendizagem Adaptativo, que foi projetado para integrar estilos de aprendizagem individuais, empregando lógica difusa, com o objetivo de sugerir itinerários educacionais personalizados. A determinação do estilo de aprendizagem de cada aluno é realizada por meio de uma pontuação baseada no desempenho e acertos dos estudantes. A eficácia da ferramenta foi avaliada em um estudo com um grupo experimental de 48 alunos, resultando em um aumento significativo na satisfação dos usuários com o serviço personalizado, alcançando índices de aprovação superiores a 90%.

Hamada e Hassan (2017) desenvolveram o Índice de Estilo de Aprendizagem Aprimorado, que expande o modelo de Felder-Silverman incorporando um sistema de avaliação do tipo Fuzzy e adicionando uma dimensão social-emocional. Essa metodologia foi implementada em um sistema de aprendizagem adaptativo, testando-a em uma amostra de 83 discentes do ensino médio. Os autores concluíram que o sistema pode permitir uma experiência de aprendizagem mais envolvente.

Cai (2018) descreve a implementação da plataforma Intellipath, que foi projetada para aprimorar a aprendizagem adaptativa em cursos online. O sistema proposto se ajusta com base em diagnósticos iniciais e avaliações contínuas (erro ou acerto), proporcionando uma experiência educacional que evolui conforme o progresso do estudante. A avaliação da implementação foi conduzida focando em critérios como envolvimento dos alunos, progressão, domínio do conteúdo e melhoria no desempenho acadêmico. O autor concluiu que os cursos que adotaram o modelo Intellipath observaram melhorias no desempenho dos alunos e taxas de aprovação mais elevadas.

Chrysafiadi, Troussas e Virvou (2018) centralizam sua investigação no aprimoramento dos sistemas de e-learning mediante uma nova estrutura para a criação de testes adaptativos online automatizados, que foi incorporada em dois sistemas de e-learning (um de tutoria inteligente para aprendizagem de línguas; um para aprendizagem de linguagens de programação). Esta abordagem recorre à análise de decisão de múltiplos critérios e ao modelo de soma ponderada para avaliar a adequação dos exercícios para os alunos, considerando o nível de conhecimento, o estilo de aprendizagem, o conhecimento prévio, os tipos de exercícios e o objetivo de aprendizagem desejável de acordo com a taxonomia de Bloom. A implementação proposta foi avaliada por especialistas em ciências da computação, instrutores da área correspondente e estudantes. Os resultados apontados por pelos autores destacaram a eficácia da abordagem proposta no reforço da adaptabilidade e personalização dos sistemas de e-learning, conduzindo a melhores resultados educativos e à satisfação dos alunos.

Barbagueletta et al. (2018) propõem o desenvolvimento de um protótipo para plataforma educacional para oferecer experiências de aprendizagem personalizadas para alunos do oitavo ano, utilizando atividades multimídia para o desenvolvimento de habilidades em geometria. As métricas empregadas para medir a aprendizagem dos alunos incluem estilos de aprendizagem, fator de dificuldade, taxas de sucesso na conclusão das atividades e comparações pré e pós-teste. Os resultados demonstraram

uma melhoria nos resultados de aprendizagem quando foram aplicados mecanismos adaptativos, independentemente de terem facilitado ou desafiado o processo de aprendizagem.

O artigo de Shubin et al. (2019) apresenta um modelo de implementação para sistemas adaptáveis em AVA, valendo-se da técnica de clusterização por meio de redes neurais. Essas redes são empregadas para classificar os alunos com base em sua performance nas atividades propostas, mediante a porcentagem de acertos e erros e, assim, ajustando as atividades subsequentes conforme o nível de conhecimento de cada estudante. Para tanto, os pesquisadores adotaram uma combinação de métricas, incluindo aspectos numéricos - que avaliam o tempo de estudo e repostas às questões -, verbais - capazes de identificar com qual subtópico o estudante está enfrentando dificuldade -, e grafos - que se concentram na precisão das repostas para determinar o grau de conhecimento do usuário.

