Mapeamento Sistemático de Modelos de Redes para Processamento de Dados Educacionais Avaliativos

Eduardo dos Santos Gonçalves, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), edusantos@edu.unirio.br, https://orcid.org/0009-0007-7117-6547
Gleison B. de Moura, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), gleison@edu.unirio.br
Eric O. Leal, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), eric.leal@edu.unirio.br
José V. F. Serra, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), vicenteserra@edu.unirio.br
Laura O. Moraes, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), laura@uniriotec.br, https://orcid.org/0000-0003-0965-6703
Jefferson Elbert Simões, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), jefferson.simoes@uniriotec.br, https://orcid.org/0000-0002-0359-118X
Ana Cristina Bicharra Garcia, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), cristina.bicharra@uniriotec.br, https://orcid.org/0000-0002-3797-5157
Simone Bacellar Leal Ferreira, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), simone@uniriotec.br, https://orcid.org/0000-0001-9031-0122

Resumo: Avanços tecnológicos geram grande volume de dados educacionais, requerendo métodos eficientes de análise, como a Mineração de Dados Educacionais (EDM). Este estudo mapeia o uso de modelos de rede, como redes neurais baseadas em grafos (GNNs) e recorrentes (RNNs), aplicados a dados educacionais avaliativos, utilizados comumente em predição de desempenho, identificação de risco de evasão, rastreamento de conhecimento e recomendação de conteúdos em MOOCs e cursos online. Com arquiteturas modernas, incluindo *Transformers* e aprendizado federado, os modelos enfrentam desafios como escassez de dados e privacidade, e a necessidade de ambientes de aprendizagem mais adaptativos e personalizados. Entretanto, o mapeamento revelou uma lacuna crítica: nenhum dos estudos analisados abordou os níveis de ensino fundamental ou médio, com uma forte concentração de pesquisas na China. Esse resultado evidencia uma falta de diversidade em níveis educacionais e representatividade geográfica.

Palavras-chave: Mineração de Dados Educacionais, Modelos Em Rede, Dados Educacionais Avaliativos

Systematic Mapping of Network Models for Processing Evaluative Educational Data

Abstract: Technological advances generate a large volume of educational data, requiring efficient analysis methods such as Educational Data Mining (EDM). This study reviews the use of network models, such as graph-based neural networks (GNNs) and recurrent neural networks (RNNs), applied to evaluative educational data, commonly used in tasks such as performance prediction, dropout risk identification, knowledge tracing, and content recommendation in MOOCs and online courses. Using modern architectures such as Transformers and federated learning, the models face challenges like data scarcity and privacy, and the need for more adaptive and personalized learning environments. However, this study revealed a critical gap: none of the analyzed studies addressed elementary or high school levels, with a strong concentration of research in China. This result highlights a lack of diversity in educational levels and geographical representation.

Palavras-chave: Educational Data Mining, Network Models, Student Assessment Data

1. Introdução

A evolução da educação impulsionada pelos avanços tecnológicos e a vasta disponibilidade de dados tem guiado um crescimento exponencial no volume de dados educacionais, e uma análise manual se torna uma tarefa árdua (Romero e Ventura, 2020; Sousa e Filho, 2024). A Mineração de Dados Educacionais (MDE) surge como uma metodologia crucial para otimizar a eficiência e a qualidade da análise, e permite a extração de *insights* valiosos, a identificação de tendências e padrões, e o auxílio na tomada de decisões baseadas em dados (Vivian *et al.*, 2022).

A modelagem em redes é presente em diversas áreas de estudo (e.g. matemática, física) e podem ser utilizadas para representar interações entre atores (seja na análise de redes sociais) ou por uma abordagem de aprendizagem de máquina baseada em dados que representam nós similares a uma grande rede de neurônios em um cérebro (Okewu *et al.*, 2021), capazes de aprender padrões complexos a partir de grandes volumes de dados (Wasserman e Faust, 1994).

Neste contexto, o presente estudo se propõe a investigar se, em dados educacionais avaliativos, a utilização de modelos de rede é mais eficaz do que os métodos tradicionais para identificar padrões de desempenho estudantil. Com o objetivo de abordar esse contexto, o presente estudo apresenta uma revisão sistemática da literatura (RSL) que busca investigar este contexto, compreendendo o estado da arte e identificando as técnicas de MDE com melhor acurácia. A motivação para este estudo se desdobra na oportunidade de otimizar a eficiência e a qualidade na análise de grandes volumes de dados educacionais, permitindo que as instituições de ensino realizem intervenções quando necessário e aprimorem continuamente a qualidade do ensino.

Para atingir esses objetivos, a RSL, baseada em um modelo que abrange fases de planejamento, implementação e resultados, estrutura a análise dos resultados em torno de questões norteadoras específicas, mapeadas a partir do objetivo principal da revisão. Estas incluem a exploração dos tipos de modelos de representação em redes empregados no processamento de dados educacionais, as suas principais aplicações nesse contexto, bem como as vantagens e limitações dos diferentes modelos identificados na literatura. Estes objetivos estão endereçados pelas questões a seguir, que são expandidas e detalhadas na Tabela 2: (i) Como as redes são estruturadas?; (ii) De que forma os modelos de redes são utilizados para identificar padrões de desempenho estudantil?; (iii) Como a eficiência é avaliada?; (iv) Quais são os desafios e limitações da aplicação de Modelos de Redes em dados educacionais avaliativos?

