


UNIVERSIDADE ESTADUAL PAULISTA - UNESP
Faculdade de Engenharia e Ciências - Campus de Guaratinguetá

BLAHA GREGORY CORREIA DOS SANTOS GOUSSAIN

NEUROCIÊNCIA APLICADA À EDUCAÇÃO EM ENGENHARIA:
avaliação do engajamento por sinais fisiológicos e aprendizado de máquina

Guaratinguetá - SP
2025



BLAHA GREGORY CORREIA DOS SANTOS GOUSSAIN

NEUROCIÊNCIA APLICADA À EDUCAÇÃO EM ENGENHARIA:
avaliação do engajamento por sinais fisiológicos e aprendizado de máquina

Tese apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências, Guaratinguetá, para obtenção do título de Doutor em Engenharia.

Área de Concentração: Produção

Orientador: Prof. Dr. Messias Borges Silva

Coorientadores: Prof. Dr. José Roberto Dale Luche e Prof. Dr. Herlandí de Souza Andrade

Guaratinguetá - SP

2025

G717n

Goussain, Blaha Gregory Correia dos Santos
Neurociência aplicada à educação em engenharia:
avaliação do engajamento por sinais fisiológicos e
aprendizado de máquina / Blaha Gregory Correia dos
Santos Goussain - Guaratinguetá, 2025.

138 f : il.

Bibliografia: f. 106-117

Tese (Doutorado) – Universidade Estadual Paulista,
Faculdade de Engenharia e Ciências de Guaratinguetá, 2025.

Orientador: Prof. Dr. Messias Borges Silva

Coorientadores: Prof. Dr. José Roberto Dale Luche

Prof. Dr. Herlandí de Souza Andrade

1. Neurociências. 2. Batimento cardíaco. 3. Aprendizado
do computador. 4. Engenharia - Estudo e ensino. I. Título.

CDU 612.8(043)

Luciana Máximo

Bibliotecária/CRB-8 3595

IMPACTO POTENCIAL DESTA PESQUISA

Esta pesquisa possui alto potencial científico e técnico ao integrar neurociência, biossensores e aprendizado de máquina na educação em engenharia, área ainda pouco explorada no Brasil. O caráter inovador está no uso de sinais fisiológicos (EDA, HR e ST) como indicadores objetivos de engajamento, o que favorece o desenvolvimento de práticas pedagógicas mais eficazes e baseadas em evidências.

Do ponto de vista social e educacional, os resultados podem contribuir para a formação de profissionais mais preparados e engajados, elevando a qualidade do ensino superior. Também estimulam o uso de tecnologias acessíveis e adaptáveis, com impacto em diferentes contextos acadêmicos e culturais.

Em termos econômicos e regionais, a pesquisa abre caminho para soluções inovadoras em instituições de ensino e setores produtivos, fortalecendo sua inserção nacional e internacional por meio de colaborações e publicações. Além disso, está alinhada à Agenda 2030 da ONU, em especial ao ODS 4 (educação de qualidade), reforçando sua relevância global e compromisso com o desenvolvimento sustentável.

POTENTIAL IMPACT OF THIS RESEARCH

This research has strong scientific and technical potential by integrating neuroscience, biosensors, and machine learning into engineering education, a field still underexplored in Brazil. Its innovative aspect lies in using physiological signals (EDA, HR, and ST) as objective indicators of student engagement, fostering the development of more effective and evidence-based teaching practices.

From a social and educational perspective, the findings may enhance the training of more engaged and better-prepared professionals, improving the overall quality of higher education. They also encourage the use of accessible and adaptable technologies, with positive impact across academic and cultural contexts.

On the economic and regional levels, the research opens opportunities for innovative solutions in educational institutions and productive sectors, strengthening both national and international presence through collaborations and publications. Furthermore, it aligns with the United Nations 2030 Agenda, particularly SDG 4 (quality education), reinforcing its global relevance and commitment to sustainable development.

BLAHA GREGORY CORREIA DOS SANTOS GOUSSAIN

**Neurociência aplicada à Educação em Engenharia: avaliação do engajamento
por sinais fisiológicos e aprendizado de máquina.**

Tese apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências de Guaratinguetá, para obtenção do título de Doutor em Engenharia.

Data da defesa: 09/09/2025

Banca Examinadora:



Documento assinado digitalmente
MESSIAS BORGES SILVA
Data: 22/09/2025 16:51:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. MESSIAS BORGES SILVA
Orientador - UNESP



Documento assinado digitalmente
MARCELA APARECIDA GUERREIRO MACHADO DI
Data: 23/09/2025 10:06:28-0300
Verifique em <https://validar.iti.gov.br>

Prof^a. Dr^a. MARCELA APARECIDA GUERREIRO MACHADO DE FREITAS
UNESP

FABRICIO MACIEL
GOMES:04628884
790

Assinado digitalmente por FABRICIO MACIEL
GOMES:04628884790
ID: C=BR, O=ICP-Brasil, OU=Presencial, OU=45218757000194, OU=Secretaria da Receita Federal do Brasil - RFB, OU=RFB e-CPF A1, OU=(em branco), CN=FABRICIO MACIEL GOMES:04628884790
Razão: Eu sou o autor deste documento
Localização:
Data: 2025.09.22 17:01:49-03'00'
Foxit PDF Reader Versão: 2025.2.0

Prof. Dr. FABRÍCIO MACIEL GOMES
EEL/USP



Documento assinado digitalmente
VALÉRIO ANTONIO PAMPLONA SALOMON
Data: 23/09/2025 12:31:55-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. VALÉRIO ANTONIO PAMPLONA SALOMON
UNESP



Documento assinado digitalmente
RENATA DA SILVA CARDOSO ROCHA TAVARES
Data: 23/09/2025 15:14:20-0300
Verifique em <https://validar.iti.gov.br>

Prof^a Dr^a RENATA DA SILVA CARDOSO ROCHA TAVARES
EEL/USP

Dedico este trabalho à memória do meu pai,
Pedro Ricardo Goussain, que sempre me
incentivou nos estudos e apoiou todas as
minhas escolhas.

AGRADECIMENTOS

Inicialmente, expresso minha mais profunda gratidão a Deus, grande criador do universo, por me agraciar com saúde, sabedoria e segurança durante toda a trajetória que culminou na finalização desta tese.

Em subsequente, dirijo um agradecimento particular ao meu orientador, Prof. Dr. Messias Borges Silva. Sua confiança, acessibilidade e a oportunidade por ele conferida foram essenciais para incentivar um ambiente de entusiasmo e dedicação, elementos imprescindíveis para a concretização deste trabalho acadêmico.

De maneira equivalente, expresso minha gratidão aos coorientadores, Prof. Dr. José Roberto Dale Luche e Prof. Dr. Herlandi de Souza Andrade. A paciência, o comprometimento e a assistência que ambos demonstraram foram fundamentais para minha orientação pessoal e acadêmica, constituindo-se alicerces sólidos para o êxito desta pesquisa.

Concluo estes agradecimentos estendendo minha profunda estima à minha família e amigos. O suporte e incentivo por eles fornecidos foram pilares de força emocional e motivacional, contribuindo significativamente para a minha jornada e consequente término desta tese.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Se você conhecer a magnificência dos números 3, 6 e 9, então você terá a chave do universo”

(Nikola Tesla).

RESUMO

A Agenda 2030 para o Desenvolvimento Sustentável, instituída pela Assembleia Geral das Nações Unidas em 2015, reafirma o papel central da educação de qualidade, conforme delineado no Objetivo de Desenvolvimento Sustentável 4 (ODS 4). Inserido nesse escopo, o presente estudo investigou o potencial de sinais fisiológicos, atividade eletrodérmica (EDA), frequência cardíaca (HR) e temperatura da pele (ST), como marcadores objetivos do engajamento estudantil em distintos contextos pedagógicos. Com base em uma abordagem quantitativa e experimental, foram coletados dados de 50 estudantes universitários durante sessões com aulas expositivas tradicionais e metodologias ativas de aprendizagem. Modelos preditivos baseados em técnicas de aprendizado de máquina (ML) foram utilizados para análise e antecipação dos estados de engajamento. Os resultados revelaram forte convergência com a literatura, especialmente no que se refere à EDA, a qual apresentou elevação significativa durante atividades de aprendizagem ativa, corroborando sua validade como indicador sensível do engajamento acadêmico. Padrões similares foram observados para a HR, embora com menor consistência, enquanto a ST apresentou valores mais elevados nas sessões tradicionais, o que sugere sua relação inversa com a ativação simpática em contextos cognitivos mais exigentes. Os modelos de ML, em particular os algoritmos Floresta Aleatória (RF) e Gradient Boosting, demonstraram desempenho superior na predição de estados de engajamento, confirmando a viabilidade da aplicação de biossensores e inteligência artificial (AI) no monitoramento e suporte ao processo pedagógico. Os resultados demonstraram que EDA, HR e ST variaram de forma consistente entre aulas expositivas e metodologias ativas, confirmando a relação dos achados biológicos com os métodos de ensino e validando seu uso como indicadores de engajamento acadêmico.

Palavras-chave: neurociência; atividade eletrodérmica; frequência cardíaca; temperatura da pele; aprendizado de máquina; educação em engenharia.

ABSTRACT

The 2030 Agenda for Sustainable Development, established by the United Nations General Assembly in 2015, reaffirms the central role of quality education, as outlined in Sustainable Development Goal 4 (SDG 4). Within this framework, the present study investigates the potential of physiological signals, electrodermal activity (EDA), heart rate (HR), and skin temperature (ST), as objective indicators of student engagement in distinct educational contexts. Based on a quantitative and experimental approach, data were collected from 50 university students during sessions involving traditional lectures and active learning methodologies. Predictive models employing machine learning (ML) techniques were applied to analyze and anticipate engagement states. The empirical findings demonstrated strong alignment with existing literature, particularly regarding EDA, which exhibited significant increases during active learning activities, thus reinforcing its validity as a sensitive marker of academic engagement. Similar patterns were observed for HR, albeit with lower consistency, while ST presented higher values during traditional sessions, suggesting an inverse relationship with sympathetic activation in cognitively demanding contexts. ML models, especially Random Forest (RF) and Gradient Boosting algorithms, showed superior performance in predicting engagement states, confirming the feasibility of using biosensors and artificial intelligence (IA) to monitor and support pedagogical processes. The results showed that EDA, HR, and ST varied consistently between traditional lectures and active learning methodologies, confirming the relationship between biological findings and teaching methods and validating their use as indicators of academic engagement.

Keywords: neuroscience; electrodermal activity; heart rate; skin temperature; machine learning; engineering education.

LISTA DE FIGURAS

Figura 1 - Visualização em rede dos termos “electrodermal activity” e “education”	25
Figura 2 - Visualização em rede dos termos “heart rate” e “education”	26
Figura 3 - Visualização em rede dos termos “skin temperature” e “education”	26
Figura 4 - Visualização em rede dos termos “machine learning” e “education”	27
Figura 5 - Dispositivo físico utilizado nas atividades práticas	57
Figura 6 - Aplicação do dispositivo durante a sessão experimental.....	58
Figura 7 - Conexão do sensor de resistência eletrodérmica	59
Figura 8 - Conexão do sensor cardíaco	60
Figura 9 - Conexão do sensor de temperatura	61
Figura 10 - Gabinete com canais para conexão dos sensores.....	64
Figura 11 - EDA da estudante 36	69
Figura 12 - EDA da estudante 26	69
Figura 13 - EDA do Estudante 46	70
Figura 14 - EDA do Estudante 7	71
Figura 15 - EDA do Estudante 3	71
Figura 16 - EDA do Estudante 30	72
Figura 17 - Medianas de EDA dos participantes.....	73
Figura 18 - HR da Estudante 19	75
Figura 19 - HR da Estudante 9	75
Figura 20 - HR da Estudante 42	76
Figura 21 - HR do Estudante 11	77
Figura 22 - HR do Estudante 20	77
Figura 23 - HR da Estudante 18	78
Figura 24 - Medianas de HR dos participantes.....	79
Figura 25 - ST do Estudante 49	80
Figura 26 - ST do Estudante 48	81
Figura 27 - ST da Estudante 18	82
Figura 28 - ST da Estudante 9	82
Figura 29 - ST do Estudante 13	83
Figura 30 - ST do Estudante 23	84
Figura 31 - Medianas de ST dos participantes	85
Figura 32 - Correlação de Spearman	86

Figura 33 - Matriz de confusão da classificação RF	91
Figura 34 - Matriz de confusão da classificação KNN.....	91
Figura 35 - Matriz de confusão da classificação ANN.....	92
Figura 36 - Matriz de confusão da classificação LR	92
Figura 37 - Matriz de confusão da classificação SVM.....	93
Figura 38 - Métricas para a classe Engajado	94
Figura 39 – Métricas para a classe Desengajado	94
Figura 40 – Comparação de desempenho - MSE	98
Figura 41 – Comparação de desempenho - R^2	98

LISTA DE ILUSTRAÇÕES

Quadro 1 - Estudos sobre EDA, HR e ST no contexto educacional.....	34
--	----

LISTA DE TABELAS

Tabela 1 - Pesquisa bibliográfica na base Elsevier.....	23
Tabela 2 - Pesquisa bibliográfica na base PubMed	23
Tabela 3 - Pesquisa bibliográfica com uma interseção na base Elsevier.....	23
Tabela 4 - Pesquisa bibliográfica com uma interseção na base PubMed	24
Tabela 5 - Pesquisa bibliográfica com duas interseções na base Elsevier.....	24
Tabela 6 - Pesquisa bibliográfica com duas interseções na base PubMed	24
Tabela 7 - Pesquisa bibliográfica com cinco interseções na base Elsevier	24
Tabela 8 - Pesquisa bibliográfica com três interseções na base PubMed.....	24
Tabela 9 - Dados demográficos dos participantes	62
Tabela 10 - Desempenho dos modelos com algoritmos de classificação.....	89
Tabela 11 - Desempenho dos modelos com algoritmos de regressão	96

LISTA DE ABREVIATURAS E SIGLAS

Ag	Prata
AgCl	Cloreto de Prata
ANN	Redes Neurais Artificiais
BPM	Batimentos Por Minuto
BVP	Pressão do Volume Sanguíneo
CMRR	Relação de Rejeição de Modo Comum
CO ₂	Dióxido de Carbono
DA	Acordo Direcional
DL	Aprendizado Profundo
DT	Árvore de Decisão
ECG	Eletrocardiograma
EDA	Atividade Eletrodérmica
EDM	Mineração de Dados Educacionais
EEG	Eletroencefalografia
FLA	Ansiedade em Falar uma Língua Estrangeira
fMRI	Imagem por Ressonância Magnética Funcional
GSR	Resposta Galvânica da Pele
H ₀	Hipótese Nula
HR	Frequência Cardíaca
HRV	Variabilidade da Frequência Cardíaca
IDM	Correspondência de Derivadas Instantâneas
KNN	K-vizinho mais próximo
LDA	Análise Discriminante Linear
LMT	Árvore Modelo Logístico
LR	Regressão Linear
LSVM	Máquinas de Vetores de Suporte Linear
MDD	Transtorno Depressivo Maior

ML	Aprendizado de Máquina
MOOCs	Cursos Online Abertos e Massivos
MSE	Erro Médio Quadrático Relativo
MUMTG	Modelagem Multimodal de Usuários para Orientação em Tarefas
NS.SCRs	Respostas de Condutância da Pele Não Específicas
ONU	Organização das Nações Unidas
PBL	Aprendizagem Baseada em Problemas
PC	Correlação de Pearson
PPG	Fotopletismografia
PSA	Ansiedade em Falar em Público
PSD	Análise da Densidade Espectral de Potência
R^2	Coefficiente de Determinação
RCLE	Registro de Consentimento Livre e Esclarecido
RF	Floresta Aleatória
RMSE	Raiz do Erro Quadrático Médio
SCL	Nível de Condutância da Pele
SCR	Resposta de Condutância da Pele
SI	Sistema Internacional de Unidades
SM	Correspondência de Sinais
ST	Temperatura da Pele
STAI	Inventário de Ansiedade Traço-Estado
SVM	Máquinas de Vetor de Suporte
TBLEs	Aprendizagem Baseados em Tecnologia
TICs	Tecnologias de Informação e Comunicação
TMP	Temperatura
WESAD	Deteção de Estresse e Afeto por Dispositivos Vestíveis

LISTA DE SÍMBOLOS

°C	Celsius
μS	Microsiemens

SUMÁRIO

1	INTRODUÇÃO	18
1.1	CONTEXTUALIZAÇÃO	20
1.2	JUSTIFICATIVAS	22
1.3	OBJETIVOS	30
1.3.1	Objetivo geral.....	30
1.3.2	Objetivos específicos.....	31
1.4	APRESENTAÇÃO DO TRABALHO	31
2	REVISÃO DA LITERATURA.....	33
2.1	ATIVIDADE ELETRODÉRMICA	37
2.1.1	EDA na educação e engajamento de estudantes	38
2.1.2	EDA em estudos de estresse e saúde	40
2.1.3	Metodologias, aplicações e avaliação de EDA.....	42
2.2	FREQUÊNCIA CARDÍACA	44
2.2.1	Monitoramento da HR e engajamento educacional	44
2.2.2	Tecnologias vestíveis e análise de HR	46
2.3	TEMPERATURA DA PELE	46
2.3.1	Monitoramento de estresse e ansiedade por meio da ST	47
2.4	APRENDIZADO DE MÁQUINA	48
2.4.1	Previsão de desempenho acadêmico com ML	48
2.4.2	Técnicas e algoritmos específicos de ML em previsão acadêmica	50
2.4.3	Revisões e análises sobre técnicas de ML em educação	52
2.4.4	Aplicações de ML em contextos de saúde e comportamento.....	53
3	MATERIAIS E MÉTODOS	56
3.1	PROTOCOLO EXPERIMENTAL.....	56
3.2	PARTICIPANTES.....	61
3.3	COLETA DE DADOS	63
3.4	ANÁLISE DE DADOS	65
4	RESULTADOS E DISCUSSÕES	68
4.1	RESULTADOS EDA	68
4.2	RESULTADOS HR.....	74
4.3	RESULTADOS ST.....	80
4.4	MATRIZES DE CORRELAÇÃO.....	86

4.5	RESULTADOS ML	87
4.5.1	Algoritmos de classificação	88
4.5.2	Algoritmos de regressão	95
4.5.3	Modelos preditivos	99
4.6	ANÁLISE COMPARATIVA COM ESTUDOS DA LITERATURA	101
5	CONSIDERAÇÕES FINAIS	103
5.1	CONCLUSÕES	103
5.2	SUGESTÕES PARA TRABALHOS FUTUROS	104
	REFERÊNCIAS	106
	APÊNDICE A - ATIVIDADES PRÁTICAS	118
	APÊNDICE B - VARIÁVEL ALVO	119
	APÊNDICE C - SINAIS DE EDA	120
	APÊNDICE D - MEDIÇÕES DE EDA	124
	APÊNDICE E - SINAIS DE HR	126
	APÊNDICE F - MEDIÇÕES DE HR	130
	APÊNDICE G - SINAIS DE ST	132
	APÊNDICE H - MEDIÇÕES DE ST	136
	APÊNDICE I - DADOS NORMALIZADOS	138

1 INTRODUÇÃO

Em 2015, a Organização das Nações Unidas (ONU), juntamente com seus 193 países membros, apresentou a Agenda 2030, um plano estratégico abrangente voltado para a promoção do desenvolvimento sustentável em escala global. Esse plano é composto por 17 objetivos e 169 metas, cuja execução abrange um período de 15 anos, buscando avanços significativos nas dimensões econômica, social e ambiental (UNITED NATIONS, 2015). Entre os objetivos estabelecidos, destaca-se a promoção de uma educação de qualidade, tema central do presente estudo.

A educação de qualidade é amplamente reconhecida como um pilar essencial para o desenvolvimento sustentável, desempenhando um papel central na formação de cidadãos conscientes, críticos e engajados. Nesse contexto, Atchison et al. (2023) analisaram os fatores que influenciam a criatividade em ambientes educacionais, demonstrando que a expectativa de avaliação por parte de docentes pode elevar excessivamente a excitação fisiológica dos estudantes, comprometendo o desempenho criativo. Por outro lado, níveis muito baixos de ativação também se associam à desatenção e ao desengajamento, reforçando que tanto o excesso quanto a falta de excitação fisiológica podem impactar negativamente o processo de aprendizagem. Complementando essa perspectiva, Qin (2024) investigou estratégias de proteção dos dados emocionais de professores, utilizando anonimização, controle de acesso e criptografia. O estudo empregou sinais fisiológicos de dispositivos vestíveis (WESAD) e eletrocardiogramas (ECG) para treinar modelos capazes de identificar estados emocionais, como baseline, recreação e tensão. Os resultados evidenciaram que a etapa de extração de características é fundamental para garantir o bom desempenho desses modelos.

Oliveira et al. (2021) destacam que diferentes formatos de ensino, como o híbrido, podem influenciar a satisfação e o engajamento dos estudantes, reforçando a relevância de se investigar como distintas abordagens pedagógicas impactam os níveis de envolvimento acadêmico. Por sua vez, Santos et al. (2020) argumentam que a superação do modelo tradicional de ensino exige melhorias estruturais e pedagógicas, especialmente em infraestrutura escolar e formação docente, para que as instituições públicas possam acompanhar as demandas da sociedade contemporânea e implementar novas metodologias educacionais.

