


BLAHA GOUSSAIN

# NEUROEDUCAÇÃO E APRENDIZADO DE MÁQUINA

## TECNOLOGIAS, ALGORITMOS E ENGAJAMENTO NO CONTEXTO EDUCACIONAL




**Atena**  
Editora  
Ano 2025

BLAHA GOUSSAIN

# NEUROEDUCAÇÃO E APRENDIZADO DE MÁQUINA

## TECNOLOGIAS, ALGORITMOS E ENGAJAMENTO NO CONTEXTO EDUCACIONAL



**Atena**  
Editora  
Ano 2025

2025 by Atena Editora

Copyright © 2025 Atena Editora

Copyright do texto © 2025, o autor

Copyright da edição © 2025, Atena Editora

Os direitos desta edição foram cedidos à Atena Editora pelo autor.

*Open access publication by Atena Editora*

**Editora chefe**

Profª Drª Antonella Carvalho de Oliveira

**Editora executiva**

Natalia Oliveira Scheffer

**Imagens da capa**

iStock

**Edição de arte**

Yago Raphael Massuqueto Rocha



Todo o conteúdo deste livro está licenciado sob a Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0).

A Atena Editora mantém um compromisso firme com a integridade editorial em todas as etapas do processo de publicação, assegurando que os padrões éticos e acadêmicos sejam rigorosamente cumpridos. Adota políticas para prevenir e combater práticas como plágio, manipulação ou falsificação de dados e resultados, bem como quaisquer interferências indevidas de interesses financeiros ou institucionais.

Qualquer suspeita de má conduta científica é tratada com máxima seriedade e será investigada de acordo com os mais elevados padrões de rigor acadêmico, transparência e ética.

O conteúdo da obra e seus dados, em sua forma, correção e confiabilidade, são de responsabilidade exclusiva do autor, não representando necessariamente a posição oficial da Atena Editora. O download, compartilhamento, adaptação e reutilização desta obra são permitidos para quaisquer fins, desde que seja atribuída a devida autoria e referência à editora, conforme os termos da Licença Creative Commons Atribuição 4.0 Internacional (CC BY 4.0).

Os trabalhos nacionais foram submetidos à avaliação cega por pares, realizada pelos membros do Conselho Editorial da editora, enquanto os internacionais passaram por avaliação de pareceristas externos. Todos foram aprovados para publicação com base em critérios de neutralidade e imparcialidade acadêmica.

# Neuroeducação e aprendizado de máquina: tecnologias, algoritmos e engajamento no contexto educacional

## | Autores:

Blaha Gregory Correia Dos Santos Goussain

## | Revisão:

O autor

## | Diagramação:

Thamires Camili Gayde

## | Capa:

Yago Raphael Massuqueto Rocha

### **Dados Internacionais de Catalogação na Publicação (CIP)**

S237 Santos Goussain, Blaha Gregory Correia dos  
Neuroeducação e aprendizado de máquina: tecnologias,  
algoritmos e engajamento no contexto educacional /  
Blaha Gregory Correia dos Santos Goussain. –  
Ponta Grossa - PR: Atena, 2025.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-258-3505-1

DOI: <https://doi.org/10.22533/at.ed.051251508>

1. Tecnologia educacional. I. Santos Goussain,  
Blaha Gregory Correia dos. II. Título.

CDD 371.3944

**Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166**

## **Atena Editora**

☎ +55 (42) 3323-5493

☎ +55 (42) 99955-2866

🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)

✉ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)

# CONSELHO EDITORIAL

## CONSELHO EDITORIAL

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano  
Profª Drª Amanda Vasconcelos Guimarães – Universidade Federal de Lavras  
Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás  
Profª Drª Ariadna Faria Vieira – Universidade Estadual do Piauí  
Prof. Dr. Arinaldo Pereira da Silva – Universidade Federal do Sul e Sudeste do Pará  
Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás  
Prof. Dr. Cirênio de Almeida Barbosa – Universidade Federal de Ouro Preto  
Prof. Dr. Cláudio José de Souza – Universidade Federal Fluminense  
Profª Drª Daniela Reis Joaquim de Freitas – Universidade Federal do Piauí  
Profª Drª. Dayane de Melo Barros – Universidade Federal de Pernambuco  
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná  
Profª Drª Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro  
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará  
Prof. Dr. Fabrício Moraes de Almeida – Universidade Federal de Rondônia  
Profª Drª Glécilla Colombelli de Souza Nunes – Universidade Estadual de Maringá  
Prof. Dr. Humberto Costa – Universidade Federal do Paraná  
Prof. Dr. Joachin de Melo Azevedo Sobrinho Neto – Universidade de Pernambuco  
Prof. Dr. João Paulo Roberti Junior – Universidade Federal de Santa Catarina  
Profª Drª Juliana Abonizio – Universidade Federal de Mato Grosso  
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense  
Profª Drª Keyla Christina Almeida Portela – Instituto Federal de Educação, Ciência e Tecnologia do Paraná  
Profª Drª Miranilde Oliveira Neves – Instituto de Educação, Ciência e Tecnologia do Pará  
Prof. Dr. Sérgio Nunes de Jesus – Instituto Federal de Educação Ciência e Tecnologia  
Profª Drª Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

# PREFÁCIO

## PREFÁCIO

Vivemos um tempo em que entender o cérebro e o comportamento humano deixou de ser apenas assunto de neurocientistas e passou a ser prioridade na educação. A neuroeducação, aliada à inteligência artificial, abre portas para personalizar o ensino, reconhecer emoções, antecipar dificuldades e potencializar o aprendizado.

Escrevo para todos que acreditam no poder transformador da educação, professores, pesquisadores, desenvolvedores, gestores e estudantes. Este livro não é apenas um manual técnico, mas um convite para refletir sobre como dados, algoritmos e dispositivos vestíveis podem ser usados de forma ética, inclusiva e inovadora. Que ele inspire novas ideias, crie pontes entre áreas e motive ações que tornem o ensino mais humano e eficaz.

# AGRADECIMENTOS

## **AGRADECIMENTOS**

Expresso minha gratidão à Faculdade de Engenharia e Ciências de Guaratinguetá da Universidade Estadual Paulista (FEG/UNESP), pelas oportunidades acadêmicas e pelo apoio à pesquisa. Agradeço à Escola de Engenharia de Lorena da Universidade de São Paulo (EEL/USP), pelas colaborações frutíferas e pelo acolhimento como pesquisador. Aos professores, orientadores e colegas que contribuíram com seu conhecimento e entusiasmo, deixo registrada minha mais profunda admiração e reconhecimento.

# SUMÁRIO

## SUMÁRIO

<b>INTRODUÇÃO .....</b>	<b>1</b>
1 Conceitos fundamentais de neuroeducação .....	1
2 A importância do monitoramento neurofisiológico na educação.....	2
3 Tecnologias vestíveis e sua aplicação educacional .....	2
<b>FUNDAMENTOS DE APRENDIZADO DE MÁQUINA .....</b>	<b>4</b>
1 Tipos de aprendizado de máquina.....	4
2 Principais algoritmos: árvores de decisão, redes neurais, SVM.....	5
3 Desafios e oportunidades no uso de ML em educação.....	6
<b>MONITORAMENTO E PREDIÇÃO DE DESEMPENHO EDUCACIONAL .....</b>	<b>7</b>
1 Modelos para previsão de desempenho acadêmico .....	7
2 Integração de dados comportamentais, demográficos e acadêmicos .....	8
3 Estudos de caso: análises preditivas em diferentes contextos e disciplinas .....	9
<b>ENGAJAMENTO, EMOÇÃO E NEUROFISIOLOGIA.....</b>	<b>10</b>
1 Medição do engajamento através de sinais fisiológicos (EDA, HR, EEG)....	10
2 Reconhecimento de emoções: métodos faciais, fisiológicos e multimodais.....	11
3 Impacto do engajamento emocional no aprendizado .....	12
<b>TECNOLOGIAS VESTÍVEIS E EDUCAÇÃO .....</b>	<b>13</b>
1 Sensores e dispositivos vestíveis: aplicações e limitações.....	13
2 Estudos empíricos com sensores em contextos escolares e acadêmicos	14
3 Ética, privacidade e desafios tecnológicos.....	15



# TÍTULO

## TÍTULO

<b>ALGORITMOS AVANÇADOS PARA EDUCAÇÃO .....</b>	<b>16</b>
1 Modelos de deep learning aplicados à educação .....	16
2 Técnicas de ensemble e stacking: benefícios na predição acadêmica .....	17
3 Análise de séries temporais e logs educacionais.....	17
<b>INTERVENÇÕES E PERSONALIZAÇÃO DO ENSINO .....</b>	<b>19</b>
1 Sistemas de recomendação e rotas personalizadas de aprendizagem.....	19
2 Feedback automático para alunos e professores.....	20
3 Perspectivas para redução da evasão escolar .....	20
<b>DESAFIOS E PERSPECTIVAS FUTURAS .....</b>	<b>22</b>
1 Limitações atuais das tecnologias aplicadas .....	22
2 Considerações éticas e inclusivas .....	23
3 Caminhos para pesquisas futuras e integração interdisciplinar .....	23
<b>CONSIDERAÇÕES FINAIS .....</b>	<b>25</b>
1 Integração de neuroeducação e inteligência artificial .....	25
2 Impactos para professores, alunos e políticas educacionais .....	26
3 Reflexões sobre o futuro da educação mediada por dados .....	26
<b>REFERÊNCIAS.....</b>	<b>28</b>
<b>SOBRE O AUTOR .....</b>	<b>31</b>



## C A P Í T U L O 1

# INTRODUÇÃO

Este capítulo apresenta os conceitos fundamentais de neuroeducação e discute a importância do monitoramento neurofisiológico na educação, abordando também as tecnologias vestíveis e suas aplicações no contexto educacional. A partir dessa base, são exploradas as interações entre cognição, emoção e tecnologia no processo de aprendizagem.