Adicionalmente, será investigado o que torna o uso da representação em redes mais eficiente em comparação com modelos tradicionais, fornecendo uma visão abrangente que sintetiza as evidências empíricas e teóricas sobre o tema.

2. Trabalhos Relacionados

Três estudos recentes revisaram aplicações de técnicas de análise de dados no contexto educacional. Cela *et al.* (2015) conduziram uma revisão sistemática sobre a análise de redes sociais (ARS) em ambientes de *e-learning*, focando na identificação de padrões de interação, uso de medidas como centralidade e densidade, e aplicação em redes de um único modo (predominantemente alunos) para descrever e analisar comportamentos em rede. Okewu *et al.* (2021) realizaram uma revisão sistemática sobre o uso de redes neurais artificiais (RNA) para mineração de dados educacionais (MDE) no ensino superior. O estudo evidenciou avanços na previsão de desempenho, identificação de padrões e detecção de risco de evasão, mas também desafios técnicos e uma carência em abordagens integradas que contemplem desde a modelagem dos dados até a intervenção pedagógica. Sousa e Filho (2024) focaram em uma revisão

sistemática sobre a mineração de dados educacionais para predição de desempenho profissional, analisando técnicas determinísticas. A revisão selecionou 5 estudos, que apontam variáveis como notas, faltas, educação dos pais e aulas particulares como preditores importantes, e o *framework Weka* como ferramenta predominante. Observou-se que modelos determinísticos como Árvore de Decisão J48 e o algoritmo de *Naïve Bayes* são eficazes na predição de desempenho profissional, com possibilidade de automação.

O presente estudo se diferencia dos trabalhos citados por integrar e expandir as perspectivas abordadas. Enquanto Okewu *et al.* (2021) focam em RNA e seus aspectos técnicos para MDE no ensino superior, Cela *et al.* (2015) se dedicam à ARS em ambientes de *e-learning*, e Sousa e Filho (2024) abordam técnicas para automação de sistemas de avaliação e previsão de desempenho profissional, esta revisão propõe uma análise mais abrangente. Nosso estudo abarca o uso de diversos modelos de redes, incluindo tanto as RNA quanto a ARS, aplicados ao processamento de dados educacionais, com um enfoque em dados avaliativos.

3. Metodologia

Uma revisão sistemática da literatura (RSL) foi conduzida, seguindo o protocolo *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (Page *et al.*, 2021), tendo como objetivo a identificação, avaliação e sintetização de pesquisas primárias sobre a utilização de modelos em rede na mineração de dados educacionais sob dados avaliativos. A RSL foi escolhida por sua capacidade de prover uma síntese do estado da arte sobre um campo de estudo (Page *et al.*, 2021). A RSL foi conduzida por quatro pesquisadores e acompanhada por uma pesquisadora experiente na disciplina de metodologia científica. Dentro do PICO, nossa População ficou estabelecida como “dados educacionais avaliativos”, para Intervenção estabelecemos a “utilização de modelos de rede”, já para Comparação estabelecemos “métodos tradicionais”.

Na pré-análise dos artigos foram detectados 62 votos por categoria, totalizando 260 votos. A proporção de sim ficou em 0,24, aproximadamente. Enquanto a proporção de não ficou em 0,76, aproximadamente. A concordância esperada ficou em 0,64. Já o KAPPA ficou em 0,84. Estas informações estão estruturadas na Tabela 1.

Tabela 1 - Métrica de Confiabilidade entre Avaliadores (Kappa)

Métrica	**Valor**
Votos por categoria	62
Total de votos	260
Proporção de “sim”	0,24
Proporção de “não”	0,76
Concordância esperada	0,64
Kappa	0,84

3.1. Planejamento

Para atingir ao objetivo do estudo, foram formuladas quatro questões de pesquisa (QP) sob a principal QP deste estudo: “**Em dados educacionais avaliativos, a utilização de modelos de rede é mais eficaz do que os métodos tradicionais para identificar padrões de desempenho estudantil?**”. As QP estão detalhadas na Tabela 2 juntamente com as subquestões que auxiliam no desenvolvimento de suas repostas.

3.2. Estratégia de busca

A busca foi realizada em bases acadêmicas de referência na área da computação: Scopus[1], ACM Digital Library [2] e IEEE Xplore [3]. Para conduzir as buscas automatizadas, foi definida uma *string* de busca com base nos principais termos utilizados nas QP, junto a estratégia PICO, que considera os elementos de População (P), Intervenção (I), Comparação (C) e Resultados (do inglês, *Outcome* - O). A elaboração e teste de diferentes versões da *string* foram realizadas nas bases de dados selecionadas.