Nesse sentido, Roman et al. (2017) ressaltam que estratégias como a Aprendizagem Baseada em Problemas (PBL) e a problematização se mostram eficazes para ampliar a motivação e o envolvimento dos estudantes, promovendo a integração entre teoria e prática, o desenvolvimento da autonomia e a formação de um perfil crítico e reflexivo, indispensável à

atuação profissional. Complementando essa perspectiva, Dias-Lima et al. (2019) apontam que a abordagem PBL possibilita uma interação mais ampla entre estudantes e professores, rompendo com os paradigmas do ensino tradicional e promovendo o desenvolvimento de competências essenciais ao perfil profissional dos estudantes.

Adicionalmente, Capalonga e Wildner (2018) defendem que as metodologias ativas, ao promoverem o protagonismo do estudante no processo de aprendizagem, são decisivas para o desenvolvimento de habilidades críticas, reflexivas e práticas. Essas metodologias não apenas melhoram o engajamento e a curiosidade dos estudantes em relação ao conteúdo estudado, mas também fomentam uma colaboração mais efetiva entre docentes e discentes. Nesse contexto, o papel do professor como facilitador e do estudante como agente ativo resulta em um aprendizado mais eficaz e significativo. A eficácia da diversificação das metodologias, conforme demonstrado por Colares et al. (2019), ao integrar técnicas tradicionais e inovadoras, facilita o aprendizado e aumenta o engajamento dos estudantes, promovendo uma educação mais eficiente e atrativa.

A pesquisa de Hernandez-de-Menendez e Morales-Menendez (2019) revisa as inovações tecnológicas e as práticas educativas, com foco na área de engenharia, destacando o uso de Tecnologias de Informação e Comunicação (TICs) como ferramentas para aprimorar o processo de ensino-aprendizagem. Segundo os autores, essas inovações tecnológicas não apenas aumentam o engajamento e a motivação dos estudantes, mas também desenvolvem habilidades essenciais como pensamento crítico, resolução de problemas e colaboração, preparando melhor os estudantes para as exigências do mercado de trabalho do século XXI.

Nesse contexto, emerge uma questão central: como avaliar de forma objetiva o engajamento dos estudantes em diferentes práticas pedagógicas no ensino de engenharia? As práticas pedagógicas constituem os meios, estratégias e metodologias de ensino, utilizadas para estimular a aprendizagem. O engajamento, por sua vez, representa a resposta comportamental, emocional e cognitiva dos alunos diante dessas práticas, enquanto o desempenho acadêmico corresponde a um resultado mensurável, que pode ou não estar diretamente associado ao nível de engajamento. Para responder a essa questão, este trabalho integra conhecimentos da neurociência e aplica sinais fisiológicos, como EDA, HR e ST, em conjunto com técnicas de aprendizado de máquina, buscando desenvolver métodos capazes de identificar e prever estados de engajamento. Essa abordagem permite compreender, de maneira mais precisa, como os estudantes respondem às diferentes metodologias educacionais, oferecendo subsídios para a construção de práticas pedagógicas mais eficazes e baseadas em evidências.

1.1 CONTEXTUALIZAÇÃO

A neurociência, enquanto campo interdisciplinar, tem desempenhado um papel fundamental no aprofundamento do entendimento sobre os processos cognitivos dos estudantes, oferecendo subsídios para a adaptação e otimização de abordagens pedagógicas. Esses avanços tornam a aprendizagem não apenas mais eficaz, mas também mais envolvente e duradoura. Segundo Amaral e Fregni (2021), a neurociência estabelece princípios fundamentais para o contexto educacional, como o aprimoramento da conectividade neural, o fortalecimento da memória de longo prazo, a atenção seletiva e a valorização das experiências do estudante. Esses aspectos são essenciais para moldar práticas pedagógicas que atendam de forma mais precisa às demandas cognitivas dos aprendizes.

A incorporação de tecnologias avançadas tem ampliado o campo de aplicação da interação humano-computador (IHC), que fornece princípios e ferramentas úteis em diversas áreas, incluindo a educação. Nesse âmbito, estudos como o de Bühler et al. (2024) indicam que a utilização de recursos multimodais, isto é, a combinação de diferentes tipos de dados e interfaces, pode aumentar a eficácia na detecção de divagações em ambientes educacionais quando comparada a métodos unimodais, contribuindo para o desenvolvimento de tecnologias pedagógicas mais adaptativas.

De forma complementar, Hashky et al. (2024) apresentaram o conjunto de dados Modelagem Multimodal de Usuários para Orientação em Tarefas (MUMTG), que reúne informações biométricas, de rastreamento espacial e avaliações subjetivas coletadas em tarefas simuladas, envolvendo desafios cognitivos e fatores estressores. Embora não inserida em um contexto educacional, essa pesquisa demonstra como a multimodalidade pode oferecer subsídios relevantes para o aprimoramento de sistemas de inteligência artificial adaptativos e para uma melhor compreensão do comportamento humano em situações complexas.

Paralelamente, metodologias inovadoras têm sido investigadas para medir e analisar o engajamento dos estudantes, destacando o papel essencial de indicadores fisiológicos nesse processo. Por exemplo, Horvers et al. (2021), em uma revisão sistemática sobre a detecção de emoções por meio da EDA em contextos de aprendizagem, identificaram variações significativas nos métodos utilizados para medir e processar os dados de EDA. A análise revelou relações consistentes entre a EDA, o desempenho acadêmico e os ganhos de aprendizagem dos estudantes. Esses achados sublinham a relevância da EDA como um indicador promissor de engajamento e sucesso acadêmico, reforçando seu potencial como ferramenta de avaliação em ambientes educacionais.

Conforme Febrianoro et al. (2023), dados fisiológicos, como EDA, têm sido utilizados para analisar estresse, emoções, esforço mental e qualidade da colaboração na aprendizagem colaborativa. Embora a excitação fisiológica e a sincronia estejam associadas ao sucesso nesse contexto, a relação entre EDA e resultados de aprendizagem apresenta limitações, como a influência de variáveis externas (ex.: ambiente e condições físicas), a variabilidade individual das respostas fisiológicas e a dificuldade em estabelecer causalidade direta entre engajamento medido e desempenho acadêmico. A aplicação de dados fisiológicos para fornecer feedback aos estudantes permanece pouco explorada, apontando a necessidade de estudos adicionais.

Além disso, a eficácia das medidas fisiológicas na predição do desempenho acadêmico tem sido investigada em estudos recentes, como o de Abromavičius et al. (2023), que utilizaram sinais de EDA, HR e ST para prever notas de exames com alta acurácia, e o de Khan et al. (2019), que analisaram a relação entre respostas fisiológicas e desempenho em provas de engenharia, encontrando correlações significativas, ainda que moderadas. Esses resultados reforçam o potencial dos dados fisiológicos como preditores do desempenho acadêmico, embora ainda exijam validação em diferentes contextos educacionais. A pesquisa de Abromavičius et al. (2023) explora a eficácia de sinais fisiológicos como EDA, HR e ST na previsão de notas de exames. Utilizando um conjunto de dados de estresse coletados durante exames, os autores demonstraram o potencial desses sinais na previsão precisa de notas. O estudo conclui que a seleção adequada de características e o uso de modelos apropriados são essenciais para previsões confiáveis, sugerindo implicações práticas significativas para a educação, especialmente no auxílio aos estudantes para gerenciar o estresse e melhorar o desempenho acadêmico.

Adicionalmente, a utilidade de medidas como EDA e sensores de temperatura em contextos de alta pressão, como durante exames, tem sido investigada como forma de fornecer feedback em tempo real aos estudantes. Nesse contexto, Khan et al. (2019) examinaram a relação entre EDA, ST e o desempenho dos estudantes durante exames de engenharia, encontrando correlações moderadamente significativas entre EDA, índice de dificuldade e ST. Esses resultados indicam que o desempenho dos estudantes pode estar intimamente relacionado às respostas fisiológicas durante a realização de exames, sugerindo uma interconexão entre emoções e cognição mediada pela fisiologia.

A combinação de medidas fisiológicas com técnicas avançadas de análise de dados abre novas perspectivas para o monitoramento e a melhoria do desempenho acadêmico. Um exemplo disso é o estudo conduzido por Quintero e Bolkhovsky (2019), que utilizou variabilidade da frequência cardíaca (HRV) e EDA para identificar tarefas cognitivas com base em reações

autônomicas. Utilizando quatro modelos de aprendizado de máquina (ML): k-vizinho mais próximo (KNN), máquinas de vetor de suporte (SVM), Árvore de Decisão (DT) e análise discriminante, os pesquisadores verificaram que os modelos KNN e SVM linear foram os mais precisos, com taxas de acurácia de 66% e 62%, respectivamente. Esses resultados sugerem que é possível identificar a tarefa realizada por um indivíduo com base em suas reações fisiológicas, indicando o potencial dessas medidas para monitorar e melhorar o desempenho em ambientes de trabalho e estudo.

Em conformidade com os princípios da Agenda 2030 e com o objetivo de promover uma educação de qualidade, esta pesquisa busca explorar uma questão central: de que maneira as variações na EDA, HR e ST de estudantes universitários se correlacionam em diferentes contextos educacionais? E como as técnicas de ML podem ser aplicadas para analisar e prever de forma eficiente essas correlações em ambientes educacionais diversificados?

Deste modo, a presente investigação pretende aprofundar a compreensão sobre a inter-relação entre sinais fisiológicos e diferentes métodos de ensino, utilizando técnicas avançadas de análise de dados para formular recomendações aplicáveis em ambientes educacionais.

1.2 JUSTIFICATIVAS

Para justificar esta pesquisa, foi realizada uma análise bibliométrica abrangente sobre o tema em questão. A bibliometria é uma ferramenta quantitativa essencial para analisar a produção científica e identificar tendências em diversas áreas do conhecimento. Suas características principais incluem a análise de citações, que mapeia a interconectividade entre pesquisas e ajuda a identificar os trabalhos e autores mais influentes em um campo específico. Além disso, utiliza indicadores como o fator de impacto, índice h e a contagem de citações por artigo para avaliar a relevância e influência das publicações e pesquisadores (DONTHU et al., 2021; COBO et al., 2011).

A bibliometria envolve procedimentos de análise de desempenho e mapeamento científico. A análise de desempenho avalia a produtividade e impacto de diferentes itens científicos, como artigos, autores, instituições e países, com base em dados de publicações e citações. Já o mapeamento científico revela a estrutura intelectual, social e conceitual de um campo de pesquisa, identificando redes de colaboração e dinâmicas evolutivas (COBO et al., 2011; ZUPIC e CATER, 2015).

Sendo assim, na análise bibliométrica, foram utilizadas palavras-chave selecionadas para o mapeamento, incluindo termos como "*education*", "*electrodermal activity*", "*heart rate*",

"*machine learning*", "*neuroscience*" e "*skin temperature*". O período de análise foi delimitado entre 2021 e 2024, abrangendo um período recente e relevante para capturar as tendências atuais e avanços recentes no campo. Para a coleta de dados relevantes, foram utilizadas as bases de dados *Elsevier* e *PubMed*. As análises realizadas permitiram identificar a evolução do interesse acadêmico pelo tema, bem como as principais contribuições e lacunas existentes na literatura, apresentadas nas Tabelas 1 e 2.

Tabela 1 - Pesquisa bibliográfica na base Elsevier

Palavras-chave	Quantidade
<i>electrodermal activity</i>	1.479
<i>neuroscience</i>	83.118
<i>skin temperature</i>	144.798
<i>machine learning</i>	239.596
<i>heart rate</i>	257.414
<i>education</i>	525.155

Fonte: Elaborado pelo autor (2025).

Tabela 2 - Pesquisa bibliográfica na base PubMed

Palavras-chave	Quantidade
<i>electrodermal activity</i>	646
<i>skin temperature</i>	4.810
<i>heart rate</i>	55.263
<i>machine learning</i>	101.202
<i>Neuroscience</i>	185.440
<i>education</i>	663.293

Fonte: Elaborado pelo autor (2025).

Na busca por artigos específicos relacionados ao tema, houve a interseção das palavras-chave "*electrodermal activity*", "*heart rate*", "*machine learning*", "*neuroscience*" e "*skin temperature*" com a expressão "*education*" na base de dados *Elsevier*, conforme detalhado na Tabela 3. Essa mesma interseção foi realizada na base de dados *PubMed*, conforme explicitado na Tabela 4.

Tabela 3 - Pesquisa bibliográfica com uma interseção na base Elsevier

Palavras-chave	Quantidade
<i>education AND electrodermal activity</i>	476
<i>education AND neuroscience</i>	18.756
<i>education AND skin temperature</i>	20.497
<i>education AND machine learning</i>	44.896
<i>education AND heart rate</i>	57.812

Fonte: Elaborado pelo autor (2025).

Tabela 4 - Pesquisa bibliográfica com uma interseção na base PubMed

Palavras-chave	Quantidade
<i>education AND electrodermal activity</i>	77
<i>education AND skin temperature</i>	571
<i>education AND heart rate</i>	6.416
<i>education AND machine learning</i>	8.804
<i>education AND neuroscience</i>	22.735

Fonte: Elaborado pelo autor (2025).

Para investigar artigos específicos sobre neurociência aplicada à educação, as palavras-chave foram combinadas com as expressões "*education*" e "*neuroscience*" nas bases de dados *Elsevier* e *PubMed*, conforme detalhado nas Tabelas 5 e 6, respectivamente.

Tabela 5 - Pesquisa bibliográfica com duas interseções na base Elsevier

Palavras-chave	Quantidade
<i>education AND neuroscience AND electrodermal activity</i>	131
<i>education AND neuroscience AND skin temperature</i>	668
<i>education AND neuroscience AND machine learning</i>	2.419
<i>education AND neuroscience AND heart rate</i>	3.080

Fonte: Elaborado pelo autor (2025).

Tabela 6 - Pesquisa bibliográfica com duas interseções na base PubMed

Palavras-chave	Quantidade
<i>education AND neuroscience AND skin temperature</i>	12
<i>education AND neuroscience AND electrodermal activity</i>	18
<i>education AND neuroscience AND heart rate</i>	313
<i>education AND neuroscience AND machine learning</i>	520

Fonte: Elaborado pelo autor (2025).

Para ressaltar o ineditismo da questão de pesquisa deste trabalho, houve a interseção de todas as palavras-chave mencionadas nas bases de dados *Elsevier* e *PubMed*, conforme detalhado nas Tabelas 7 e 8, respectivamente.

Tabela 7 - Pesquisa bibliográfica com cinco interseções na base Elsevier

Palavras-chave	Quantidade
<i>education AND neuroscience AND electrodermal activity AND heart rate AND machine learning AND skin temperature</i>	24

Fonte: Elaborado pelo autor (2025).

Tabela 8 - Pesquisa bibliográfica com três interseções na base PubMed


Palavras-chave	Quantidade
<i>education AND neuroscience AND electrodermal activity AND heart rate AND machine learning AND skin temperature</i>	1

Fonte: Elaborado pelo autor (2025).

Esta análise bibliométrica responde a uma lacuna evidente de estudos empíricos disponíveis sobre o tema em questão. Tal cenário destaca a necessidade de uma análise mais aprofundada para ampliar o escopo de dados quantitativos, visando a uma compreensão mais abrangente da temática.


Ferramentas computacionais como *VOSviewer* e *Gephi* são frequentemente utilizadas para a visualização de redes de colaboração, facilitando a compreensão das relações entre autores e temas de pesquisa. Além disso, métodos emergentes como *altmetria* e *webmetria* complementam a bibliometria tradicional ao analisar o impacto de conteúdos web e metadados não tradicionais, como alcance em redes sociais (Maggio et al., 2021). Deste modo, para complementar a análise bibliométrica, utilizou-se o software *VOSviewer* para a visualização de rede dos termos "*electrodermal activity*", "*heart rate*", "*machine learning*" e "*skin temperature*", combinados com o termo "*education*" e limitado à área de "*neuroscience*" na base de dados *Scopus*. O número de citações das palavras-chave é ilustrado pelo tamanho dos nós, e o número de ocorrências das palavras-chave é representado pela espessura dos arcos, conforme ilustrado nas Figuras 1 a 4.

Figura 1 - Visualização em rede dos termos “electrodermal activity” e “education”



Fonte: Elaborado pelo autor (2025), utilizando o software VOSviewer.

Figura 4 - Visualização em rede dos termos “machine learning” e “education”



Fonte: Elaborado pelo autor (2025), utilizando o software VOSviewer.

A análise das figuras revela diferentes áreas, evidenciados pela centralidade de termos específicos em cada uma delas. Na Figura 1, observa-se que os termos centrais incluem "*humans*", "*female*", "*male*", "*electrodermal response*" e "*galvanic skin response*". Isso sugere uma concentração de estudos voltados para respostas fisiológicas, como a resposta galvânica da pele e a resposta eletrodérmica, com uma distinção de gênero, isto é, "*male*" e "*female*". Já na Figura 2, os termos centrais são "*humans*", "*female*", "*male*" e "*heart rate*", indicando um enfoque em estudos clínicos e fisiológicos, especialmente relacionados à saúde e atividades físicas. Ademais, o cluster verde parece estar mais associado a pesquisas sobre fatores de risco e condições médicas, incluindo "*hypertension*" e "*blood pressure*".

Na Figura 3, identifica-se novamente uma rede com termos centrais como "*humans*", "*male*", "*female*", "*controlled study*" e "*skin temperature*". Este gráfico, por sua vez, parece direcionar-se a estudos controlados que envolvem a fisiologia humana, especificamente a ST, e sua relação com a educação física. Além disso, o cluster azul pode representar um subgrupo de pesquisas focadas em educação e aprendizado. Na Figura 4, o termo "*machine learning*" se destaca como central, conectado a "*humans*", "*controlled study*", "*education*" e "*cognition*". Essa rede sugere um claro foco nas interações entre ML a e estudos de fisiologia humana, bem como em aprendizagem e cognição. O cluster verde, fortemente ligado a termos como "*machine*

learning", "*deep learning*" e "*artificial intelligence*", sugere uma interseção entre esses campos e a educação.

As redes apresentadas nas figuras evidenciam a interconexão entre estudos clínicos e fisiológicos com aplicações em ML, gênero e educação. Os clusters coloridos indicam agrupamentos temáticos focados em diferentes áreas de pesquisa, como fisiologia, ML, educação e saúde. A interconexão de termos como "*machine learning*", "*education*", e "*human physiology*" ressalta o forte componente interdisciplinar presente nos estudos analisados.

Compreender o cenário contemporâneo e identificar como as inovações tecnológicas podem ser aplicadas para atender às demandas do ensino é uma tarefa essencial. Conforme apontado por González-Díez et al. (2024), a integração de registros multicanais no ensino superior ainda enfrenta limitações, sobretudo devido à complexidade envolvida na análise dos dados. No entanto, a utilização combinada de dispositivos neurofisiológicos, como rastreamento ocular, eletroencefalografia (EEG) e atividade eletrodérmica (EDA), desponta como uma metodologia promissora para a compreensão dos processos cognitivos durante a aprendizagem, em diferentes contextos educacionais.

Complementarmente, Cheaha et al. (2024) ressaltam que atividades pedagógicas baseadas em projetos de pesquisa oferecem contextos ricos para investigar como diferentes demandas cognitivas se refletem em respostas neurofisiológicas. Nesses cenários, foram observadas associações significativas entre padrões de atividade cerebral, como beta e gama no córtex temporal, teta frontal em tarefas aritméticas e delta temporal em processos de biofeedback, e o desenvolvimento de habilidades como inteligência fluida, aprendizado matemático e autocontrole cognitivo. Outro aspecto relevante diz respeito às condições ambientais, que também podem influenciar a aprendizagem ao interagir com os processos fisiológicos dos estudantes. Zohdi et al. (2024) enfatizam a importância de investigar, por exemplo, os efeitos da exposição à luz colorida na fisiologia humana, uma variável cotidiana ainda pouco explorada. Embora não tenham sido identificadas diferenças significativas no desempenho cognitivo sob luz vermelha ou azul, os resultados sugerem que o histórico e a sequência de exposição impactam as respostas fisiológicas e cerebrais.

De forma complementar, a literatura educacional tem destacado que não apenas fatores ambientais, mas também emocionais exercem papel fundamental na aquisição e retenção do conhecimento. Eliot e Hirumi (2019) realizaram uma análise interdisciplinar das principais teorias das emoções aplicadas à educação, comparando modelos multidimensionais da psicologia educacional com abordagens de emoções básicas, derivadas das ciências neurobiológicas e cognitivas. A partir dessa comparação, os autores defendem o uso ampliado

de medidas fisiológicas e da análise da linguagem emocional espontânea, como forma de aumentar a validade e a confiabilidade das pesquisas sobre a relação entre emoção e aprendizagem.

