

■ DOSSIÊ - ARTIGOS

■ **Deep Learning em Sistemas Tutores Inteligentes (STIs): uma revisão sistemática de literatura das publicações de 2023**

Deep Learning in Intelligent Tutoring Systems (ITS): a systematic literature review of 2023 publications

 Jefferson da Silva *
Matheus Henrique Bastos Leite **
Lúcio de França Teles ***

Recebido em: 2 ago. 2023
Aprovado em: 31 out. 2023

Resumo: Este artigo apresenta uma revisão sistemática da literatura sobre o avanço das pesquisas recentes em Sistemas de Tutoria Inteligente (STIs) utilizando *deep learning* para personalização do ensino, em especial na modalidade de Educação a Distância (EaD). O estudo aplicou o método quantitativo *Methodi Ordinatio*, selecionando 22 artigos relevantes para a área educacional. Os resultados destacam os países, revistas e áreas com mais publicações sobre o tema, bem como os autores mais prolíficos e citados. Também foram mapeadas as tecnologias de *deep learning* utilizadas e as aplicações apresentadas nos artigos. A pesquisa examinou o que a literatura revela sobre a efetividade da tecnologia, procurando evidências de melhoria nos resultados de aprendizagem, além de analisar o embasamento em teorias pedagógicas. Esse estudo oferece um panorama atualizado do estado da arte da aplicação do *deep learning* em STIs, contribuindo para o conhecimento científico nessa área. Os resultados ressaltam a relevância contemporânea do tema e o crescente interesse em aprimorar as abordagens personalizadas de ensino. Essa pesquisa fornece subsídios valiosos para pesquisadores, educadores e profissionais interessados em compreender e implementar o uso do *deep learning* em STIs, visando melhorar a experiência e os resultados de aprendizagem dos alunos.

Palavras-chave: Inteligência Artificial. Sistemas Tutores Inteligentes. Processo de Ensino-aprendizagem.

Abstract: This article presents a systematic literature review on the recent advancements in Intelligent Tutoring Systems (ITS) using deep learning for personalized instruction, as a focus on the Distance Education modality. The study applied the quantitative *Methodi Ordinatio* method, selecting 22 relevant articles in the educational field. The results highlight the countries, journals, and areas with the highest number of publications on the subject, as well as the most prolific and cited authors. The deep learning technologies utilized and the applications presented in the articles were also mapped. The research examined the effectiveness of the technology, seeking evidence of improved learning outcomes, and analyzed the grounding in pedagogical theories. This study provides an updated overview of the state-of-the-art in applying deep learning to ITS, contributing to scientific knowledge in this field. The results emphasize the contemporary relevance of the topic and the growing interest in enhancing personalized teaching approaches. This research offers valuable insights for researchers, educators, and professionals interested in understanding and implementing the use of deep learning in ITS, aiming to improve students' learning experience and outcomes.

Keywords: Artificial Intelligence. Intelligent Tutoring Systems. Learning. Teaching.

* Jefferson da Silva é engenheiro e mestrando em educação (PPGE/UnB), com experiência em educação profissional e educação corporativa, atuando no desenvolvimento, na implementação e na gestão de projetos e programas educacionais. Contato: silvajefferon@yahoo.com.br.

** Matheus Henrique Bastos Leite é contador (UnB) e mestre em Estudos Organizacionais e Gestão de Pessoas (PPGA/UnB). Doutorando em Administração (PPGA/UnB). Membro dos grupos de pesquisa Contabilidade Financeira Aplicada (CCA/UnB) e do Grupo de Pesquisa e Estudos Avançados sobre Comportamento Organizacional - Gepaco (PPGA/UnB). Analista em Políticas Públicas e Gestão Educacional na Secretaria de Estado de Educação do Distrito Federal. Contato: matheushenriquebl@gmail.com.

*** Lúcio de França Teles é graduado da Universidade Johann Wolfgang Goethe, Frankfurt, Alemanha, com mestrado pela Universidade de Genebra. Completou o doutorado na Faculdade de Educação, Universidade de Toronto, em Informática na Educação. Pós-doutor sobre fundamentos teóricos da colaboração online na Universidade Livre de Berlim (2016). Professor Associado, Faculdade de Educação, Universidade de Brasília. Coordenador do Projeto de pesquisa CAPES, "PROEJA Transiarte" (www.proejatransiarte.ifg.edu.br). Contato: teleslucio@gmail.com

Introdução

Segundo Siciliana (2021), atualmente, a população mundial vive a chamada Quarta Revolução Industrial ou Indústria 4.0 que, em síntese, inclui um conjunto de tecnologias avançadas, como inteligência artificial, robótica, internet das coisas e computação em nuvem, que estão alterando tanto as formas de produção quanto os padrões de negócios no Brasil e no mundo. Toda essa transformação digital pode trazer celeridade ao desenvolvimento de processos, além de modernizar a execução de diversas atividades, educando indivíduos cada vez mais exigentes e questionadores frente às mudanças e dinâmicas da vida em sociedade.

Devido aos efeitos causados pela pandemia de covid-19, doença causada pelo novo coronavírus (Sars-Cov-2), o processo de transformação digital da sociedade – que já ocorria há um tempo – foi acelerado e, de maneira repentina, diferentes atividades passaram a ser exercidas em ambiente digital (ROF; BIKFALVI; MARQUES, 2022). Em virtude do isolamento social, atividades realizadas de forma física/presencial foram diminuídas e somente ocorreram em casos essenciais. Tal fato impactou diretamente a educação no Brasil e no mundo, que precisou se reinventar e dar mais espaço à modalidade de Educação a Distância (EaD) (BROILO; BROILO NETO, 2021). A modalidade EaD, que outrora se fazia opcional, se tornava condição *sine qua non* para manter a saúde e a integridade física dos estudantes, conforme recomendado pelas autoridades de saúde à época.

Dados do Censo da Educação Superior de 2021 mostram uma redução de 28% no número de vagas em cursos de graduação presenciais quando comparado a 2019, ano anterior à pandemia. Contrapondo-se, a modalidade EaD apresentou um crescimento significativo na rede privada de ensino, aumentando sua oferta de 24,3% em 2018 para 41,4% em 2021. Além da pandemia, a expansão da rede de internet no Brasil e o maior acesso a ferramentas digitais são fatores que também contribuem para o crescimento da oferta de cursos na modalidade EaD (BROILO; BROILO NETO, 2021). Dentre as vantagens da modalidade EaD, estão o alcance em escala, baixo custo e acesso flexível em termos de tempo e localização. Além disso, a EaD também poderá exercer um espaço complementar às atividades de ensino presencial.