### 1 Conceitos fundamentais de neuroeducação

A neuroeducação é um campo interdisciplinar que conecta a neurociência, a psicologia cognitiva e as ciências da educação, com o objetivo de compreender como o cérebro aprende e como esse conhecimento pode melhorar os processos de ensino e aprendizagem. Trata-se de uma área emergente que busca traduzir descobertas científicas sobre os mecanismos cerebrais em práticas pedagógicas mais eficazes, visando não apenas a aquisição de conhecimento, mas também o desenvolvimento de habilidades emocionais, sociais e cognitivas.

Watanabe et al. (2019) destacam que a neuroeducação vai além de estudar as estruturas cerebrais envolvidas no aprendizado; ela busca entender como fatores como atenção, memória, motivação e emoção interagem para moldar a experiência educacional. Esse campo também considera a importância das diferenças individuais, reconhecendo que cada estudante possui um perfil cognitivo e emocional único, o que desafia os modelos tradicionais de ensino homogêneo.

Estudos da neurociência, como os de Åhs et al. (2015a), mostraram que a proximidade espacial pode amplificar respostas emocionais, indicando que o contexto social influencia diretamente a memória emocional. Essa descoberta tem implicações relevantes para a educação, pois destaca a necessidade de criar ambientes seguros e emocionalmente positivos, nos quais os alunos possam desenvolver vínculos e se engajar plenamente no processo de aprendizagem.

Assim, os conceitos fundamentais de neuroeducação nos convidam a repensar a sala de aula como um espaço dinâmico, no qual aspectos cognitivos, emocionais e sociais se entrelaçam e onde a compreensão científica do cérebro pode orientar estratégias pedagógicas mais adaptativas, personalizadas e inclusivas.

## **2 A importância do monitoramento neurofisiológico na educação**

O monitoramento neurofisiológico na educação refere-se à utilização de sinais corporais e cerebrais, como atividade eletrodérmica (EDA), frequência cardíaca (HR) e eletroencefalografia (EEG), para compreender em tempo real os estados cognitivos e emocionais dos estudantes durante o processo de aprendizagem. Essa abordagem permite acessar informações que nem sempre são percebidas externamente, oferecendo uma visão mais profunda sobre engajamento, atenção, estresse e motivação.

Segundo Watanabe et al. (2019), o uso de sinais neurofisiológicos permite superar limitações das avaliações tradicionais, baseadas apenas em desempenho final ou observação comportamental. Por exemplo, um aluno pode aparentar calma, mas apresentar níveis elevados de estresse detectáveis apenas por sinais fisiológicos. Essa informação é valiosa para adaptar intervenções pedagógicas de forma precisa, criando experiências de aprendizado mais eficazes e acolhedoras.

Os estudos de Åhs et al. (2015b) também ressaltam a relevância de monitorar os estados emocionais, mostrando que o cérebro responde diferentemente a contextos de ameaça ou segurança, ativando áreas distintas como o córtex pré-frontal dorsomedial (dmPFC) e ventromedial (vmPFC). No contexto educacional, compreender essas respostas pode ajudar professores e pesquisadores a identificarem fatores que impactam negativamente o aprendizado e a desenvolver estratégias para minimizar ansiedade, medo de fracasso e desmotivação.

Além disso, o monitoramento neurofisiológico oferece uma nova dimensão para pesquisas em educação, permitindo testar, validar e ajustar métodos pedagógicos com base em dados objetivos. Ele também abre caminho para personalizar a experiência educacional, adaptando conteúdos, ritmo e atividades às necessidades momentâneas de cada aluno, promovendo uma aprendizagem mais humanizada e eficiente.

## **3 Tecnologias vestíveis e sua aplicação educacional**

As tecnologias vestíveis, como pulseiras inteligentes, relógios, faixas de cabeça com sensores EEG e adesivos cutâneos para monitoramento de sinais fisiológicos, têm sido incorporadas progressivamente no contexto educacional, oferecendo oportunidades inovadoras para coletar dados sobre o estado físico e emocional dos estudantes durante atividades de aprendizagem.

De acordo com Watanabe et al. (2019), essas tecnologias são particularmente úteis porque permitem o monitoramento contínuo e não invasivo de variáveis como EDA, HR, variabilidade da frequência cardíaca (HRV), temperatura da pele (ST) e sinais cerebrais. Essas medições fornecem informações valiosas sobre o nível de engajamento, fadiga, estresse e até mesmo satisfação do aluno ao longo do processo educativo.

Os achados de Åhs et al. (2015a, 2015b) ilustram a importância de captar respostas fisiológicas em contextos que envolvem emoções intensas, como tarefas desafiadoras ou avaliações, que podem impactar diretamente a memória e o aprendizado. A integração dessas informações em sistemas de apoio à decisão educacional possibilita a personalização do ensino, permitindo que plataformas adaptativas, professores ou tutores ajustem atividades, conteúdos e estratégias pedagógicas conforme a resposta fisiológica do estudante.

Além disso, tecnologias vestíveis têm potencial para promover a inclusão educacional. Por exemplo, alunos com dificuldades de comunicação verbal podem se beneficiar de dispositivos que captam sinais emocionais, facilitando a mediação de suas necessidades. Contudo, seu uso demanda atenção ética, considerando privacidade, consentimento informado e segurança dos dados coletados.

Em resumo, as tecnologias vestíveis representam uma fronteira promissora para transformar a prática educacional, oferecendo novas maneiras de entender, apoiar e aprimorar o processo de ensino e aprendizagem, sempre com um olhar atento às dimensões humanas e éticas envolvidas.

- I **Pergunta:** Como os conceitos de neuroeducação podem transformar as práticas pedagógicas atuais?
- I **Atividade:** Pesquise exemplos de aplicações reais de neuroeducação em escolas ou universidades e elabore um breve resumo destacando um caso que chamou sua atenção.



## C A P Í T U L O 2

# FUNDAMENTOS DE APRENDIZADO DE MÁQUINA

Este capítulo explora os fundamentos do aprendizado de máquina (ML), apresentando seus principais tipos e algoritmos, como árvores de decisão, redes neurais e máquinas de vetor de suporte (SVM). Também são discutidos os desafios e as oportunidades envolvidos em sua aplicação no contexto educacional.

### 1 Tipos de aprendizado de máquina

O ML é uma área central da inteligência artificial (IA) que permite que sistemas computacionais aprendam automaticamente a partir de dados, identificando padrões e realizando previsões ou decisões sem intervenção humana direta. Dentro desse campo, destacam-se três principais tipos de aprendizado: supervisionado, não supervisionado e por reforço.

No aprendizado supervisionado, os modelos são treinados usando conjuntos de dados rotulados, onde a resposta correta já é conhecida. Esse método é amplamente utilizado para tarefas como classificação e regressão, aplicando algoritmos como redes neurais, SVM e árvores de decisão (Mahesh, 2020; Rajasekaran & Saravanan, 2020).

O aprendizado não supervisionado, por outro lado, trabalha com dados não rotulados, buscando identificar estruturas ocultas, padrões ou agrupamentos nos dados. Exemplos comuns incluem algoritmos de agrupamento (clustering), como k-means, e técnicas de redução de dimensionalidade, como análise de componentes principais (PCA). Esse tipo de aprendizado é particularmente útil quando não há informações prévias sobre os resultados desejados (Mahesh, 2020).

Já o aprendizado por reforço consiste em treinar agentes que aprendem a partir de interações com o ambiente, recebendo recompensas ou penalidades de acordo com suas ações. Essa abordagem tem sido utilizada em áreas como jogos, robótica e, mais recentemente, em educação personalizada, onde sistemas adaptativos aprendem a propor conteúdo ou desafios ao aluno, baseando-se em seu desempenho anterior (Rajasekaran & Saravanan, 2020).

Além dessas categorias principais, os avanços recentes ampliaram a classificação para incluir aprendizado semissupervisionado, aprendizado profundo (deep learning), aprendizado de características e modelos híbridos, ampliando significativamente as possibilidades de aplicação no contexto educacional.

## 2 Principais algoritmos: árvores de decisão, redes neurais, SVM

Os algoritmos de aprendizado de máquina constituem o núcleo das aplicações educacionais baseadas em dados, permitindo transformar grandes volumes de informações em insights úteis para professores, gestores e estudantes. Entre os principais algoritmos utilizados destacam-se as árvores de decisão, as redes neurais artificiais e as SVM.