Dando continuidade a essa discussão, Schneider et al. (2020) exploraram a sincronia fisiológica como uma possível ferramenta para avaliar a aprendizagem colaborativa, investigando a relação entre diferentes medidas de sincronia e o desempenho em tarefas de programação. Utilizando dados de EDA de participantes inexperientes em programação, os pesquisadores analisaram quatro medidas de sincronia: Correspondência de Sinais (SM), Correspondência de Derivadas Instantâneas (IDM), Acordo Direcional (DA) e Correlação de Pearson (PC). Os resultados revelaram que a PC estava positivamente associada aos ganhos de aprendizagem, $r = 0,35$, enquanto o DA correlacionou-se com a qualidade da colaboração, $r = 0,3$. Esses achados sugerem que diferentes aspectos da sincronia fisiológica podem refletir distintas dimensões da interação colaborativa, evidenciando o potencial dessas medidas como indicadores para a avaliação da qualidade da colaboração e dos resultados educacionais.

No contexto dos ambientes de Aprendizagem Baseados em Tecnologia (TBLEs), Loderer et al. (2020) conduziram uma revisão sistemática sobre o papel das emoções, utilizando a teoria do controle-valor como estrutura teórica. Os achados indicam que emoções positivas, como prazer e curiosidade, estão intimamente ligadas a avaliações positivas de controle e valor, ao passo que emoções negativas, como ansiedade e frustração, se associam a avaliações negativas. Essas emoções exercem influência direta sobre o engajamento dos estudantes, o uso de estratégias de aprendizagem e o desempenho acadêmico. Assim, os autores concluem que é imprescindível o desenvolvimento de TBLEs que promovam emoções positivas, visando otimizar a aprendizagem e o desempenho dos estudantes.

Thammasan et al. (2020) investigaram a viabilidade de monitorar sinais fisiológicos, como EDA e HR, em ambientes educacionais utilizando sensores vestíveis. Os resultados apontaram para a viabilidade do monitoramento em ambientes escolares, apesar dos desafios inerentes, como sinais inválidos devido ao mau posicionamento dos sensores e ruídos de quantização. O estudo também enfatiza a importância do uso de ferramentas automáticas de pré-processamento de sinais, alertando para os riscos de se ignorar as diferenças entre dispositivos e contextos de medição, o que pode levar a interpretações equivocadas. A implementação das etapas de pré-processamento sugeridas pelos autores resultou em uma maior clareza dos sinais fisiológicos coletados durante as aulas, ressaltando a necessidade de um processamento rigoroso para evitar interpretações errôneas.

Em síntese, a integração das dimensões emocionais e fisiológicas no contexto educacional emerge como um fator essencial para o desenvolvimento de práticas pedagógicas mais eficazes e personalizadas. As evidências trazidas pelos estudos reforçam a necessidade de considerar esses aspectos na concepção de ambientes de aprendizagem, indicando a importância de uma abordagem educacional holística e multimodal, capaz de atender às necessidades individuais dos estudantes de maneira mais precisa e abrangente.

Apesar desses avanços, observa-se uma lacuna significativa quando o foco recai sobre a educação em engenharia. Estudos têm demonstrado o potencial da EDA, da HR e da ST como indicadores de engajamento, mas ainda são escassas as pesquisas que investigam sistematicamente a relação desses sinais com diferentes metodologias de ensino. Além disso, a aplicação de técnicas de aprendizado de máquina para analisar e prever padrões de engajamento em ambientes educacionais permanece incipiente, sobretudo em contextos brasileiros. Assim, este estudo se justifica pela necessidade de preencher tais lacunas, oferecendo evidências empíricas que orientem práticas pedagógicas mais eficazes e fundamentadas, contribuindo para o avanço da neurociência aplicada à educação e para a formação de engenheiros mais engajados e preparados para os desafios contemporâneos.

O ineditismo deste trabalho reside na integração inédita de sinais fisiológicos, EDA, HR e ST, com técnicas avançadas de aprendizado de máquina aplicadas especificamente ao contexto da educação em engenharia. Embora existam estudos internacionais que exploram individualmente alguns desses marcadores, ainda são escassas as investigações que os analisam de forma combinada em ambientes educacionais reais e, sobretudo, em turmas de engenharia no cenário brasileiro. Assim, a presente pesquisa contribui de maneira original ao propor e validar modelos preditivos capazes de identificar padrões objetivos de engajamento estudantil, ampliando as possibilidades de inovação pedagógica por meio do uso de biossensores e inteligência artificial no ensino superior.

1.3 OBJETIVOS

1.3.1 Objetivo geral

O objetivo geral desta pesquisa é verificar se sinais fisiológicos, EDA, HR e ST, podem ser utilizados como marcadores objetivos de engajamento estudantil. Para isso, buscou-se investigar as correlações dessas variáveis em distintos contextos educacionais e, com base

nesses achados, desenvolver e validar modelos preditivos com algoritmos de aprendizado de máquina, capazes de antecipar padrões fisiológicos associados ao engajamento.

1.3.2 Objetivos específicos

- Avaliar como as variáveis fisiológicas EDA, HR e ST se comportam em diferentes atividades educacionais, identificando padrões de variação e sua relação com o engajamento acadêmico.
- Utilizar algoritmos de ML para desenvolver modelos preditivos, validando sua eficácia na antecipação de respostas fisiológicas em distintos contextos educacionais.
- Investigar de que modo diferentes abordagens pedagógicas influenciam as respostas fisiológicas dos estudantes e se essas variações estão associadas a diferentes níveis de engajamento.

1.4 APRESENTAÇÃO DO TRABALHO

O presente estudo está organizado em seis capítulos, cada um estruturado para fornecer uma compreensão abrangente do estudo realizado. O primeiro capítulo introduz o tema central da pesquisa, destacando a importância e relevância do estudo, bem como seus objetivos e hipóteses principais.

O segundo capítulo realiza uma revisão da literatura que fundamenta a pesquisa. São abordados temas essenciais, como EDA, HR, ST e ML, estabelecendo o contexto teórico necessário para o entendimento do estudo.

O terceiro capítulo detalha os materiais e métodos empregados na pesquisa. Descreve-se o método utilizado para explorar as correlações entre as variações na EDA, HR e ST de estudantes universitários, incluindo a aplicação de técnicas de ML para análise e predição dos dados.

No quarto capítulo, são apresentados e discutidos os resultados obtidos. A análise interpretativa dos dados coletados em diferentes contextos educacionais é realizada, fornecendo insights sobre o comportamento dos sinais neurofisiológicos estudados.

O quinto capítulo aborda as conclusões do estudo, destacando as implicações teóricas e práticas dos achados. Além disso, são propostas sugestões para futuras investigações neste campo de estudo, apontando possíveis direções para pesquisas futuras.

Por fim, o sexto capítulo lista todas as referências bibliográficas consultadas ao longo da pesquisa. As referências são organizadas em ordem alfabética e seguem as diretrizes da norma ABNT NBR 6023:2018.

2 REVISÃO DA LITERATURA

A compreensão dos processos cerebrais relacionados ao processamento de informações é um aspecto essencial para a otimização dos métodos de ensino e aprendizagem no contexto educacional. O alinhamento das estratégias pedagógicas com os princípios neurocientíficos que sustentam o aprendizado tem sido amplamente discutido na literatura. De acordo com Sánchez-Carracedo et al. (2021), a eficácia das aulas pode ser significativamente aprimorada por meio da aplicação de estratégias baseadas em descobertas da neurociência. Essas estratégias enfatizam a necessidade de motivar e manter a atenção dos estudantes, além de facilitar a memorização dos conceitos, demonstrando assim uma relação direta entre a neurociência e a pedagogia.

No campo específico da neurociência, há uma crescente evidência de que os indivíduos possuem estilos e preferências de aprendizagem distintos, o que exige abordagens pedagógicas diversificadas. Ghannam et al. (2020) realizaram uma revisão dos programas de pós-graduação em neuroengenharia, com foco em tecnologias implantáveis e vestíveis. Eles identificaram quatro áreas essenciais para a formação, Neurociência, Circuitos Integrados, Comunicação e Processamento de Sinais e Dispositivos Eletrônicos, categorizadas como áreas NICE. O estudo sugere a necessidade de métodos de ensino inovadores para preparar melhor os estudantes para um mercado de trabalho em constante evolução, evidenciando a importância da personalização e inovação nas estratégias de ensino.

Além disso, a literatura destaca a eficácia de envolver os estudantes em atividades práticas e desafiadoras, como parte integrante do processo de aprendizagem, com respaldo em evidências neurocientíficas. A revisão sistemática conduzida por Darvishi et al. (2022) sobre o uso de medições neurofisiológicas no ensino superior traz à tona a relevância dessas medições no desenvolvimento de tecnologias educacionais que visam melhorar as práticas de ensino e aprendizagem. Todavia, a revisão também aponta uma lacuna significativa: embora muitas dessas medições monitorem o estado dos estudantes, poucas fornecem feedback ou se adaptam às necessidades individuais, contrastando com as abordagens adotadas em ambientes clínicos.

O Quadro 1 apresenta um resumo de estudos que investigaram o uso de medidas fisiológicas, como a EDA, HR e ST, em contextos educacionais. Esses estudos abrangem uma variedade de cenários experimentais, desde salas de aula tradicionais até ambientes de ensino à distância, destacando o potencial dessas métricas para o monitoramento de engajamento, estresse e estados emocionais. A síntese apresentada na tabela inclui informações sobre os

participantes, condições experimentais e principais resultados, fornecendo insights tanto sobre as aplicações práticas quanto sobre as limitações das tecnologias de monitoramento fisiológico.

Quadro 1 - Estudos sobre EDA, HR e ST no contexto educacional

Referências	Títulos	Participantes / Condições	Resultados
Abromavičius et al. (2023)	Prediction of exam scores using a multi-sensor approach for wearable exam stress dataset with uniform preprocessing	10 estudantes de graduação / Estresse em três exames	Os sinais fisiológicos (EDA, HR e ST) demonstraram elevado potencial preditivo para o desempenho em exames. O modelo alcançou acurácia de 0,90, indicando que 90% das previsões foram corretas. A área sob a curva ROC (AUROC) foi de 0,89, refletindo uma excelente capacidade de distinguir entre diferentes níveis de desempenho. Além disso, o F1-score foi de 0,87, valor que representa o equilíbrio entre precisão e revocação na classificação dos resultados.
Al-Awani (2016)	A Combined Approach to Improve Supervised E-Learning using Multi-Sensor Student Engagement Analysis	20 estudantes / Sessões de e-learning	Análise de correlação entre EDA, HR e expressões faciais revelou potencial significativo para medir engajamento.
Cain e Lee (2016)	Measuring electrodermal activity to capture engagement in an afterschool maker program	2 jovens / Atividades práticas em um makerspace	Dados de EDA indicaram maior engajamento durante atividades interativas, como apresentações, e variação de engajamento em tarefas individuais.
Darnell e Krieg (2019)	Student Engagement Assessed Using Heart Rate Shows No Reset Following Active Learning Sessions in Lectures	15 estudantes / Sessões de aprendizagem ativa em sala de aula	A HR aumentou durante atividades de aprendizagem ativa, mas retornou à linha de base imediatamente após as atividades, destacadas.

(continua)

Quadro 1 - Estudos sobre EDA, HR e ST no contexto educacional

(continuação)

Referências	Títulos	Participantes / Condições	Resultados
Lu et al. (2017)	A Framework for Learning Analytics Using Commodity Wearable Devices	24 participantes / Estresse acadêmico e atividade física	O framework LEARNSense, que integrou os sinais fisiológicos EDA, HR e ST, alcançou um F1-score de 0,9 na classificação dos estados de engajamento. Esse resultado indica um excelente equilíbrio entre precisão e revocação, já que o F1-score é a média harmônica dessas duas métricas, sendo especialmente útil em contextos com possíveis desequilíbrios entre classes.
Nourbakhsh et al. (2012)	Using galvanic skin response for cognitive load measurement in arithmetic and reading tasks	25 participantes / Tarefas de leitura e aritmética de diferentes dificuldades	Análise espectral de GSR mostrou alta relevância para mensuração da carga cognitiva após normalização.
Pérez et al. (2018)	Evaluation of Commercial-Off-The-Shelf Wrist Wearables to Estimate Stress on Students	12 estudantes universitários / Tarefas laboratoriais e atividades em sala de aula	Wearables comerciais demonstraram eficácia na coleta de dados fisiológicos (HR, HRV, ST) para análise de estresse acadêmico.
Pijera-Díaz et al. (2018)	Profiling sympathetic arousal in a physics course how active are students	24 estudantes / Curso de física avançada e exame final	Arousal medido por EDA correlacionou-se positivamente com desempenho acadêmico ($r = 0,66$).
Quintero e Bolkhovsky (2019)	Machine learning models for the identification of cognitive tasks using autonomic reactions from heart rate variability and electrodermal activity	16 participantes / Tarefas cognitivas de vigilância e memória	Índices de EDA e HRV permitiram identificação de tarefas cognitivas com precisão de até 66% usando modelos como KNN e SVM.
Rodríguez-Arce et al. (2020)	Towards an Anxiety and Stress Recognition System for Academic Environments	21 estudantes universitários / Tarefas acadêmicas estressantes e autorrelatos	Detecção de estresse com 90% de precisão usando k-NN e dados de HR, temperatura da pele e oximetria. Reconhecimento de ansiedade atingiu 95% de precisão com SVM usando GSR.

(continua)

Quadro 1 - Estudos sobre EDA, HR e ST no contexto educacional
(conclusão)

Referências	Títulos	Participantes / Condições	Resultados
Schneider et al. (2020)	Unpacking the relationship between existing and new measures of physiological synchrony and collaborative learning: a mixed methods study	42 pares (84 indivíduos) / Tarefas colaborativas envolvendo programação	Sincronia fisiológica medida por EDA correlacionou-se com ganhos de aprendizado ($r = 0,35$) e qualidade da colaboração ($r = 0,3$). Novo índice baseado em ciclos de EDA melhorou correlações ($r = 0,57$).
Terriault et al. (2021)	Use of electrodermal wristbands to measure students' cognitive engagement in the classroom	8 participantes (7 estudantes e 1 professor) / Aulas, oficinas e exames	Dados de EDA revelaram padrões de engajamento, mas fatores externos, como atividade física e temperatura ambiente, prejudicaram a consistência dos dados.
Thammasan et al. (2020)	A Usability Study of Physiological Measurement in School Using Wearable Sensors	86 adolescentes / Atividades acadêmicas diárias	Demonstrou a viabilidade de medir EDA e HR em escolas, enfrentando desafios de qualidade e processamento de dados.

Fonte: Goussain et al. (2025).

Os estudos apresentados na Quadro 1 ressaltam a versatilidade e a eficácia das medidas fisiológicas na melhoria das práticas educacionais. Resultados indicam que a EDA se destaca como um indicador confiável de engajamento estudantil, conforme demonstrado por Di Lascio et al. (2018), alcançando taxas de acurácia de detecção de engajamento de até 81% por meio de modelos de ML. De forma complementar, a HR e a ST também foram validadas como métricas auxiliares, particularmente em contextos acadêmicos que induzem estresse, como observado por Pérez et al. (2018), cujos resultados destacaram a alta precisão na estimativa de níveis de estresse.

Uma tendência nos estudos é o aumento do uso de abordagens multimodais que integram EDA, HR e ST para obter insights mais robustos. Por exemplo, Rodríguez-Arce et al. (2020) alcançaram uma acurácia de 90% na detecção de estresse ao combinar essas métricas, evidenciando o potencial sinérgico dos dados multimodais para compreender respostas fisiológicas complexas durante tarefas acadêmicas. Além disso, as aplicações de ML, como as observadas no estudo de Gao et al. (2020), ampliaram ainda mais o poder preditivo dessas medidas, permitindo o monitoramento em tempo real do engajamento e das emoções com alta precisão.

Apesar destes resultados, os achados também destacam desafios importantes. Fatores externos, como condições ambientais e atividade física, podem comprometer a confiabilidade das medições de HR e ST, conforme apontado por Terriault et al. (2021). Além disso, o tamanho limitado de amostras em alguns estudos, como o de Cain e Lee (2016), restringe a generalização dos resultados, evidenciando a necessidade de investigações em maior escala. Questões éticas relacionadas ao uso de dispositivos vestíveis em ambientes educacionais também requerem maior atenção, especialmente para garantir a privacidade dos estudantes e a segurança dos dados.

Em suma, a aplicação de princípios neurocientíficos à educação possui o potencial de gerar melhorias significativas nos métodos de ensino e aprendizagem. A integração de estratégias pedagógicas baseadas na neurociência, o uso de metodologias multimodais e a adoção de tecnologias educacionais avançadas emergem como elementos essenciais para a construção de ambientes de aprendizagem mais eficazes e inclusivos.

2.1 ATIVIDADE ELETRODÉRMICA

A EDA é um sinal fisiológico amplamente utilizado como indicador da atividade do sistema nervoso autônomo (SNA), em especial de sua divisão simpática. O SNA é responsável por regular funções involuntárias do organismo, como frequência cardíaca, respiração e secreção glandular, e divide-se em duas partes principais: o sistema nervoso simpático e o parassimpático. O simpático está diretamente associado às respostas de ativação e mobilização do corpo diante de estímulos internos ou externos, o chamado mecanismo de “luta ou fuga”, enquanto o parassimpático atua na recuperação e na conservação de energia. No caso da EDA, a ativação simpática provoca a estimulação das glândulas sudoríparas écrinas, especialmente nas palmas das mãos e plantas dos pés, resultando em variações na condutância elétrica da pele que podem ser mensuradas em microsiemens (μS).

A mensuração da EDA é realizada por meio de sensores específicos, geralmente compostos por eletrodos de prata/cloreto de prata (Ag/AgCl), posicionados na superfície da pele. Esses eletrodos captam mudanças na condutância elétrica geradas pela secreção de suor e transmitem os dados a dispositivos de registro, que podem variar de equipamentos laboratoriais de alta precisão a dispositivos vestíveis de baixo custo. Entre os mais utilizados estão pulseiras inteligentes (ex.: Empatica E4), sensores integrados a sistemas de biofeedback e unidades de aquisição de dados fisiológicos (ex.: Biopac). Esses equipamentos permitem tanto a coleta

contínua em condições controladas quanto a avaliação em ambientes naturais de aprendizagem, viabilizando o estudo da relação entre estados fisiológicos e engajamento acadêmico.

2.1.1 EDA na educação e engajamento de estudantes

A integração de sensores de EDA na análise da carga cognitiva e das funções cognitivas em contextos educacionais tem se apresentado uma abordagem promissora, como demonstrado no estudo de Reid et al. (2020). A pesquisa combinou dados quantitativos obtidos através de EDA com dados qualitativos relacionados ao comportamento dos estudantes, oferecendo, assim, uma análise detalhada das experiências de aprendizagem. Por meio de um software de mapeamento temporal desenvolvido para marcar eventos-chave durante a realização das tarefas, os pesquisadores observaram que a convergência dos dados de EDA e comportamento permite insights sobre os fatores que influenciam o desempenho acadêmico.

No que tange ao monitoramento do engajamento emocional dos estudantes em sala de aula, o estudo de Di Lascio et al. (2018) investigou a viabilidade do uso de sensores de EDA integrados em dispositivos vestíveis. Utilizando dados coletados de 24 estudantes, 9 professores e 41 aulas, os autores aplicaram técnicas de mineração de dados para identificar padrões de engajamento e desengajamento, alcançando um recall de 81% com SVM. Além da distinção entre estudantes engajados e não engajados, os resultados também sugerem que a EDA pode captar situações de hiperativação simpática, nas quais a excitação fisiológica excessiva se aproxima do estresse, indicando que tanto a baixa quanto a alta ativação podem impactar negativamente o processo de aprendizagem.

Villanueva et al. (2018), em um estudo exploratório, utilizaram abordagens multimodais para investigar o envolvimento de estudantes de engenharia durante atividades de design, medindo tanto emoções quanto EDA. O estudo incluiu 88 estudantes, que responderam a questionários sobre emoções antes e depois de participarem de cinco diferentes atividades de design, enquanto um subconjunto de 14 a 18 estudantes utilizou sensores de EDA. Os resultados indicaram um aumento da EDA durante atividades de aprendizagem ativa, tanto individuais quanto colaborativas, em comparação com aulas expositivas. Contudo, não foram observadas diferenças significativas entre as atividades individuais e colaborativas. Ademais, verificou-se uma correlação negativa entre EDA e emoções negativas apenas na primeira atividade, sugerindo que as atividades de aprendizagem ativa contribuem para um maior envolvimento dos estudantes.

Dando continuidade ao estudo do engajamento em sala de aula, Potter et al. (2019) analisaram a EDA como métrica para medir o engajamento dos estudantes, com a premissa de que estudantes mais engajados aprendem melhor. Experimentos preliminares realizados em dois cursos de engenharia industrial utilizaram dispositivos de medição de EDA, como o Empatica E4. Os resultados iniciais demonstraram a possibilidade de correlacionar atividades e métodos de ensino com o nível de engajamento dos estudantes. Além disso, foi observado que fatores externos, como movimento, temperatura sazonal e mudanças abruptas de humor, podem influenciar a EDA, sugerindo que essa métrica pode ser uma ferramenta útil para educadores ao buscar formas de aumentar o engajamento e, conseqüentemente, a aprendizagem em sala de aula.