Ao adentrar o universo da EaD, é possível usufruir de uma série de ferramentas e estratégias que viabilizem o ensino a distância e facilitem o processo de aprendizagem. Isso inclui plataformas de aprendizagem, videoaulas, fóruns de discussão, materiais didáticos digitais, avaliações on-line, *gamificação*, entre outros. Essas abordagens podem proporcionar um ambiente virtual

de ensino e aprendizagem eficaz, no qual exista interação entre alunos e professores e acompanhamento individualizado do progresso acadêmico dos estudantes (AGUIAR; FERREIRA; GARCIA, 2012).

Nesse sentido, Bloom (1984), em um dos estudos precursores acerca da temática, afirma que a tutoria individualizada, na figura da personalização do ensino, é uma ferramenta mais célere e de maior poder de alcance no que se refere aos objetivos educacionais, quando comparada a abordagens usuais. Considera-se personalização do ensino o uso de estratégias, métodos, técnicas e tecnologias que atendem às necessidades individuais de cada estudante (BERNACKI; GREENE; LOBCZOWSKI, 2021). Assim sendo, com a ampliação da oferta remota, o desafio da tutoria individualizada ultrapassa as limitações das salas de aula presenciais e adentra as plataformas EaD.

O uso da tecnologia de Inteligência Artificial (IA) é visto como um dos principais caminhos para auxiliar educadores no processo de personalização do ensino, trazendo benefícios diretos aos estudantes durante o processo de aprendizagem (KAUFMAN, 2022). Pesquisas têm sido conduzidas com vistas ao aprimoramento das tecnologias baseadas em IA visando obter maior precisão nos modelos preditivos desenvolvidos (ZHAI *et al.*, 2020). Um exemplo factível de aplicação da IA na educação são os *Intelligent Tutoring Systems* (ITS) ou Sistemas Tutores Inteligentes (STI), em português.

Ante o exposto, o objetivo do presente estudo é responder à seguinte questão de pesquisa: como as pesquisas mais atuais em STIs, utilizando a tecnologia *deep learning*, têm evoluído para aumentar a personalização do ensino e obter melhores resultados de aprendizagem? Visando complementar o estudo de Silva e Teles (no prelo), esta pesquisa realizou o levantamento do estado da arte sobre a aplicação da tecnologia *deep learning* em STIs, no ano de 2023.

Justifica-se a relevância da pesquisa dada a contemporaneidade da temática e os índices cada vez maiores de publicações sobre o tema proposto. Esse aumento é atribuído às novas tecnologias que possibilitam novas formas de investigação científica e à demanda por produção de conhecimento por parte do mercado (PAGANI; KOVALESKI; RESENDE, 2015).

Adicionalmente, para subsidiar o alcance do objetivo supracitado, o estudo se propõe a responder às seguintes questões de pesquisa:

1. Quais são os países, revistas e áreas em que mais se publicou sobre o tema?
2. Quais são os autores que mais publicam sobre o tema? Quais os autores mais citados?
3. Quais tecnologias de *deep learning* foram utilizadas nos estudos encontrados?

4. Quais são as aplicações apresentadas nos artigos?
5. Há medição de efetividade da aplicação da tecnologia?
6. Há evidência de embasamento em teorias pedagógicas?

Na seção seguinte, será apresentado o referencial teórico que servirá como base para interpretar os resultados encontrados ao término desta pesquisa, além de apresentar os principais conceitos, teorias e estudos acerca da temática.

1. Referencial teórico

A IA tem crescido de forma exponencial e está presente em praticamente tudo o que a humanidade faz. De forma não visível, ela captura dados de variadas fontes de informação geradas pelo usuário e os trata por meio de métodos estatísticos a fim de prever o comportamento humano. Nesse sentido, ela parte da premissa de que a ação humana é esperada e segue um padrão. Assim, tem ganhado cada vez mais espaço na sociedade. Tem se tornado uma forma de otimização de custos com a mão de obra humana, geração de receita ao prever o comportamento humano e uma forma de personalizar a experiência do usuário com produtos e marcas.

O termo IA foi cunhado na década de 50 em uma conferência realizada em Dartmouth com os especialistas McCarthy, Minsky, Rochester e Shannon. McCarthy (2007) definiu a IA como “a ciência e a engenharia de fazer máquinas inteligentes, especialmente programas de computador inteligentes” (MCCARTHY, 2007, tradução nossa). Apesar de a IA não ser inteligente como o termo pressupõe, McCarthy (2007) coloca que “a inteligência é a parte computacional da capacidade de alcançar objetivos no mundo”. O autor traz um dos conceitos presentes referentes à IA que é a visão da racionalidade, ou seja, fazer a coisa certa (RUSSELL; NORWIG, 2022).

Russell e Norwig (2022) trazem ainda o conceito de fidelidade ao desempenho humano, comportamento inteligente ou os processos de pensamento e raciocínio interno. Apesar das definições, colocadas em um plano cartesiano, é possível encontrar quatro campos de estudo da IA, onde diversas disciplinas fazem contribuições à área (RUSSELL; NORWIG, 2022).

A interdisciplinaridade da área permitiu que várias linhas de pesquisa surgissem acerca do funcionamento do cérebro humano. Uma delas é a conexionista, que busca emular o cérebro humano por meio de neurônios artificiais, como as Redes Neurais Artificiais (HAYKIN, 2007). Outra linha de pesquisa é a simbólica que processa símbolos por meio de sistemas especialistas

que detêm o conhecimento humano e se comporta como se fosse um. Por fim, Luger (2013) traz as abordagens estocásticas, a qual o *Machine Learning* é o expoente dessa abordagem.

O *machine learning* é considerado uma subárea da IA e busca aprender, de forma automática, por meio de relacionamentos e padrões significativos, a partir de exemplos e observações (BISHOP, 2006). Dentro do *machine learning* é encontrado o *deep learning*, que é um subconjunto do aprendizado de máquina. É uma rede neural com um grande número de camadas e parâmetros. “A maioria dos métodos de aprendizado profundo usa arquiteturas de rede neural. Portanto, também é referido como redes neurais profundas” (SHINDE; SHAH, 2018, p. 3, tradução nossa). As autoras ainda detalham o conceito:

O aprendizado profundo usa uma cascata de várias camadas de unidades de processamento não linear para extração e transformação de recursos. As camadas inferiores próximas à entrada de dados aprendem recursos simples, enquanto as camadas superiores aprendem recursos mais complexos derivados dos recursos da camada inferior. A arquitetura forma uma representação hierárquica e poderosa de recursos. Isso significa que o aprendizado profundo é adequado para analisar e extrair conhecimento útil de grandes quantidades de dados e dados coletados de diferentes fontes (*Ibid.*, p. 3).