As árvores de decisão são modelos preditivos que mapeiam atributos em uma estrutura hierárquica de regras, levando a decisões finais com base em divisões sucessivas dos dados. Baradwaj e Pal (2011) demonstraram a eficácia do algoritmo ID3 para prever o desempenho acadêmico de estudantes universitários, usando variáveis como frequência, notas de testes e trabalhos. A vantagem das árvores de decisão reside na sua interpretabilidade, permitindo que educadores visualizem claramente os fatores que contribuem para o sucesso ou dificuldade dos alunos.

As redes neurais artificiais, por sua vez, são inspiradas no funcionamento do cérebro humano e compostas por camadas interconectadas de nós (neurônios artificiais). Kumar et al. (2017) destacam sua capacidade de capturar relações complexas e não lineares entre variáveis educacionais, sendo eficazes para tarefas de classificação, regressão e detecção de padrões ocultos em grandes volumes de dados.

Já as SVM são algoritmos poderosos para problemas de classificação e regressão, especialmente úteis quando os dados apresentam alta dimensionalidade. Mahesh (2020) explica que o SVM busca encontrar o hiperplano que melhor separa as classes de dados, maximizando a margem entre elas, o que garante bom desempenho mesmo em cenários desafiadores.

Esses algoritmos, aplicados isoladamente ou combinados em técnicas de ensemble, representam ferramentas fundamentais para análises preditivas em educação, auxiliando na identificação precoce de alunos em risco, no desenvolvimento de intervenções personalizadas e na melhoria contínua dos processos de ensino-aprendizagem.

### 3 Desafios e oportunidades no uso de ML em educação

A aplicação do ML na educação oferece oportunidades significativas para personalização, previsão de desempenho, identificação de dificuldades e melhoria contínua dos processos de ensino e aprendizagem. No entanto, esses benefícios vêm acompanhados de desafios técnicos, éticos e pedagógicos que precisam ser cuidadosamente considerados.

Do ponto de vista técnico, Kumar et al. (2017) e Cui et al. (2019) destacam que a qualidade e a integridade dos dados utilizados para treinar modelos de ML são determinantes para o sucesso das aplicações. Dados incompletos, ruidosos ou enviesados podem comprometer a precisão das previsões e gerar interpretações equivocadas. Além disso, o pré-processamento dos dados, como o tratamento de valores ausentes e a normalização das variáveis, é uma etapa crítica frequentemente subestimada.

Outro desafio importante está relacionado à interpretabilidade dos modelos. Enquanto algoritmos como árvores de decisão oferecem explicações intuitivas para seus resultados, modelos mais complexos, como redes neurais profundas, funcionam como “caixas-pretas”, dificultando a compreensão dos fatores que levam a determinadas previsões (Mahesh, 2020). Isso pode gerar resistência por parte de educadores e gestores, que necessitam de confiança e clareza para implementar intervenções baseadas nos insights produzidos.

No entanto, as oportunidades são igualmente expressivas. Peña-Ayala (2013) salienta que o uso de ML permite compreender padrões ocultos de aprendizagem, apoiar decisões pedagógicas e desenvolver sistemas adaptativos que respondam em tempo real às necessidades individuais dos estudantes. Além disso, a combinação de dados acadêmicos, demográficos e comportamentais, como defendido por Cui et al. (2019), potencializa a capacidade de identificar alunos em risco, promovendo ações preventivas e personalizadas.

Finalmente, para que essas oportunidades se concretizem de forma ética e inclusiva, é necessário enfrentar desafios relacionados à privacidade, à segurança dos dados e à transparência algorítmica. Isso exige não apenas soluções tecnológicas, mas também marcos regulatórios e práticas institucionais comprometidas com o bem-estar e os direitos dos estudantes.

- I **Pergunta:** Qual a diferença entre aprendizado supervisionado, não supervisionado e por reforço, e como cada um pode ser aplicado na educação?
- I **Atividade:** Escolha um dos algoritmos apresentados e prepare um esquema visual explicando seu funcionamento básico e um exemplo de uso em contexto educacional.



## C A P Í T U L O 3

# MONITORAMENTO E PREDIÇÃO DE DESEMPENHO EDUCACIONAL

Este capítulo aborda como modelos de aprendizado de máquina podem ser usados para prever desempenho acadêmico, integrar dados de diferentes fontes e gerar análises preditivas úteis em diversos contextos e disciplinas, auxiliando na tomada de decisão educacional.

### 1 Modelos para previsão de desempenho acadêmico

A previsão do desempenho acadêmico é uma das aplicações mais estudadas do ML na educação. Ela visa identificar, antecipadamente, quais estudantes estão em risco de baixo desempenho, reprovação ou evasão, permitindo a implementação de intervenções pedagógicas direcionadas e personalizadas.

Daud et al. (2017) desenvolveram modelos discriminativos e generativos para prever a conclusão de cursos entre bolsistas universitários no Paquistão, incorporando variáveis como despesas familiares com gás e eletricidade, status de emprego e características demográficas. O modelo atingiu uma impressionante taxa de precisão de 86%, destacando a importância de incluir dados não convencionais e personalizados na análise.

No contexto do ensino online, Félix et al. (2018) realizaram um mapeamento sistemático de 42 estudos que aplicaram técnicas de mineração de dados no ambiente Moodle. Os autores observaram que os modelos preditivos mais utilizados incluem árvores de decisão, redes neurais e Naive Bayes, sendo os logs de participação em fóruns e as notas em atividades online os atributos mais significativos para prever desempenho.

Alshanqiti e Namoun (2020) propuseram um modelo híbrido de regressão que combina filtragem colaborativa, regras fuzzy e regressão linear Lasso. Esse modelo não apenas melhorou as previsões em comparação com métodos tradicionais, mas também demonstrou capacidade de classificar fatores determinantes de sucesso acadêmico por meio de mapas auto-organizáveis, mostrando o potencial de abordagens híbridas para enfrentar problemas complexos no ensino.



Esses modelos não apenas identificam estudantes em risco, mas também permitem às instituições otimizar recursos, priorizando atendimentos, mentorias e apoio psicológico de forma estratégica. O uso de previsões acadêmicas, no entanto, deve ser acompanhado de responsabilidade ética, garantindo que os dados sejam utilizados para apoiar os alunos e não para rotulá-los ou limitá-los.

## **2 Integração de dados comportamentais, demográficos e acadêmicos**

A integração de múltiplas fontes de dados é fundamental para aumentar a precisão e a utilidade dos modelos preditivos no contexto educacional. Dados acadêmicos isolados, como notas e frequência, muitas vezes não capturam a complexidade das trajetórias de aprendizagem dos estudantes. Por isso, pesquisadores têm defendido a inclusão de informações comportamentais e demográficas para construir modelos mais robustos e personalizados (Cui et al., 2019; Daud et al., 2017).

Daud et al. (2017) mostraram que atributos socioeconômicos, como status de emprego e despesas familiares, podem ser tão ou mais relevantes que dados acadêmicos tradicionais na previsão de evasão escolar. Ao integrar essas variáveis, os modelos conseguem detectar vulnerabilidades que passariam despercebidas em análises convencionais.

Félix et al. (2018) destacaram, em seu estudo sobre o ambiente Moodle, que dados de interação com a plataforma, como participação em fóruns, envio de tarefas e engajamento em quizzes, são preditores poderosos de desempenho final. Quando combinados com dados demográficos (sexo, idade, origem) e acadêmicos (notas, aprovação prévia), esses atributos aumentam significativamente a acurácia das previsões.

Além disso, Alshanqiti e Namoun (2020) reforçam que a integração de dados heterogêneos requer abordagens de aprendizado híbrido, como modelos de ensemble, que conseguem combinar os pontos fortes de diferentes algoritmos para lidar com a complexidade das relações entre variáveis.

Portanto, a integração de dados comportamentais, demográficos e acadêmicos não só enriquece a análise preditiva, mas também amplia as possibilidades de intervenções personalizadas e sensíveis ao contexto individual de cada estudante, promovendo uma educação mais equitativa e eficaz.

### 3 Estudos de caso: análises preditivas em diferentes contextos e disciplinas

Estudos de caso em diferentes contextos e disciplinas mostram como as análises preditivas podem ser aplicadas de forma prática para melhorar os resultados educacionais. Essas experiências ilustram não apenas os benefícios, mas também os desafios e limitações associados à adoção de modelos de ML em cenários reais.

No ensino superior, Daud et al. (2017) aplicaram modelos discriminativos e generativos em dados de bolsas universitárias no Paquistão, alcançando 86% de precisão na previsão de conclusão de curso. Esse estudo reforçou a importância de considerar fatores sociais e econômicos, como gastos familiares e emprego, que influenciam diretamente o sucesso acadêmico.