No contexto do ensino médio, Pijera-Díaz et al. (2018) investigaram os níveis de ativação simpática de estudantes em um curso avançado de física, medindo a EDA com o uso de pulseiras Empatica E4. O estudo revelou que estados de baixa ativação, como o tédio, predominavam em 60% das aulas e apresentavam alta persistência. Embora a correlação entre a ativação durante as aulas e o desempenho acadêmico tenha sido baixa, uma correlação positiva e significativa foi encontrada entre a ativação durante os exames e as notas dos estudantes, $r = 0,66$. Esses achados sugerem que estados de baixa ativação pode ser comuns e prejudiciais ao aprendizado, destacando a necessidade de estratégias pedagógicas que visem aumentar a ativação dos estudantes para melhorar seu desempenho acadêmico.

Avançando na aplicação de sensores de EDA para mensuração do engajamento cognitivo em sala de aula, Terriault et al. (2021) realizaram um projeto piloto que explorou a viabilidade do uso desses sensores, embutidos em dispositivos similares a relógios, para medir a condutividade da pele em tempo real. Durante as aulas, oficinas e exames, tanto os estudantes quanto o professor utilizaram a pulseira Empatica E4, permitindo a comparação dos dados. Apesar do potencial da tecnologia, os resultados mostraram-se desafiadores de interpretar, uma vez que fatores externos, como movimentação excessiva dos participantes, variações de temperatura ambiente e interferências no posicionamento dos sensores, impactaram as medições e resultaram em discrepâncias significativas.

Por outro lado, Lee et al. (2019) focaram no engajamento momentâneo de jovens em programas de *Makerspace* após a escola, utilizando sensores de EDA e câmeras vestíveis. Em dois programas destinados a adolescentes, foi observada uma correlação moderada entre EDA e respostas de engajamento coletadas em pesquisas diárias. As atividades que enfatizaram a expressão pessoal, a socialização entre pares, a instrução interativa e as atividades físicas de montagem apresentaram-se eficazes para promover altos níveis de engajamento. Além disso,

momentos específicos de alto engajamento foram identificados quando houve respostas simultâneas de vários participantes, sugerindo que o ambiente e a dinâmica das atividades desempenham um papel essencial no envolvimento dos jovens.

No domínio do ensino à distância, Al-Alwani (2016) investigou o aprimoramento do ensino supervisionado à distância através da análise do engajamento dos estudantes com múltiplos sensores, incluindo reconhecimento facial, EDA e taxa de pulso. Os resultados apresentaram uma correlação significativa entre essas três modalidades de medição, sugerindo que elas podem ser utilizadas de maneira combinada para avaliar o nível de engajamento dos estudantes.

Cain e Lee (2016) exploraram a aplicação da EDA como uma métrica para medir o engajamento de jovens em atividades de programas *maker* após o horário escolar. Utilizando sensores de pulso para EDA e câmeras de ponto de vista em primeira pessoa, os pesquisadores correlacionaram os picos na condutividade da pele com momentos de envolvimento nas atividades. Os resultados indicaram que os participantes apresentaram tanto engajamentos compartilhados quanto divergentes em atividades como soldagem, montagem e programação.

O estudo de Villanueva et al. (2019) investigou a relação entre identidade e respostas psicofisiológicas em mentoria acadêmica, utilizando uma abordagem interseccional que combinou métodos qualitativos e quantitativos. Os resultados indicaram que diferentes identidades, como a institucional, discursiva e social, influenciam significativamente as respostas de EDA dos participantes, com interações entre identidade institucional e discursiva apresentando uma influência cooperativa.

2.1.2 EDA em estudos de estresse e saúde

A EDA tem sido amplamente utilizada em estudos que investigam o estresse e a saúde, dada sua capacidade de fornecer insights sobre a resposta emocional e fisiológica dos indivíduos. Um exemplo notável dessa aplicação é o estudo de Lui e Du (2018), que propôs um método inovador para a detecção de níveis de estresse psicológico utilizando exclusivamente a EDA como sinal fisiológico. Neste estudo, foram extraídas dezoito características de segmentos de dados de cinco minutos, seguidas pela aplicação de técnicas de projeção de Fisher e análise discriminante linear para classificar os níveis de estresse em três categorias: baixo, médio e alto. Os resultados demonstraram uma taxa de reconhecimento de 81,82%, o que, embora inferior a sistemas que utilizam múltiplos sinais, sugere um equilíbrio promissor entre desempenho e carga computacional.

Em um contexto mais amplo, a revisão conduzida por Sánchez-Reolid et al. (2020) destacou o papel da EDA em conjunto com outras variáveis fisiológicas na detecção do estresse, com ênfase no uso de técnicas de ML. A análise abrangeu tanto a utilização isolada da EDA quanto sua combinação com outros sinais fisiológicos, como pressão do volume sanguíneo (BVP), temperatura (TMP), EEG, entre outros. A revisão concluiu que a EDA é um indicador confiável de variações de excitação, especialmente quando acompanhada de um processo robusto de aquisição e pré-processamento dos sinais. Entre as técnicas de ML avaliadas, as redes neurais artificiais (ANN) e o algoritmo *Adaboost* se destacaram, alcançando até 99,69% de precisão. Mesmo métodos não supervisionados, como o *K-means*, apresentaram bons resultados, com 77,5% de precisão, reforçando a importância de métodos adequados de processamento para o sucesso dessas abordagens.

A aplicação da EDA também se estende ao desenvolvimento de dispositivos práticos para monitoramento emocional, como evidenciado pela pesquisa de Villarejo et al. (2012). Este estudo focou no desenvolvimento de um sensor de estresse baseado na resposta galvânica da pele (GSR), controlado por *ZigBee*. O dispositivo demonstrou ser eficaz na detecção de estados emocionais, com uma taxa de sucesso de 76,56%. No âmbito da segurança viária, o estudo de Malathi et al. (2018) trouxe uma contribuição importante ao desenvolver um dispositivo vestível baseado na EDA para detectar sonolência em motoristas. Este dispositivo visa prevenir acidentes ao monitorar em tempo real os níveis de suor e emitir alertas quando a sonolência é detectada.

Ainda no campo dos dispositivos vestíveis, o estudo de Poh et al. (2010) explorou a viabilidade de um sensor vestível para a avaliação contínua e a longo prazo da EDA. O estudo demonstrou alta correlação entre os resultados obtidos durante estressores físicos, cognitivos e emocionais, validando o uso do antebraço distal como alternativa aos métodos tradicionais de medição. A escolha do material dos eletrodos, especificamente Prata e Cloreto de Prata (Ag/AgCl), foi identificada como superior, o que, juntamente com medições de longo prazo, revelou padrões consistentes de modulação simpática, especialmente durante atividades diárias, como estudar e dormir.

A pesquisa de Domínguez-Jiménez et al. (2020) investigou o reconhecimento de emoções a partir de sinais fisiológicos, utilizando dispositivos vestíveis para captar tanto a fotopletismografia (PPG) quanto a GSR. O estudo aplicou técnicas avançadas de análise em domínios de tempo e frequência, extraíndo características que, após um processo de seleção, resultaram em um modelo de reconhecimento de emoções com precisão de até 100%.

A EDA, assim, se consolida como uma ferramenta versátil e eficaz em estudos de estresse e saúde, sendo empregada em uma variedade de contextos que vão desde a detecção de estresse psicológico até o monitoramento contínuo de estados emocionais. O estudo de Lee et al. (2020), que focou na ansiedade em falantes não nativos de inglês, exemplifica essa aplicação ao demonstrar como a EDA pode ser utilizada para distinguir entre diferentes tipos de ansiedade, como a ansiedade em falar em público (PSA) e a ansiedade em falar uma língua estrangeira (FLA).

2.1.3 Metodologias, aplicações e avaliação de EDA

A análise da atividade simpática utilizando a EDA tem avançado significativamente, como demonstrado na pesquisa conduzida por Quintero et al. (2016b). Nesse estudo, foi explorada a eficácia da análise espectral de tempo-frequência da EDA na medição da atividade simpática. Os resultados indicaram que a análise da densidade espectral de potência da EDA oferece uma medida mais consistente da atividade simpática em comparação com métodos baseados no domínio do tempo. Para alcançar esses resultados, experimentos foram realizados com doze sujeitos que foram submetidos a testes que evocam a dinâmica simpática, como o teste do mergulho frio, inclinação, teste de pé e tarefa de *Stroop*. O desenvolvimento do índice *TVSymp* foi um dos destaques do estudo, apresentando alta sensibilidade às variações simpáticas com maior consistência e menor variação.

Além disso, em um estudo complementar, Quintero et al. (2016a) aprofundaram a análise da densidade espectral de potência (PSD) da EDA como método para avaliação da função simpática. A pesquisa identificou que os componentes de baixa frequência (0,045–0,15 Hz) da PSD da EDA são especialmente relevantes para capturar a dinâmica do sistema nervoso simpático, notadamente sob estímulos ortostáticos, físicos e cognitivos. Nesse contexto, a EDA mostrou-se mais robusta do que as análises tradicionais baseadas em seus próprios componentes, como o nível tônico de condutância da pele (SCL) e a resposta fásica de condutância da pele (SCR). Essa superioridade foi particularmente evidente durante o teste do cold pressor. A introdução da normalização da EDA, denominada *EDASympn*, também contribuiu para maior confiabilidade e sensibilidade na detecção de estímulos simpáticos, sugerindo que a PSD da EDA pode ser uma ferramenta mais precisa para a avaliação do tônus simpático.

Em outra frente, Geršak e Drnovšek (2020) investigaram a aplicação de um simulador de EDA projetado especificamente para testar a funcionalidade e precisão de dispositivos de

medição de EDA. O simulador foi capaz de gerar sinais de resistência elétrica que imitam as ondas fisiológicas típicas da condutância da pele, permitindo uma avaliação metrológica precisa tanto em condições estáticas quanto dinâmicas. O dispositivo destacou-se por sua estabilidade, com um desvio padrão de $0,05\mu\text{S}$, considerado suficiente para a maioria das aplicações de monitoramento de EDA.

Explorando a relação entre EDA e carga cognitiva, a pesquisa de Nourbakhsh et al. (2012) investigou o uso da GSR como indicador dessa carga durante tarefas de aritmética e leitura. Para interpretar os dados, os autores analisaram a resposta galvânica tanto no domínio do tempo quanto no domínio da frequência. O domínio do tempo corresponde às variações da condutância da pele ao longo da própria linha temporal do experimento, permitindo observar diretamente parâmetros como amplitude, duração e tendência acumulada das respostas. Já o domínio da frequência refere-se à decomposição do sinal em diferentes bandas de frequência, o que possibilita identificar oscilações relacionadas a estados fisiológicos específicos.

Após a normalização para remover variações individuais, os resultados mostraram que, no domínio do tempo, a soma acumulativa do GSR foi mais eficaz do que a média simples para indicar aumento de carga cognitiva. No domínio da frequência, a análise do espectro de potência, tanto em tarefas completas quanto em segmentos menores, diferenciou significativamente os níveis de dificuldade, reforçando a utilidade das duas abordagens para monitorar o esforço mental.

A pesquisa de Sharma et al. (2019) propôs um algoritmo de ML para o reconhecimento de padrões emocionais durante estímulos audiovisuais, utilizando a EDA. A análise incluiu várias características do sinal, como domínio do tempo, frequência e *wavelet*, com resultados que demonstraram a superioridade das características de *wavelet* em relação às características convencionais de domínio do tempo em termos de precisão de classificação. A configuração de rede mais eficaz atingiu uma precisão de 79% para excitação, 69,8% para valência e 71,2% para dominância, utilizando o algoritmo de *Levenberg-Marquardt* e a função de MSE.

A medição da EDA tem se apresentado um instrumento essencial na superação das limitações inerentes aos autorrelatos emocionais, conforme evidenciado por Caruelle et al. (2019). Em estudos voltados para a compreensão das respostas emocionais, a EDA oferece a vantagem de capturar essas respostas de maneira imediata e precisa, evitando os vieses associados à verbalização e à memória. A pesquisa realizada por Lee (2021) amplia a aplicação da EDA no campo educacional, particularmente no engajamento de jovens durante atividades de aprendizado em programas de criação. Em um estudo longitudinal, conduzido em um programa extracurricular de um ano, Lee utilizou dados de EDA em conjunto com questionários

para avaliar o nível de engajamento dos participantes. Os resultados indicaram que atividades envolvendo planejamento de projetos apresentaram níveis elevados de engajamento, em contraste com tarefas como costura, que apresentaram ser menos envolventes, especialmente quando a interação social era limitada.

2.2 FREQUÊNCIA CARDÍACA

A medição da HR, quantificada em batimentos por minuto (bpm), constitui uma métrica fundamental que reflete a atividade dinâmica do sistema cardiovascular. Este parâmetro fisiológico é altamente sensível, respondendo a uma ampla gama de estímulos físicos, emocionais e cognitivos. Em indivíduos saudáveis, a HR normalmente oscila entre 60 e 100 bpm, representando a eficiência e a adaptabilidade do sistema circulatório.

Do ponto de vista fisiológico, a HR é regulada pelo SNA, composto pelas divisões simpática e parassimpática. A ativação simpática está associada ao aumento da frequência cardíaca, preparando o organismo para situações de alerta ou demanda energética, o chamado mecanismo de “luta ou fuga”. Já a ativação parassimpática exerce efeito oposto, reduzindo a frequência cardíaca e promovendo estados de repouso, recuperação e conservação de energia. O equilíbrio entre essas duas divisões permite que a HR funcione como um marcador objetivo das respostas do corpo ao ambiente, sendo, portanto, um recurso valioso para a compreensão de estados de engajamento, estresse e carga cognitiva em contextos educacionais.

2.2.1 Monitoramento da HR e engajamento educacional

A relação entre o monitoramento da HR e o engajamento educacional tem sido investigada para compreender como diferentes modalidades de ensino modulam a resposta fisiológica dos estudantes. Darnell e Krieg (2019) observaram que a HR média de alunos de medicina diminuiu gradualmente ao longo das aulas, exceto durante momentos de aprendizagem ativa, como discussões em grupo, nos quais houve um aumento significativo da HR. Fisiologicamente, essa elevação está associada à maior ativação simpática do sistema nervoso autônomo, que prepara o organismo para maior atenção, esforço cognitivo e interação social. O retorno da HR aos níveis médios após a atividade reflete a atuação parassimpática, promovendo recuperação e conservação de energia. Contudo, é importante destacar que aumentos excessivos e sustentados da HR podem indicar não apenas engajamento, mas também

estresse e sobrecarga fisiológica, evidenciando que tanto a hipoativação quanto a hiperativação podem comprometer a qualidade da aprendizagem.

Complementando o estudo sobre o monitoramento fisiológico em contextos educacionais, Rodic-Trmcic et al. (2016) exploraram o uso de soluções vestíveis para avaliar a excitação fisiológica e sua relação com o interesse e engajamento dos estudantes em sala de aula. A pesquisa destaca a relevância de dispositivos vestíveis, computação móvel e tecnologias da Internet das Coisas como recursos para monitorar e gerenciar o estresse no ambiente educacional. Ao acompanhar parâmetros como HR e SCR, foi possível identificar diferentes níveis de excitação durante as aulas. Do ponto de vista fisiológico, níveis moderados de estresse podem ser positivos, favorecendo a atenção e a motivação; entretanto, a hiperativação prolongada pode levar à sobrecarga, comprometendo o aprendizado. Nesse sentido, a implementação de um sistema móvel de avaliação das unidades de ensino permitiu oferecer feedback contínuo e imediato, contribuindo para o ajuste das práticas pedagógicas e para a melhoria da qualidade do ensino.

Avançando na aplicação prática dessas tecnologias, Wang e Liu (2019) desenvolveram uma pulseira inteligente voltada para o monitoramento da intensidade e segurança de exercícios em aulas de educação física. Em um estudo com 188 estudantes de duas escolas chinesas, a pulseira demonstrou eficácia na medição em tempo real da atividade física, carga de exercício e HR dos estudantes, proporcionando feedback imediato aos professores. Os dados coletados revelaram que a HR média dos meninos foi de 125 bpm e das meninas, 122 bpm, ambos dentro dos limites seguros. Além disso, a pulseira monitorou a carga média de exercício, que foi de 65,6%, e o tempo de exercício efetivo, que alcançou 55,8%. Notavelmente, o dispositivo também emitiu alertas quando a HR ultrapassou a faixa segura, permitindo intervenções imediatas para prevenir a sobrecarga física.

A pesquisa conduzida por Quintero et al. (2019) avaliou a reprodutibilidade de diferentes índices de HRV e de EDA em condições controladas, utilizando o teste de inclinação (*Head-Up Tilt*, HUT) e o teste *Stroop*. Os resultados mostraram que os índices de HRV, em especial o componente de baixa frequência, apresentaram maior consistência, evidenciada por um coeficiente de variação (CV) de 85,4% e por um índice de correlação intraclass (ICC) de 0,83 durante o HUT. Em contraste, índices tradicionais de EDA, como o nível tônico de SCL e a frequência de respostas não específicas (NS.SCRs), revelaram maior instabilidade. No entanto, o índice temporal variável da EDA (TVSymp) destacou-se pela sua maior confiabilidade, alcançando ICC = 0,85 no HUT e ICC = 0,79 no teste *Stroop*, configurando-se como a medida mais reprodutível entre os parâmetros de EDA.

2.2.2 Tecnologias vestíveis e análise de HR

O uso de tecnologias vestíveis para a análise do engajamento educacional tem ganhado destaque, oferecendo novas perspectivas para a compreensão do comportamento dos estudantes em sala de aula. Nesse contexto, Lu et al. (2017) desenvolveram um *framework* que se propõe a fornecer informações contextuais sobre o processo de aprendizado, utilizando dispositivos vestíveis comuns. Este *framework* inclui módulos que identificam ações básicas dos estudantes e inferem o contexto de aprendizado por meio de sensores integrados, como acelerômetros e sensores de HR, complementados por técnicas de mineração de dados. Um dos casos de uso analisados foi a avaliação do engajamento em sala de aula, onde o sistema demonstrou a capacidade de reconhecer com precisão as ações dos estudantes e inferir seu nível de engajamento, permitindo intervenções pedagógicas adequadas.

Complementando essa abordagem, Gao et al. (2020) conduziram um estudo que explora a previsão do engajamento emocional, comportamental e cognitivo dos estudantes em sala de aula por meio da combinação de dados de sensores vestíveis e informações ambientais coletadas por estações meteorológicas internas. A pesquisa focou em dados fisiológicos, como a EDA e a HRV, além de fatores ambientais, como os níveis de dióxido de carbono (CO₂) na sala de aula. As análises demonstraram que esses dados são eficazes na diferenciação dos níveis de engajamento dos estudantes.

A pesquisa de Kanna et al. (2018) exemplifica uma aplicação prática dessas tecnologias ao integrar sensores vestíveis no currículo de cursos de Engenharia Elétrica e Eletrônica, sendo observado um aumento substancial no engajamento e aprendizado dos estudantes ao incorporarem atividades práticas de processamento de sinais utilizando dados fisiológicos próprios, como ECG. Por meio da utilização de sensores vestíveis e instruções em vídeo, os estudantes puderam gravar seus próprios ECG e realizar análises tanto no domínio do tempo quanto no espectral.

2.3 TEMPERATURA DA PELE

A investigação da ST como um indicador auxiliar da homeostase corporal tem atraído crescente atenção nos âmbitos médico, biológico e educacional. Embora normalmente varie entre 32 e 34,5 °C em indivíduos saudáveis, a ST deve ser entendida como uma medida complementar, pois sofre influência não apenas da regulação fisiológica interna, mas também

de condições ambientais externas (como temperatura e umidade do ar) e de estados emocionais, que podem provocar alterações vasomotoras periféricas. Assim, a ST reflete a integração entre mecanismos autonômicos do organismo e fatores contextuais, sendo útil para complementar outras métricas fisiológicas no monitoramento do engajamento e do estresse.

Do ponto de vista instrumental, a mensuração da ST é realizada por meio de sensores de contato, geralmente termistores ou termopares miniaturizados, que convertem variações de temperatura em sinais elétricos. Esses sensores são posicionados em áreas com alta densidade de receptores térmicos e boa estabilidade de contato com a pele, como dedos, punho ou região distal do antebraço. Dispositivos vestíveis, como pulseiras inteligentes (ex.: Empatica E4) e sistemas de biofeedback, incorporam esses sensores em suas estruturas, permitindo a coleta contínua e não invasiva da ST em ambientes laboratoriais ou naturais de aprendizagem.

2.3.1 Monitoramento de estresse e ansiedade por meio da ST

O monitoramento de estados emocionais como estresse e ansiedade, utilizando a ST em conjunto com outros sinais fisiológicos, tem avançado com o apoio de dispositivos vestíveis e soluções de baixo custo. Yoon et al. (2016) desenvolveram um patch flexível que integra sensores de ST, SCR e ondas de pulso em uma estrutura multilayer altamente adaptável. Esse dispositivo, 125 vezes menor do que sensores convencionais, demonstrou maior conforto para o usuário e precisão na coleta de dados, confirmando sua viabilidade para o monitoramento contínuo de estresse psicológico.

Complementando essas investigações, Pérez et al. (2018) utilizaram dispositivos de pulso comercialmente disponíveis para estimar níveis de estresse em estudantes em dois contextos: laboratório e sala de aula. Na fase laboratorial, os participantes foram expostos a tarefas indutoras de estresse, enquanto na fase em sala de aula o monitoramento ocorreu durante atividades acadêmicas regulares. Por meio de técnicas de aprendizado de máquina, foi possível alcançar alta precisão na detecção de estresse, demonstrando a eficácia desses dispositivos para identificar respostas fisiológicas associadas ao ambiente educacional.