Devido ao crescimento do *deep learning* nos últimos anos, motivou-se a pesquisa em Sistema Tutores Inteligentes utilizando este método. Os STIs são sistemas de instrução inteligentes, baseados em computador, com modelos de conteúdo instrucional e estratégias de ensino próprios, buscando imitar a tutoria personalizada oferecida por humanos (LIMA JÚNIOR; SILVA, 2022). Os avanços percebidos na última década têm sido impulsionados pelo modelo de *deep learning*, uma técnica de *machine learning* (subárea da IA) que permite que as máquinas “aprendam” com os dados atribuídos, dispensando a necessidade de programação manual (KAUFMAN, 2022, p.6).

A estrutura básica de um STI é composta pelo módulo tutor, que contém as estratégias de ensino; um módulo especialista, que contém o conhecimento de um especialista em determinada área do conhecimento; o módulo do aluno, que contém as características do estudante; e a interface do usuário, parte do dispositivo que permite que o aluno interaja com o sistema.

2. Metodologia

Realizou-se uma revisão sistemática da literatura (para publicações do ano de 2023), utilizando o método quantitativo *Methodi Ordinatio*, para obter um panorama atual do conhecimento existente, em busca de verificar o estado da arte do tema proposto. Para

Morosini, Kohls-Santos e Bittencourt (2021), o termo estado da arte pode variar de acordo com a área de estudo. No campo das Ciências Humanas, o termo refere-se à identificação, registro e categorização da produção científica em uma determinada área e período de tempo determinado, abrangendo periódicos, teses, dissertações e livros relacionados a um tema específico, com o objetivo de fornecer reflexão e síntese. A seguir, serão apresentados, de forma detalhada, os procedimentos necessários ao cálculo do *Methodi Ordinatio*, bem como a coleta de dados que compõem a presente pesquisa.

2.1. Methodi Ordinatio

O *Methodi Ordinatio* é descrito no artigo por Pagani, Kovaleski e Resende (2015), como uma metodologia que tem como objetivo auxiliar pesquisadores na seleção de material bibliográfico relevante em um contexto de aumento significativo de publicações científicas e periódicos nos últimos anos. Para isso, a metodologia utiliza métodos bibliométricos, como o *ProKnow-C*, adaptado para a seleção de artigos científicos, e o *InOrdinatio*, para classificação com base na relevância do documento.

Os autores propõem uma equação, chamada *Index Ordinatio (InOrdinatio)*, para o ranqueamento das publicações científicas com base em sua relevância científica. Antes da análise sistemática, são considerados critérios para o ranqueamento dos artigos científicos, incluindo: (1) O fator de impacto do periódico em que o artigo foi publicado; (2) O número de citações; e (3) O ano de publicação. O método contém 9 etapas, conforme descrito por Pagani, Kovaleski e Resende (2015):

Etapa 1: O pesquisador deve definir um problema ou intenção de pesquisa.

Etapa 2: Deve-se realizar buscas em bases de dados utilizando palavras-chave relacionadas ao problema de pesquisa. Nessa etapa, é importante verificar se alguma palavra-chave relevante não foi definida. Se for o caso, novas buscas devem ser realizadas, em um processo iterativo. A mesma busca deve ser conduzida em diferentes bases de dados, mantendo os mesmos parâmetros de pesquisa.

Etapa 3: Definição das palavras-chave que serão utilizadas como base para a pesquisa, conforme busca realizada na Etapa 2.

Etapa 4: Realização da busca nas bases de dados utilizando as palavras-chave definidas na Etapa 3. As referências encontradas devem ser exportadas para um *software* de gerenciamento de referências, formando a bibliografia inicial do projeto.

Etapa 5: Nesta etapa, é realizada uma filtragem inicial das referências, com o objetivo de

reduzir dados duplicados e remover referências que não sejam relevantes para o objetivo da pesquisa. Essa filtragem é feita por meio da análise das palavras-chave, títulos e resumos dos artigos.

Etapa 6: É feita a identificação do fator de impacto, número de citações e ano de publicação das referências. Os autores mencionam que as citações são mais comuns em artigos gratuitos, que publicações mais recentes tendem a ter menos citações e que existem artigos com um alto número de citações, mas sem fator de impacto. Nesse sentido, eles recomendam considerar a relevância do periódico, avaliada pelo fator de impacto, o reconhecimento científico do artigo, avaliado pelo número de citações, e a recenticidade do artigo, avaliando o ano de publicação.

Etapa 7: Deve-se calcular o *Index Ordinatio*, que atribui uma classificação numérica às referências com base nos valores encontrados e selecionar a quantidade de documentos que farão parte da revisão sistemática. Para o cálculo, é utilizada a Equação 1 proposta pelos autores:

$$In\ Ordinato = IF\ 1000 + \alpha \cdot [10 - (Research\ Year - Publish\ Year)] + (\sum Ci) (1)$$

Onde:

O IF é o fator de impacto do periódico.

Alpha é o "valor a ser atribuído pelo pesquisador e pode variar de 1 a 10. Quanto mais próximo o número estiver de um, menor será a importância que o pesquisador atribui ao critério ano".

ResearchYear é o ano em que foi realizada a pesquisa.

PublishYear é o ano em que foi publicado o artigo

(PAGANI; KOVALESKI; RESENTE, 2015, p. 7).

Etapa 8: Encontrar o arquivo dos artigos selecionados.

Etapa 9: Realizar análise sistemática dos artigos selecionados na Etapa 8.

2.2. Coleta de Dados

Realizou-se pesquisa bibliográfica nas bases *Web of Science (WoS)* e *Scopus*¹, considerando:

- Pesquisas realizadas no ano de 2023.
- Uso do operador booleano OR.
- Para a base *Scopus*: buscas no título, resumo e palavras-chave.
- Para a base *WoS*: buscas realizada por tópico (título, resumos e indexadores).
- Conjunto de palavras-chave delimitadas por aspas para pesquisa do termo completo.