Por fim, a *string* foi revisada pelos quatro pesquisadores e a pesquisadora experiente na disciplina de metodologia científica. A seguinte *string* de busca foi utilizada neste estudo: *("network models" OR "neural networks" OR "bayesian networks" OR "graph models") AND ("educational data" OR "student assessment" OR "learning evaluation") AND ("efficiency" OR "effectiveness" OR "accuracy" OR "performance") AND ("data processing" OR "data analysis").*

Tabela 2 - Questões de Pesquisa

ID	Questão de Pesquisa	Sub-questão	Meta
QP1	Quais as estruturações destas redes?	Quais as características das redes (nós e arestas)?	Identificar as características das redes, os modelos utilizados e as técnicas de otimização/ajuste.
		Qual modelo de rede utilizado?	
		Quais técnicas otimizam ou ajustam a estrutura?	
QP2	Como os Modelos de Redes revelam padrões de desempenho?	Quais tarefas analíticas são realizadas?	Listar tarefas analíticas, explicar como capturam padrões e onde superam modelos tradicionais.
		Como capturam e representam padrões de desempenho?	
		Em que cenários superam abordagens tradicionais?	
QP3	Como a eficiência é avaliada?	Quais métricas são mais reportadas?	Apontar métricas comparativas, contextos de uso e impacto da escolha de métricas.
		Em quais contextos as métricas se concentram?	
		Como influenciam a escolha dos métodos?	
QP4	Quais desafios e limitações nos dados educacionais?	Quais barreiras técnicas (hardware, software, algoritmos)?	Levantar barreiras técnicas, limitações de dados e cenários de melhor aplicabilidade.
		Quais limitações de qualidade e quantidade de dados?	
		Em que cenários a aplicação é mais eficaz?	

3.3. Critérios de seleção

Para a seleção dos estudos, foram definidos e aplicados critérios de inclusão (CI) e exclusão (CE), conforme listado abaixo na Tabela 3. Os estudos foram incluídos se atendiam a todos os CI e foram excluídos caso se enquadrassem em pelo menos um dos CE.

Tabela 3 - Critérios de seleção

	ID	Descrição
Critérios de Inclusão	CI1	Estudo responde pelo menos uma QP.
	CI2	Estudo publicado entre janeiro de 2018 e maio de 2025.
Critérios de Exclusão	CE1	Estudo secundário (e.g., mapeamento sistemático da literatura e revisão sistemática da literatura).
	CE2	Estudo duplicado.
	CE3	Estudo sem evidências quantitativas ou qualitativas.
	CE4	Estudo que não esteja escrito em inglês.
	CE5	Estudo que seja prefácio, livro, capítulo de livro, resumo, pôster, painel, palestra, *keynote*, tutorial, editorial ou demonstração.
	CE6	Estudo publicado antes de janeiro de 2018.
	CE7	Estudo não atende nenhum dos CI.

3.4. Processo de seleção dos estudos

Este estudo contou com o processo de seleção em seis etapas:

(i) Execução da busca automatizada dos estudos primários (aplicação da *string* de busca)

[1]https://www.scopus.com
[2]https://dl.acm.org
[3]https://ieeexplore.ieee.org

sob o título, *abstract* ou palavras-chave junto ao ano de publicação;
(ii) 1º Filtro: Remoção de estudos duplicados (aplicação do CE2);
(iii) Aplicação do 2º Filtro: leitura do título, resumo e palavras-chave;
(iv) Aplicação do 3º Filtro: leitura completa do estudo; e
(v) Extração de dados e síntese.

3.5. Extração de dados e síntese

A extração dos dados foi conduzida pelos quatro pesquisadores, seguida por uma verificação dos resultados pela pesquisadora experiente na disciplina de metodologia científica. A extração dos dados foi realizada de maneira sistemática com o auxílio da ferramenta Parsifal[4] e com apoio da ferramenta Planilhas Google para registrar as informações necessárias. Para responder às QP assegurando uma compreensão sistemática e a coleta de informações relevantes, estruturas específicas foram definidas para a extração e organização dos dados, conforme apresentado no material suplementar disponível abertamente [5].

4. Resultados

Para obter um resultado que representasse uma atualidade nos resultados, foi aplicado um filtro na seleção de artigos para incluir somente artigos posteriores a 2018 (conforme CE6), para que fosse possível apresentar as metodologias mais avançadas e as aplicações práticas mais relevantes no uso de modelos de redes para processar dados educacionais avaliativos.

O processo de seleção dos estudos seguiu as diretrizes do PRISMA (Page *et al.*, 2021), conforme as definições:

1. **Identificação**: Busca sistemática nas bases de dados sob a *string* de busca definida, resultando na identificação inicial de 495 estudos;
2. **Triagem inicial**: Aplica a remoção de estudos duplicados e uma análise preliminar sob os títulos e resumos realizada independente por quatro pesquisadores;
3. **Elegibilidade**: Dentre os estudos pré-selecionados, os quatro pesquisadores realizaram uma análise detalhada sobre os estudos, gerando uma calibração nos critérios de inclusão e exclusão, visando uniformizar o entendimento e assegurar a consistência das análises realizadas. Cada estudo foi revisado de forma independente e com resolução de divergências por consenso;
4. **Inclusão final**: Após a avaliação detalhada, 14 estudos foram selecionados para compor a lista de estudos analisados por esta RSL.

A Figura 1 apresenta o número de estudos restantes em cada etapa do processo de seleção da RSL. Ao final do processo de seleção, foram selecionados 14 estudos para extração e síntese dos dados. Os dados brutos e todas as etapas necessárias para reproduzir a pesquisa estão detalhados no material suplementar disponível abertamente [5].

4.1. Resultados descritivos da revisão

Os estudos analisados para o desenvolvimento desta revisão indicam que o tema é relativamente recente, uma vez que o artigo mais antigo selecionado foi publicado em 2017, abrangendo, portanto, uma janela temporal de apenas oito anos de pesquisa. Além disso, observa-se um crescimento expressivo no número de estudos realizados nos últimos três anos. A Figura 2 apresenta a distribuição das publicações ao longo dos anos, juntamente com os países de origem dos autores.