Rodríguez-Arce et al. (2020) também exploraram a predição de estresse e ansiedade em contextos acadêmicos, utilizando sensores de baixo custo conectados a uma placa Arduino. O protocolo experimental envolveu tarefas indutoras de estresse aplicadas a 21 estudantes, além da aplicação do Inventário de Ansiedade Traço-Estado (STAI). A análise de múltiplas características fisiológicas mostrou que classificadores de ML, como KNN e SVM, atingiram

precisão superior a 90% na identificação de estresse e ansiedade, destacando o potencial do uso integrado de ST, HR, GSR e oximetria.

No campo do reconhecimento emocional, Katmada et al. (2015) propuseram um sistema de biofeedback associado a um aplicativo Android, que coleta sinais como EDA, HR e ST e classifica níveis de ansiedade em tempo real. Essa integração foi aplicada em jogos educacionais, demonstrando potencial para aumentar o engajamento dos estudantes. De modo semelhante, Jamal e Kamioka (2019) investigaram a detecção de emoções a partir da ST facial e da HRV em 20 voluntários. A análise, baseada em redes neurais artificiais, alcançou precisão de 88,75% na identificação de estados emocionais como relaxamento, medo, tristeza e alegria, reforçando a eficácia de abordagens não invasivas no reconhecimento emocional.

2.4 APRENDIZADO DE MÁQUINA

O ML é uma área da inteligência artificial que desenvolve algoritmos capazes de aprender e tomar decisões com base em dados. Ao invés de seguir regras pré-programadas, os sistemas de ML melhoram automaticamente seu desempenho à medida que são expostos a grandes volumes de dados. Essa capacidade de adaptação torna o ML essencial em aplicações como reconhecimento de imagem e processamento de linguagem natural, revolucionando a forma como utilizamos a tecnologia para resolver problemas complexos.

2.4.1 Previsão de desempenho acadêmico com ML

A previsão do desempenho acadêmico dos estudantes tem sido objeto de intensas investigações, especialmente no que diz respeito à identificação de estudantes em risco de baixo desempenho. Neste contexto, o estudo de Polyzou e Karypis (2023) se destaca ao focar em técnicas de ML para a classificação binária desses estudantes. Os autores utilizaram dados históricos de notas da Universidade de Minnesota, extraindo características interpretáveis que permitem compreender os fatores que influenciam negativamente o desempenho acadêmico. A pesquisa concluiu que os métodos de *Gradiente Boosting* e RF são particularmente eficazes para essa tarefa, destacando que diferentes conjuntos de características apresentam capacidades preditivas distintas, dependendo da tarefa de classificação em questão.

Avançando na aplicação de técnicas de ML, Pang et al. (2017) desenvolveram um modelo baseado em SVM para prever os resultados de graduação dos estudantes. Este estudo diferenciou-se por integrar até 100 variáveis, incluindo fatores psicopedagógicos, e avaliar o

modelo utilizando dados longitudinais de uma universidade estadual. Os resultados obtidos evidenciaram que o modelo é altamente eficaz, demonstrando considerável precisão na previsão.

Complementando essa linha de investigação, Gray e Perkins (2019) concentraram-se na relação entre a participação em sessões programadas e o desempenho acadêmico dos estudantes. Os autores desenvolveram um método estatístico descritivo inovador para medir a presença dos estudantes e aplicaram ferramentas modernas de ML para criar um modelo preditivo robusto. O estudo revelou que é possível identificar, com precisão de cerca de 97%, os estudantes em risco de insucesso acadêmico já na terceira semana do semestre, o que demonstra a importância de intervenções pedagógicas precoces e direcionadas, apoiando a implementação de mecanismos de suporte mais eficazes.

Em um contexto diferente, mas igualmente relevante, Al-Shabandar et al. (2017) exploraram a previsão de resultados de aprendizagem em cursos online abertos e massivos (MOOCs) utilizando técnicas de ML. O estudo revelou uma correlação significativa entre as ações de *click stream* dos estudantes e seus sucessos nos cursos, destacando o algoritmo RF como o de melhor desempenho na previsão dos resultados. Por outro lado, a Análise Discriminante Linear (LDA) apresentou o pior desempenho relativo.

Na mesma linha de aplicação de técnicas avançadas, Tsiakmaki et al. (2020) investigaram o uso de estratégias de AutoML para a previsão do desempenho estudantil em plataformas de aprendizagem online. Os resultados indicaram que as ferramentas de AutoML consistentemente superaram os métodos tradicionais em termos de precisão preditiva. Os experimentos realizados em diversos cursos demonstraram que classificadores baseados em árvores e regras, como RF e Árvore Modelo Logístico (LMT), apresentaram os melhores resultados, ressaltando a importância das configurações automatizadas de parâmetros.

Explorando a aplicação do ML em contextos específicos de disciplinas, Zabriskie et al. (2019) utilizaram modelos de RF e regressão logística para criar sistemas de alerta precoce no contexto de cursos introdutórios de física baseada em cálculo. Combinando variáveis de desempenho em sala de aula e institucionais, os autores conseguiram prever, com alta precisão, o desempenho dos estudantes logo na primeira semana de aula. O estudo revelou que, enquanto variáveis institucionais foram fundamentais nas primeiras semanas, variáveis em sala de aula, como as notas de trabalhos de casa, ganharam importância após o primeiro exame. Uma revisão conduzida por Hellas et al. (2018) trouxe à tona o aumento significativo de pesquisas sobre predição de desempenho acadêmico, utilizando uma variedade de técnicas de ML. A revisão

destacou a necessidade de relatórios mais detalhados sobre métodos e resultados, além de uma validação e replicação mais rigorosas dos estudos.

A pesquisa de Yang et al. (2020) analisou o uso de algoritmos de ML para prever o desempenho dos estudantes em uma disciplina introdutória de física. O estudo ajustou modelos preditivos para melhorar a precisão na identificação de estudantes em risco de obter notas baixas, mesmo diante de um cenário de desbalanceamento de variáveis. Os autores conseguiram aumentar a precisão de classificação para 53% já na segunda semana de aula, utilizando dados institucionais e coletados em sala de aula. Iatrellis et al. (2020), ao investigarem abordagens de ML em duas fases, combinando técnicas supervisionadas e não supervisionadas, fizeram importantes avanços na previsão de resultados acadêmicos em programas de ensino superior. O estudo, realizado em um curso de Ciência da Computação na Universidade de Tessália, identificou *clusters* de estudantes com base em fatores educacionais específicos, utilizando o algoritmo K-Means. Subsequentemente, modelos de predição foram treinados para cada *cluster*, resultando em previsões precisas sobre o tempo de conclusão dos cursos e a matrícula dos estudantes.

2.4.2 Técnicas e algoritmos específicos de ML em previsão acadêmica

A crescente aplicação de algoritmos de classificação em ambientes educacionais tem sido explorada em diversas pesquisas, destacando-se como uma abordagem promissora para prever o desempenho acadêmico dos estudantes. Nesse contexto, Pavani et al. (2017) investigaram a utilização de DT, com ênfase no algoritmo C4.5, para prever o rendimento dos estudantes com base em registros acadêmicos. A pesquisa se insere na área emergente da Mineração de Dados Educacionais (EDM), que combina técnicas de mineração de dados, ML e estatística para analisar dados gerados em contextos educacionais. O estudo avaliou um conjunto de dados composto por 250 estudantes e concluiu que o modelo desenvolvido é capaz de prever a classificação dos estudantes em categorias como "bom", "médio" ou "ruim" com base em atributos selecionados, proporcionando uma ferramenta tanto para educadores quanto para estudantes monitorarem o desempenho acadêmico de maneira acessível, mesmo sem conhecimentos técnicos avançados.

Dando continuidade à exploração de algoritmos de classificação, a pesquisa de Shanthini et al. (2018) concentrou-se em técnicas de *ensemble methods*, especificamente utilizando classificadores de meta DT como *Adaboost*, *Bagging*, *Dagging* e *Grading*, com base no algoritmo *REPTree*. O estudo analisou o desempenho acadêmico de 401 estudantes de

graduação em Ciência da Computação e Engenharia, identificando que o classificador *Adaboost* alcançou a maior precisão (97,6%) e *recall* (97,5%) na predição do desempenho acadêmico. Essa pesquisa ressalta o potencial dos *ensemble methods* em melhorar a acurácia das previsões, evidenciando sua utilidade para identificar estudantes que necessitam de intervenções educacionais adicionais, contribuindo assim para a melhoria dos processos educacionais e redução das taxas de reprovação.

Ainda na linha de modelos de *ensemble*, Yan e Liu (2020) propuseram um modelo de predição baseado na técnica de *stacking*, demonstrando superioridade em relação a outros modelos tradicionais e técnicas de *ensemble*. Este modelo combinou algoritmos como RF, SVM e *AdaBoost* como *base-learners*, utilizando regressão logística como *meta-learner* e validação cruzada 10x10-*fold* para evitar vazamentos de rótulos. Os resultados destacaram que o comportamento durante competições acadêmicas e a média de notas foram as variáveis mais relevantes para a predição do desempenho, enquanto o *background* acadêmico exerceu menor influência.

A relevância de algoritmos de ML em contextos educacionais com conjuntos de dados pequenos também foi abordada por Abu Zohair (2019), cujo estudo buscou auxiliar instituições educacionais na identificação de estudantes em risco. Utilizando algoritmos como SVM e LDA, o estudo demonstrou que é possível alcançar taxas de acurácia e confiabilidade aceitáveis mesmo com conjuntos de dados limitados. A SVM, em particular, destacou-se pela eficiência na identificação de indicadores-chave, resultando em modelos de previsão confiáveis que podem contribuir para a melhoria do desempenho acadêmico dos estudantes.

O estudo de Ofori et al. (2020) amplia a discussão ao examinar a eficácia de diferentes modelos de ML na previsão do desempenho acadêmico e na melhoria dos resultados de aprendizagem. A pesquisa testou modelos como ANN, *Naive Bayesian* e SVM, revelando precisões de predição variadas e indicando a necessidade de estudos adicionais para determinar o modelo mais eficaz. Além disso, o estudo trouxe à tona a influência significativa de fatores socioeconômicos, como renda familiar e nível de educação dos pais, no desempenho acadêmico, que não foram amplamente considerados nos testes de precisão dos modelos, sugerindo uma lacuna importante na literatura existente.

Na mesma direção, Naicker et al. (2020) compararam o desempenho de máquinas de vetores de suporte linear (LSVM) com outros dez algoritmos tradicionais de ML, utilizando um conjunto de dados de 1000 registros de estudantes do ensino médio. A pesquisa destacou a superioridade do LSVM na precisão da predição, com uma taxa de 90,1%, e identificou fatores como raça, gênero e acesso ao almoço como determinantes significativos para o desempenho

em leitura e escrita. Por outro lado, Wakelam et al. (2019) focaram em prever o desempenho de estudantes em turmas pequenas, utilizando um conjunto limitado de atributos estudantis. Analisando 23 estudantes de um módulo de último ano de graduação, o estudo utilizou técnicas de ML como DT, KNN e RF. Os resultados demonstraram que a RF e o KNN apresentaram as melhores acurácias, oferecendo uma ferramenta essencial para a identificação precoce de estudantes em risco e possibilitando intervenções oportunas pelos líderes de módulo.

Outrossim, a pesquisa de Hussain et al. (2018) explorou a utilização de algoritmos de ML para prever dificuldades dos estudantes em sessões subsequentes de um curso de design digital, utilizando dados do sistema DEEDS. Modelos como ANN e SVM apresentaram maior precisão em comparação a outros algoritmos, sugerindo que essas técnicas podem ser integradas aos sistemas de aprendizado para fornecer *feedback* em tempo real. Em consonância com a importância do uso de técnicas de ML na educação, Yousafzai et al. (2020) desenvolveram um sistema de previsão de notas e desempenho acadêmico utilizando técnicas de aprendizado supervisionado, baseado em dados históricos, uma vez que após o pré-processamento dos dados, 29 atributos selecionados foram utilizados para treinar um classificador de DT e um modelo de regressão. A combinação dessas técnicas apresentou-se eficaz na previsão do desempenho, permitindo identificar estudantes com baixo desempenho e fornecer a eles a atenção necessária para melhorar seu rendimento acadêmico.

2.4.3 Revisões e análises sobre técnicas de ML em educação

A pesquisa conduzida por Rastrollo-Guerrero et al. (2020) oferece uma ampla revisão de quase 70 estudos que investigam as técnicas de predição do desempenho estudantil, com foco especial em algoritmos de ML, filtragem colaborativa, sistemas de recomendação e ANN. Essa revisão destaca que a maioria das pesquisas está concentrada no nível universitário, sublinhando a relevância do aprendizado supervisionado e, em particular, do algoritmo de SVM, que se sobressai em termos de precisão quando comparado a outras técnicas.

Complementando essa perspectiva, Simjanoska et al. (2014) propõem a introdução de inteligência nos processos de *e-Learning* e *e-Assessment* por meio da aplicação de algoritmos de ML para criação de perfis de estudantes e predição de seus resultados. Este estudo, desenvolve uma estratégia adaptativa que assegura a realização dos objetivos de aprendizagem por meio da correção contínua de respostas durante avaliações online. Os resultados apontam que a estratégia de três respostas corretas consecutivas foi particularmente eficaz na

minimização da adivinhação aleatória, ao exigir um mínimo de três perguntas para garantir a aquisição do conhecimento específico.

Dando continuidade ao exame das técnicas de aprendizado supervisionado, o estudo de Imran et al. (2019) foca na predição do desempenho acadêmico de estudantes, abordando desafios comuns na mineração de dados educacionais, como o desequilíbrio de classes e a alta dimensionalidade dos dados. Utilizando um conjunto de dados de estudantes portugueses, os autores aplicaram três algoritmos de classificação: J48, NNge e *Multilayer Perceptron* (MLP). Os achados indicaram que o algoritmo J48, quando combinado com a técnica de *ensemble Realadaboost*, atingiu a maior precisão, com uma taxa de 95,78%. Este resultado destaca a importância do pré-processamento dos dados e da seleção de atributos como elementos essenciais para melhorar a acurácia dos modelos preditivos.

Walsh e Mahesh (2017) realizaram uma pesquisa exploratória utilizando ML para prever os resultados dos estudantes em cursos universitários tradicionais. Ao combinar dados comportamentais com dados tradicionais, o estudo foi capaz de realizar previsões precisas sobre as notas dos estudantes, permitindo intervenções pedagógicas logo no início do processo de aprendizagem.

2.4.4 Aplicações de ML em contextos de saúde e comportamento

A aplicação de algoritmos de ML em diferentes contextos de saúde tem se apresentado promissora, especialmente em relação ao monitoramento de estados emocionais e fisiológicos. Um exemplo notável é o estudo de Anusha et al. (2019), que desenvolveram um esquema automatizado para detectar o estresse pré-cirúrgico com base na EDA, medida por um dispositivo de pulso. Com a participação de 41 indivíduos, o estudo monitorou a EDA continuamente em um ambiente clínico, a fim de identificar níveis de estresse baixo, moderado e alto. Para melhorar a precisão da detecção, os pesquisadores implementaram um algoritmo supervisionado que identificou e corrigiu artefatos de movimento, atingindo uma precisão de 97,83%. O modelo adaptativo desenvolvido, que levou em consideração variações individuais como densidade das glândulas sudoríparas e espessura da pele, alcançou uma precisão de classificação de 85,06%, superando os modelos de classificação geral tradicionalmente usados.

Ainda no contexto de monitoramento de estados emocionais por meio de sinais fisiológicos, Kim et al. (2018) exploraram o potencial da EDA na detecção automática do transtorno depressivo maior (MDD) utilizando técnicas de ML. Este estudo, que incluiu 30 pacientes com MDD e 37 indivíduos saudáveis, mediu a EDA durante cinco fases experimentais

distintas. Com a extração e análise das características da EDA por meio de um classificador de DT, foi possível atingir uma precisão de 74%, com sensibilidade e especificidade semelhantes, de 74% e 71%, respectivamente.

Em um cenário mais próximo da vida real, Can et al. (2019) investigaram a eficácia de um sistema de detecção de estresse com base em sinais fisiológicos obtidos de dispositivos portáteis. O estudo, conduzido ao longo de um evento de nove dias com 21 participantes, envolveu a coleta de dados fisiológicos durante atividades que variavam entre palestras, competições e tempos livres. Utilizando sinais como HR, EDA e dados de acelerômetros, o sistema conseguiu discriminar entre diferentes níveis de estresse, alcançando uma precisão de classificação de 90,40% com o dispositivo Empatica E4 e 84,67% com dispositivos Samsung. Os resultados enfatizam a superioridade dos modelos personalizados, que alcançaram precisão de até 97,92%, em comparação com os modelos gerais. A pesquisa destaca que a combinação de diferentes sinais fisiológicos pode aumentar a acurácia na detecção de estresse em ambientes reais.

Chowdhury et al. (2019) também exploraram o uso de ML para analisar dados de sensores multimodais na predição da intensidade relativa da atividade física. O estudo envolveu 22 participantes equipados com sensores de pulso que registraram HR, EDA e ST durante sessões de atividades físicas. Três classificadores, RF, ANN e SVM, foram testados para prever a intensidade da AF como baixa, moderada ou alta. Os resultados demonstraram que os dados de HR apresentaram o melhor desempenho na previsão, com leve melhoria ao combinar outras modalidades de sensores, embora a fusão de decisões não tenha oferecido benefícios adicionais significativos.

A interseção entre ML e a robótica social foi explorada por Fiorini et al. (2019), que investigaram a classificação de estados emocionais usando sinais fisiológicos para aprimorar a interação humano-robô. O estudo analisou dados de ECG, EDA e EEG coletados por uma rede de sensores vestíveis. Durante a experimentação, três estados emocionais distintos, relaxamento, positivo e negativo, foram induzidos por meio de interação social. Diferentes algoritmos de ML, tanto supervisionados quanto não supervisionados, foram avaliados para identificar a combinação mais eficaz de sensores e classificadores. Os melhores resultados foram alcançados com métodos supervisionados, que atingiram uma precisão de 85%, sugerindo que a detecção de emoções por meio de sinais fisiológicos pode melhorar significativamente a interação entre humanos e robôs.

No contexto da segurança viária, Gjoreski et al. (2020) aplicaram técnicas de ML e aprendizado profundo (DL) para monitorar distrações de motoristas a partir de sinais

fisiológicos e visuais. O estudo comparou a eficácia de diferentes sensores, como a EDA, HR e rastreamento ocular, na detecção de quatro tipos distintos de distração. O classificador XGB apresentou o melhor desempenho, com uma pontuação F1 de 94% ao classificar sessões completas de direção usando unidades de ação facial.

3 MATERIAIS E MÉTODOS

A presente investigação foi conduzida por meio de um delineamento experimental com abordagem quantitativa, tendo como objetivo principal a análise da atividade do sistema nervoso simpático de estudantes universitários, a partir da coleta de dados fisiológicos. A amostra foi composta por cinquenta estudantes do ensino superior.

Foram monitoradas três variáveis fisiológicas, EDA, HR e ST, com o uso de sensores não invasivos, aplicados durante a exposição dos participantes a dois distintos métodos de ensino, a aula expositiva tradicional e a aula fundamentada em metodologias ativas de aprendizagem, cujo protocolo de estudo foi previamente aprovado pelo Comitê de Ética em Pesquisa (CAAE 77167723.5.0000.5431/2024).

Durante as sessões experimentais, os sinais fisiológicos foram registrados de forma contínua, com o intuito de captar as flutuações da excitação autonômica em resposta aos diferentes estímulos pedagógicos. A etapa de análise estatística contemplou o cálculo dos valores mínimo, máximo, média e mediana para cada variável, em ambos os métodos de ensino. Adicionalmente, foram calculadas as diferenças entre as médias e medianas dos dois métodos para cada participante, permitindo uma avaliação individualizada das variações fisiológicas em função das estratégias didáticas adotadas.

3.1 PROTOCOLO EXPERIMENTAL

O presente estudo adotou um delineamento experimental composto por duas fases sequenciais, com o propósito de avaliar os efeitos de diferentes métodos de ensino sobre o engajamento estudantil, a partir da coleta de sinais fisiológicos.

As sessões experimentais foram realizadas individualmente, com duração aproximada de 30 minutos cada. O procedimento teve início com a recepção dos participantes em um ambiente controlado (sala de aula), ocasião em que foram informados a respeito dos procedimentos da pesquisa, sem, contudo, a divulgação dos objetivos específicos do estudo. Em seguida, sensores de EDA, HR e ST foram fixados nos dedos da mão não dominante dos participantes. Posteriormente, procedeu-se a um período de repouso de dois minutos, destinado à calibração da linha de base e à verificação da qualidade dos sinais fisiológicos.