O trabalho de Dounas et al. (2019) tem como objetivo aprimorar a compreensão do funcionamento dos sistemas adaptativos durante o processo de aprendizagem e melhorar seu design. Os pesquisadores conduziram um estudo empírico, no qual analisaram arquivos de log de 21 estudantes, registrados ao longo de um curso de três meses, oferecido em um AVA. A coleta de dados incluiu o comportamento dos alunos e as interações com o sistema, os resultados de avaliações e os recursos disponibilizados aos alunos. Com base neste estudo, recomendaram quatro critérios de avaliação: compatibilidade do material instrucional com o estilo de aprendizagem do aluno; equilíbrio entre navegação livre e guiada; fomento à comunicação entre alunos; opção de o estudante desabilitar o modo adaptativo.

Zaoud e Belhadaoui (2020) destacam a ausência de personalização nas plataformas de e-learning e propõem o modelo Learner Behavior Analytics, que usa User Behavior Analytics e Inteligência Artificial para ajustar constantemente o conteúdo educacional ao nível e estilo de aprendizagem do aluno. Adicionalmente, introduzem um novo sistema métrico, Score and Behavior Analytics, para avaliar o progresso do aluno por meio de pontuações - baseadas em erro e certo às respostas - e padrões comportamentais - tempo de resposta, cliques, qualidade das respostas. Entretanto, é válido destacar que Zaoud e Belhadaoui (2020) não especificam claramente em seu artigo a relevância das métricas empregadas, tampouco detalham essas métricas de maneira extensiva.

A pesquisa de Tnazefti - Kerkeni, Belaid e Talon (2020) discorre sobre a implementação de uma arquitetura de aprendizagem personalizada, com as seguintes propriedades: um modelo de aluno, estratégias de aprendizagem de acordo com o perfil dos estudantes e estratégias de aprendizagem personalizadas. No entanto, o trabalho encontra-se em fase de desenvolvimento, focando inicialmente na finalização da ontologia aplicada ao modelo do aluno, que utiliza agentes inteligentes para rastrear as atividades dos discentes (número de vezes que ele teve que realizar o exercício até acertá-lo; tempo na plataforma; tempo para resolver cada atividade) dentro de um Learning Management Systems. Com base nesses dados, a ideia é gerar painéis inteligentes capazes de automatizar a detecção das dificuldades enfrentadas pelos estudantes, oferecendo alternativas ou soluções personalizadas.

D'aniello et al. (2020) investigam as altas taxas de evasão dos cursos online, atribuindo a causa primária à falta de motivação e engajamento dos discentes. Os

autores propõem uma abordagem que envolve o desenvolvimento de um sistema que utiliza Mapas Cognitivos Fuzzy para verificar a motivação e o engajamento (atividade no fórum, conclusão de tarefas e interação geral com a plataforma) dos estudantes. Com base nestas métricas, é gerado e entregue feedback personalizado para melhorar a experiência de aprendizagem dos estudantes.

Krechetov e Romanenko (2020) descrevem a possibilidade do desenvolvimento de soluções de aprendizagem adaptativas utilizando análise de big data e IA para atender a percursos de aprendizagem personalizados. Os autores utilizam um algoritmo genético para otimizar os caminhos de aprendizagem com base na relação entre o nível de conhecimento na conclusão do curso e o tempo gasto, visando a máxima retenção com mínimo investimento de tempo. Os resultados demonstraram melhorias significativas nas avaliações em diversas atividades educacionais.


Qu e Ogunkunle (2021) discutem o desenvolvimento de um algoritmo de aprendizado de máquina simples, que considera três índices de atributos de aprendizagem - conhecimento prévio, percepção de autoeficácia e colaboração entre pares - como variáveis em um espaço tridimensional de eficácia educacional. Para os autores, esta abordagem facilita o agrupamento dos alunos com base nos seus atributos de aprendizagem, fornecendo, assim, experiências de aprendizagem personalizadas. Os resultados foram demonstrados por meio da aplicação desse algoritmo, que mostrou a capacidade de criar clusters de alunos com atributos de aprendizagem semelhantes. Este agrupamento permitiu a previsão de conselhos de aprendizagem com vários graus de precisão em diferentes agrupamentos, mostrando o potencial deste algoritmo para melhorar o processo de tomada de decisão de aprendizagem adaptativa com base em análises abrangentes dos atributos de aprendizagem dos alunos.