No ambiente de educação online, Félix et al. (2018) analisaram cursos em Moodle e identificaram que a participação em fóruns, o envio de tarefas e o tempo de permanência na plataforma eram preditores consistentes de sucesso e retenção. Esses insights permitiram que instituições planejassem intervenções mais eficazes, como feedback personalizado, mensagens motivacionais e ajustes no design do curso para aumentar o engajamento.

Alshanqiti e Namoun (2020) realizaram estudos em sete conjuntos de dados públicos e demonstraram que um modelo híbrido combinando filtragem colaborativa, regras fuzzy e regressão linear Lasso superou modelos tradicionais na previsão de notas futuras. Esse estudo também utilizou mapas auto-organizáveis para categorizar fatores de sucesso, oferecendo aos educadores uma visualização intuitiva das influências sobre o desempenho estudantil.

Esses casos mostram que, quando bem planejadas e eticamente aplicadas, as análises preditivas podem transformar a educação, permitindo intervenções personalizadas, melhorias curriculares e apoio direcionado a diferentes perfis de estudantes. Ao mesmo tempo, reforçam a necessidade de capacitação institucional e cuidado ético para evitar o uso inadequado ou discriminatório desses modelos.

- I **Pergunta:** De que forma a integração de dados acadêmicos, comportamentais e demográficos pode melhorar a previsão de desempenho escolar?
- I **Atividade:** Analise uma base de dados educacional (pode ser fictícia) e sugira quais variáveis você incluiria em um modelo preditivo para identificar alunos em risco de evasão.



## C A P Í T U L O 4

# ENGAJAMENTO, EMOÇÃO E NEUROFISIOLOGIA

Este capítulo explora como medir engajamento e emoções através de sinais fisiológicos, métodos faciais e abordagens multimodais, destacando o impacto do engajamento emocional no processo de aprendizado e no desempenho acadêmico.

### 1 Medição do engajamento através de sinais fisiológicos (EDA, HR, EEG)

A medição do engajamento estudantil por meio de sinais fisiológicos representa um avanço significativo nas pesquisas em educação, permitindo acessar estados internos que não são capturados por observação direta ou autorrelatos. Entre os sinais mais utilizados destacam-se a EDA, a HR e a EEG, que oferecem informações valiosas sobre atenção, esforço cognitivo, estresse e estados emocionais durante o aprendizado.

Feidakis (2016) destacou que a ausência de mecanismos para reconhecimento emocional em plataformas de e-learning limita a personalização da experiência educacional. Por isso, o uso de sensores fisiológicos surge como solução para monitorar e adaptar o ensino em tempo real. Rajavenkanarayanan et al. (2018) mostraram, por exemplo, que é possível combinar análise de expressões faciais, postura e sinais fisiológicos para prever níveis de engajamento com precisão de até 71%, utilizando sistemas inteligentes multissensoriais.

Apicella et al. (2022) apresentaram um modelo inovador de detecção personalizada de engajamento, utilizando EEG com eletrodos secos e técnicas como Análise de Componentes de Transferência (TCA) para reduzir as diferenças interindividuais. O estudo alcançou acurácia média de 76,9% para engajamento cognitivo e 76,7% para engajamento emocional, ressaltando o potencial do EEG como ferramenta de monitoramento educacional.

Além disso, Abromavičius et al. (2023) mostraram que sinais fisiológicos como EDA, HR e ST possuem alto potencial preditivo para notas em exames, com acurácia de 0,9 e F1-score de 0,87. Esses dados indicam que o monitoramento fisiológico não só informa sobre engajamento momentâneo, mas também pode antecipar resultados acadêmicos.

Esses avanços colocam os sinais fisiológicos no centro das discussões sobre educação personalizada, abrindo caminho para sistemas que respondem dinamicamente ao estado do aluno e promovem intervenções mais eficazes e ajustadas às suas necessidades.

## **2 Reconhecimento de emoções: métodos faciais, fisiológicos e multimodais**

O reconhecimento de emoções no contexto educacional tem ganhado destaque como ferramenta para compreender melhor as necessidades emocionais dos estudantes e aprimorar as experiências de aprendizagem. Ele pode ser realizado por diferentes métodos: análise de expressões faciais, monitoramento de sinais fisiológicos ou abordagens multimodais que combinam múltiplas fontes de dados.

Wei et al. (2017) desenvolveram uma faixa de cabeça para detecção de emoções baseada em EEG, mostrando que a disposição estratégica dos eletrodos e a escolha de técnicas de classificação podem aumentar significativamente a acurácia, alcançando até 91,75% de precisão dependente do sujeito. Esse tipo de tecnologia permite capturar estados emocionais momentâneos, como estresse, tédio ou interesse, que impactam diretamente o aprendizado.

Fernández-Caballero et al. (2016) propuseram um sistema que não apenas detecta emoções por meio de sinais fisiológicos, mas também atua na regulação emocional, utilizando música, configurações de luz e cor para induzir estados positivos. Essa integração entre reconhecimento e intervenção emocional oferece perspectivas promissoras para criar ambientes de aprendizagem mais afetivos e acolhedores.

Rajavenkanarayanan et al. (2018) demonstraram a eficácia de sistemas multimodais que combinam expressões faciais, posturas corporais e sinais fisiológicos, alcançando resultados superiores aos obtidos por métodos isolados. Já Abromavičius et al. (2023) mostraram que a fusão de variáveis fisiológicas melhora o desempenho preditivo, destacando a relevância de abordagens integradas.

Essas tecnologias de reconhecimento emocional não apenas fornecem informações valiosas sobre o estado atual do aluno, mas também possibilitam adaptações dinâmicas nos conteúdos, no ritmo e nas estratégias pedagógicas, promovendo um ensino mais personalizado, empático e centrado no bem-estar.

### 3 Impacto do engajamento emocional no aprendizado

O engajamento emocional é um componente central do processo de aprendizagem, influenciando diretamente a motivação, a atenção, a memória e, consequentemente, o desempenho acadêmico. Diferentemente do engajamento cognitivo ou comportamental, o engajamento emocional envolve as reações afetivas do aluno frente às atividades, conteúdos e interações no ambiente de aprendizagem.

Fernández-Caballero et al. (2016) destacaram que emoções positivas, como interesse e entusiasmo, estão associadas ao aumento da atividade atencional e à melhora no desempenho em tarefas cognitivas, enquanto emoções negativas, como ansiedade ou tédio, podem gerar bloqueios cognitivos e desengajamento. O sistema desenvolvido por esses autores, que integra reconhecimento e regulação emocional, busca justamente manter estados afetivos positivos para favorecer o aprendizado.

Raheel et al. (2021) contribuíram para essa discussão ao apresentar o dataset DEAR-MULSEMEDIA, projetado para estudar emoções humanas em resposta a conteúdo multimídia multissensoriais. Utilizando EEG, resposta galvânica da pele (GSR) e fotopletismografia (PPG), o estudo demonstrou que estímulos multissensoriais modulam significativamente o estado emocional e, por consequência, os níveis de engajamento e atenção.

Além disso, Abromavičius et al. (2023) mostraram que sinais fisiológicos como EDA, HR e ST não apenas refletem o estado emocional momentâneo, mas também possuem forte correlação com o desempenho acadêmico futuro, sugerindo que a emoção não é apenas um subproduto do aprendizado, mas um fator que o impulsiona ou compromete.

Essas evidências reforçam a necessidade de repensar os ambientes de aprendizagem de forma a integrar aspectos emocionais nas estratégias pedagógicas. Reconhecer, acolher e modular o engajamento emocional dos alunos não é apenas uma inovação tecnológica, mas um caminho para construir experiências educacionais mais humanas, eficazes e inclusivas.

- I **Pergunta:** Por que o engajamento emocional é considerado tão importante quanto o engajamento cognitivo no aprendizado?
- I **Atividade:** Pesquise ferramentas ou dispositivos que monitoram engajamento emocional em ambientes educacionais e faça uma breve análise sobre seus benefícios e limitações.



## CAPÍTULO 5

# TECNOLOGIAS VESTÍVEIS E EDUCAÇÃO

Este capítulo discute os sensores e dispositivos vestíveis utilizados na educação, apresentando estudos empíricos que avaliam seu potencial e analisando as questões éticas, de privacidade e desafios tecnológicos relacionados ao seu uso em sala de aula.

### 1 Sensores e dispositivos vestíveis: aplicações e limitações

Os dispositivos vestíveis vêm ganhando destaque na educação por sua capacidade de monitorar continuamente variáveis fisiológicas e comportamentais dos estudantes durante atividades de aprendizagem. Esses dispositivos incluem pulseiras inteligentes, relógios, faixas de cabeça com EEG, óculos de realidade aumentada e sensores epidérmicos, oferecendo uma gama diversificada de aplicações.

Segundo Tamsin (2015), os sensores vestíveis podem ser classificados em três grandes grupos: sensores de movimento (acelerômetros, giroscópios), sensores bioquímicos (como tatuagens eletrônicas que monitoram sódio no suor) e sensores PPG, que medem variações volumétricas sanguíneas através da pele. Esses dispositivos permitem capturar informações sobre movimento, esforço físico, frequência cardíaca, atividade elétrica do cérebro, níveis de estresse e até indicadores bioquímicos relacionados ao metabolismo.