[4] https://parsif.al/
[5] https://doi.org/10.5281/zenodo.17388111

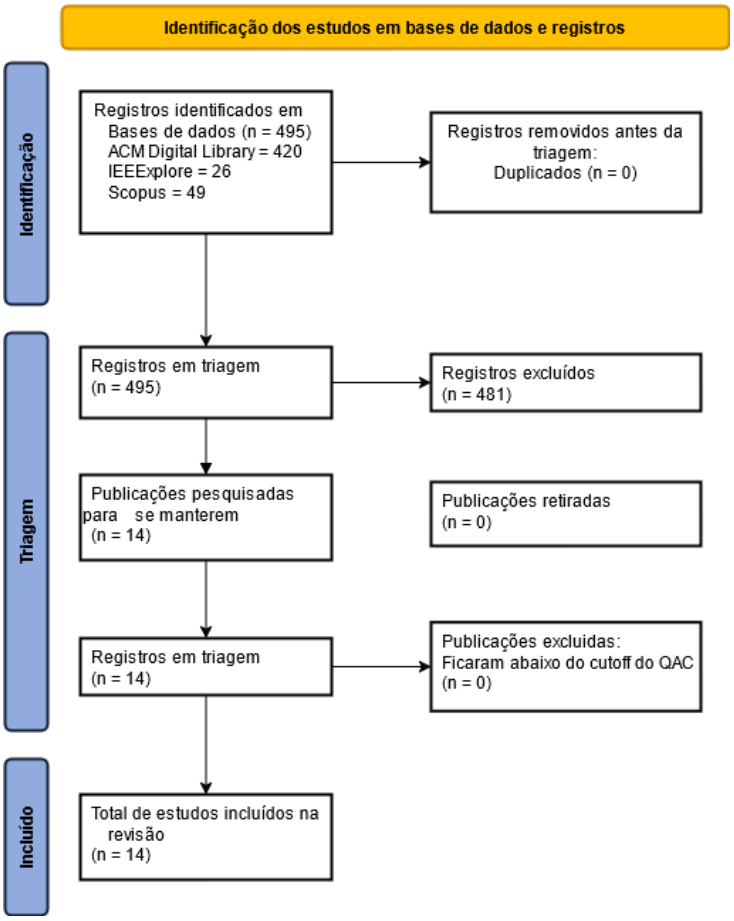

Figura 1 - Processo de seleção dos estudos

A distribuição geográfica, obtida a partir dos países de origem dos autores, indica que a expressiva maioria dos estudos foi produzida por pesquisadores provenientes de países asiáticos, os quais correspondem a 11 estudos (78% do total de publicações analisadas), sendo que 8 destes (72% dos asiáticos) destes são de autoria chinesa. A Figura 3 ilustra os países identificados no levantamento dos artigos, bem como a respectiva quantidade de publicações atribuídas a cada um.

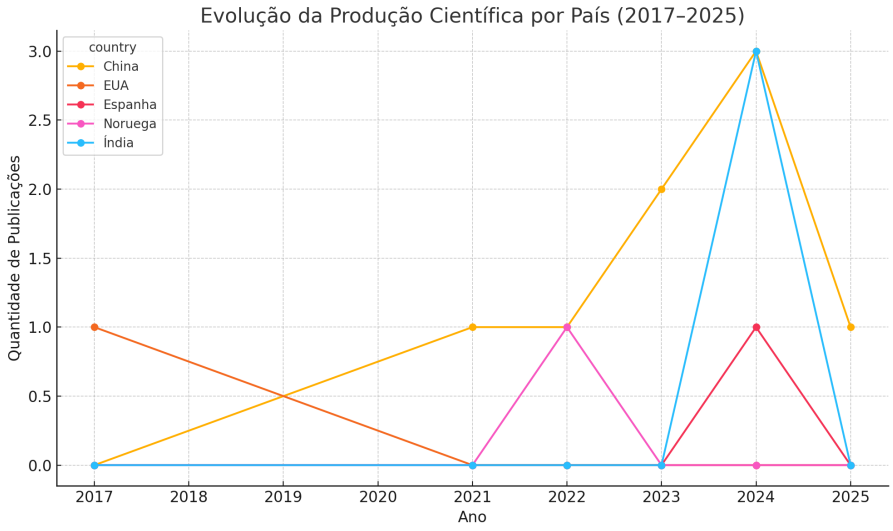

Figura 2 - Evolução temporal de publicações por país

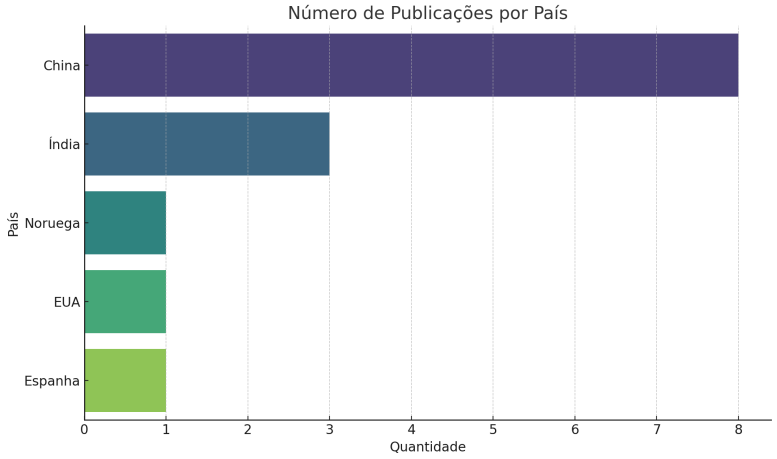

Figura 3 - Quantidade de publicações por país

4.2. Resultados específicos da revisão

Esta revisão foi projetada de forma que pudesse responder as questões levantadas na Seção 3.1. Com isso, esta seção vai explorar as descobertas obtidas a partir das pesquisas levantadas.