Ghergulescu et al. (2021) propõem uma estrutura conceitual para um Sistema de Aprendizagem Adaptativa aprimorado por Inteligência Artificial. Essa estrutura amplia o Modelo de Domínio ao incorporar modelagem de sub-habilidades, visando fornecer aos educadores percepções mais aprofundadas, elevar o nível de consciência dos estudantes sobre sua proficiência em diferentes subcompetências e oferecer recomendações de aprendizagem mais eficazes. Além disso, o artigo apresenta o BuildUp Algebra Tutor, uma plataforma online dedicada ao ensino de Matemática. Para avaliar a eficácia da aprendizagem dos alunos, foram adotadas métricas como o progresso após receber uma dica e o progresso após cometer um erro, o que demonstrou que a identificação precisa de subcompetências e a oferta de suporte estruturado são estratégias eficazes para auxiliar os alunos a responder às perguntas com êxito. O sistema recebeu avaliações positivas dos alunos, destacando-se dos métodos tradicionais quanto à utilidade e facilidade de uso. Os autores também ressaltam o potencial do sistema em capacitar professores por meio de painéis inteligentes que fornecem informações sobre o conhecimento e progresso dos alunos. Além disso, o feedback da pesquisa apontou um impacto positivo nas métricas de autoavaliação dos alunos, incluindo um aumento na confiança.

Shabbir et al. (2021) propõem um modelo que enfatiza a identificação e o gerenciamento em tempo real dos estados motivacionais dos alunos por meio de uma estrutura de módulo duplo. Essa abordagem permite intervenções oportunas, como feedbacks, para aumentar o envolvimento dos alunos. A análise de arquivos de log foi sugerida, pelos autores, como método para detectar a motivação dos alunos em tempo

real, utilizando como indicadores o tempo de leitura, movimento do mouse e as respostas às questões, classificadas como corretas ou erradas, no final de cada tópico. Conforme os pesquisadores, a aplicação desse modelo demonstrou resultados promissores, aumentando significativamente o envolvimento dos alunos e reduzindo as taxas de abandono escolar.

Portanto, a análise dos trabalhos filtrados pela avaliação qualitativa apresenta diferentes indicadores para avaliar o conhecimento e a aprendizagem dos estudantes, e, assim, possibilitar que a aprendizagem adaptativa em AVA ocorra. A Figura 7 mostra que a maioria das pesquisas utiliza de erro e acerto como métrica para decidir qual percurso o aluno deve percorrer. No entanto, isso ainda é bastante simplista quando tratamos de uma aprendizagem efetiva dos estudantes.



**Figura 7.** Indicadores de aprendizagem utilizados.  
Fonte: Dados da pesquisa extraídos pelos autores.

A Tabela 1 expande a Figura 7, descrevendo, de forma sucinta, os autores dos 16 artigos investigados e os indicadores propostos, por cada um, para que a aprendizagem adaptativa aconteça. Nota-se, que alguns dos artigos empregam mais de uma métrica para orientar este tipo de aprendizagem.

Dessa maneira, observa-se que os trabalhos mencionados são capazes de identificar e ajustar dinamicamente os percursos educacionais, adaptando o conteúdo e as atividades de aprendizagem em resposta ao desempenho e às preferências dos alunos, tais como os estilos de aprendizagem, ritmo de trabalho e níveis de conhecimento prévio, entre outros fatores. Algumas das pesquisas abordadas implementam processos adaptativos que se orientam por mais de uma métrica, não se limitando apenas à correção das respostas em atividades. Essa abordagem permite um olhar mais detalhado no processo formativo do estudante. Os resultados dessas metodologias apontam para um aumento na satisfação dos alunos e na eficácia da aprendizagem.

**Tabela 1.** Indicadores de aprendizagem utilizados na aprendizagem adaptativa dos 16 artigos filtrados e sua autoria. Fonte: Dados da pesquisa extraídos pelos autores.