Linha de comando para busca e palavras-chave:

Web of Science - (TS=("deep learning" OR "deep neural network*" OR "Deep structured learning" OR "Hierarchical learning" OR "convolutional neural network*")) AND (TS=("Intelligent tutoring system*" OR "Intelligent Computer-Assisted Instruction" OR "Adaptive educational system*" OR "Adaptive learning systems" OR "Constraint-based tutors" OR "Cognitive Tutor" OR "intelligent tutor" OR "SQL-tutor" OR "assistments" OR "elm-art" OR "iweaver" OR "DeepTutor" OR "Coh-Matrix" OR "Electronix Tutor" OR "Student modeling" OR "Knowledge Tracing"))

Scopus - (TITLE-ABS-KEY ("deep learning") OR TITLE-ABS-KEY ("deep neural network*") OR TITLE-ABS-KEY ("Deep structured learning") OR TITLE-ABS-KEY ("Hierarchical learning") OR TITLE-ABS-KEY ("convolutional neural network*")) AND (TITLE-ABS-KEY ("Intelligent tutoring system*") OR TITLE-ABS-KEY ("Intelligent Computer-Assisted Instruction") OR TITLE-ABS-KEY ("Adaptive educational system*") OR TITLE-ABS-KEY ("Adaptive learning systems") OR TITLE-ABS-KEY ("Constraint-based tutors") OR TITLE-ABS-KEY ("Cognitive Tutor") OR TITLE-ABS-KEY ("intelligent tutor") OR TITLE-ABS-KEY ("SQL-tutor") OR TITLE-ABS-KEY ("assistments") OR TITLE-ABS-KEY ("elm-art") OR TITLE-ABS-KEY ("iweaver") OR TITLE-ABS-KEY ("DeepTutor") OR TITLE-ABS-KEY ("Coh-Matrix") OR TITLE-ABS-KEY ("Electronix Tutor") OR TITLE-ABS-KEY ("Student modeling") OR TITLE-ABS-KEY ("Knowledge Tracing"))

A remoção dos artigos em duplicidade foi realizada utilizando o *software* estatístico R com a biblioteca *Bibliometrix*, totalizando 53 artigos. Os documentos digitais foram recuperados por meio do *Digital Object Identifier* (DOI) usando a ferramenta Zotero.

Na análise bibliométrica, verificou-se que as publicações são predominantemente da China, com 22 artigos; seguido por Coréia do Sul, com 7 publicações; Austrália e Irã, com 3 cada um. Quando se verifica os periódicos em que houve publicação (ou os anais de eventos), há uma distribuição de certa forma igualitária. O Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) é que possui mais periódicos com publicações e, que de certa forma, faz sentido, haja vista que publicações da área de engenharia e de computação são realizadas nos periódicos desta instituição, conforme demonstrado na tabela 1.

Tabela 1. Artigos por periódico ou anais de evento

Periódico	Quantidade
IEEE Transactions on Learning Technologies	3
ACM Web Conference 2023 - Proceedings of the World Wide Web 2023	2
Applied Intelligence	2
Applied Sciences-Basel	2
Computers in Biology and Medicine	2
Expert Systems with Applications	2
IEEE Access	2
Image and Vision Computing	2
Multimedia Tools and Applications	2
19th IEEE International Colloquium on Signal Processing and its Applications (CSPA) 2023 - Conference Proceedings	1

Fonte: Elaborado pelos autores

Em relação aos autores que mais publicam, Abdali-Mohammadi F., Liu Q., Liu Z., Sepahvand M., Wang Y. e Wang Z. publicaram três artigos. Já Chen E., Chen J., Ding X. e Hu Y. publicaram 2 artigos em 2023. O artigo mais citado é *Knowledge tracing: a survey*, de Ghodai Abdelrahman, Qing Wang e Bernardo Nunes, com três citações. Na sequência, com duas citações, o artigo *An adaptive teacher-student learning algorithm with decomposed knowledge distillation for on-edge intelligence*, de Majid Sepahvand, Fardin Abdali-Mohammadi e Amir Taherkordi.

A predominância dos artigos é da área da computação com as palavras-chave mais citadas: *deep Learning* (26 artigos), *knowledge distillation* (16 artigos) e *knowledge tracing* (15 artigos). O rastreamento do conhecimento (*knowledge tracing*) por meio de *deep learning* é um tema de pesquisa relevante e que abarca grande partes dos artigos, haja vista que o rastreamento de conhecimento é um fator crítico para a personalização do ensino e que obteve considerável avanço com o *deep learning*.

Com objetivo de filtrar os artigos para estudo, foram analisados os títulos, resumos e palavras-chave dos 53 artigos restantes. Retirou-se os artigos que não traziam contexto educacional e vinculados ao processo de destilação do conhecimento (*knowledge distillation*), que apresenta o modelo aluno e professor, mas que não possui correlação com o contexto educacional. Como resultado, restaram 22 artigos voltados para a área educacional. A seguir, será apresentado, de forma detalhada, o resultado desta pesquisa, seção na qual poderão ser verificadas com maior precisão as informações apresentadas nesta metodologia.

3. Análise e discussão dos resultados

Nesta etapa, será apresentada a análise resumida de cada artigo, separando-os nos subitens por aplicação, medição de efetividade ou uso de teorias pedagógicas.

As tecnologias identificadas são percorridas na análise de cada artigo.

3.1. Aplicações de rastreamento do conhecimento

O rastreamento de conhecimento *Knowledge Tracing* (KT) é o principal foco dos artigos analisados, como evidenciado também no estudo de Silva e Teles (no prelo). Abdelrahman *et al.* (2023) explicam que na EaD existe uma necessidade emergente de rastrear o conhecimento do aluno, com vistas a personalizar o ensino. Os autores ainda afirmam que o rastreamento do conhecimento – que busca observar, representar e quantificar o estado de conhecimento de um aluno – é um problema na literatura e que resolvê-lo liberaria o potencial das aplicações educacionais baseadas em *software*.

Em sua revisão sistemática de literatura, Abdelrahman *et al.* (2023) relatam que as primeiras tentativas de rastreamento do conhecimento foram realizadas por meio de inferência *bayesiana*² e, depois, regressão logística. Outro tipo de abordagem KT é a análise fatorial paramétrica que considera o conhecimento prévio do estudante, dificuldades, práticas realizadas, período de realização entre atividades, estudos psicológicos sobre a aprendizagem.

A análise fatorial ainda é utilizada, mas não considera *deep learning*. O *Deep Knowledge Tracing* (DKT) com Redes Neurais Recorrentes (RNN) foi elaborado e mostrou eficiência no rastreamento de conhecimento ao prever respostas de alunos às perguntas. Apesar dos avanços com o DKT, vários autores abordam oportunidades de melhoria neste método, como mostrado nos parágrafos seguintes.

Wang *et al.* (2023) relatam que os métodos tradicionais de diagnóstico de aprendizagem não conseguem equilibrar precisão e interpretabilidade (é a tentativa de entender e determinar qual grau de confiança atribuir ao resultado obtido com a IA). Os autores citam que os modelos baseados em psicometria, que levam em conta parâmetros cognitivos, conseguem interpretar o domínio, mas falham em dados de aprendizagem em larga escala.

Os modelos de diagnóstico com *deep learning* melhoraram consideravelmente, no entanto, a complexidade dos modelos dificulta a interpretação, resultando em uma falta de confiança nos resultados para aplicações educacionais.

Nesse sentido, Wang *et al.* (2023) propõem resolver o problema acima por meio de uma estrutura de diagnóstico de aprendizado inteligente que considera a capacidade de aprendizado dos sistemas *deep learning* com a interpretabilidade da psicometria, provendo melhor previsão de aprendizagem e interpretabilidade.