4.2.1. Q1 - Como as redes são estruturadas?

A sistematização das abordagens de modelagem de redes em contextos educacionais evidencia duas categorias predominantes: redes com estrutura explícita e redes com estrutura implícita. As primeiras são caracterizadas pela definição manual dos elementos da rede — nós e arestas — com base em critérios pedagógicos ou analíticos previamente estabelecidos pelos pesquisadores, como a similaridade de desempenho entre estudantes ou a sequência lógica de conceitos disciplinares.

Já as redes com estrutura implícita emergem a partir da aplicação de técnicas de aprendizado profundo, nas quais a estrutura relacional é inferida automaticamente a partir dos dados, permitindo capturar dinâmicas complexas de aprendizagem, como a evolução dos estados de conhecimento ao longo do tempo. A Tabela 4 sintetiza essas abordagens, contrastando suas principais características, métodos de construção, técnicas computacionais envolvidas, estratégias de refinamento estrutural e requisitos de pré-processamento, com base em estudos recentes da literatura especializada.

4.2.2. Q2 - De que forma os modelos de redes são utilizados para identificar padrões de desempenho estudantil?

Modelos de rede na educação servem para prever resultados, identificar alunos em risco e personalizar a jornada de aprendizagem. A força desses modelos está em sua capacidade de analisar o desempenho estudantil como um processo dinâmico.

Modelos como redes neurais recorrentes bidirecionais (do inglês, *bidirectional long short-term memory* - LSTM) e *temporal convolutional networks* (TCN) são usados para analisar padrões de comportamento dos estudantes ao longo do tempo, antecipando sucesso acadêmico ou dificuldades futuras (Alanya-Beltran, 2024; Murugan *et al.*, 2024; Yang *et al.*, 2017; Zhang *et al.*, 2024). Essa capacidade é crucial para combater a evasão em cursos online, onde sistemas de alerta detectam sinais de desengajamento a partir da análise de interações e tempo de dedicação (G *et al.*, 2024; Zhang *et al.*, 2023; Zhang *et al.*, 2024). Os modelos também personalizam o aprendizado:

Tabela 4 - Comparação de redes com estrutura explícita e implícita em pesquisas educacionais

Aspecto	Redes com Estrutura Explícita	Redes com Estrutura Implícita
Definição	Estrutura definida previamente pelos pesquisadores.	Estrutura descoberta automaticamente pelos modelos.
Quem define a estrutura	Pesquisadores	Modelo de IA (aprendizado profundo)
Nós (exemplos)	Estudantes, conceitos de uma matéria	Estados de conhecimento, comportamentos processados
Arestas (exemplos)	Similaridade de desempenho, relações lógicas entre conceitos	Transições entre estados de conhecimento, padrões implícitos
Modelos / Técnicas utilizadas	Mapas de afinidade; Sequenciamento de conceitos	CNNs (*convolutional neural network*); BKT; LSTM; TCN; Módulos de atenção; Regularização bayesiana
Referências	Jing (2024); Lai e Zhang (2024) e Xue (2023)	Strukova *et al.* (2023); Yang *et al.* (2017) e Zhang *et al.* (2024)
Exemplos de aplicação	Agrupamento por desempenho; Criação de percursos de aprendizagem	Extração de padrões de comportamento; Rastreamento da progressão de conhecimento
Refinamento da estrutura	Conexões definidas manualmente; Limiar de correlação; Aprendizado adversarial	Regularização bayesiana; Módulos de atenção para foco em padrões relevantes
Pré-processamento e preparação de dados	Seleção de atributos (ex: Random Forest); Padronização de dados heterogêneos	Essencial para modelos implícitos; Pré-requisito para Transformers
Ajuste fino	Ajuste manual ou via otimização de taxas de acerto e erro	Realizado durante o treinamento e validação do modelo

- **Acompanhamento contínuo do conhecimento:** Funcionam como um "GPS educacional", oferecendo *feedback* e sugestões de atividades com base no progresso individual, como os modelos *Bayesian Knowledge Tracing* (BKT) e Elo (Strukova *et al.*, 2023).
- **Agrupamento de alunos:** Identificam padrões de similaridade para agrupar estudantes com perfis e trajetórias semelhantes, utilizando redes de grafos (Lai e Zhang, 2024) ou combinando técnicas de agrupamento com redes neurais profundas (Yang *et al.*, 2022).
- **Sistemas de recomendação:** Grafos de conhecimento traçam trilhas de estudo únicas, compreendendo as relações entre tópicos e os interesses do aluno (Xue, 2023).