<b>Indicadores ou métricas</b>	<b>Autores</b>
Erro ou Acerto	Dolores et al. (2017) Su (2017) Cai (2018) Barbaguehatta et al. (2018) Dounas et al. (2019) Shubin et al. (2019) Zaoud e Belhadaoui (2020) Shabbir et al. (2021) Ghergulescu et al. (2021)
Tempo de Resolução	Zaoud e Belhadaoui (2020) Krechetov e Romanenko (2020) Tnazefti – Kerkeni et al. (2020)
Velocidade de Leitura	Shabbir et al. (2021)
Movimento/ cliques do mouse	Zaoud e Belhadaoui (2020) Shabbir et al. (2021)
Quantidade de Tentativas	Tnazefti – Kerkeni, Belaid e Tailon (2020)
Atividades Finalizadas	D'aniello et al. (2020)
Feedback	Ghergulescu et al. (2021)
Conhecimento Prévio	Chrysafiadi et al. (2018) Qu e Ogunkunle (2021) Chrysafiadi et al. (2018) Dolores et al. (2017)
Estilos de aprendizagem	Rezaei e Montazer (2016) Hamada e Hassan (2017) Chrysafiadi et al. (2018) Barbaguehatta et al. (2018)

#### **4. Discussão**

Embora seja uma proposta promissora, sobretudo atualmente, em que o ensino remoto e o ensino a distância estão em evidência, o resultado dessa Revisão Sistemática de Literatura nos mostra que a digitalização do ensino não está sendo aproveitada dentro do contexto da aprendizagem adaptativa, pois ainda verificamos a avaliação de aprendizagem da mesma forma que sempre ocorreu, utilizando, na maioria das vezes, apenas a correteude das respostas. Essa forma de avaliação remonta a um passado de pensamento cartesiano.

Desde o século XIX, prevalece a concepção de avaliação nos moldes do raciocínio lógico e da memorização. A primeira tentativa do que se tornaria aprendizagem adaptativa foi desenvolvida na década de 1950 com o trabalho de Skinner (1970). O autor desenvolveu uma máquina de ensino que tinha foco na construção incremental de habilidades. A máquina adaptava-se, oferecendo novas questões aos estudantes, tendo como base as respostas corretas anteriores, e fornecia aos estudantes um feedback imediato, além de possibilitar ao estudante avançar em seu próprio ritmo.

Assim, os resultados revelam que a aprendizagem adaptativa ainda é influenciada por um fator histórico de avaliação, associado com uma certa precaução sobre a complexidade da implementação. Quanto às questões históricas, o pragmatismo do Século 19 influenciou as primeiras propostas de aprendizagem adaptativa em Skinner, que tentaram de certa maneira, mecanizar a (auto)aprendizagem. A avaliação de aprendizagem era realizada baseando-se em erros e acertos por parte dos estudantes, pois a decisão binária era mecanicamente mais acessível ao desenvolvimento da proposta.

O que reconhecemos como tecnologia de aprendizagem adaptativa tem suas origens no desenvolvimento da inteligência artificial durante os anos 1970. Pesquisadores começaram a desenvolver sistemas que poderiam mimetizar a experiência do professor. Embora os sistemas que resultaram desse trabalho inicial tenham tido algum sucesso, o poder da computação e as tecnologias de inteligência artificial da época não eram avançadas o suficiente para uma inteligência complexa ou uso generalizado.

No entanto, a implementação via programação da aprendizagem adaptativa ainda é, em grande parte, binária, o que faz com que “novas” propostas ainda usem um modelo de escolhas booleanas que remonta desde sua primeira proposição. Portanto, o erro e o acerto ainda é a métrica predominante, devido à natureza das linguagens de programação, que tem como base, os desvios condicionais. Além disso, outros fatores podem ser visualizados, ainda tentando evitar a complexidade no desenvolvimento das soluções. O uso do tempo (despendido durante e na completude das atividades) como fator complementar para verificar aprendizagem remete a um gerenciamento da aprendizagem em termos de tempo discreto, que permite a observação da ação do estudante na forma de grandezas inteiras.

Em trabalhos práticos e futuras investigações, deve-se levar em consideração o avanço do poder de processamento disponível, as metodologias de desenvolvimento de sistemas de maneira rápida e a inteligência artificial que atingem patamares inéditos em termos de complexidade e sofisticação. Isso oferece suporte à implementação de modelos mais complexos de aprendizagem adaptativa. Tais modelos devem considerar diversos aspectos de conhecimento e aprendizagem dos estudantes em correlação para que, realmente, o aluno seja contemplado como sujeito de seu próprio percurso formativo. Dessa forma, ele será avaliado por seu processo formativo completo, e não apenas por suas respostas certas ou erradas em atividades e avaliações.