No aspecto da interpretabilidade, Zhong *et al.* (2023) propõem o *Temporal Convolutional Knowledge Tracing with Graph Attention network Mechanism* (GATCKT).

Em outro artigo, Wang *et al.* (2023b), atacando o mesmo problema, colocam que, para algumas aplicações, seria mais útil a previsão de habilidades ou proficiência dos alunos ao invés de previsão de desempenho. Na área de psicometria, já existem soluções de diagnóstico cognitivo para identificar os estados de conhecimento em condições estáticas, como por exemplo, exames. Os autores propõem o diagnóstico cognitivo dinâmico, “[...] que integra a interpretabilidade de antecedentes educacionais do diagnóstico cognitivo em métodos de rastreamento de conhecimento baseados em *deep learning*” (Wang *et al.*, 2023b, p. 306, tradução nossa).

Para Ding *et al.* (2023), os modelos de rastreamento de conhecimento utilizando *deep learning* possuem algumas limitações, como: utilização de respostas dicotômicas (correta ou incorreta) ao invés de informações adicionais de utilização pelo aluno, projeto de arquitetura considerando tentativa e erro e utilização de concatenação simples. Para solução deste problema, o autor propõe o *Multimodal Fusion and Neural Architecture Search* (MFNAS), com objetivo de tornar mais eficiente o modelo de rastreamento do conhecimento.

Zhu *et al.* (2023) evidenciam outro problema nas técnicas de KT com *deep learning*, que desconsideram a reconstrução de informações de entrada observadas, levando a previsões pouco eficazes do conhecimento do aluno. Nesse sentido, propõem inferência causal para análise explicativa no rastreamento do conhecimento e, também, propõe um algoritmo de aprendizagem para rastreamento estável com base nos resultados da análise, utilizando redes neurais. Zhao *et al.* (2023) afirmam, ainda, que as técnicas de KT não deixam explícito o uso de teorias básicas da psicologia educacional. Assim, os autores propõem a utilização de uma estrutura intitulada *Gating-controlled Forgetting and Learning mechanisms for Deep Knowledge Tracing* (GFLDKT), que considera a Teoria do Esquecimento e a Teoria da Curva de Aprendizagem (que defende que quanto mais se pratica mais se domina o conhecimento) em diferentes alunos.

Considerando a mesma Teoria da Curva de Aprendizagem, Su *et al.* (2023), propõem o *Convolution-Augmented Knowledge Tracing* (CAKT) e um modelo *Capsule-Enhanced CAKT* (CECAKT) para permitir a modelagem da curva de aprendizado. Os dois modelos utilizam Redes Neurais *Long Short Term Memory* (LSTM).

Su *et al.* (2023b) ainda apresentam que há baixa previsão para problemas de habilidades múltiplas. Para solução, apresentam uma aplicação do algoritmo

XG Boost para melhorar a previsão no rastreamento do conhecimento.

Li e Wang (2023) apontam que o rastreamento de conhecimento realizado por meio de redes neurais profundas utiliza-se de dados de interações de alunos e *logs* do sistema, mas que ignoram as interações passadas dos estudantes, que incluem fator de esquecimento e comportamento.

Os autores propõem um modelo intitulado *Relational Attention Knowledge Tracing* (RAKT) para rastrear a proficiência de conhecimento dos alunos na realização de exercícios, levando em consideração os comportamentos de interação dos estudantes, incluindo deslizos e adivinhação do aluno.

Naranjo *et al.* (2023), utilizando-se também de interações de estudantes, como tempo de resposta aos exercícios, número de tentativas, tempo de interação e esquecimento, propõe uma camada pré-treinada no modelo DKT para aprimorar o rastreamento.

Han *et al.* (2023, p. 92, tradução nossa) afirmam que os modelos possuem “[...] limitação no sentido de que eles não podem utilizar as atividades de aprendizagem de outros alunos além do aluno-alvo e podem usar apenas uma forma limitada das informações dos exercícios”. Han *et al.* (2023) aplicaram o conceito de previsão de classificação ao problema de rastreamento de conhecimento do exercício do aluno, baseando-se no *Inductive Graph-based Knowledge Tracing* (IGKT), resolvendo as limitações dos modelos existentes.

Jiang *et al.* (2023) propõem um novo método, que não somente considera o estado de conhecimento dos alunos, mas também o envolvimento do aluno no processo de aprendizagem.

Hung e Lee (2023) desenvolveram um sistema de rastreamento de conhecimento para melhorar a capacidade de aprendizado dos estudantes em programação por meio da identificação do nível de proficiência das principais dificuldades obtidas durante a resolução de exercícios.

Liu *et al.* (2023) mencionam que cada estudante possui uma estrutura mental para resolução de problemas utilizando-se de conhecimentos prévios e que os modelos DKT não capturam a variabilidade de formas de aprendizado do aluno. Os autores desenvolvem um algoritmo que considera o desempenho histórico do estudante, considerando o conhecimento prévio do aluno.

Yin *et al.* (2023) desenvolve uma nova arquitetura de rastreamento do conhecimento, intitulada *Diagnostic Transformer* (DTransformer), juntamente com um novo paradigma de treinamento, para melhor diagnosticar a proficiência de conhecimento do estudante. Com o mesmo objetivo, Mao *et al.* (2023) estabelece o *Fine-Grained Knowledge Tracing* (FGKT).

3.2 Aplicação na detecção das emoções

Diferentemente do que foi abordado nos parágrafos anteriores acerca do KT, Cárdenas-López *et al.* (2023) trazem um estudo no qual abordam sobre as emoções. Segundo os autores, as emoções estão envolvidas no processo de aprendizagem e a IA pode auxiliar na detecção e na melhoria do aprendizado. Os STIs utilizam as frases e opiniões dos estudantes para personalizar o ensino. Os STIs que utilizam emoções são chamados de Sistemas Tutores Afetivos (ATS) (CÁRDENAS-LÓPEZ *et al.*, 2023).

No entanto, apontam um problema: os vieses imputados pelos alunos e que podem incorrer em uma informação falsa. Segundo os autores, os ATSS têm utilizado o reconhecimento de expressões faciais para aprimoramento, mas há emoções que são detectadas de forma incorreta devido a sutilezas das emoções utilizadas em processos educacionais.

3.3 STIs baseados em movimento

Ashwin *et al.* (2023) realizaram uma revisão sistemática de literatura, de 2010 a 2022, no uso de STIs baseados em movimentos. Eles verificaram que a detecção é realizada por meio de visão computacional, que analisam gestos, postura e movimentos do corpo. As principais aplicações estão na aprendizagem de instrumentos musicais, esportes e dança.