A principal força desses modelos reside em sua capacidade de enxergar o desempenho estudantil como algo dinâmico. Pesquisas recentes focam em capturar dependências temporais nos dados, "assistindo" à trajetória de cada aluno (G *et al.*, 2024; Guo *et al.*, 2021; Jing, 2024). Isso envolve a organização de dados estudantis processados por redes convolucionais para extrair padrões espaciais e relacionais, como no modelo IC-BTCN (Zhang *et al.*, 2024) e ajuste dinâmico do nível de competência e dificuldade, oferecendo um retrato mais fiel das habilidades cognitivas (Strukova *et al.*, 2023).

A análise se estende à similaridade e interações sociais. Pesquisadores utilizam correlações estatísticas para encontrar estudantes com evolução parecida (Lai e Zhang, 2024), empregam embeddings semânticos para revelar padrões coletivos em grafos de conhecimento (Xue, 2023), e chegam a integrar a estrutura das redes sociais dos alunos para prever o sucesso acadêmico com base nas interações entre pares (Tian *et al.*, 2025). Essa visão dinâmica é complementada por sistemas de avaliação contínua, como o modelo baseado em Elo (Vesin *et al.*, 2022), que reavalia a proficiência do estudante a cada nova atividade.

4.2.3. Q3 - Como a eficiência é validada?

Os estudos analisados demonstram que a eficiência foi observada sob dois principais contextos: a precisão do modelo, citada em praticamente todos os artigos, e sua robustez, mencionada em dois deles. Para essa análise, foi fundamental identificar quais métricas foram utilizadas para mensurar o nível de eficiência de cada modelo na execução de suas tarefas. A Figura 4 ilustra a distribuição dessas métricas.

A Tabela 5 explicita quais autores mencionam cada métrica na avaliação da eficiência

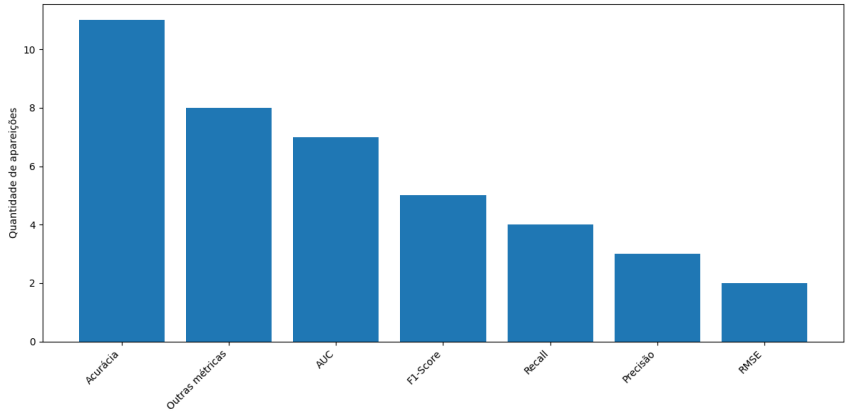

Figura 4 - Quantidade de artigos por métrica

de seus modelos. Além dos autores presentes na tabela, Jing (2024) discute o Valor de Perda; Zhang *et al.* (2023) apresenta o Erro Absoluto Médio (MAE); Tian *et al.* (2025) traz a Precisão Média Ponderada, o Recall Médio Ponderado e o F1-Score Médio Ponderado; e, por fim, Yang *et al.* (2022) utiliza o Erro Quadrático Médio (MSE).

Tabela 5 - Citações em artigos por métrica

Métrica	**Artigos**
Acurácia	Alanya-Beltran (2024); G *et al.* (2024); Guo *et al.* (2021); Jing (2024); Lai e Zhang (2024); Murugan *et al.* (2024); Strukova *et al.* (2023); Tian *et al.* (2025); Vesin *et al.* (2022); Xue (2023) e Zhang *et al.* (2024)
Área sobre a curva ROC (AUC)	Alanya-Beltran (2024) G *et al.* (2024); Guo *et al.* (2021); Jing (2024); Strukova *et al.* (2023); Zhang *et al.* (2023) e Zhang *et al.* (2024)
F1-Score	Jing (2024); Murugan *et al.* (2024); Strukova *et al.* (2023); Xue (2023) e Zhang *et al.* (2024)
Recall	Murugan *et al.* (2024); Vesin *et al.* (2022); Xue (2023) e Zhang *et al.* (2024)
Precisão	Murugan *et al.* (2024); Xue (2023) e Zhang *et al.* (2024)
RMSE	Xue (2023) e Zhang *et al.* (2023)

Os autores também discutem como a escolha de cada métrica influencia a seleção dos métodos estudados. A maioria dos textos destaca um grande foco na performance do modelo, geralmente visando o desempenho em predição e previsão, mas também considerando a quantidade de dados e o processo como um todo. Além disso, são abordados aspectos relacionados à consistência e à qualidade das recomendações fornecidas pelo modelo.

4.2.4. Q4 - Quais são os desafios e limitações da aplicação de modelos de redes em dados educacionais avaliativos?

A implementação de redes neurais na educação enfrenta desafios notáveis, como a complexidade computacional exigida por arquiteturas avançadas, a escassez e a baixa qualidade de dados estruturados em ambientes educacionais, e questões éticas relacionadas à privacidade em modelos federados (Guo *et al.*, 2021; Jing, 2024; Strukova *et al.*, 2023; Tian *et al.*, 2025; Vesin *et al.*, 2022; Zhang *et al.*, 2023). Esses obstáculos limitam a adoção generalizada dessas tecnologias em contextos com recursos mais modestos.