Na fase correspondente ao método tradicional de ensino, os participantes assistiram a uma videoaula com slides, sem qualquer forma de interação entre estudante e professor, com duração de 15 minutos e 26 segundos. Esse formato, baseado na exposição teórica unidirecional,

caracteriza-se como método tradicional por favorecer a aprendizagem passiva, sem estímulo à participação ativa dos estudantes, o que pode comprometer o engajamento e a retenção do conteúdo (Klein et al., 2023; Zhang et al., 2006). O conteúdo abordado incluiu o contexto industrial do problema de corte de estoque unidimensional e a apresentação de heurísticas clássicas, como *Next Fit*, *First Fit* e *First Fit Decreasing* (FFD).

Após uma transição breve de aproximadamente um minuto, teve início a fase de aprendizagem ativa, com o intuito de manter a continuidade da sessão e reduzir possíveis variações na linha de base fisiológica. Essa etapa consistiu na realização de duas atividades práticas, detalhadas no Apêndice A, nas quais os estudantes foram inicialmente orientados a aplicar a heurística FFD. Na sequência, realizaram o refinamento da solução, com o objetivo de alcançar um resultado mais eficiente. As atividades envolveram a resolução de um problema de otimização de corte de material por meio da manipulação de um dispositivo físico confeccionado em bambu e componentes de PVC, composto por hastes verticais e anéis coloridos e numerados, os quais deveriam ser organizados conforme instruções específicas.

Tal recurso foi empregado com a finalidade de intensificar o envolvimento motor e atencional dos estudantes ao longo dos blocos experimentais. A Figura 5 apresenta o dispositivo utilizado, enquanto a Figura 6 ilustra sua aplicação prática durante as sessões.

Figura 5 - Dispositivo físico utilizado nas atividades práticas



Fonte: Elaborado pelo autor (2025).

Figura 6 - Aplicação do dispositivo durante a sessão experimental



Fonte: Elaborado pelo autor (2025).

É importante considerar que a própria percepção de estar sendo monitorado pode ter induzido alterações fisiológicas, refletindo-se em diferentes níveis de ativação simpática. Essas mudanças podem influenciar tanto o engajamento quanto o desempenho, uma vez que níveis moderados de ativação favorecem a atenção, enquanto a hiperativação pode gerar ansiedade e comprometer a execução. Além disso, a análise das respostas fisiológicas foi relacionada ao desempenho acadêmico, permitindo observar diferenças entre momentos de acerto e erro, bem como entre a conclusão bem-sucedida ou não das atividades propostas. Essa abordagem possibilitou avaliar de forma mais abrangente a relação entre engajamento fisiológico, monitoramento e resultados obtidos durante as tarefas.

Na Parte A, os estudantes foram instruídos a aplicar, passo a passo, a heurística FFD para resolver um problema de corte baseado em uma demanda específica de peças com diferentes comprimentos. Na Parte B, os alunos foram desafiados a encontrar uma solução otimizada utilizando no máximo 13 barras, sem a obrigatoriedade de seguir um algoritmo preestabelecido, estimulando o raciocínio heurístico e a busca por soluções alternativas.

Durante ambas as etapas, foram coletados dados fisiológicos (EDA, HR e ST) de cada participante de forma individual, totalizando 50 sessões experimentais. A sequência experimental foi mantida constante para todos os indivíduos, com o método tradicional sempre antecedendo a metodologia ativa, a fim de assegurar comparabilidade entre os contextos e

reduzir efeitos de ordem ou fadiga. Cabe destacar que cuidados adicionais foram tomados para minimizar possíveis artefatos, como aqueles gerados por movimentação excessiva dos participantes ou pela pressão mecânica dos eletrodos sobre a pele, fatores que poderiam mascarar os resultados. As verificações de qualidade dos sinais durante a coleta e os procedimentos de normalização aplicados na análise ajudaram a garantir maior confiabilidade aos dados obtidos.

Para as medições de EDA, este estudo empregou um sensor de resistência eletrodérmica, modelo Neurometria V6, produzido pela BioEvolution Ltda. O dispositivo possui uma frequência de amostragem de ponta de 4 Hz, eletrodos de disco de Ag/AgCl com uma área de contato de 1,0 cm², posicionados nas falanges distais dos dedos. Esses eletrodos foram utilizados de maneira seca para garantir a compatibilidade biológica. Este dispositivo foi selecionado por sua precisão de $\pm 0,2 \mu\text{S}$ e sua confiabilidade na detecção de mudanças na condutância da pele. Para quantificar e avaliar a EDA, o sensor foi colocado nos dedos indicador e médio de cada participante, conforme ilustrada na Figura 7.

Figura 7 - Conexão do sensor de resistência eletrodérmica



Fonte: Elaborado pelo autor (2025).

O sensor de resistência eletrodérmica, com uma precisão relativa de $\pm 5\%$ em relação ao valor real e uma precisão absoluta de $\pm 0,2 \mu\text{S}$ em relação à variação máxima esperada nas leituras do sensor, possui uma configuração de fio duplo que termina em dois discos metálicos.

Durante a coleta, procedimentos de controle de qualidade foram realizados manualmente. Isso incluiu a inspeção visual dos traçados em tempo real e a exclusão de segmentos comprometidos por artefatos, como aqueles causados por movimentação excessiva dos participantes ou pela pressão mecânica sobre os eletrodos. Esse processo assegurou maior confiabilidade e integridade dos dados utilizados na análise.

Para as medições de HR, um sensor cardíaco, modelo Neurometria V6, fabricado pela BioEvolution Ltda, foi utilizado neste estudo. Este sensor, equipado com dois LEDs, foi empregado para capturar os dados de HR com precisão. Para garantir uma quantificação e avaliação precisas da HR, o sensor foi posicionado na falange distal do dedo, com a ponta voltada para cima na impressão digital do polegar de cada participante, conforme ilustrado na Figura 8.

Figura 8 - Conexão do sensor cardíaco



Fonte: Elaborado pelo autor (2025).

O sensor cardíaco, com uma precisão de $\pm 5\%$ e uma faixa de resposta de frequência de 0,05 a 175 Hz, foi afixado de maneira segura à pele dos participantes. Este sensor possui uma configuração de LED duplo que emprega um sistema óptico moderno, suportando uma faixa de HR de 20 bpm a 208 bpm.

Para a coleta de dados de ST, utilizou um sensor de temperatura, modelo Neurometria V6, fabricado pela BioEvolution Ltda. Para quantificar e avaliar os níveis de ST, o sensor foi

afixado na falange proximal do dedo anelar de cada participante. O sensor foi posicionado no centro da falange proximal, conforme ilustrado na Figura 9.

Figura 9 - Conexão do sensor de temperatura



Fonte: Elaborado pelo autor (2025).

O sensor de temperatura, com uma precisão de $\pm 1,0\text{ }^{\circ}\text{C}$ ($\pm 1,8\text{ }^{\circ}\text{F}$) dentro da faixa de $20\text{ }^{\circ}\text{C}$ a $40\text{ }^{\circ}\text{C}$ ($68\text{ }^{\circ}\text{F}$ a $104\text{ }^{\circ}\text{F}$) e uma amplitude de temperatura de $10\text{ }^{\circ}\text{C}$ a $40\text{ }^{\circ}\text{C}$ ($50\text{ }^{\circ}\text{F}$ a $104\text{ }^{\circ}\text{F}$), foi configurado para aderir à falange proximal do dedo anelar. Esse posicionamento garantiu que a ponta do sensor estivesse em contato direto com o centro da falange proximal, precisamente na parte mais proeminente.

3.2 PARTICIPANTES

Participaram deste estudo 50 estudantes de engenharia, regularmente matriculados na Faculdade de Engenharia e Ciências, Campus de Guaratinguetá, da Universidade Estadual Paulista (FEG/UNESP). A seleção dos participantes foi realizada por conveniência, considerando a disponibilidade dos alunos e a compatibilidade de horário com a agenda experimental.

A amostra foi composta por homens e mulheres, distribuídos em diferentes anos do curso, com variação em idade, estatura e peso, conforme descrito nos registros demográficos da Tabela 9. Esses dados possibilitaram uma caracterização inicial dos participantes e o controle de

variáveis individuais. Além desses aspectos demográficos, reconhece-se que fatores circunstanciais, como o horário do dia em que ocorreu a coleta, a qualidade do sono na noite anterior, eventuais indisposições ou doenças respiratórias, bem como estados de estresse ou ansiedade, podem ter influenciado os padrões fisiológicos observados. Embora tais condições não tenham sido controladas de forma sistemática, sua menção é relevante para contextualizar possíveis variações entre os participantes e para indicar limitações inerentes à interpretação dos resultados.

Tabela 9 - Dados demográficos dos participantes

Estudante	Gênero	Idade	Altura (cm)	Peso (kg)	Curso matriculado	Ano
1	Masculino	20	175	73	Engenharia	3º
2	Masculino	19	173	68	Engenharia	3º
3	Masculino	20	170	70	Engenharia	2º
4	Masculino	19	175	65	Engenharia	3º
5	Feminino	20	160	56	Engenharia	3º
6	Masculino	19	171	67	Engenharia	3º
7	Masculino	19	177	73	Engenharia	3º
8	Masculino	20	183	80	Engenharia	3º
9	Feminino	20	162	52	Engenharia	3º
10	Feminino	19	160	50	Engenharia	3º
11	Masculino	20	173	65	Engenharia	3º
12	Feminino	21	170	63	Engenharia	5º
13	Masculino	24	170	81	Engenharia	5º
14	Feminino	22	174	65	Engenharia	3º
15	Feminino	22	170	60	Engenharia	3º
16	Feminino	22	167	59	Engenharia	5º
17	Masculino	22	176	62	Engenharia	3º
18	Feminino	25	149	51	Engenharia	4º
19	Feminino	22	170	63	Engenharia	3º
20	Masculino	22	174	64	Engenharia	4º
21	Feminino	21	172	77	Engenharia	4º
22	Masculino	19	176	70	Engenharia	4º
23	Masculino	24	170	55	Engenharia	2º
24	Masculino	25	167	70	Engenharia	5º
25	Masculino	24	176	80	Engenharia	3º
26	Feminino	21	158	65	Engenharia	3º
27	Masculino	26	183	91	Engenharia	3º
28	Masculino	21	173	63	Engenharia	4º
29	Masculino	21	181	70	Engenharia	4º
30	Masculino	28	190	95	Engenharia	3º
31	Masculino	21	185	86	Engenharia	3º
32	Feminino	20	166	80	Engenharia	3º

(continua)

Tabela 9 - Dados demográficos dos participantes

						(conclusão)
33	Masculino	26	181	105	Engenharia	5º
34	Feminino	24	160	71	Engenharia	4º
35	Masculino	22	173	85	Engenharia	4º
36	Feminino	21	163	52	Engenharia	5º
37	Feminino	25	155	53	Engenharia	5º
38	Masculino	26	180	62	Engenharia	3º
39	Masculino	19	177	65	Engenharia	2º
40	Feminino	23	165	90	Engenharia	5º
41	Masculino	25	169	67	Engenharia	3º
42	Feminino	23	165	46	Engenharia	4º
43	Masculino	23	173	75	Engenharia	5º
44	Masculino	21	186	76	Engenharia	3º
45	Feminino	21	158	55	Engenharia	3º
46	Masculino	25	183	95	Engenharia	1º
47	Feminino	24	177	80	Engenharia	3º
48	Masculino	28	175	74	Engenharia	1º
49	Masculino	20	175	66	Engenharia	4º
50	Masculino	20	172	72	Engenharia	4º

Fonte: Elaborado pelo autor (2025).

Cada estudante foi submetido individualmente ao experimento divididas entre a exposição à videoaula (método tradicional) e a realização das duas atividades práticas (metodologia ativa), sendo ambas ministradas pelo mesmo docente, em ambiente controlado com temperatura fixa de 23 °C, visando minimizar interferências ambientais sobre os dados fisiológicos. Todos os participantes assinaram um Registro de Consentimento Livre e Esclarecido (RCLE), com base nos preceitos éticos da pesquisa com seres humanos. O estudo seguiu os princípios metodológicos descritos por Miguel et al. (2012), os quais sustentam a viabilidade de amostras reduzidas em investigações experimentais de caráter exploratório.

3.3 COLETA DE DADOS

Os dados empregados nesta pesquisa foram extraídos do repositório disponibilizado por Luche et al. (2025). A coleta foi conduzida em ambiente controlado, por meio de sessões individuais com cada um dos 50 estudantes participantes. Durante toda a experiência, os discentes utilizaram sensores fisiológicos capazes de registrar sinais em tempo real. A coleta foi estruturada em duas fases consecutivas: (i) durante a exibição de uma videoaula com duração de 15 minutos e 26 segundos, abordando o tema "heurísticas para o problema de corte de estoque unidimensional inteiro" (condição correspondente ao método tradicional); e (ii)

durante a execução de atividades práticas baseadas em metodologias ativas de aprendizagem, cujo tempo de realização variou entre os participantes, oscilando de aproximadamente 2 a 15 minutos.

Complementarmente, foi empregada uma abordagem análoga à neuroimagem funcional em tempo real, a fim de monitorar simultaneamente os sinais de EDA, HR e ST. Para isso, sensores não invasivos foram fixados nas mãos dos estudantes, permitindo a captura contínua dos sinais fisiológicos. Esses sinais eram processados por um computador, via codificador com microprocessador integrado, e transmitidos por interface USB. Tal configuração assegurou a integridade dos dados e preservou a mobilidade dos participantes.

A calibração dos sensores foi realizada de forma automática e remota pelo responsável técnico do sistema Neurometria V6, eliminando a necessidade de ajustes manuais locais e assegurando a padronização inicial dos registros, bem como maior confiabilidade dos dados coletados. A alimentação elétrica ocorreu por meio de módulo de bateria conectado via USB, garantindo isolamento elétrico e preservando a não invasividade do procedimento durante toda a coleta experimental.

Adicionalmente, utilizou-se um isolador com interface USB integrado a um gabinete multicanal, projetado para conexão segura dos eletrodos. O sistema operava com entrada de sinal de até 500 mV, tensão de 5 V DC e corrente de 0,01 A, com conversor analógico-digital de 14 bits calibrado para diferentes taxas de amostragem. Essa configuração proporcionou baixa interferência eletromagnética, alta impedância de entrada e relação de rejeição de modo comum (CMRR), assegurando fidelidade e qualidade dos sinais. Foram adotadas medidas de segurança com precisão dentro da faixa de $\pm 2\%$, além da aplicação de filtro de frequência em 60 Hz. Para a conexão dos sensores de EDA, HR e ST, foi utilizado o gabinete de canais modelo Neurometria V6, fabricado pela empresa BioEvolution Ltda, conforme ilustrado na Figura 10.

Figura 10 - Gabinete com canais para conexão dos sensores



Fonte: Elaborado pelo autor (2025).

As medições foram realizadas durante as duas sessões instrucionais (tradicional e ativa), sendo que cada estudante foi monitorado em ambas as condições experimentais. Os sensores foram fixados nos dedos dos participantes, registrando, em tempo real, os dados de EDA, em microsiemens (μS), HR, em batimentos por minuto (bpm), e ST, em graus Celsius ($^{\circ}\text{C}$).

O protocolo experimental compreendeu, inicialmente, a aplicação dos sensores, seguida da apresentação da videoaula tradicional e, em sequência, da atividade de aprendizagem ativa. Ao término, os sensores eram removidos e o procedimento era reiniciado com o próximo participante, até a conclusão do ciclo com os 50 estudantes. A utilização dessa amostra permitiu a coleta de um volume consistente de dados fisiológicos em diferentes contextos pedagógicos, aumentando a confiabilidade das análises estatísticas e possibilitando a identificação de padrões individuais e coletivos de engajamento.

Os dados foram convertidos em representações gráficas temporais, com o objetivo de ilustrar a evolução das variáveis fisiológicas ao longo das sessões. Esses gráficos facilitaram a visualização de picos, oscilações e tendências associadas aos diferentes métodos pedagógicos.

3.4 ANÁLISE DE DADOS

A presente investigação adotou uma abordagem quantitativa para a análise dos dados, integrando métodos estatísticos descritivos, inferenciais e computacionais, com o intuito de examinar as variações fisiológicas dos estudantes (EDA, HR e ST) em resposta a distintas metodologias de ensino, bem como avaliar seu desempenho cognitivo e engajamento percebido.

O processo analítico teve início com o pré-processamento dos sinais fisiológicos, realizado manualmente por meio da inspeção direta dos traçados. Essa etapa incluiu a identificação e remoção de ruídos e artefatos, a normalização temporal dos dados e o tratamento criterioso de valores atípicos, com decisões de correção, exclusão ou manutenção fundamentadas no impacto observado sobre a consistência do sinal. Esse rigor metodológico assegurou a qualidade e a comparabilidade necessárias para as análises subsequentes.

Na etapa descritiva, foram extraídas métricas como valores mínimos, máximos, médias e medianas, segmentadas conforme o tipo de atividade (ensino tradicional e aprendizagem ativa), permitindo comparações entre os contextos investigados. Para a análise inferencial, testaram-se a hipótese nula (H_0 : inexistência de diferenças significativas entre os métodos) e a hipótese alternativa (H_1 : existência de diferenças significativas), utilizando-se o software Minitab. Optou-se pelo teste de normalidade Anderson-Darling, em virtude de sua maior sensibilidade

às caudas das distribuições, em detrimento dos testes de Shapiro-Wilk e Kolmogorov-Smirnov. Na sequência, o teste de Levene foi empregado para verificar a homogeneidade das variâncias no contexto da ANOVA.

Os resultados indicaram ausência de normalidade para as variáveis EDA, HR e ST, tanto nas condições de aprendizagem ativa quanto nas de aula tradicional ($p < 0,05$), além de ausência de homoscedasticidade. Tais achados justificaram a adoção de métodos estatísticos não paramétricos, uma vez que os pressupostos fundamentais para os testes paramétricos foram violados.

Dessa forma, o teste U de Mann-Whitney foi utilizado para comparar as medianas das variáveis fisiológicas entre as condições, adotando-se um nível de significância de 5% ($\alpha = 0,05$). Os valores de p obtidos foram inferiores a 0,05, o que levou à rejeição da hipótese nula para todos os estudantes, evidenciando efeitos estatisticamente significativos atribuíveis à metodologia pedagógica adotada. O tamanho do efeito da diferença entre os dois métodos de ensino (EDA: $r \approx 0,36$; HR: $r \approx 0,07$; ST: $r \approx 0,21$) indicou uma magnitude média (moderada), conforme os parâmetros estabelecidos por Cohen (2013), em que $r \geq 0,5$ caracteriza um efeito grande, sugerindo uma diferença substancial nas respostas fisiológicas entre os contextos avaliados.

As correlações entre as variáveis fisiológicas foram examinadas por meio dos coeficientes de *Spearman*, adequados para dados não paramétricos por medirem relações monotônicas sem pressupor normalidade (SCHOBER et al., 2018; SHENGXIN et al., 2025). Essa análise permitiu identificar associações entre os indicadores nos distintos contextos educacionais.

Na etapa preditiva, adotou-se uma abordagem baseada em técnicas de ML, conforme diretrizes metodológicas identificadas na revisão sistemática de Sánchez-Reolid et al. (2022). Os dados fisiológicos contínuos foram consolidados em um único banco de dados e os sinais foram normalizados individualmente por meio da padronização robusta baseada no escore de mediana (*robust z-score*), com o objetivo de reduzir efeitos de escala, aumentar a robustez frente a outliers e preservar a distribuição não paramétrica.

A variável “Nota Final” foi definida como variável-alvo (*target*), representando o desempenho acadêmico por meio do tempo de resolução das atividades, métrica amplamente reconhecida como indicativa de sucesso educacional e fortemente associada ao engajamento estudantil (LEI et al., 2018; KASSAB et al., 2024; DOUDS, 2018). Essa variável foi posteriormente categorizada em duas classes, “Desengajado” (Nota Final < 5) e “Engajado” (Nota Final ≥ 5), caracterizando o problema como uma tarefa de classificação supervisionada, conforme ilustrado no Apêndice B.

A construção dos modelos foi realizada em *Python*, utilizando algoritmos de aprendizado supervisionado, nos quais o modelo aprende a partir de dados rotulados, com o objetivo de prever saídas para novas entradas (BZDOK et al., 2018; JIANG et al., 2020). O conjunto de dados, composto por 28.125 dados referentes ao método de aprendizagem ativa, único método de ensino no qual a variável-alvo foi medida, foi dividido em 80% para treinamento (22.500 dados) e 20% para teste (5.625 dados), garantindo balanceamento entre as classes.

Na tarefa de classificação, em que o objetivo é atribuir uma categoria a cada instância com base em seus atributos (JIANG et al., 2020), foram aplicados os algoritmos SVM, *Logistic Regression* (LR), RF, KNN e ANN. O desempenho de cada modelo foi avaliado por meio das métricas de proporção de previsões corretas (Acurácia), de proporção de verdadeiros positivos entre todos os preditos como positivos (Precisão), de proporção de verdadeiros positivos entre todos os casos positivos reais (Revocação) e da média harmônica entre precisão e revocação (F1-Score), calculadas separadamente para as classes “Desengajado” e “Engajado”. Além disso, foram analisadas as matrizes de confusão de cada modelo, nas quais a diagonal principal representa as classificações corretas e a diagonal secundária indica erros e confusões entre classes (TING, 2011; SWAMINATHAN e TANTRI, 2024).