3.4 Medição de efetividade e aplicação

Na maioria dos artigos, há menção a treinamentos dos modelos em bases de dados com dados reais e simulados com o objetivo de avaliar a efetividade do modelo proposto. Alguns exemplos de base são: ASSISTments, STATICS2011, Junyi Academy, Simulated-5 (Synthetic), KDDcup, EdNet, entre outros. Muitas delas são para aplicação em sistemas de ensino da matemática, algumas do idioma inglês e programação, a qual são as aplicações encontradas nas publicações. Abde-rahman *et al.* (2023) relatam problemas em algumas bases, a qual são listadas: falta de informações precisas e descritivas dos atributos dos conjuntos de dados, falta de dados demográficos, formato de arquivo escolhido para representar os dados que pode trazer dificuldade em interpretação de dados, os dados são de domínios de conhecimento específicos.

Liu *et al.* (2023b) colocam que, apesar de que modelos DKT tenham evoluído e apresentado resultados promissores, a aplicação em contextos educacionais “permanecem um tanto quanto desconhecidos” (Liu *et al.*, 2023b, p. 1295). Foi evidenciado apenas uma aplicação em sala de aula ou em alunos no artigo de

Hung e Lee (2023) e não foi evidenciado estudos longitudinais, como evidenciado por Silva e Teles (no prelo).

3.5. Utilização de teorias pedagógicas

Não há menção a teorias pedagógicas nos artigos analisados, mas estratégias ou técnicas pedagógicas são mencionadas, como a aprendizagem contínua ou o diagnóstico cognitivo, como também evidenciado por Silva e Teles (no prelo), como segue:

Wang *et al.* (2023a) menciona a psicometria e a aprendizagem contínua.

Wang *et al.* (2023b) comenta que, embora vários estudos tenham fornecido interpretações sobre os estados de conhecimento dos alunos, elas se basearam apenas em sua concepção e na falta de apoio da teoria educacional” (Wang *et al.*, 2023b, p. 319, tradução nossa). Os autores mencionam que, para o rastreamento de conhecimento, é necessário considerar os antecedentes educacionais, que são “os fatores de teorias educacionais ou pesquisas de tecnologia, que são pensados ou descobertos relacionados ao processo de aprendizagem dos alunos” (p. 310, tradução nossa). Para o artigo, foram considerados os antecedentes do diagnóstico cognitivo, uma estratégia de aprendizagem.

Su *et al.* (2023) utilizam a estratégia da Curva de Aprendizagem. Zhao *et al.* (2023) considera também esta estratégia de aprendizagem assim como a “Teoria” do Esquecimento.

Cárdenas-López *et al.* (2023) consideraram estudos de emoções em processos de aprendizagem.

Liu *et al.* (2023) mencionam a utilização de estruturas mentais para resolução de problemas e também faz a correlação com conhecimentos pré-existentes.

Por fim, Li e Wang (2023) e Naranjo *et al.* (2023) consideram aspectos de interação do aluno na construção do seu modelo. Hung e Lee (2023) consideram exercícios práticos para aprendizagem de programação.

Considerações finais

Na análise bibliométrica, verificou-se que as publicações são oriundas, predominantemente, da China, com 22 artigos; seguida por Coréia do Sul, com 7 publicações; Austrália e Irã, com 3 cada um. Quando se verificam os periódicos em que houve publicação, há uma distribuição igualitária, de certa forma. O Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) possui mais periódicos com publicações. Inclusive, as publicações são predominantemente da área de computação.

Abdali-Mohammadi F., Liu Q., Liu Z., Sepahvand M., Wang Y. e Wang Z. são os autores que mais publicaram sobre o tema, sendo 3 artigos. Já Chen E, Chen J., Ding X. e Hu Y. publicaram 2 artigos em 2023. O artigo

mais citado é o *Knowledge Tracing: A Survey*, de Ghodai Abdelrahman, Qing Wang e Bernardo Nunes, com 3 citações. Na sequência, com duas citações, o artigo *An adaptive teacher–student learning algorithm with decomposed knowledge distillation for on-edge intelligence*, de Majid Sepahvand, Fardin Abdali-Mohammadi e Amir Taherkordi. O rastreamento do conhecimento (*knowledge tracing*) por meio de *deep learning* é um tema de pesquisa recente e que abarca grande parte dos artigos.

O rastreamento do conhecimento é aplicado em sistemas de recomendação educacional, oferta de currículo personalizado de acordo com as necessidades dos alunos, para potencializar a interação por meio de atividades práticas e baseadas em gamificação (ABDELRAHMAN *et al.*, 2023).

O rastreamento do conhecimento do aluno é fator crucial para que se construam sistemas adaptativos e são chave para a personalização do ensino, a qual estão inclusos os Sistemas Tutores Inteligentes, que foram mencionados em 6 artigos de forma direta, seja no título, palavras-chave ou resumo.

O fim de qualquer proposta educacional é que os estudantes aprendam. Este foi o objetivo que se verificou nos artigos analisados. A aprendizagem é o fim do processo. Para que a aprendizagem dos estudantes seja eficiente, é necessária uma prática pedagógica embasada em metodologias de ensino e que teorias pedagógicas sejam consideradas. São as teorias pedagógicas, que se desdobram em metodologias e estratégias de ensino que facilitam a aprendizagem. Em alguns artigos, são apresentadas teorias de aprendizagem e nos demais não são evidenciadas teorias básicas em psicologia educacional, como citado por Zhao *et al.* (2023) e evidenciado por Silva e Teles (no prelo). Uma das possibilidades para que estas teorias não sejam mencionadas é devido à falta de espaço nos artigos analisados ou não serem tão importantes visto o escopo da publicação. O *learning science* é comumente utilizado pelos desenvolvedores de STIs.

São utilizados conjunto de dados reais e artificiais para treinamento dos modelos. Estes dados são influenciados por metodologias de ensino e teorias pedagógicas das próprias instituições de ensino que os produzem. Da mesma forma, os dados contêm influência de processos mentais dos estudantes para resolução dos problemas, como contexto em que vivem e conhecimentos prévios.

Neste sentido, podem imputar ruídos que reduzem a eficiência do modelo no rastreamento do conhecimento. Abdelrahman *et al.* (2023) trazem problemas levantados em algumas bases, como mencionado anteriormente.

A pesquisa evidenciou falta de aplicações em contextos reais de sala de aula e estudos longitudinais, como

evidenciado por Silva e Teles (no prelo). Somente um artigo apresentou aplicação em sala de aula.