No entanto, o potencial transformador das redes neurais na educação é inegável. Elas permitem a detecção precoce de dificuldades de aprendizagem, a personalização de conteúdos em plataformas adaptativas e a identificação de riscos de evasão em MOOCs (Tian *et al.*, 2025; Xue, 2023; Yang *et al.*, 2017; Zhang *et al.*, 2024). O futuro dessas ferramentas no cenário educacional dependerá do equilíbrio cuidadoso entre suas limitações técnicas e as vastas oportunidades que oferecem para aprimorar o processo de ensino-aprendizagem.

5. Discussão

A análise sistemática conduzida nesta revisão revela que os modelos de redes — como redes neurais gráficas, RNNs, LSTMs, TCNs e *Transformers* — possuem grande potencial para melhorar o processamento de dados avaliativos na educação. Sua eficiência em capturar padrões complexos e dinâmicos do desempenho estudantil, supera métodos tradicionais mais estáticos.

As aplicações incluem previsão de resultados acadêmicos, detecção de risco de evasão e personalização de trajetórias de aprendizagem, tornando a análise de dados educacionais mais precisa e voltada para intervenções pedagógicas eficazes. Modelos como LSTM e TCN se mostram especialmente úteis em tarefas que envolvem dependências temporais, enquanto redes de grafos contribuem para entender relações sociais e padrões de desempenho entre estudantes.

A avaliação da eficácia desses modelos é feita com métricas como acurácia, AUC e *F1-Score*, focando no desempenho preditivo. No entanto, surgem preocupações com a interpretabilidade dos modelos, sua viabilidade prática e os altos custos computacionais, especialmente em instituições com infraestrutura limitada.

Entretanto, esta revisão identificou uma lacuna de pesquisa significativa: todos os estudos analisados concentram-se exclusivamente em dados provenientes do ensino superior. Considerando que os níveis de Ensino Fundamental e Médio abrangem uma quantidade muito maior de estudantes, com grande diversidade de contextos socioeconômicos e pedagógicos, seria natural esperar maior atenção da comunidade científica a esses segmentos. A ausência de estudos voltados para a educação básica levanta questionamentos importantes: por que as tecnologias de redes, amplamente utilizadas em outros campos e níveis de ensino, ainda não estão sendo aplicadas de forma sistemática para aprimorar os processos avaliativos nas redes formais de educação básica? Quais barreiras – sejam elas relacionadas a disponibilidade de dados, infraestrutura, políticas educacionais ou prioridades de pesquisa – estão limitando o avanço nessa direção?

Embora esta RSL não permita a identificação de respostas absolutas para as lacunas observadas, é possível levantar algumas hipóteses fundamentadas nos achados da literatura. A ausência de pesquisas voltadas para a educação básica pode estar relacionada à dificuldade de acesso a dados educacionais desse segmento, uma vez que os artigos analisados indicam que a maioria dos conjuntos de dados utilizados provém de instituições de ensino superior. Nesses ambientes, o uso de Learning Management Systems (LMS) e outras plataformas digitais facilita a coleta e o armazenamento de dados em larga escala.

Em contraste, na educação básica, esse tipo de infraestrutura tecnológica ainda é muito menos comum. Além disso, barreiras técnicas também podem limitar a aplicação de modelos de redes nesse contexto, considerando que a análise desses dados demanda recursos computacionais e competências técnicas frequentemente indisponíveis nas escolas de ensino fundamental e médio. Outro aspecto relevante refere-se às questões éticas e legais envolvidas na coleta e uso de dados de menores de idade, que tornam o processo de pesquisa mais restrito e sensível. Esses fatores, em conjunto, podem explicar a lacuna identificada, mas demandam investigação mais aprofundada em estudos futuros.

6. Conclusão e Trabalhos Futuros

A partir da revisão sistemática apresentada é possível concluir que modelos de redes oferecem vantagens expressivas sobre métodos tradicionais na análise de dados educacionais: eles são mais eficazes para identificar padrões complexos de desempenho, prever resultados acadêmicos, detectar riscos de evasão e personalizar o aprendizado, especialmente em ambientes online como MOOCs. A análise de 14 estudos entre 2018 e 2025 confirma o potencial dessas abordagens para otimizar o uso de grandes volumes de dados e apoiar

intervenções pedagógicas mais precisas.

Contudo, foi identificada uma lacuna crítica na literatura: não há estudos considerando modelos de rede em dados da educação básica (ensino fundamental e médio). Além disso, observou-se uma forte concentração geográfica das pesquisas, em especial na China, indicando uma baixa diversidade educacional e representatividade global.

Apesar do potencial dos modelos, ainda há desafios, especialmente em instituições com poucos recursos. Recomendamos que estudos futuros explorem como tornar esses modelos mais acessíveis, integrem princípios éticos desde o início e considerem abordagens híbridas com métodos tradicionais. Também sugerimos expandir as pesquisas para contextos educacionais diversos, promovendo equidade no acesso às tecnologias analíticas.

Agradecimentos

Este estudo foi realizado com apoio da UNIRIO através do PPInst 2024.

Referências

Alanya-Beltran, J. Machine learning in education: Predicting student performance using long short-term memory networks. In: **2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)**. [S.l.: s.n.], 2024. p. 1–5.

Cela, K. L.; Sicilia, M. Á.; Sánchez, S. Social network analysis in e-learning environments: A preliminary systematic review. **Educational Psychology Review**, v. 27, n. 1, p. 219–246, Mar 2015. ISSN 1573-336X. Disponível em: ⟨https://doi.org/10.1007/s10648-014-9276-0⟩.