No contexto educacional, essas tecnologias oferecem aplicações promissoras, como monitoramento do engajamento cognitivo, detecção de fadiga, acompanhamento de estados emocionais e personalização de conteúdos de acordo com a resposta fisiológica do aluno. Contudo, Monkaresi et al. (2016) destacam que essas soluções ainda enfrentam desafios técnicos, incluindo interferências de movimento, limitações na coleta contínua de dados e necessidade de calibragem individual para reduzir erros de medição.

Dzedzickis et al. (2020) reforçam que, além das limitações técnicas, existem desafios de padronização, interoperabilidade entre dispositivos e comparação entre métodos, que dificultam a adoção ampla dessas tecnologias na educação.

Além disso, surgem questões éticas importantes, como privacidade, consentimento informado e segurança dos dados gerados, que precisam ser enfrentadas para garantir a implementação responsável e benéfica dessas soluções.

Em resumo, os sensores e dispositivos vestíveis oferecem oportunidades inovadoras para enriquecer o processo de ensino-aprendizagem, mas demandam avanços técnicos e atenção cuidadosa a aspectos éticos e pedagógicos.

## **2 Estudos empíricos com sensores em contextos escolares e acadêmicos**

Diversos estudos empíricos têm investigado como os sensores vestíveis podem ser aplicados em ambientes educacionais reais, avaliando tanto seu potencial quanto suas limitações práticas. Essas pesquisas têm contribuído para mapear os benefícios do uso dessas tecnologias no monitoramento do engajamento, na detecção de emoções e na personalização de estratégias pedagógicas.

Monkaresi et al. (2016) conduziram um estudo utilizando visão computacional e sensores fisiológicos para detectar engajamento de estudantes em tarefas de aprendizagem. O modelo proposto combinou características extraídas de vídeo (expressões faciais), sinais fisiológicos (frequência cardíaca remota) e aprendizado supervisionado, alcançando área sob a curva (AUC) de 0,758 para anotações concorrentes. O estudo mostrou que a fusão de múltiplas fontes de dados aumenta a precisão e a confiabilidade das medições.

Dzedzickis et al. (2020) realizaram uma análise comparativa de diferentes métodos de reconhecimento de emoções, destacando que técnicas baseadas em respostas inconscientes, como as medidas fisiológicas, tendem a ser mais confiáveis do que os autorrelatos. No entanto, também apontaram limitações importantes, como a necessidade de equipamentos sofisticados, sensibilidade a movimentos e desafios na interpretação dos sinais em contextos dinâmicos, como salas de aula.

Além disso, estudos de caso envolvendo o uso de sensores vestíveis em contextos acadêmicos têm mostrado resultados promissores para aplicações como detecção de fadiga mental, avaliação de esforço cognitivo e adaptação de conteúdos pedagógicos em tempo real. Esses resultados reforçam que, embora ainda existam desafios a superar, o uso de sensores representa uma fronteira inovadora para transformar a prática educacional.

### 3 Ética, privacidade e desafios tecnológicos

O uso de tecnologias vestíveis na educação levanta importantes questões éticas e desafios tecnológicos que precisam ser cuidadosamente considerados para garantir sua adoção responsável. Embora esses dispositivos ofereçam oportunidades inovadoras para personalizar a aprendizagem e monitorar o engajamento, eles também introduzem riscos relacionados à privacidade, consentimento, segurança de dados e equidade de acesso.

Tamsin (2015) alerta que os sensores vestíveis geram grandes volumes de dados sensíveis, incluindo informações fisiológicas, emocionais e comportamentais, que podem ser usados não apenas para fins pedagógicos, mas também para controle, vigilância ou discriminação. A coleta e o armazenamento desses dados exigem protocolos rigorosos de anonimização, criptografia e limitação de acesso, além de políticas transparentes que garantam o consentimento informado de alunos, responsáveis e educadores.

Dzedzickis et al. (2020) destacam que, do ponto de vista técnico, ainda há barreiras a superar para tornar esses dispositivos amplamente utilizáveis em contextos educacionais. Entre elas, estão o consumo energético elevado, a interferência de movimento durante a coleta de dados, a necessidade de calibração personalizada e a falta de padronização entre diferentes fabricantes e plataformas. Essas limitações não apenas impactam a precisão das medições, mas também afetam a viabilidade econômica e operacional de sua implementação em larga escala.

Além disso, há desafios sociais e pedagógicos importantes: garantir que os dados coletados não reforcem desigualdades pré-existentes, que os professores sejam capacitados para interpretar corretamente os resultados e que o uso das tecnologias não substitua, mas complemente, a relação humana fundamental para o processo de ensino e aprendizagem.

Em resumo, enfrentar as questões éticas e tecnológicas associadas às tecnologias vestíveis é essencial para garantir que elas sejam incorporadas de forma segura, equitativa e benéfica ao contexto educacional.

- I **Pergunta:** Quais são os principais desafios éticos envolvidos no uso de tecnologias vestíveis no contexto educacional?
- I **Atividade:** Elabore uma proposta de código de ética resumido para o uso de tecnologias vestíveis em sua instituição ou contexto de atuação.





## C A P Í T U L O 6

# ALGORITMOS AVANÇADOS PARA EDUCAÇÃO

Este capítulo apresenta algoritmos avançados, como deep learning, técnicas de ensemble e análise de séries temporais, discutindo seus benefícios, desafios e aplicações na área educacional para melhorar análises e intervenções pedagógicas

### 1 Modelos de deep learning aplicados à educação

Os modelos de deep learning, ou aprendizado profundo, têm ganhado destaque no campo educacional por sua capacidade de lidar com grandes volumes de dados não estruturados e capturar relações complexas entre variáveis. Inspirados na arquitetura do cérebro humano, esses modelos consistem em múltiplas camadas de redes neurais que processam informações hierarquicamente, aprendendo padrões representacionais de forma automática.

Kanjo et al. (2019) aplicaram redes neurais convolucionais (CNNs) e redes de memória de longa e curta duração (LSTM) para classificar emoções a partir de sinais fisiológicos, ambientais e de localização coletados por dispositivos móveis. O modelo híbrido apresentou acurácia média de 95% e medida F de 95%, superando modelos tradicionais e métodos de ensemble anteriores, o que demonstra o potencial do deep learning para aplicações em educação, como detecção de engajamento, avaliação emocional e personalização de atividades.

No campo da análise textual, Ming e Ming (2024) exploraram a alocação latente de Dirichlet hierárquica (hLDA) para modelar tópicos em textos educacionais gerados por alunos, como postagens em fóruns e redações. Em comparação com a análise semântica latente probabilística (pLSA), a hLDA produziu previsões mais precisas para notas finais, destacando a utilidade de modelos hierárquicos para extrair relações conceituais e padrões de aprendizado em dados textuais.

Além disso, modelos de deep learning têm sido aplicados em tarefas como recomendação de conteúdos personalizados, previsão de evasão, identificação de padrões de interação em ambientes virtuais e até reconhecimento de voz para

acessibilidade. Seu potencial, porém, depende diretamente da qualidade e diversidade dos dados, além de demandar atenção especial à interpretabilidade, já que esses modelos funcionam muitas vezes como “caixas-pretas”.

## 2 Técnicas de ensemble e stacking: benefícios na predição acadêmica

As técnicas de ensemble e stacking têm se destacado no ML educacional por sua capacidade de combinar múltiplos modelos para melhorar a precisão preditiva e a robustez das análises. Essas abordagens aproveitam as forças de diferentes algoritmos, reduzindo erros de generalização e compensando limitações individuais.

Kanjo et al. (2019) mostraram que modelos híbridos que combinam CNNs e redes LSTM oferecem ganhos substanciais em tarefas como classificação emocional a partir de dados fisiológicos. Esses resultados reforçam a ideia de que arquiteturas combinadas são capazes de capturar aspectos complementares dos dados, proporcionando análises mais precisas.

Ming e Ming (2024) demonstraram, em suas análises de textos educacionais, que a integração de modelos como hLDA e pLSA melhora a detecção de tópicos e a previsão de notas finais, sugerindo que o uso de diferentes perspectivas probabilísticas enriquece a compreensão dos padrões latentes nos dados.

Alshanqiti e Namoun (2020), por sua vez, propuseram um modelo híbrido que combina aprendizado supervisionado (regressão linear Lasso), aprendizado não supervisionado (regras fuzzy) e filtragem colaborativa. Esse modelo foi testado em sete conjuntos de dados públicos e superou significativamente os modelos tradicionais, demonstrando que o ensemble learning é uma estratégia eficaz para lidar com a diversidade e complexidade dos dados educacionais.

Essas abordagens, quando aplicadas de forma cuidadosa e alinhadas a práticas éticas, não apenas aumentam a precisão preditiva, mas também oferecem uma base mais sólida para intervenções pedagógicas personalizadas, apoiadas em evidências múltiplas.