É também identificado que a maioria das publicações estão relacionadas a área da Ciência da Computação. É necessário que profissionais da área de Educação sejam inseridos em todo o processo de desenvolvimento (SILVA; TELES, no prelo). Por fim, Jing *et al* (2023, p. 16, tradução nossa), em sua pesquisa bibliográfica, coloca que se deve:

[...] prestar atenção aos limites das aplicações tecnológicas, usar a tecnologia de forma razoável para capacitar a pesquisa

e a aplicação da aprendizagem adaptativa e evitar comportamentos indesejáveis, incluindo educação liderada pela tecnologia e invasão de privacidade pessoal, para que a aprendizagem adaptativa possa realmente ser usada para maximizar seu valor em ajudar a alcançar uma aprendizagem personalizada de forma saudável e eficaz.

A IA, por meio da *deep learning*, tem o potencial de ajudar docentes no processo de ensino e os estudantes no processo de aprendizagem. Com o surgimento da IA generativa, que é um tipo de IA que utiliza técnicas de *deep learning* para gerar conteúdo, pesquisas futuras poderão ser realizadas com o objetivo de aplicá-la em STIs. ■

Notas

¹ As bases de dados IEEE Xplore e ACM Digital Library, as quais são reconhecidas pela alta qualidade técnica da literatura relacionada a *Deep Learning* em Sistemas Tutores Inteligentes, são indexadas à base de dados *Scopus*.

² A inferência bayesiana é uma abordagem estatística que utiliza o Teorema de Bayes para atualizar as probabilidades de hipóteses com base em novas evidências ou dados observados. Ela é chamada assim em homenagem ao matemático e estatístico Thomas Bayes.

Referências

- ABDELRAHMAN, Ghodaj; WANG, Qing; NUNES, Bernardo. Knowledge Tracing: A Survey. **ACM Computing Surveys**, v. 55, n. 11, p. 224:1-224:37, 2023. Disponível em: <https://dl.acm.org/doi/10.1145/3569576>. Acesso em: 8 jul. 2023.
- AGUIAR, Juliana Maciel; FERREIRA, Cristina Dos Santos; GARCIA, Ana Beatriz. Aplicação de modelo de tutoria proativa na modalidade semipresencial de ensino a distância utilizando ferramentas de interatividade e personalização. **EaD em Foco**, v. 1, n. 1, 2010. Disponível em: <https://eademfoco.cecierj.edu.br/index.php/Revista/article/view/17>. Acesso em: 29 out. 2023.
- ASHWIN, T.S.; PRAKASH, Vijay; RAJENDRAN, Ramkumar. A systematic review of intelligent tutoring systems based on Gross body movement detected using computer vision. **Computers and Education: artificial intelligence**, v. 4, p. 100125, 2023. Disponível em: <https://www.sciencedirect.ez54.periodicos.capes.gov.br/science/article/pii/S2666920X23000048>. Acesso em: 15 jul. 2023.
- BERNACKI, Matthew L.; GREENE, Meghan J.; LOBCZOWSKI, Nikki G. A systematic review of research on personalized learning: personalized by whom, to what, how, and for what purpose(s). **Educational Psychology Review**, v. 33, n. 4, p. 1675-1715, 2021.
- BLOOM, Benjamin Samuel. The 2 Sigma Problem: The search for methods of group instruction as effective as one-to-one tutoring. **Educational Researcher**, v. 13, n. 6, p. 4-16, 1984. Disponível em: <http://www.jstor.org/stable/1175554>. Acesso em: 20 jun. 2023.
- BISHOP, Christopher Michael. **Pattern recognition and machine learning**. Information science and statistics: Springer-Verlag. New York, 2006.
- BROILO, Liane; BROILO NETO, Gilberto. Pandemia 2020 e a EaD: o impacto do Covid-19 no ensino brasileiro. **ECCOM: Educação, Cultura e Comunicação**, v. 12, n. 23, p. 139-150, 2021.
- CÁRDENAS-LÓPEZ, Héctor Manuel; ZATARAIN-CABADA, Ramón; BARRÓN-ESTRADA, María Lucía; *et al*. Semantic fusion of facial expressions and textual opinions from different datasets for learning-centered emotion recognition. **Soft Computing**, 2023. Disponível em: <https://doi.org/10.1007/s00500-023-08076-1>. Acesso em: 9 jul. 2023.
- CHEN, Xieling; XIE, Haoran; ZOU, Di; *et al*. Application and theory gaps during the rise of Artificial Intelligence in Education. **Computers and Education: Artificial Intelligence**, v. 1, p. 100002, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2666920X20300023>. Acesso em: 29 out. 2023.
- DING, Xinyi; HAN, Tao; FANG, Yili; *et al*. An approach for combining multimodal fusion and neural architecture search applied to knowledge tracing. **Applied Intelligence**, v. 53, n. 9, p. 11092-11103, 2023. Disponível em: <https://doi.org/10.1007/s10489-022-04095-x>. Acesso em: 8 jul. 2023.