## 5. Conclusões

A aprendizagem adaptativa é um método de ensino e aprendizagem que considera as dificuldades e o ritmo individualmente, tendo como premissa a adaptabilidade do objeto educacional às necessidades específicas do estudante. Para que isto ocorra, os algoritmos presentes nas TDICs devem se remodelar, pois ao passo que o usuário interage com a plataforma, o sistema se atualiza dinamicamente, viabilizando ao estudante um direcionamento personalizado.

Considerando que cada pessoa tem à sua maneira e o seu tempo para a aprendizagem, e ressaltando que se busca adaptar as próprias TDICs para auxiliar neste processo, buscou-se com este trabalho encontrar na literatura existente, entre os anos de 2016 e 2023 os indicadores mais utilizados para guiar a aprendizagem adaptativa em ambientes virtuais de aprendizagem.

De acordo com os trabalhos revisados nesta RSL, há um amplo espaço para implementação de adaptações de aprendizado em ambientes virtuais. Isso ocorre porque o indicador amplamente utilizado para guiar a aprendizagem adaptativa consiste em acertos e erros das questões. A aprendizagem não pode ser reduzida a uma métrica tão reducionista ao ponto de não dar importância às questões sociais e emocionais que afetam diretamente o cognitivo. Isso destaca a necessidade premente em buscar e integrar um conjunto de novas métricas para promover uma adaptação da aprendizagem mais abrangente, e que possa levar em consideração questões mais humanizadas.

## 6. Referências

- Azzi, I., Jeghal, A., Radouane, A. *et al.* (2020). *A robust classification to predict learning styles in adaptive E-learning systems*. *Educ Inf Technol* 25, 437–448. <https://doi.org/10.1007/s10639-019-09956-6>
- Barbaguehatta D. E., Mellado S. R., Diaz B. F., Cubillos F.C., (2018). *X9: An Adaptive Learning Platform for Geometry at School Level*. 37th International Conference of the Chilean Computer Science Society (SCCC), 2018, pp. 1-9. DOI: 10.1109/SCCC.2018.8705242
- Behar, Patrícia Alejandra. (2013) *Competências em educação à distância*. Porto Alegre, Penso, 312 p. <https://doi.org/10.15448/2179-8435.2014.2.17803>
- Cai, R., (2018). *Adaptive Learning Practice for Online Learning and Assessment*. In *Proceedings of the 2018 International Conference on Distance Education and Learning (ICDEL '18)*. Association for Computing Machinery, New York, NY, USA, 103–108. <https://doi.org/10.1145/3231848.3231868>
- Camillo, E. J., & Raymundo, G. M. C. (2019). *Avaliação formativa na EAD: uma forma eficaz para (re) construção do conhecimento?* *Revista Exitus*, 9(3), 476-505. DOI: <https://doi.org/10.24065/2237-9460.2019v9n3ID925>
- Chrysaftadi, K., Troussas, C., Virvou, M., (2018). *A Framework for Creating Automated Online Adaptive Tests Using Multiple-Criteria Decision Analysis*. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 226-231. DOI: 10.1109/SMC.2018.00049
- D'aniello, G., De Falco, M., Gaeta, M.; Lepore, M.; (2020). *Feedback generation using Fuzzy Cognitive Maps to reduce dropout in situation-aware e-Learning systems*. *IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 202, pp. 195-199. DOI: 10.1109/CogSIMA49017.2020.9216177