G, S.; R, A. P.; T, B. Predicting student dropout using educational data with temporal convolutional network. In: **2024 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES)**. [S.l.: s.n.], 2024. p. 1–7.

Guo, T. *et al.* Improving knowledge tracing through multi-source scaling with decoder-only transformers. **ACM Transactions on Intelligent Systems and Technology**, p. 1–25, 2021.

Jing, L. Integrating advanced neural techniques in educational data: Attention-enhanced lstm and agcn for time series and clustering analysis. **2024 4th Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)**, IEEE, p. 1–5, 2024.

Lai, X.; Zhang, Z. Research on student performance prediction based on clustered graph neural networks. In: IEEE. **2024 4th International Conference on Machine Learning and Intelligent Systems Engineering (MLISE)**. [S.l.], 2024. p. 1–4.

Murugan, R. *et al.* Utilizing recurrent neural networks for predictive student performance analysis in online courses. In: **2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)**. [S.l.: s.n.], 2024. p. 1–6.

Okewu, E.; Adewole, P.; Misra, S.; Maskeliunas, R.; and, R. D. Artificial neural networks for educational data mining in higher education: A systematic literature review. **Applied Artificial Intelligence**, Taylor & Francis, v. 35, n. 13, p. 983–1021, 2021. Disponível em: ⟨https://doi.org/10.1080/08839514.2021.1922847⟩.

Page, M. J. *et al.* The prisma 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, BMJ Publishing Group Ltd, v. 372, 2021. Disponível em: ⟨https://www.bmj.com/content/372/bmj.n71⟩.

Romero, C.; Ventura, S. Educational data mining and learning analytics: An updated survey. **WIREs Data Mining and Knowledge Discovery**, v. 10, n. 3, p. e1355, 2020. Disponível em:

⟨https://wires.onlinelibrary.wiley.com/doi/abs/10.1002/widm.1355⟩.

Sousa, T. Lopes de A.; Filho, M. C. Mineração de dados educacionais para predição de desempenho profissional: uma revisão sistemática. **Informática na educação: teoria & prática**, v. 27, n. 1, jun. 2024. Disponível em: ⟨https://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/137608⟩.

Strukova, S.; Ruipérez-Valiente, J. A.; Mármol, F. G. Adapting knowledge inference algorithms to measure geometry competencies through a puzzle game. **ACM Trans. Knowl. Discov. Data**, Association for Computing Machinery, New York, NY, USA, v. 18, n. 1, set. 2023. ISSN 1556-4681. Disponível em: ⟨https://doi.org/10.1145/3614436⟩.

Tian, J.; Lin, J.; Li, D. From social to academic: Associations and predictions between different types of peer relationships and academic performance among college students. **Appl. Sci.**, MDPI, v. 15, n. 5, p. 2262, 2025.

Vesin, B.; Mangaroska, K.; Akhuseyinoglu, K.; Giannakos, M. Adaptive assessment and content recommendation in online programming courses: On the use of elo-rating. **ACM Trans. Comput. Educ.**, Association for Computing Machinery, New York, NY, USA, v. 22, n. 3, jun. 2022. Disponível em: ⟨https://doi.org/10.1145/3511886⟩.

Vivian, R. L.; Cazella, S. C.; Machado, L. R.; Behar, P. A. Mineração de dados educacionais e análise de sentimentos em ambientes virtuais de aprendizagem: um mapeamento sistemático. **EaD em Foco**, v. 12, n. 2, p. e1786, jun. 2022. Disponível em: ⟨https://eademfoco.cecierj.edu.br/index.php/Revista/article/view/1786⟩.

Wasserman, S.; Faust, K. **Social Network Analysis: Methods and Applications**. [S.l.]: Cambridge University Press, 1994. (Structural Analysis in the Social Sciences).

Xue, Y. Knowledge graph based recommendation by adversarial learning algorithm in application of lifelong education data classification. **ACM Trans. Asian Low-Resour. Lang. Inf. Process.**, Association for Computing Machinery, New York, NY, USA, jun. 2023. ISSN 2375-4699. Just Accepted. Disponível em: ⟨https://doi.org/10.1145/3595636⟩.

Yang, T.-Y.; Brinton, C. G.; Joe-Wong, C.; Chiang, M. Behavior-based grade prediction for moocs via time series neural networks. **IEEE Journal of Selected Topics in Signal Processing**, v. 11, n. 5, p. 716–728, 2017.

Yang, X. *et al.* Research on forecasting of student grade based on adaptive k-means and deep neural network. **Wireless Communications and Mobile Computing**, v. 2022, n. 1, p. 5454158, 2022. Disponível em: ⟨https://onlinelibrary.wiley.com/doi/abs/10.1155/2022/5454158⟩.

Zhang, T. *et al.* Enhancing dropout prediction in distributed educational data using learning pattern awareness: A federated learning approach. **Mathematics**, v. 11, n. 24, 2023. ISSN 2227-7390. Disponível em: ⟨https://www.mdpi.com/2227-7390/11/24/4977⟩.

Zhang, X.; Wang, X.; Zhao, J.; Zhang, B.; Zhang, F. Ic-btcn: A deep learning model for dropout prediction of moocs students. **IEEE Transactions on Education**, v. 67, n. 6, p. 974–982, 2024.