## 3 Análise de séries temporais e logs educacionais

A análise de séries temporais e logs educacionais tem se tornado uma ferramenta essencial para compreender os processos de aprendizagem ao longo do tempo, oferecendo insights detalhados sobre padrões de engajamento, progresso acadêmico e comportamento dos estudantes. Ao explorar esses dados sequenciais, modelos de ML conseguem detectar tendências, prever eventos futuros e propor intervenções em momentos críticos.

Alshanqiti e Namoun (2020) utilizaram mapas auto-organizáveis para classificar fatores determinantes do sucesso acadêmico, analisando séries temporais de interações e notas. Essa abordagem permitiu identificar não apenas padrões agregados, mas também variações individuais, oferecendo uma base para personalização do ensino.

No campo textual, Ming e Ming (2024) exploraram a hLDA para rastrear a evolução conceitual em produções escritas ao longo do curso, enquanto Kanjo et al. (2019) aplicaram LSTM para processar sequências de sinais fisiológicos, revelando mudanças dinâmicas no estado emocional e cognitivo dos estudantes.

A análise de logs educacionais inclui dados como acessos à plataforma, tempo gasto em atividades, cliques, submissões e participação em fóruns, permitindo monitorar padrões de comportamento digital. Essas informações são particularmente úteis para detectar estudantes em risco de evasão, identificar gargalos no design instrucional e avaliar a eficácia de intervenções pedagógicas.

Apesar de suas vantagens, a análise de séries temporais demanda atenção especial a questões como granularidade dos dados, sincronização entre diferentes fontes e modelagem apropriada das dependências temporais. Quando bem conduzida, porém, oferece um poderoso instrumento para transformar dados brutos em insights acionáveis para melhorar a aprendizagem.

- I **Pergunta:** Como as técnicas de ensemble e stacking podem aumentar a precisão das previsões acadêmicas?
- I **Atividade:** Monte um pequeno glossário explicando, com suas palavras, o significado de termos como deep learning, ensemble, stacking e séries temporais no contexto educacional.



## C A P Í T U L O 7

# INTERVENÇÕES E PERSONALIZAÇÃO DO ENSINO

Este capítulo aborda como sistemas de recomendação, feedback automático e intervenções personalizadas podem ser utilizados para apoiar o aprendizado, promover engajamento e reduzir a evasão escolar, gerando percursos de aprendizagem mais eficazes e inclusivos

### 1 Sistemas de recomendação e rotas personalizadas de aprendizagem

Os sistemas de recomendação educacionais têm se consolidado como ferramentas fundamentais para personalizar a experiência de aprendizagem, orientando os estudantes em rotas adaptadas às suas necessidades, interesses e dificuldades. Esses sistemas utilizam dados históricos, desempenho, comportamento em plataformas e até sinais fisiológicos para sugerir conteúdos, atividades ou estratégias pedagógicas personalizadas.

Smith et al. (2012) apresentaram o modelo RioPACE, que aplica algoritmos preditivos para monitorar semanalmente o progresso dos estudantes, permitindo identificar rapidamente quem está em risco de baixo desempenho. Essa abordagem não apenas fornece alertas aos professores, mas também orienta os alunos, oferecendo sugestões de estudo e recursos específicos para superar suas dificuldades.

Félix et al. (2018), em sua revisão de aplicações de mineração de dados no Moodle, destacaram que sistemas baseados em árvores de decisão e redes neurais conseguem oferecer recomendações personalizadas com alta acurácia, utilizando como base dados como participação em fóruns, frequência de acesso, realização de atividades e notas em avaliações.

Além dos benefícios acadêmicos, os sistemas de recomendação têm potencial para aumentar a motivação e o engajamento dos estudantes, ao proporcionar experiências mais alinhadas aos seus interesses e ritmos individuais. No entanto, para alcançar esse potencial, é essencial garantir a qualidade dos dados, a transparência dos critérios de recomendação e a preservação da autonomia do estudante no processo de aprendizagem.

## 2 Feedback automático para alunos e professores

O feedback automático tem se mostrado uma das aplicações mais promissoras das tecnologias educacionais, permitindo oferecer retornos rápidos, personalizados e contínuos tanto para estudantes quanto para professores. Ele se baseia na análise de dados de desempenho e engajamento, identificando pontos fortes, lacunas de aprendizado e sugerindo estratégias de melhoria.

Smith et al. (2012), no modelo RioPACE, demonstraram como relatórios automáticos semanais, combinando dados acadêmicos e de engajamento, podem alertar alunos sobre seu progresso e fornecer insights aos professores para ajustar estratégias pedagógicas. Esses relatórios incluem recomendações personalizadas, como a necessidade de reforçar determinados tópicos, participar mais ativamente de fóruns ou melhorar a gestão do tempo.

Félix et al. (2018) também destacaram a importância do feedback em ambientes de aprendizagem virtual, como o Moodle, onde análises em tempo real permitem oferecer aos estudantes indicadores de progresso e sugestões de recursos complementares. Ao mesmo tempo, os professores recebem informações agregadas e individuais, possibilitando monitorar a turma e tomar decisões pedagógicas informadas.

O feedback automático não apenas melhora o desempenho acadêmico, mas também aumenta a percepção de suporte, autonomia e pertencimento, fatores fundamentais para o engajamento. Contudo, para ser eficaz, ele deve ser preciso, relevante, empático e apresentado de forma compreensível, evitando sobrecarga de informações ou interpretações equivocadas.

## 3 Perspectivas para redução da evasão escolar

A evasão escolar é um dos desafios mais complexos e persistentes enfrentados pelas instituições educacionais em todo o mundo. As tecnologias baseadas em ML, aliadas à análise de dados acadêmicos e comportamentais, têm aberto novas perspectivas para enfrentar esse problema, permitindo identificar precocemente estudantes em risco e propor intervenções personalizadas.

Smith et al. (2012) mostraram, por meio do modelo RioPACE, que o monitoramento semanal de indicadores como frequência de acesso, ritmo de progressão e resultados em avaliações permite detectar padrões de risco logo nas primeiras semanas de curso. Isso possibilita que instituições intervenham rapidamente, oferecendo apoio acadêmico, psicológico e social antes que o estudante desista.

Félix et al. (2018), em sua revisão sobre aplicações no Moodle, destacaram que a análise de logs de plataforma (como participação em fóruns, envio de tarefas e tempo de permanência) tem sido essencial para prever evasão em cursos online, que apresentam índices de abandono particularmente elevados. Esses dados permitem criar alertas automáticos e personalizar mensagens motivacionais, além de redesenhar conteúdos e estratégias para melhorar a retenção.

Além das intervenções individuais, os dados agregados também oferecem insights para ajustes institucionais, como revisão de currículos, capacitação docente e políticas de acolhimento. Contudo, os autores ressaltam que o sucesso dessas estratégias depende de uma abordagem ética, garantindo que as informações sejam usadas para apoiar os estudantes e não para rotulá-los ou estigmatizá-los.

Em resumo, o uso responsável de tecnologias preditivas oferece oportunidades reais para reduzir a evasão escolar, promovendo ambientes mais inclusivos, personalizados e atentos às necessidades dos alunos.

- I **Pergunta:** Quais são os principais benefícios do uso de sistemas de recomendação personalizados no processo de ensino-aprendizagem?
- I **Atividade:** Desenvolva um esboço de como seria um sistema de feedback automático para uma disciplina de sua escolha, incluindo que tipos de mensagens seriam enviadas a alunos e professores.



## C A P Í T U L O 8

# DESAFIOS E PERSPECTIVAS FUTURAS

Este capítulo analisa as limitações atuais das tecnologias educacionais, as considerações éticas e inclusivas que as envolvem e os caminhos para pesquisas futuras, destacando a importância de uma integração interdisciplinar e responsável dessas inovações.

### 1 Limitações atuais das tecnologias aplicadas

Apesar dos avanços promissores das tecnologias educacionais baseadas em ML, sensores vestíveis e análise neurofisiológica, há limitações importantes que precisam ser reconhecidas para garantir uma aplicação eficaz, ética e sustentável.

Do ponto de vista técnico, Mahesh (2020) e Rajasekaran & Saravanan (2020) destacam que muitos algoritmos de ML dependem de grandes volumes de dados de alta qualidade para alcançar bom desempenho, mas, na prática, os dados educacionais frequentemente apresentam problemas como valores ausentes, ruídos, vieses e desbalanceamento entre classes. Além disso, dispositivos vestíveis ainda enfrentam desafios como consumo elevado de energia, interferência de movimento, necessidade de calibração individual e falta de padronização entre diferentes marcas e modelos (Tamsin, 2015; Dzedzickis et al., 2020).

Outro desafio importante é a interpretabilidade dos modelos. Enquanto abordagens como árvores de decisão oferecem resultados facilmente compreensíveis, modelos mais sofisticados, como redes neurais profundas, muitas vezes funcionam como “caixas-pretas”, tornando difícil explicar por que uma determinada predição foi feita. Isso gera resistência por parte de educadores e gestores, que precisam de clareza para confiar nos insights gerados (Mahesh, 2020).