- Despotovic-zrakic, M. *et al.* (2012). *Providing Adaptivity in Moodle LMS Courses*. Educational Technology & Society, v. 15 n. 1, p. 326–338.
- Dolores Lers, Mara Luisa Sein-Echaluce, Miguel Hernández, and Concepción Bueno. (2017). *Validation of indicators for implementing an adaptive platform for MOOCs*. Comput. Hum. Behav. 72, C (July 2017), 783–795. DOI: <https://doi.org/10.1016/j.chb.2016.07.054>
- Dounas, L., Salinesi, C., & El Beqqali, O. (2019). *Requirements monitoring and diagnosis for improving adaptive e-learning systems design*. Journal of Information Technology Education: Research, 18, 161-184. <https://doi.org/10.28945/4270>
- Fontaine G, Cossette S, Maheu-Cadotte MA, Mailhot T, Deschênes MF, Mathieu-Dupuis G. (2017). *Effectiveness of Adaptive E-Learning Environments on Knowledge, Competence, and Behavior in Health Professionals and Students: Protocol for a Systematic Review and Meta-Analysis*. JMIR Res Protoc. Jul 5;6(7):e128. DOI: 10.2196/resprot.8085
- Ghergulescu, I., Flynn, C., O'Sullivan, C., van Heck, I., and Slob, M. (2021). *A Conceptual Framework for Extending Domain Model of AI-enabled Adaptive Learning with Sub-skills Modeling*. In Proceedings of the 13th International Conference on Computer Supported Education (CSEDU 2021) - Volume 1, pages 116-123 ISBN: 978-989-758-502-9. DOI: 10.5220/0010451201160123
- Gomes, Alex Sandro; Pimentel, Edson Pinheiro. Ambientes. (2021). *Virtuais de Aprendizagem para uma Educação mediada por tecnologias digitais*. In: Pimentel, Mariano; Sampaio, Fábio F.; Santos, Edméa (Org.). Informática na Educação: ambientes de aprendizagem, objetos de aprendizagem e empreendedorismo. Porto Alegre: Sociedade Brasileira de Computação (Série Informática na Educação CEIE-SBC, v.5) Disponível em: <https://ieducacao.ceie-br.org/ava>
- Hamada, M., & Hassan, M. (2017). *An Enhanced Learning Style Index: Implementation and Integration into an Intelligent and Adaptive e-Learning System*. Eurasia Journal of Mathematics, Science and Technology Education, 13(8), 4449-4470. DOI:10.12973/eurasia.2017.00940a
- Hasibuan, M. S.; Nugroho, L.; Santos A, P.; (2018). *Prediction Learning Style Based on prior Knowledge for Personalized Learning*, 4th International Conference on Science and Technology (ICST), Yogyakarta, pp. 1-5. DOI: 10.1109/ICSTC.2018.8528572\_
- Inoue Y. (2012). *Virtual Reality Learning Environments*. In: Seel N.M. (eds) Encyclopedia of the Sciences of Learning. Springer, Boston, MA. [https://doi.org/10.1007/978-1-4419-1428-6\\_651](https://doi.org/10.1007/978-1-4419-1428-6_651)
- Krechetov, I.; Romanenko, V.; (2020). *Implementing the adaptive learning techniques, Educational Studies Moscow*, nº. 2, pp. 252–277. [Online]. Available: <https://vo.hse.ru/en/2020-2/373410249.htm> DOI: 10.17323/1814-9545-2020-2-252-277
- Li, L. X.; Abdul Rahman, S.S.; (2018). *Students' learning style detection using tree augmented naive Bayes*. R Soc Open Sci.; Published 24 Jul. <https://doi.org/10.1098/rsos.172108>
- Li, F., He, Y., & Xue, Q. (2021). *Progress, Challenges and Countermeasures of Adaptive Learning: A Systematic Review*. Educational Technology & Society, 24(3), 238–255. <https://www.jstor.org/stable/27032868>
- Maravanyika, M.; Dlodlo, N. and Jere, N.;(2017) *An adaptive recommender-system based framework for personalised teaching and learning on e-learning platforms, 2017 IST-Africa Week Conference (IST-Africa)*, pp. 1-9. DOI: 10.23919/ISTAFRICA.2017.8102297
- Martin, F., Chen, Y., Moore, R.L. *et al.* (2020). *Systematic review of adaptive learning research designs, context, strategies, and technologies from 2009 to 2018*. Education Tech Research Dev 68, 1903–1929 DOI: 10.1007/s11423-020-09793-2
- Miquelante, M. A., Pontara, C. L., Cristovão, V. L. L., Silva, R. O. da. (2017). *As modalidades da avaliação e as etapas da sequência didática: articulações possíveis*. Trabalhos em Linguística Aplicada, Campinas, SP, v.