- HAYKIN, Simon. **Redes Neurais**. 2ª ed. Bookman Editora, 2007.
- HAN, Donghee; KIM, Daehee; HAN, Keejun; *et al.* Inductive Graph-based Knowledge Tracing. *In: 2023 IEEE International Conference on Big Data and Smart Computing (BigComp)*. [s.l.: s.n.], 2023, p. 92-99.
- HUNG, Hui-Chun; LEE, Ping-Han. Applying Deep Knowledge Tracing Model for University Students' Programming Learning. *In: 2023 International Conference on Information Networking (ICOIN)*. [s.l.: s.n.], 2023, p. 574-577.
- JIANG, Hua; XIAO, Bing; LUO, Yintao; *et al.* A self-attentive model for tracing knowledge and engagement in parallel. **Pattern Recognition Letters**, v. 165, p. 25-32, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167865522003464>. Acesso em: 9 jul. 2023.
- JING, Yuhui; ZHAO, Leying; ZHU, Keke; *et al.* Research Landscape of Adaptive Learning in Education: A Bibliometric Study on Research Publications from 2000 to 2022. **Sustainability**, v. 15, n. 4, p. 3115, 2023. Disponível em: <https://www.mdpi.com/2071-1050/15/4/3115>. Acesso em: 9 jul. 2023.
- KAUFMAN, Dora. **Desmistificando a Inteligência Artificial**. Belo Horizonte/São Paulo: Autêntica, 2022.
- LI, Linqing; WANG, Zhifeng. Calibrated Q-Matrix-Enhanced Deep Knowledge Tracing with Relational Attention Mechanism. **Applied Sciences**, v. 13, n. 4, p. 2541, 2023. Disponível em: <https://www.mdpi.com/2076-3417/13/4/2541>. Acesso em: 10 jul. 2023.
- LIMA JÚNIOR, Afonso Barbosa de; SILVA, Lebiã Tamar Gomes. Os sistemas tutores inteligentes e a adaptação do ensino aos perfis de aprendizagem do usuário. **ETD - Educação Temática Digital**, v. 24, n. 3, p. 618-632, 2022. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/etd/article/view/8663707>. Acesso em: 29 out. 2023.
- LIU, Zitao; CHEN, Jiahao; LUO, Weiqi. Recent Advances on Deep Learning based Knowledge Tracing. *In: Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2023, p. 1295-1296. (WSDM '23). Disponível em: <https://dl.acm.org/doi/10.1145/3539597.3575790>. Acesso em: 15 jul. 2023.
- LIU, Zitao; LIU, Qionggiong; CHEN, Jiahao; *et al.* Enhancing Deep Knowledge Tracing with Auxiliary Tasks. *In: Proceedings of the ACM Web Conference 2023*. Austin TX USA: ACM, 2023, p. 4178-4187. Disponível em: <https://dl.acm.org/doi/10.1145/3543507.3583866>. Acesso em: 10 jul. 2023.
- LUGER, George F. **Inteligência Artificial**. 6ª ed. Pearson Education do Brasil, 2013.
- MAO, Shun; ZHAN, Jieyu; WANG, Yizhao; *et al.* Improving Knowledge Tracing via Considering Two Types of Actual Differences From Exercises and Prior Knowledge. **IEEE Transactions on Learning Technologies**, v. 16, n. 3, p. 324-338, 2023.
- MCCARTHY, J. **What is AI?** / Basic Questions. Stanford University, 2007. Disponível em: <http://jmc.stanford.edu/artificial-intelligence/what-is-ai/index.html>. Acesso em: 26 jun. 2023.
- MEDEIROS, Luciano Frontino de. **Inteligência artificial aplicada: uma abordagem introdutória**. Curitiba: InterSaberes, 2018. Disponível em: <https://plataforma.bvirtual.com.br/Leitor/Publicacao/161682/epub/0?code=CUGHo2AMFIE+ede3S2ehSUz-TTL2n6lowI0EA5Q0JBusFLCuVnkgBiMjxMgMI3xVHxR8JKWd2/jr65FTNzMeeuQ==>. Acesso em: 26 jun. 2023.
- MOROSINI, Marília; KOHLS-SANTOS, Pricila; BITTENCOURT, Zoraia. **Estado do conhecimento: teoria e prática**. Curitiba: Editora CRV, 2021.
- NARANJO, Jose; ZHU, Changsheng; STOFFOVA, Veronika. Amended feeding for deep knowledge tracing. *In: 2023 10th International Conference on Signal Processing and Integrated Networks (SPIN)*. [s.l.: s.n.], 2023, p. 306-311.
- PAGANI, Regina Negri; KOVALESKI, João Luiz; RESENDE, Luis Mauricio. Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. **Scientometrics**, v. 105, n. 3, p. 2109-2135, 2015. Disponível em: <http://link.springer.com/10.1007/s11192-015-1744-x>. Acesso em: 29 out. 2023.
- ROF, Albert; BIKFALVI, Andrea; MARQUES, Pilar. Pandemic-accelerated Digital Transformation of a Born Digital Higher Education Institution: Towards a Customized Multimode Learning Strategy. **Educational Technology & Society**, v. 25, n. 1, p. 124-141, 2022.
- RUSSELL, Stuart Jonathan; NORWIG, Peter. **Inteligência Artificial: uma abordagem moderna**. 4ªed. São Paulo: LTC, 2022.
- SICILIANA, Isabel D. N. Aspectos da indústria 4.0 e a aplicação no compliance tributário. **J² - Jornal Jurídico**, [S. l.], v. 3, n. 2, p. 29-40, 2021. Disponível em: <https://revistas.ponteditora.org/index.php/j2/article/view/466>. Acesso em: 29 out. 2023.

- SHINDE, Pramila P.; SHAH, Seema. A review of machine learning and deep learning Applications. *In: 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*. Pune, Índia: IEEE, 2018, p. 1-6. Disponível em: <https://ieeexplore.ieee.org/document/8697857/>. Acesso em: 29 out. 2023.
- SILVA, Jefferson; TELES, Lúcio França. O uso de *deep learning* em Sistemas Tutores Inteligentes: uma análise do estado da arte no período entre 2018 a 2022. **Revista Brasileira de Informática na Educação – RBIE**. No prelo.
- SU, Hang; LIU, Xin; YANG, Shanghui; *et al.* Deep knowledge tracing with learning curves. **Frontiers in Psychology**, v. 14, 2023. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpsyg.2023.1150329>. Acesso em: 9 jul. 2023.
- WANG, Fei; HUANG, Zhenya; LIU, Qi; *et al.* Dynamic Cognitive Diagnosis: An Educational Priors-Enhanced Deep Knowledge Tracing Perspective. **IEEE Transactions on Learning Technologies**, v. 16, n. 3, p. 306-323, 2023a.
- WANG, Zhifeng; YAN, Wenxing; ZENG, Chunyan; *et al.* A Unified Interpretable Intelligent Learning Diagnosis Framework for Learning Performance Prediction in Intelligent Tutoring Systems. **International Journal of Intelligent Systems**, v. 2023, p. e4468025, 2023. Disponível em: <https://www.hindawi.com/journals/ijis/2023/4468025/>. Acesso em: 8 jul. 2023b.
- YIN, Yu; DAI, Le; HUANG, Zhenya; *et al.* Tracing Knowledge Instead of Patterns: Stable Knowledge Tracing with Diagnostic Transformer. *In: Proceedings of the ACM Web Conference 2023*. New York, NY, USA: Association for Computing Machinery, 2023, p. 855–864. Disponível em: <https://dl.acm.org/doi/10.1145/3543507.3583255>. Acesso em: 10 jul. 2023.
- ZHAI, Xuesong; CHU, Xiaoyan; CHAI, Ching Sing; *et al.* A Review of Artificial Intelligence (AI) in Education from 2010 to 2020. **Complexity**, v. 2021, p. 1-18, 2021. Disponível em: <https://www.hindawi.com/journals/complexity/2021/8812542/>. Acesso em: 29 out. 2023.
- ZHAO, Weizhong; XIA, Jun; JIANG, Xingpeng; *et al.* A novel framework for deep knowledge tracing via gating-controlled forgetting and learning mechanisms. **Information Processing & Management**, v. 60, n. 1, p. 103114, 2023. Disponível em: <https://www.sciencedirect.ez54.periodicos.capes.gov.br/science/article/pii/S0306457322002151>. Acesso em: 10 jul. 2023.
- ZHONG, Zhentao; LIU, Zhaohui; GU, Weifeng. Temporal Convolutional Knowledge Tracking Model with Embedded Graph Association Information. *In: 2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)*. [s.l.: s.n.], 2023, p. 1464-1469.
- ZHU, Jia; MA, Xiaodong; HUANG, Changqin. Stable Knowledge Tracing using Causal Inference. **IEEE Transactions on Learning Technologies**, p. 1-11, 2023.