Além disso, há limitações relacionadas à infraestrutura das instituições educacionais, incluindo acesso desigual a tecnologias, conectividade precária em regiões remotas e falta de capacitação docente para lidar com ferramentas digitais avançadas. Esses fatores podem comprometer a implementação e ampliação dessas inovações, agravando desigualdades educacionais já existentes.

Reconhecer essas limitações é um passo essencial para desenhar soluções mais robustas, inclusivas e ajustadas à realidade dos diferentes contextos educacionais.

## 2 Considerações éticas e inclusivas

A adoção de tecnologias educacionais avançadas traz consigo uma série de considerações éticas e inclusivas que não podem ser ignoradas. O uso de ML, sensores vestíveis e análise neurofisiológica envolve a coleta, processamento e interpretação de dados sensíveis, tornando fundamental garantir o respeito à privacidade, ao consentimento informado e à equidade de acesso.

Alshanqiti e Namoun (2020) destacam que, mesmo quando modelos preditivos alcançam alta precisão, eles podem perpetuar ou amplificar desigualdades se forem baseados em dados enviesados ou utilizados sem reflexão crítica. Por exemplo, estudantes de contextos socioeconômicos desfavorecidos podem ser rotulados como “de alto risco”, recebendo menos oportunidades ou sendo tratados de forma diferenciada, agravando estigmas e exclusões.

Tamsin (2015) e Dzedzickis et al. (2020) alertam para desafios relacionados à segurança dos dados gerados por dispositivos vestíveis, que incluem informações biométricas e comportamentais extremamente pessoais. Garantir a proteção desses dados exige medidas robustas de criptografia, anonimização, limitação de acesso e transparência nas finalidades do uso.

Além disso, há desafios inclusivos: muitos dos avanços tecnológicos dependem de infraestrutura, conectividade e equipamentos que não estão igualmente disponíveis em todas as regiões ou instituições, levantando a necessidade de políticas públicas e investimentos que evitem que a tecnologia aprofunde desigualdades educacionais.

Por fim, é essencial capacitar professores, gestores e alunos para compreenderem não apenas como usar essas tecnologias, mas também como interpretar criticamente seus resultados, fortalecendo uma cultura educacional baseada em evidências, ética e inclusão.

## 3 Caminhos para pesquisas futuras e integração interdisciplinar

As perspectivas futuras para o uso de tecnologias avançadas na educação apontam para uma integração cada vez mais profunda entre diferentes áreas do conhecimento, como neurociência, ciência da computação, psicologia, pedagogia e design educacional. Essa convergência interdisciplinar é essencial para desenvolver soluções mais eficazes, éticas e centradas no ser humano.



Mahesh (2020) e Rajasekaran & Saravanan (2020) destacam que novas pesquisas devem explorar modelos híbridos que combinem diferentes tipos de aprendizado (supervisionado, não supervisionado, por reforço), buscando maior adaptabilidade e precisão. Além disso, há espaço para investigações mais profundas sobre o uso de aprendizado profundo (deep learning), redes neurais explicáveis e técnicas de IA ética, que conciliem desempenho técnico com interpretabilidade e responsabilidade social.

Deo et al. (2020) e Wang et al. (2020) sugerem que a aplicação de modelos avançados, como Extreme Learning Machines (ELM) e redes recorrentes híbridas, pode expandir as fronteiras das análises educacionais, principalmente no monitoramento em tempo real de engajamento e desempenho. Já Ming e Ming (2024) reforçam a importância de explorar dados não estruturados, como textos, interações sociais e produções criativas, como fontes ricas de informações pedagógicas.

Além disso, futuros estudos precisarão investigar os impactos emocionais, sociais e cognitivos do uso dessas tecnologias, incluindo efeitos não intencionais sobre motivação, identidade e relações interpessoais. Para isso, será indispensável o trabalho colaborativo entre pesquisadores de diferentes disciplinas, incluindo a participação ativa de professores e estudantes na construção e avaliação das soluções.

Por fim, integrar essas inovações de forma inclusiva e acessível exigirá avanços não apenas tecnológicos, mas também em políticas públicas, formação docente e desenho curricular, garantindo que os benefícios alcancem todos os estudantes, independentemente de seu contexto.

- I **Pergunta:** Como podemos garantir que os avanços tecnológicos na educação sejam inclusivos e não reforcem desigualdades existentes?
- I **Atividade:** Redija uma reflexão breve (até meia página) sobre os cuidados éticos que você considera essenciais ao implementar tecnologias educacionais em contextos diversos.



## C A P Í T U L O 9

# CONSIDERAÇÕES FINAIS

Este capítulo sintetiza as discussões do livro, refletindo sobre a integração entre neuroeducação e inteligência artificial, seus impactos para professores, alunos e políticas educacionais, além de apontar direções para o futuro da educação mediada por dados.

### 1 Integração de neuroeducação e inteligência artificial

A integração entre neuroeducação e IA representa uma transformação paradigmática na forma como concebemos o ensino e a aprendizagem. Ao reunir conhecimentos sobre os processos neurocognitivos humanos com ferramentas tecnológicas avançadas, abre-se um espaço para repensar práticas pedagógicas, estratégias de engajamento e modelos de avaliação de forma personalizada, inclusiva e baseada em evidências.

Mahesh (2020) e Rajasekaran & Saravanan (2020) destacam que a combinação de aprendizado supervisionado, não supervisionado e por reforço permite construir modelos preditivos e adaptativos altamente eficazes, capazes de capturar nuances individuais de aprendizado. Quando integrados a sinais neurofisiológicos, como aqueles estudados por Kanjo et al. (2019) e Apicella et al. (2022), esses modelos oferecem uma compreensão mais rica e profunda do estado emocional, cognitivo e comportamental dos alunos.

Essa integração também permite ir além das análises retrospectivas, abrindo caminho para intervenções em tempo real. Plataformas educacionais baseadas em IA podem ajustar conteúdos, níveis de dificuldade e abordagens pedagógicas conforme as necessidades momentâneas do estudante, promovendo não apenas melhores resultados acadêmicos, mas também maior bem-estar e engajamento.

Contudo, para que essa integração cumpra seu potencial transformador, é essencial que seja guiada por princípios éticos sólidos, garantindo que a tecnologia esteja sempre a serviço do humano, e não o contrário. Isso envolve transparência, responsabilidade e um compromisso constante com a inclusão e a justiça social.

## 2 Impactos para professores, alunos e políticas educacionais

A adoção de tecnologias baseadas em neuroeducação e IA tem impactos profundos em diferentes níveis do ecossistema educacional, afetando diretamente professores, alunos e as políticas que orientam as instituições de ensino.

Para os professores, essas ferramentas oferecem novas possibilidades para compreender o progresso e as necessidades dos estudantes. Estudos como os de Smith et al. (2012) e Félix et al. (2018) mostram que sistemas preditivos e feedback automático permitem identificar dificuldades precocemente, personalizar intervenções e otimizar a gestão do tempo pedagógico. No entanto, para que esses benefícios se concretizem, é necessário investir em formação docente, garantindo que os educadores saibam interpretar e aplicar os insights gerados de forma crítica e ética.

Para os alunos, o impacto é duplo: por um lado, a personalização aumenta a relevância e a eficácia das experiências de aprendizagem; por outro, surge a necessidade de preparar os estudantes para entender como seus dados estão sendo utilizados e para participar ativamente desse processo. Modelos como os de Alshantqi e Namoun (2020) mostram que envolver os estudantes nas decisões sobre seu percurso educacional potencializa não apenas os resultados acadêmicos, mas também a motivação e o engajamento.

No campo das políticas educacionais, o avanço dessas tecnologias exige marcos regulatórios que assegurem privacidade, segurança, inclusão e transparência. Também demanda investimentos em infraestrutura, conectividade e pesquisa interdisciplinar, evitando que a adoção desigual das tecnologias amplie ainda mais as disparidades educacionais existentes.

Assim, o impacto dessas inovações não se limita ao uso de ferramentas tecnológicas, mas envolve transformações culturais, institucionais e políticas que exigem planejamento estratégico e compromisso coletivo.

## 3 Reflexões sobre o futuro da educação mediada por dados

O futuro da educação mediada por dados aponta para um cenário em que personalização, adaptatividade e integração interdisciplinar serão marcas centrais das experiências de aprendizagem. À medida que tecnologias de ML, neuroeducação e dispositivos vestíveis evoluem, surgem oportunidades inéditas para transformar o modo como ensinamos, aprendemos e avaliamos.

Estudos como os de Deo et al. (2020), Wang et al. (2020) e Ming e Ming (2024) mostram que a combinação de modelos avançados, como redes recorrentes híbridas, Extreme Learning Machines e análise hierárquica de tópicos, permitirá capturar

não apenas o desempenho acadêmico, mas também aspectos emocionais, sociais e cognitivos do estudante. Essa riqueza de dados cria condições para desenvolver sistemas educacionais mais humanizados, centrados no aluno e ajustados às suas trajetórias individuais.

No entanto, como destacam Alshantqi e Namoun (2020) e Félix et al. (2018), o avanço tecnológico precisa caminhar lado a lado com o avanço ético, social e institucional. Garantir inclusão, acessibilidade, transparência e respeito à privacidade não será opcional, será essencial para assegurar que a educação mediada por dados beneficie a todos, sem reforçar desigualdades ou criar formas de exclusão.