- 56, n. 1, p. 259–299, 2017. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/tla/article/view/8650771>.
- Moraes, S. B. A. (2014). Notas Sobre a Avaliação da Aprendizagem em Educação a Distância. *EaD Em Foco*, 4(2). <https://doi.org/10.18264/eadf.v4i2.229>.
- Moresco, S.F.S.; Behar, P.A. (2003). *ROODA Tekton: uma proposta pedagógica no ambiente virtual de aprendizagem ROODA*. Simpósio Brasileiro de Informática na Educação, 14. Rio de Janeiro.
- Page, M.J., Mckenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E., et al. (2021). *The prisma 2020 statement: an updated guideline for reporting systematic reviews*. *BMJ* 2021; 372: n 71. <https://doi.org/10.1136/bmj.n71>.
- Pitigala, L.P.; Gunawardena, L.; Hirakawa, M. (2013). *A framework for adaptive learning management systems using learning styles*. International Conference on Advances in ICT for Emerging Regions, ICTer - Conference Proceedings. 261-265. <http://dx.doi.org/10.4038/icterv7i2.7153>
- Rezaei, M. S., & Montazer, Gholam Ali. (2016). *An automatic adaptive grouping of learners in an e-learning environment based on fuzzy grafting and snap-drift clustering*, *International Journal of Technology Enhanced Learning*, vol. 8, no. 2, pp. 169–186. DOI: <https://doi.org/10.1504/IJTEL.2016.078090>
- Shabbir, S., Ayub, M.A., Khan, F.A. And Davis, J. (2021). *Short-term and long-term learners' motivation modeling in Web-based educational systems*. *Interactive Technology and Smart Education*, Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/ITSE-09-2020-0207>
- Sheeba, T., Krishnan, R. (2018). *Prediction of student learning style using modified decision tree algorithm in e-learning system*. *International Conference on Data Science and Information Technology*, 85–90, July. <https://doi.org/10.1145/3239283.3239319>.
- Shemshack, A., Spector, J.M. (2020). *A systematic literature review of personalized learning terms*. *Smart Learn. Environ.* 7, 33. DOI: 10.1186/s40561-020-00140-9.
- Shubin, I., Skovorodnikova, V., Kozyriev, A., Pitiukova, M. (2019). *Mining methods for adaptation metrics in e-learning*, vol.2362, [On-line].
- Skinner, B. F. *Ciência e Comportamento Humano*. (1970). Brasília: Ed. UnB/ FUNBEC, (1953), 1970.
- Su, C. (2017). *Designing and Developing a Novel Hybrid Adaptive Learning Path Recommendation System (ALPRS) for Gamification Mathematics Geometry Course*. *Eurasia Journal of Mathematics, Science and Technology Education*, 13(6), 2275-2298. DOI: 10.12973/eurasia.2017.01225a
- Tnazefti - Kerkeni, I., Belaid, H. And Talon, B. (2020). *An Adaptive Learning System based on Tracking*. In *Proceedings of the 12th International Conference on Computer Supported Education - Volume 2: CSEDU*, ISBN 978-989-758-417-6; ISSN 2184-5026, pages 455-460. DOI: 10.5220/0009571604550460
- Y. Qu and O. Ogunkunle, "Enhancing the Intelligence of the Adaptive Learning Software through an AI assisted Data Analytics on Students Learning Attributes with Unequal Weight," *2021 IEEE Frontiers in Education Conference (FIE)*, Lincoln, NE, USA, 2021, pp. 1-6, doi: 10.1109/FIE49875.2021.9637387
- Yan, W., Yiping, L., Tingting, Z. and Jianzhong, C. (2010). *Research of Data Model of SCORM Run-time Environment*. 3rd International Conference on Information Management, Innovation Management and Industrial Engineering, pp. 240-243. DOI: 10.1109/ICIII.2010.222
- Wohlin, C. (2014). *Guidelines for snowballing in systematic literature studies and a replication in software engineering*, in: *Proceedings of the 18th international conference on evaluation and assessment in software engineering*, pp. 1–10. DOI: <https://doi.org/10.1145/2601248.2601268>
- Zaoud, M., & Belhadaoui, H. (2020). *Adaptive E-learning: Adaptation of Content According to the Continuous Evolution of the Learner During his Training*. *Proceedings of the 3rd International Conference on Networking*,

- Information Systems & Security.  
<https://doi.org/10.1145/3386723.3387890>
- Zawacki - Richter, O., Marín, V. I., Bond, M. et al. (2019). *Systematic review of research on artificial intelligence applications in higher education – where are the educators?* Int J Educ Technol High Educ 16, 39. DOI: <https://doi.org/10.1186/s41239-019-0171-0>
- Zhao, L., Wang, H. (2019). *Research on Adaptive Learning System Based on Three Core Modules*. 10th International Conference on Information Technology in Medicine and Education (ITME), pp. 447-452.