Na tarefa de regressão, problema supervisionado cujo objetivo é prever um valor numérico contínuo a partir de variáveis de entrada (RASHIDI et al., 2023), a variável-alvo “Nota Final” foi mantida em sua forma contínua. Aplicaram-se os algoritmos *Linear Regression*, *Support Vector Regression* (SVR), *Gradient Boosting Regressors*, *KNN Regressor* e *MLP Regressor*. O desempenho foi mensurado pelo Erro Quadrático Médio (MSE), isto é, a média dos quadrados dos erros, sendo menor valor indicativo de melhor desempenho, cujo MSE = 0 corresponde a previsão perfeita, e pelo Coeficiente de Determinação (R^2), cuja proporção da variabilidade dos dados reais é explicada pelo modelo.

4 RESULTADOS E DISCUSSÕES


Esta seção apresenta e discute os resultados obtidos a partir da análise dos sinais fisiológicos (EDA, HR e ST) dos estudantes, durante as sessões de ensino tradicional e de aprendizagem ativa.

4.1 RESULTADOS EDA

A análise da EDA entre os estudantes universitários, conduzida durante sessões de ensino tradicional e de aprendizagem ativa, revelou diferenças no engajamento fisiológico. Os gráficos apresentados ilustram a variação das respostas de EDA ao longo do tempo, destacando diferenças em função do método de ensino adotado. Entre os participantes, evidenciaram-se aqueles que apresentaram as maiores diferenças entre as medianas de EDA nos dois contextos educacionais. Ressalta-se que a análise se concentrou na comparação entre metodologias de ensino, não sendo incluídas correlações adicionais com características individuais da amostra, como idade, IMC, qualidade do sono ou estados emocionais, aspectos que permanecem como potenciais linhas para investigações futuras.


A estudante identificada como número 36, do sexo feminino, com 21 anos de idade, 163 cm de altura, 52 kg de peso e matriculada no 5º ano do curso de Engenharia, apresentou a maior diferença registrada na mediana da EDA, com variação de 4,1 μ S, sendo os valores obtidos na aprendizagem ativa superiores aos observados no ensino tradicional, conforme ilustrado na Figura 11.

Figura 11 - EDA da estudante 36




Em seguida, a estudante número 26, também do sexo feminino, com 21 anos, 158 cm de altura, 65 kg de peso e cursando o 3º ano de Engenharia, apresentou diferença de 3,2 µS na mediana da EDA, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 12.

Figura 12 - EDA da estudante 26




O estudante número 46, do sexo masculino, com 25 anos, 183 cm de altura, 95 kg de peso e matriculado no 1º ano de Engenharia, apresentou diferença de 2,7 μS na mediana da EDA, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 13.

Figura 13 - EDA do Estudante 46




Já o estudante número 7, do sexo masculino, com 19 anos, 177 cm de altura, 73 kg de peso e cursando o 3º ano, registrou diferença de 2,6 μS na mediana da EDA, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 14.

Figura 14 - EDA do Estudante 7




Outro participante de destaque foi o estudante número 3, do sexo masculino, com 20 anos, 170 cm de altura, 70 kg de peso e matriculado no 2º ano, que apresentou diferença de 2,5 μS na mediana da EDA, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 15.

Figura 15 - EDA do Estudante 3




Por fim, o estudante número 30, do sexo masculino, com 28 anos, 190 cm de altura, 95 kg de peso e matriculado no 3º ano, apresentou diferença de 2,1 μS na mediana da EDA, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 16.

Figura 16 - EDA do Estudante 30



As observações obtidas indicam que ambientes de aprendizagem ativa tendem a promover, de forma mais eficaz, o engajamento estudantil, evidenciado pelos níveis mais elevados de EDA registrados nessa modalidade. Os gráficos correspondentes aos demais 44 estudantes foram disponibilizados no Apêndice C, possibilitando uma avaliação abrangente das variações nas respostas fisiológicas e reforçando a constatação de que a aprendizagem ativa apresenta vantagens consistentes em diferentes perfis estudantis. A Figura 17 apresenta as medianas gerais de EDA dos participantes considerando ambos os contextos pedagógicos.

Figura 17 - Medianas de EDA dos participantes



De forma geral, verificou-se que, dos 50 estudantes analisados, 48 apresentaram valores medianos de EDA mais elevados durante a aprendizagem ativa, enquanto 2 não apresentaram alterações relevantes entre os métodos. Esses resultados sugerem que a abordagem ativa tende a promover maior ativação do sistema nervoso simpático, associada a estados de atenção e envolvimento. No entanto, deve-se considerar que níveis elevados de ativação podem refletir não apenas engajamento positivo, mas também estresse excessivo, o que poderia comprometer o desempenho em vez de favorecê-lo. Além disso, parte da resposta fisiológica pode estar relacionada ao próprio contexto experimental, como a novidade da situação ou a sensação de estar sendo monitorado, e não unicamente ao tipo de metodologia de ensino. Medidas adicionais, incluindo valores máximos, mínimos, médias e medianas, bem como suas diferenças entre os dois ambientes, encontram-se no Apêndice D, oferecendo uma visão detalhada do comportamento da EDA para todos os participantes.

Esses achados estão em consonância com pesquisas recentes que reforçam a utilidade da EDA como indicador fisiológico de engajamento e atenção. Stuldreher e Brouwer (2025) demonstraram que tanto o índice de correlação intersujeito da EDA (ISC-EDA) quanto a EDA fásica são eficazes para identificar padrões de atenção e momentos de maior envolvimento em ambientes reais, com destaque para a sensibilidade da EDA fásica na detecção de picos específicos de engajamento. De forma complementar, Jukiewicz e Marcinkowska (2025)

observaram que medidas estatísticas como média, mediana, valores máximos e mínimos são particularmente eficientes para distinguir estados de repouso de estímulos cognitivos ou emocionais, além de apresentarem alta correlação entre si, o que permite simplificações analíticas sem perda significativa de informação.


Esses resultados contribuem para uma seleção mais criteriosa dos indicadores de EDA, especialmente em estudos voltados à avaliação do engajamento cognitivo. Em complemento, Ananthan et al. (2024) evidenciaram diferenças nas respostas fisiológicas de estudantes em distintas disciplinas, associando padrões de EDA e sincronização fisiológica à natureza cognitiva e emocional das atividades. Nesse sentido, os dados obtidos neste estudo reforçam que variações nos índices de EDA refletem a complexidade das interações entre características individuais, conteúdo da atividade e ambiente de aprendizagem, oferecendo subsídios relevantes para a compreensão aprofundada do engajamento em contextos educacionais.

4.2 RESULTADOS HR

A análise da HR entre estudantes universitários, realizada durante sessões de ensino tradicional e de aprendizagem ativa, revelou diferenças no envolvimento fisiológico dos participantes. As representações gráficas ilustram o espectro das respostas de HR ao longo do tempo, destacando as distinções entre as abordagens pedagógicas adotadas. De modo semelhante ao observado nas medições de EDA, constataram-se diferenças significativas nas medianas de HR entre os dois métodos de ensino.


Entre os participantes, destaca-se o caso da estudante nº 19, sexo feminino, 22 anos, 170 cm, 63 kg, 3º ano do curso de Engenharia, que apresentou a maior diferença registrada na mediana da HR, com variação de 33 bpm. Nesse caso específico, os valores obtidos no ensino tradicional foram superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 18. Ressalta-se que esse exemplo é apresentado apenas de forma ilustrativa e não deve ser interpretado isoladamente, mas como parte do conjunto de respostas individuais que compõem a análise global da amostra.

Figura 18 - HR da Estudante 19




Em seguida, a estudante número 9, do sexo feminino, com 20 anos, 162 cm de altura, 52 kg de peso e cursando o 3º ano de Engenharia, apresentou diferença de 16 bpm na mediana da HR, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 19.

Figura 19 - HR da Estudante 9




A estudante número 42, do sexo feminino, com 23 anos, 165 cm de altura, 46 kg de peso e matriculado no 4º ano de Engenharia, apresentou diferença de 11 bpm na mediana da HR, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 20. Ressalta-se que as informações de idade, peso e altura foram registradas apenas para a caracterização geral da amostra, não tendo sido utilizadas nas análises comparativas, que se concentraram exclusivamente nos sinais fisiológicos.

Figura 20 - HR da Estudante 42




Já o estudante número 11, do sexo masculino, com 20 anos, 173 cm de altura, 65 kg de peso e cursando o 3º ano, registrou diferença de 10 bpm na mediana da HR, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 21.

Figura 21 - HR do Estudante 11




Outro participante de destaque foi o estudante número 20, do sexo masculino, com 22 anos, 174 cm de altura, 64 kg de peso e matriculado no 4º ano, que apresentou diferença de 9 bpm na mediana da HR, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 22.

Figura 22 - HR do Estudante 20




Por fim, a estudante número 18, do sexo feminino, com 25 anos, 149 cm de altura, 51 kg de peso e matriculado no 4º ano, apresentou diferença de 8 bpm na mediana da HR, sendo os valores obtidos na aprendizagem ativa superiores aos registrados no ensino tradicional, conforme ilustrado na Figura 23.

Figura 23 - HR da Estudante 18



As observações realizadas indicam que ambientes de aprendizagem ativa estiveram associados a níveis mais elevados de HR na maior parte dos participantes, sugerindo um impacto fisiológico compatível com maior engajamento atencional e emocional. Os gráficos correspondentes aos demais 44 estudantes encontram-se no Apêndice E, ampliando a análise e permitindo uma visão abrangente das variações nas respostas de HR entre os contextos pedagógicos. A Figura 24 apresenta as medianas gerais de HR dos participantes nos dois métodos de ensino, evidenciando as mudanças fisiológicas observadas. Ressalta-se, contudo, que a avaliação da eficácia da aprendizagem ativa em termos de desempenho acadêmico exigiria métricas adicionais específicas de rendimento, não contempladas neste estudo.

Figura 24 - Medianas de HR dos participantes



De modo geral, dos 50 estudantes analisados, 43 apresentaram valores medianos de HR mais altos durante a aprendizagem ativa, o que fortalece a evidência de que esse tipo de abordagem promove maior ativação do sistema nervoso simpático, relacionado ao envolvimento e à atenção. Além disso, medidas adicionais de HR, como valores máximos, valores mínimos, medias, medianas, diferenças das médias e diferenças medianas de HR para ambos os ambientes de aprendizagem foram fornecidas no Apêndice F, oferecendo uma visão detalhada dos dados de HR dos 50 estudantes participantes do estudo.

Esses resultados estão em consonância com evidências recentes que reforçam o papel da sincronização da HR como marcador de estados atencionais compartilhados. Hammond et al. (2024) demonstraram que a sincronização cardíaca entre indivíduos pode ocorrer mesmo na ausência de estímulos sensoriais complexos, sendo impulsionada por aspectos narrativos e cognitivos de alto nível, especialmente durante momentos emocionalmente ou cognitivamente exigentes. De forma complementar, Stuldreher et al. (2023) observaram que a sincronização fisiológica durante a exposição a narrativas está relacionada ao desempenho atencional posterior, indicando que a HR sincronizada reflete processos cognitivos sustentados, em contraste com a EDA, mais sensível a estímulos intensos e momentâneos.

Já Drachen et al. (2010) destacaram que a HR se correlaciona significativamente com medidas subjetivas de experiência do usuário, tanto positiva quanto negativamente, ao passo que a EDA apresenta maior especificidade para dimensões emocionais negativas. Esses achados


sustentam a ideia de que diferentes indicadores fisiológicos capturam aspectos distintos do engajamento e da experiência, sendo a HR uma via promissora para compreender o alinhamento atencional e emocional em contextos educacionais e interativos. Assim, os dados observados neste estudo apontam para a relevância da HR como marcador fisiológico entre os estudantes durante atividades com diferentes graus de complexidade cognitiva.

4.3 RESULTADOS ST

A análise da ST entre estudantes universitários, conduzida durante sessões de ensino tradicional e de aprendizagem ativa, revelou diferenças no engajamento fisiológico. As representações gráficas ilustram as variações nas respostas de ST ao longo do tempo, destacando as diferenças induzidas por cada abordagem pedagógica. De modo oposto ao observado nas medições de EDA e HR, verificaram-se diferenças mais pronunciadas nas medianas de ST no método de ensino tradicional, em comparação ao método de aprendizagem ativa.


O estudante identificado como número 49, do sexo masculino, com 20 anos de idade, 175 cm de altura, 66 kg de peso e matriculado no 4º ano do curso de Engenharia, apresentou a maior diferença registrada na mediana da ST, com variação de 6,1 °C, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 25.

Figura 25 - ST do Estudante 49




Em seguida, o estudante número 48, também do sexo masculino, com 28 anos, 175 cm de altura, 74 kg de peso e cursando o 1º ano de Engenharia, apresentou diferença de 4,3 °C na mediana da ST, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 26.

Figura 26 - ST do Estudante 48




A estudante número 18, do sexo feminino, com 25 anos, 149 cm de altura, 51 kg de peso e matriculada no 4º ano de Engenharia, apresentou diferença de 3,7 °C na mediana da ST, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 27.

Figura 27 - ST da Estudante 18




Já a estudante número 9, do sexo feminino, com 20 anos, 162 cm de altura, 52 kg de peso e cursando o 3º ano, registrou diferença de 3,0 °C na mediana da ST, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 28.

Figura 28 - ST da Estudante 9




Outro participante de destaque foi o estudante número 13, do sexo masculino, com 24 anos, 170 cm de altura, 81 kg de peso e matriculado no 5º ano, que apresentou diferença de 2,9 °C na mediana da ST, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 29.

Figura 29 - ST do Estudante 13




Por fim, o estudante número 23, do sexo masculino, com 24 anos, 170 cm de altura, 55 kg de peso e matriculado no 2º ano, apresentou diferença de 2,8 °C na mediana da ST, sendo os valores obtidos no ensino tradicional superiores aos observados na aprendizagem ativa, conforme ilustrado na Figura 30.

Figura 30 - ST do Estudante 23



Essas observações indicam que a ST foi consideravelmente inferior durante a aprendizagem ativa, sugerindo uma intensificação da excitação autonômica, em consonância com os aumentos observados nos índices de EDA e HR nas seções anteriores. Os gráficos correspondentes aos demais 44 estudantes foram disponibilizados no Apêndice G, ampliando a análise e permitindo uma avaliação abrangente das variações nas respostas de ST. A Figura 31 apresenta as medianas gerais das medições de ST dos participantes nos contextos de aula tradicional e aprendizagem ativa.

Figura 31 - Medianas de ST dos participantes



De modo geral, entre os 50 estudantes analisados, 44 apresentaram valores medianos de ST mais elevados durante o ensino tradicional, em contraste com os resultados obtidos para EDA e HR. Informações adicionais, incluindo valores máximos, mínimos, médias, medianas, diferenças entre médias e diferenças entre medianas nos dois ambientes educacionais, encontram-se no Apêndice H, oferecendo uma visão detalhada do comportamento fisiológico dos 50 estudantes analisados.


Os achados observados neste estudo reforçam a relevância da ST como indicador fisiológico associado tanto ao conforto térmico quanto à regulação autonômica e emocional. De acordo com Song et al. (2024), a temperatura média e local da pele, especialmente em regiões sensíveis como o rosto e as mãos, está intimamente relacionada à percepção subjetiva de conforto térmico, sendo influenciada por fatores individuais e contextuais, como idade, gênero e clima. Esses aspectos são particularmente relevantes em ambientes dinâmicos, como salas de aula, onde pequenas variações térmicas podem impactar a concentração e o bem-estar.

Complementarmente, Ichiba et al. (2019) demonstraram que o aquecimento de áreas específicas, como a região periocular, pode promover sensações de sonolência e relaxamento, associadas à ativação parassimpática e à vasodilatação periférica, sem alterar a temperatura central. Tais efeitos fisiológicos, mediados por mecanismos autonômicos, sugerem que intervenções térmicas pontuais podem modular estados psicofisiológicos de alerta e

relaxamento. Por fim, Mifsud et al. (2022) destacam a importância da monitorização contínua da temperatura cutânea para fins clínicos, evidenciando que elevações sutis podem sinalizar riscos teciduais em populações vulneráveis. Em conjunto, essas evidências sustentam o potencial da ST como um marcador sensível e multifacetado de conforto, regulação fisiológica e risco clínico, com aplicações promissoras em contextos educacionais e de saúde.

4.4 MATRIZES DE CORRELAÇÃO

Com o intuito de aprofundar a compreensão acerca das interrelações entre os sinais fisiológicos dos participantes, EDA, HR e ST, foram construídas matrizes de correlação de Spearman para os dois contextos pedagógicos analisados, aprendizagem ativa e ensino tradicional. A escolha do coeficiente de Spearman se justifica pela natureza não paramétrica dos dados e pela necessidade de captar associações monotônicas entre as variáveis, sem pressupor linearidade ou normalidade nas distribuições. Esta abordagem é particularmente adequada frente à heterogeneidade fisiológica entre os indivíduos, conforme a Figura 32.



Fonte: Elaborado pelo autor (2025).

As análises evidenciaram correlações de baixa magnitude em ambos os contextos. No ambiente de aprendizagem ativa, os coeficientes foram EDA_A vs HR_A = -0,086; EDA_A vs ST_A = 0,15; HR_A vs ST_A = -0,061. Observa-se, nesse caso, uma correlação levemente positiva entre EDA e ST, o que pode sugerir, de forma marginal, uma tendência de elevação da ST em resposta ao aumento da excitação simpática. Entretanto, tal padrão não é suficientemente forte para indicar uma associação estatística robusta. De forma semelhante, no contexto tradicional, os coeficientes obtidos foram: EDA_T vs HR_T = -0,083; EDA_T vs ST_T = -

0,12; HR_T vs ST_T = -0,034. Embora a correlação negativa entre EDA e ST tenha sido ligeiramente mais pronunciada, ela ainda se manteve dentro de uma faixa que denota associação fraca e sem relevância prática consolidada.

É importante destacar que, dado o tamanho da amostra ($n = 50$), as correlações observadas estão sujeitas a uma margem de erro estatístico considerável. Em estudos com esse porte, associações fracas podem facilmente resultar de flutuações amostrais e, portanto, exigem cautela em sua interpretação. O impacto do tamanho da amostra se manifesta na limitação da potência estatística, dificultando a detecção de associações sutis entre variáveis fisiológicas. Isso significa que, em uma replicação com uma amostra maior e mais diversa, é provável que a variância global dos dados aumente, permitindo maior estabilidade dos coeficientes e, possivelmente, revelando padrões mais consistentes de associação.

Do ponto de vista prático, a taxa de variação observada nas correlações sugere que a resposta fisiológica ao engajamento educacional não se dá de maneira uniforme entre os estudantes. A ausência de correlações implica que os sinais de EDA, HR e ST devem ser interpretados individualmente ou em abordagens multimodais mais sofisticadas, ao invés de utilizados de forma isolada como indicadores diretos de engajamento. Essa constatação reforça a necessidade de abordagens analíticas que considerem a complexidade das respostas psicofisiológicas em ambientes de aprendizagem e estimula o desenvolvimento de modelos preditivos personalizados, apoiados por IA.

Em síntese, os resultados das matrizes de correlação de Spearman corroboram a natureza multifatorial do engajamento acadêmico e demonstram que os sinais fisiológicos avaliados não apresentam associações lineares ou monotônicas relevantes entre si, em nenhum dos contextos educacionais analisados. Tais achados estão alinhados com evidências de que fatores como o estilo de apresentação ou a presença visual de instrutores em vídeos instrucionais, embora possam atrair a atenção do estudante, nem sempre impactam significativamente o aprendizado ou variáveis psicológicas relevantes (Lee & Muldner, 2020). Além disso, aspectos relacionados às expectativas dos professores e à qualidade do feedback aos alunos demonstram influência indireta sobre o desempenho, reforçando a necessidade de considerar múltiplas variáveis contextuais e cognitivas ao analisar a eficácia de métodos educacionais (Gentrup et al., 2020).

4.5 RESULTADOS ML

Os dados fisiológicos coletados, EDA, HR e ST, durante a aplicação de ambos os métodos de ensino foram submetidos a um processo de padronização e normalização utilizando o escore

de mediana (*Robust Z-score*), conforme ilustrado no Apêndice I. Esta abordagem foi escolhida por sua robustez frente à presença de outliers, característica comum em dados fisiológicos.

A normalização foi realizada individualmente para cada variável fisiológica e para cada estudante, utilizando a Equação (1):

$$z_i = \frac{x_i - \text{mediana}(X)}{\text{MAD}(X)} \quad (1)$$

Em que:

- x_i representa o valor original da série temporal da variável fisiológica;
- $\text{mediana}(X)$ corresponde à mediana de todos os valores da série;
- $\text{MAD}(X)$ é o desvio absoluto mediano, calculado conforme a Equação (2):

$$\text{MAD}(X) = \text{mediana}(|x_i - \text{mediana}(X)|) \quad (2)$$

Esse procedimento garantiu que as medidas fisiológicas estivessem em escalas comparáveis entre os participantes, possibilitando uma análise mais precisa dos efeitos dos diferentes métodos de ensino a partir das métricas derivadas e utilizadas nas etapas subsequentes de modelagem de ML.