Por fim, o futuro da educação será construído coletivamente: não apenas por engenheiros e cientistas de dados, mas também por educadores, alunos, gestores, famílias e formuladores de políticas públicas. A colaboração entre esses atores será fundamental para transformar dados em sabedoria, algoritmos em cuidado e tecnologia em uma aliada real na construção de uma educação mais justa, eficaz e humana.

- I **Pergunta:** Quais são os principais impactos positivos e negativos da integração entre neuroeducação e inteligência artificial no contexto educacional?
- I **Atividade:** Elabore um mapa mental conectando os principais conceitos abordados no livro e indicando como eles se relacionam entre si e com o futuro da educação.

# REFERÊNCIAS

ABROMAVICIUS, V.; SERACKIS, A.; KATKEVICIUS, A.; KAZLAUSKAS, M.; SLEDEVIČ, T. Prediction of exam scores using a multi-sensor approach for wearable exam stress dataset with uniform preprocessing. **Technology and Health Care**, v. 31, n. 6, p. 2499-2511, 2023.

ÅHS, F.; DUNSMOOR, J. E.; ZIELINSKI, D.; LABAR, K. S. Spatial proximity amplifies valence in emotional memory and defensive approach-avoidance. **Neuropsychologia**, v. 70, p. 476-485, 2015a.

ÅHS, F.; KRAGEL, P. A.; ZIELINSKI, D. J.; BRADY, R.; LABAR, K. S. Medial prefrontal pathways for the contextual regulation of extinguished fear in humans. **NeuroImage**, 2015b.

ALSHANQITI, A.; NAMOUN, A. Predicting Student Performance and Its Influential Factors Using Hybrid Regression and Multi-Label Classification. **IEEE Access**, v. 8, p. 203827-203842, 2020.

APICELLA, A.; ARPAIA, P.; FROSOLONE, M.; IMPROTA, G.; MOCCALDI, N.; POLLASTRO, A. EEG-based measurement system for monitoring student engagement in learning 4.0. **Scientific Reports**, v. 12, n. 5857, 2022.

BARADWAJ, B. K.; PAL, S. Mining Educational Data to Analyze Students' Performance. **International Journal of Advanced Computer Science and Applications**, v. 2, n. 6, p. 63-69, 2011.

CUI, Y.; CHEN, F.; SHIRI, A.; FAN, Y. Predictive analytic models of student success in higher education: A review of methodology. **Information and Learning Sciences**, v. 120, n. 3/4, p. 208-227, 2019.

DAUD, A.; ALJOHANI, N. R.; ABBASI, R. A.; LYTRAS, M. D.; ABBAS, F.; ALOWIBDI, J. S. Predicting Student Performance using Advanced Learning Analytics. In: **WWW 2017 Companion**, 2017, Perth, Australia. ACM, 2017.

DEO, R. C.; YASEEN, Z. M.; AL-ANSARI, N.; NGUYEN-HUY, T.; LANGLANDS, T. A. M.; GALLIGAN, L. Modern Artificial Intelligence Model Development for Undergraduate Student Performance Prediction: An Investigation on Engineering Mathematics Courses. **IEEE Access**, v. 8, p. 136697-136716, 2020.

DZEDZICKIS, A.; KAKLAUSKAS, A.; BUCINSKAS, V. Human Emotion Recognition: Review of Sensors and Methods. **Sensors**, v. 20, n. 3, p. 592, 2020.

FEIDAKIS, M. A review of emotion-aware systems for e-learning in virtual environments. In: **CABALLÉ, S. (Ed.). Formative assessment, learning data analytics and gamification**. 1. ed. Elsevier, 2016. Cap. 11, p. 217-232.

FÉLIX, I. M.; AMBRÓSIO, A. P.; LIMA, P. S. N.; BRANCHER, J. D. Data Mining for Student Outcome Prediction on Moodle: a systematic mapping. In: **SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO**, 29., 2018, Fortaleza. Anais [...]. Porto Alegre: SBC, 2018. p. 1393-1402.

FERNÁNDEZ-CABALLERO, A.; MARTÍNEZ-RODRIGO, A.; PASTOR, J. M.; CASTILLO, J. C.; LOZANO-MONASOR, E.; LÓPEZ, M. T.; ZANGRÓNIZ, R.; LATORRE, J. M.; FERNÁNDEZ-SOTOS, A. Smart environment architecture for emotion detection and regulation. **Journal of Biomedical Informatics**, v. 64, p. 55-73, 2016.

KANJO, E.; YOUNIS, E. M. G.; ANG, C. S. Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection. **Information Fusion**, v. 49, p. 46-56, 2019.

KUMAR, M.; SINGH, A. J.; HANDA, D. Literature Survey on Student's Performance Prediction in Education using Data Mining Techniques. **International Journal of Education and Management Engineering**, v. 7, n. 6, p. 40-49, 2017.

MAHESH, B. Machine learning algorithms - a review. **International Journal of Science and Research (IJSR)**, v. 9, n. 1, p. 380-386, Jan. 2020.

MING, N. C.; MING, V. L. Predicting Student Outcomes from Unstructured Data. **Nexus Research & Policy Center**, San Francisco CA, 2024.

MONKARESI, H.; BOSCH, N.; CALVO, R. A.; D'MELLO, S. K. Automated detection of engagement using video-based estimation of facial expressions and heart rate. **IEEE Transactions on Affective Computing**, 2016.

PEÑA-AYALA, A. Educational data mining: A survey and a data mining-based analysis of recent works. **Expert Systems with Applications**, 2013.

RAHEEL, A.; MAJID, M.; ANWAR, S. M. DEAR-MULSEMEDIA: Dataset for emotion analysis and recognition in response to multiple sensorial media. **Information Fusion**, v. 65, p. 37-49, 2021.

RAJASEKARAN, K.; SARAVANAN, P. Conceptual Methodology on Machine Learning and Types of Learning Algorithms. **JAC: A Journal of Composition Theory**, v. XIII, n. V, p. 233-240, maio 2020.

RAJAVENKANARAYANAN, A.; BABU, A. R.; TSIAKAS, K.; MAKEDON, F. Monitoring Task Engagement using Facial Expressions and Body Postures. In: **IWISC 2018: 3rd International Workshop on Interactive and Spatial Computing**, 12-13 Apr. 2018, Richardson, TX, USA. Proceedings [...]. New York: ACM, 2018. p. 1-6.

SMITH, V. C.; LANGE, A.; HUSTON, D. R. Predictive Modeling to Forecast Student Outcomes and Drive Effective Interventions in Online Community College Courses. **Journal of Asynchronous Learning Networks**, v. 16, n. 3, p. 51-61, 2012.

TAMSIN, M. Wearable biosensor technologies. **International Journal of Innovation and Applied Studies**, v. 13, n. 2, p. 697-703, fev. 2015.

WANG, X.; YU, X.; GUO, L.; LIU, F.; XU, L. Student performance prediction with short-term sequential campus behaviors. **Information**, v. 11, n. 4, p. 201, 2020.

WATANABE, Y.; WASHIZAKI, H.; SAKAMOTO, K.; SAITO, D.; HONDA, K.; TSUDA, N.; FUKAZAWA, Y.; YOSHIOKA, N. Preliminary systematic literature review of machine learning system development process. **arXiv preprint** arXiv:1910.05528, 2019.

WEI, Y.; WU, Y.; TUDOR, J. A real-time wearable emotion detection headband based on EEG measurement. *Sensors & Actuators: A. Physical*, v. 263, p. 614-621, 2017.

## **SOBRE O AUTOR**

Blaha Gregory Correia dos Santos Goussain é doutorando em Engenharia pela FEG/UNESP, com doutorado sanduíche (PDSE/CAPES) na University of Tennessee, Knoxville (UTK), Estados Unidos. Mestre em Engenharia de Produção pela UNESP, especialista em Processos Didático-Pedagógicos (UNIVESP) e Gestão da Produção (UNESP). Graduado em Engenharia de Produção (UNIVESP) e licenciado em Matemática (UNESP), possui certificação Black Belt em Lean Six Sigma e especialização em Lean Manufacturing. Atua como pesquisador visitante na EEL/USP e orientador de pós-graduação lato sensu na POLI USP PRO.



# NEUROEDUCAÇÃO E APRENDIZADO DE MÁQUINA

## TECNOLOGIAS, ALGORITMOS E ENGAJAMENTO NO CONTEXTO EDUCACIONAL



[www.atenaeditora.com.br](http://www.atenaeditora.com.br)



[contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)



[@atenaeditora](https://www.instagram.com/atenaeditora)



[www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)

# NEUROEDUCAÇÃO E APRENDIZADO DE MÁQUINA

## TECNOLOGIAS, ALGORITMOS E ENGAJAMENTO NO CONTEXTO EDUCACIONAL



[www.atenaeditora.com.br](http://www.atenaeditora.com.br)



[contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)



[@atenaeditora](https://www.instagram.com/atenaeditora)



[www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)