4.5.1 Algoritmos de classificação

O conjunto total de dados analisados foi composto por 28.125 registros, coletados a partir de 50 estudantes durante as atividades de aprendizagem ativa. Cada segundo da atividade correspondia simultaneamente à aquisição de um dado de EDA, um dado de HR e um dado de ST. Assim, os 28.125 registros equivalem a 28.125 segundos de tempo de participação dos estudantes nessas atividades. A divisão dos dados em conjunto de treino e teste foi realizada com proporção de 80% para treino (22.500 dados) e 20% para teste (5.625 dados), preservando o balanceamento entre as classes "Engajado" e "Desengajado". Os algoritmos de classificação SVM, LR, RF, KNN e ANN foram aplicados aos dados categorizados da "Nota Final", com classes engajado e desengajado, conforme apresentado o desempenho de cada modelo na Tabela 10.

Tabela 10 - Desempenho dos modelos com algoritmos de classificação

Modelo	Acurácia	Engajado			Desengajado		
		Precisão	Recall	F1-Score	Precisão	Recall	F1-Score
RF	78%	0.74	0.66	0.69	0.80	0.85	0.83
KNN	72%	0.66	0.58	0.62	0.76	0.81	0.78
ANN	65%	0.63	0.24	0.35	0.66	0.91	0.76
SVM	63%	0.85	0.05	0.10	0.63	0.99	0.77
LR	62%	1.00	0.01	0.01	0.62	1.00	0.76

Fonte: Elaborado pelo autor (2025).

A acurácia, conforme a Equação (3), foi utilizada como a primeira métrica de avaliação, representando a proporção de classificações corretas em relação ao total de observações. Essa métrica fornece uma visão geral do desempenho do modelo, sendo especialmente útil em cenários equilibrados entre classes.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

Em que:

- **TP** representa o valor verdadeiro positivo;
- **TN** representa o valor verdadeiro negativo;
- **FP** representa o valor falso positivo;
- **FN** representa o valor falso negativo;

A precisão, apresentada na Equação (4), quantifica a proporção de instâncias corretamente identificadas como pertencentes à classe positiva em relação a todas as instâncias classificadas como tal. Em outras palavras, avalia o quão confiáveis são as previsões positivas feitas pelo modelo.

$$Precisão = \frac{TP}{TP + FP} \quad (4)$$

O recall, definido na Equação (5), corresponde à proporção de instâncias positivas corretamente identificadas em relação ao total de instâncias positivas reais. Essa métrica é particularmente relevante em problemas nos quais a identificação de todos os casos positivos é crítica, mesmo que à custa de um maior número de falsos positivos.

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

Para combinar as métricas de precisão e recall em uma única medida, foi utilizado o F1-score, definido na Equação (6). Essa métrica corresponde à média harmônica entre precisão e recall, equilibrando os dois indicadores e fornecendo uma avaliação mais robusta do desempenho do modelo em cenários com classes desbalanceadas.

$$F1 = 2 \cdot \frac{Precisão \cdot Recall}{Precisão + Recall} \quad (6)$$


A análise dos modelos de classificação aplicados aos dados categorizados da "Nota Final" revelou diferenças no desempenho entre os algoritmos testados. O modelo RF apresentou os melhores resultados gerais, com uma acurácia de 77,8% e desempenho equilibrado entre as classes "Engajado" e "Desengajado". Esse modelo conseguiu identificar corretamente uma proporção significativa de estudantes em ambas as categorias, com F1-scores de 69,4% e 82,6%, respectivamente, demonstrando ser o mais robusto para o conjunto de dados analisado.

O algoritmo KNN também se mostrou consistente, atingindo uma acurácia de 72,3% e um desempenho razoável na identificação das duas classes, embora com métricas levemente inferiores às do RF. Em contraste, os modelos SVM e RL apresentaram forte viés para a classe "Desengajado", resultando em baixíssima revocação para a classe "Engajado", o que compromete sua capacidade de generalização para os casos de maior interesse. O modelo de ANN demonstrou desempenho intermediário, apesar de superar SVM e regressão logística na detecção de "Engajados", sua revocação para essa classe ainda foi limitada, o que impactou negativamente o equilíbrio do modelo. Esses resultados indicam que, sem ajustes adicionais, os modelos mais simples tendem a favorecer a classe majoritária, enquanto o RF, com sua capacidade de modelar relações mais complexas e lidar com variações nos dados, se destacou como a abordagem mais eficaz para essa tarefa.

As matrizes de confusão dos cinco modelos de classificação permitem observar, de forma clara, como cada algoritmo distribuiu as instâncias entre as classes "Engajado" e "Desengajado". A diagonal principal de cada matriz representa as instâncias corretamente classificadas, correspondendo aos acertos de previsão, enquanto a diagonal secundária indica as instâncias classificadas de forma incorreta, como nos casos em que estudantes da classe "Desengajado" foram preditos como "Engajado", evidenciando erros de classificação e confusões entre categorias.

A matriz de confusão do modelo RF, apresentada na Figura 33, demonstra um desempenho equilibrado, com identificação correta de uma proporção significativa de estudantes tanto “Engajados” quanto “Desengajados” e com redução notável nos índices de falsos negativos e falsos positivos. Tal comportamento se traduz em maior precisão e revocação para ambas as classes, confirmando a superioridade do RF em relação aos demais algoritmos.


Figura 33 - Matriz de confusão da classificação RF



Fonte: Elaborado pelo autor (2025).

O modelo KNN, ilustrado na Figura 34, também apresenta desempenho equilibrado, embora inferior ao RF, especialmente na identificação de “Engajados”. Ainda assim, o número de acertos para ambas as classes é substancial e as taxas de falsos negativos e falsos positivos permanecem dentro de limites aceitáveis.


Figura 34 - Matriz de confusão da classificação KNN



Fonte: Elaborado pelo autor (2025).

A matriz de confusão da ANN, representada na Figura 35, revela um comportamento intermediário. O modelo consegue identificar uma parte considerável dos “Desengajados” e, embora acerte alguns casos de “Engajados”, apresenta uma quantidade relevante de falsos negativos para essa categoria. Esse padrão indica poder discriminativo moderado, mas sugere a necessidade de ajustes para melhorar a sensibilidade à classe minoritária.


Figura 35 - Matriz de confusão da classificação ANN



Fonte: Elaborado pelo autor (2025).

A LR, ilustrada na Figura 36, apresenta um padrão mais extremo, classificando praticamente todas as instâncias como “Desengajado” e falhando quase completamente na detecção de “Engajados”. Essa configuração resulta em precisão de 100% para a classe “Engajado”, decorrente da ausência de falsos positivos, mas com revocação irrelevante, evidenciando um viés pronunciado em favor da classe mais frequente.


Figura 36 - Matriz de confusão da classificação LR



Fonte: Elaborado pelo autor (2025).

Por sua vez, o SVM, cuja matriz está apresentada na Figura 37, exibe severa assimetria na classificação. O modelo praticamente ignora a classe “Engajado”, com pouquíssimos acertos, concentrando-se na classificação da maioria das instâncias como “Desengajado”. Isso leva a uma elevada taxa de verdadeiros negativos, mas também a uma alta taxa de falsos negativos para a classe minoritária.

Figura 37 - Matriz de confusão da classificação SVM




Fonte: Elaborado pelo autor (2025).

De modo geral, as matrizes de confusão corroboram os padrões observados nas métricas globais de desempenho e evidenciam o grau de desequilíbrio no reconhecimento das classes. Os modelos que não incorporam estratégias explícitas de balanceamento tendem a privilegiar a classe majoritária, enquanto apenas o RF, e em menor medida o KNN e a ANN, conseguiram manter desempenho relativamente simétrico, mostrando-se mais adequados ao problema em estudo.

Para facilitar a visualização comparativa, a Figura 38 apresenta gráficos de barras com as métricas de precisão, revocação e F1-score para a classe “Engajado”. Nessa comparação, observa-se diferença entre os modelos, com o RF destacando-se por apresentar os maiores valores em todas as métricas, indicando maior eficácia na detecção de estudantes engajados, combinando alta precisão com elevada capacidade de identificar os casos reais da classe, o que resulta em F1-score expressivo.


Figura 38 - Métricas para a classe Engajado



Fonte: Elaborado pelo autor (2025).

A Figura 39, por sua vez, apresenta as mesmas métricas para a classe “Desengajado”, permitindo avaliar o desempenho relativo de cada modelo também para a categoria majoritária e reforçando as conclusões obtidas a partir das matrizes de confusão.

Figura 39 – Métricas para a classe Desengajado



Fonte: Elaborado pelo autor (2025).

No gráfico referente à classe “Engajado”, observa-se uma diferença entre os modelos. O algoritmo RF se destaca com os maiores valores em todas as métricas, precisão, revocação e F1-score. Isso indica que, entre os modelos testados, o RF é o mais eficaz na detecção de estudantes engajados, conseguindo não apenas acertar quando prediz essa classe (alta precisão), mas também identificar uma proporção dos engajados reais (revocação), resultando em um F1-score expressivo.

O KNN apresenta um desempenho também consistente, embora um pouco inferior, mantendo um bom equilíbrio entre as três métricas. Já o modelo de ANN mostra uma precisão aceitável, mas uma revocação baixa, refletindo sua dificuldade em detectar engajados com consistência. Os modelos SVM e LR, por sua vez, têm desempenhos visivelmente

insatisfatórios para essa classe, embora a precisão da SVM seja elevada, sua revocação é extremamente baixa, o que compromete severamente o F1-score. No caso da RL, a revocação é praticamente nula, sinalizando que o modelo não consegue identificar estudantes engajados.

Já no gráfico da classe “Desengajado”, nota-se uma inversão de desempenho nos modelos menos eficazes para engajados. Tanto o SVM quanto a LR apresentam valores altos de revocação e F1-score para desengajados, evidenciando o viés desses modelos para a classe majoritária. Entretanto, esse bom desempenho ocorre às custas da incapacidade de reconhecer a classe oposta.

O RF mantém novamente o melhor desempenho geral, com as três métricas bem distribuídas e superiores, consolidando-se como o modelo mais equilibrado. O KNN também apresenta métricas robustas para desengajados, apenas ligeiramente inferiores às do RF. A ANN, embora tenha uma revocação bastante alta (superior a 90%), apresenta uma precisão moderada, indicando que tende a superestimar a presença de desengajados, o que reduz seu F1-score.

Em resumo, os gráficos confirmam visualmente a superioridade do RF, seguido pelo KNN. Ambos conseguem tratar adequadamente o desequilíbrio entre as classes e manter bons níveis de desempenho em ambas as categorias. Modelos como SVM e LR, embora apresentem resultados altos para a classe “Desengajado”, falham de forma crítica na identificação de “Engajados”, o que os torna inadequados para aplicações em que essa classe é relevante. A ANN, por sua vez, apresenta um desempenho misto, com espaço para melhoria especialmente na identificação da classe minoritária. Essa análise reforça a importância de considerar não apenas a acurácia global, mas também o desempenho individual por classe, sobretudo em cenários com distribuição desigual dos rótulos.

4.5.2 Algoritmos de regressão

Os algoritmos de regressão *Linear Regression*, *SVR*, *Gradient Boosting Regressors*, *KNN Regressor* e *MLP Regressor* foram aplicados para prever a "Nota Final" como uma variável contínua. O modelo *Gradient Boosting Regressor* apresentou o melhor desempenho entre os testados, com o menor erro quadrático médio ($MSE \approx 4,35$) e o maior coeficiente de determinação ($R^2 \approx 0,143$), indicando que consegue explicar cerca de 14,3% da variabilidade dos dados. O *KNN Regressor* teve desempenho semelhante, seguido pelo *MLP Regressor* e *SVR*. O *Linear Regression* foi a que menos se ajustou aos dados, com R^2 próximo de zero, conforme demonstrado na Tabela 11.

Tabela 11 - Desempenho dos modelos com algoritmos de regressão

Modelo	MSE	R ²
Gradient Boosting	4.352	0.143
KNN Regressor	4.399	0.134
MLP Regressor	4.721	0.070
SVR	4.848	0.045
Linear Regression	5.049	0.006

Fonte: Elaborado pelo autor (2025).

O Erro Quadrático Médio (MSE), descrito na Equação (7), mede a média dos quadrados das diferenças entre os valores previstos e os valores reais observados. Quanto menor o MSE, mais próximo o modelo está de reproduzir os valores observados, refletindo maior acurácia preditiva.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

O coeficiente de determinação (R²), conforme a Equação (8), expressa a proporção da variabilidade da variável dependente que é explicada pelo modelo em relação à variabilidade total dos dados. Valores de R² próximos de 1 indicam forte capacidade explicativa, enquanto valores próximos de 0 sinalizam baixo poder preditivo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

A tabela de desempenho dos modelos de regressão revela diferenças na capacidade preditiva de cada algoritmo ao estimar a variável contínua "Nota Final". Dois indicadores principais foram utilizados, o Erro Quadrático Médio (MSE), que mede o erro absoluto médio ao quadrado entre os valores reais e preditos (quanto menor, melhor), e o coeficiente de determinação (R²), que expressa a proporção da variância da variável dependente explicada pelo modelo (quanto mais próximo de 1, melhor o ajuste).

O modelo *Gradient Boosting Regressor* apresentou o melhor desempenho global, com o menor MSE ($\approx 4,35$) e o maior R² ($\approx 0,143$). Contudo, o valor de R² foi baixo, o que demonstra que, nesse caminho, os modelos testados não alcançaram resultados significativos para prever a “Nota Final”. O desempenho relativamente superior do *Gradient Boosting*, em comparação

aos demais, indica apenas uma leve vantagem, mas ainda insuficiente para garantir poder preditivo consistente.

O *KNN Regressor* apresentou um desempenho próximo ao do *Gradient Boosting*, com MSE ligeiramente superior ($\approx 4,40$) e R^2 de aproximadamente 0,134. O modelo se beneficia da simplicidade e da ausência de pressupostos sobre a forma funcional da relação entre as variáveis, o que pode ser vantajoso quando os dados possuem padrões locais relevantes. Contudo, sua eficácia depende da distribuição dos dados no espaço de entrada e pode ser afetada por ruído.

O *MLP Regressor*, que utiliza uma rede neural artificial, mostrou desempenho intermediário, com MSE de 4,72 e R^2 de 0,070. Embora esse resultado indique que o modelo capturou alguma estrutura nos dados, ele ainda ficou distante dos melhores desempenhos. Vale destacar que redes neurais costumam demandar ajustes mais refinados de hiperparâmetros e podem ter dificuldade de convergência em dados com ruído ou baixa dimensionalidade.


O *SVR* teve desempenho semelhante ao *MLP*, com MSE de 4,85 e R^2 de 0,045. Apesar de sua robustez teórica, o modelo não conseguiu capturar adequadamente a variabilidade da “Nota Final”, possivelmente por limitações na escolha do kernel ou sensibilidade à escala dos dados.

Por fim, o *Linear Regression* obteve o pior desempenho entre os modelos testados. Seu MSE foi o mais alto ($\approx 5,05$) e o R^2 foi praticamente nulo ($\approx 0,006$), o que indica que o modelo falhou em explicar a variância da variável dependente. Esse resultado sugere que a relação entre as variáveis explicativas e a “Nota Final” não é linear, tornando o modelo inadequado para essa tarefa.

Em resumo, os resultados indicam que modelos baseados em aprendizado não linear e métodos de *ensemble* (conjunto de várias árvores de decisão), como o *Gradient Boosting*, são mais adequados para prever a “Nota Final” neste conjunto de dados. A escolha do modelo deve considerar tanto a capacidade preditiva quanto a complexidade e interpretabilidade, e ajustes adicionais podem contribuir para melhorar ainda mais os resultados obtidos.


Com o intuito de apresentar de forma mais clara os resultados obtidos, a Figura 40 exibe gráficos de barras que comparam o desempenho dos modelos preditivos com base no MSE, possibilitando identificar, de maneira objetiva, os algoritmos que melhor se ajustam à tarefa de prever a “Nota Final” como variável contínua.

Figura 40 – Comparação de desempenho - MSE



Fonte: Elaborado pelo autor (2025).

Enquanto a Figura 41 apresenta gráficos de barras que comparam os modelos preditivos com base no R^2 . Esses dois indicadores oferecem perspectivas complementares, enquanto o MSE quantifica o erro médio absoluto ao quadrado entre os valores observados e preditos (sendo desejável valores menores), o R^2 expressa a proporção da variância dos dados explicada pelo modelo (quanto mais próximo de 1, melhor).

Figura 41 – Comparação de desempenho - R^2 

Fonte: Elaborado pelo autor (2025).

O modelo *Gradient Boosting Regressor* se destaca nos dois gráficos como aquele que obteve, relativamente, o melhor desempenho. Ele apresentou o menor valor de MSE entre todos os modelos testados, indicando previsões ligeiramente mais próximas dos valores reais. Entretanto, mesmo tendo alcançado o maior R^2 ($\approx 0,143$), esse valor permaneceu baixo, revelando que a variabilidade da “Nota Final” não foi explicada de forma significativa. Esse resultado reforça que, embora técnicas de ensemble como o *Gradient Boosting* tenham maior potencial que abordagens lineares simples, no presente contexto não atingiram poder preditivo satisfatório.

Em segundo lugar aparece o *KNN Regressor*, que também apresentou desempenho sólido. Seu MSE foi apenas ligeiramente superior ao do *Gradient Boosting*, e o R^2 , embora menor, ainda evidenciou boa capacidade explicativa. A abordagem do KNN, baseada na similaridade entre instâncias, pode ser eficaz quando há estrutura local nos dados, embora sua performance dependa da distribuição e densidade dos pontos de treinamento.

Os modelos *MLP Regressor* e *SVR* apresentaram desempenhos intermediários. Ambos obtiveram valores de MSE moderadamente altos e R^2 baixos, o que indica que suas previsões apresentam erro considerável e explicam uma parcela pequena da variabilidade da variável alvo. No caso da MLP, o desempenho pode estar relacionado à necessidade de ajuste fino nos hiperparâmetros ou à complexidade do modelo frente à quantidade e estrutura dos dados. Já o SVR pode ter sido limitado pela escolha do kernel ou por sensibilidade à escala e à dispersão dos dados.

O *Linear Regression* foi claramente o modelo com pior desempenho. Seu MSE foi o mais elevado, e o R^2 foi praticamente nulo, indicando que o modelo falhou em capturar qualquer estrutura explicativa útil nos dados. Esse resultado evidencia a inadequação de uma abordagem linear simples para um problema que parece exigir modelagem de relações mais complexas entre as variáveis fisiológicas e a “Nota Final”.

Em conjunto, os gráficos mostram que os modelos não lineares, especialmente os baseados em *ensemble* como o *Gradient Boosting*, são os mais apropriados para esse problema de previsão. A escolha do modelo deve considerar não apenas a performance bruta, mas também a complexidade computacional, interpretabilidade e necessidade de ajuste fino. Esses resultados sugerem que abordagens mais sofisticadas são justificadas para alcançar previsões mais confiáveis e úteis nesse contexto.

4.5.3 Modelos preditivos

A construção dos modelos preditivos partiu da aplicação de algoritmos de ML aos dados fisiológicos padronizados e normalizados dos participantes. As variáveis envolvidas, EDA, HR e ST, foram tratadas por meio da normalização robusta baseada no escore de mediana, conforme detalhado no Apêndice I, garantindo maior resistência à presença de outliers, característica típica de sinais fisiológicos.

Para a tarefa de classificação do engajamento estudantil (classes "Engajado" e "Desengajado"), os dados foram divididos em conjuntos de treino (80%) e teste (20%), mantendo o balanceamento entre as classes. Foram testados os algoritmos RF, KNN, ANN,

SVM e LR. O modelo RF apresentou o melhor desempenho geral, com acurácia de 78% e equilíbrio entre precisão, revocação e F1-score para ambas as classes, destacando-se como o mais robusto para a tarefa de classificação. Os modelos KNN e ANN também demonstraram desempenho razoável, enquanto SVM e LR apresentaram forte viés para a classe majoritária ("Desengajado"), com baixa capacidade de identificar estudantes engajados.

As matrizes de confusão e os gráficos comparativos evidenciaram que apenas os modelos mais sofisticados, como RF, conseguiram balancear adequadamente as taxas de erro e acerto entre as classes. O desempenho dos modelos foi impactado pela assimetria dos dados e pela complexidade das relações fisiológicas com os estados de engajamento. Assim, a RF se mostrou a abordagem mais adequada para aplicações educacionais que demandam sensibilidade a ambas as categorias comportamentais.

Em paralelo, foram implementados modelos de regressão para prever a “Nota Final” como variável contínua. Entre os algoritmos testados, *Linear Regression*, SVR, KNN Regressor, MLP Regressor e *Gradient Boosting*, o *Gradient Boosting* apresentou o melhor desempenho, com menor erro quadrático médio ($MSE = 4,35$) e maior $R^2 (\approx 0,143)$. No entanto, como o R^2 obtido em todos os algoritmos foi baixo, essa abordagem não gerou resultados significativos para prever a variabilidade da nota a partir dos sinais fisiológicos. O caso do *Linear Regression*, com R^2 praticamente nulo, evidencia de forma ainda mais clara a limitação de modelos lineares nesse tipo de aplicação.

De forma geral, os resultados confirmam a viabilidade do uso de modelos preditivos para analisar e antecipar o engajamento estudantil com base em dados fisiológicos. Modelos como RF e *Gradient Boosting* se destacam como alternativas eficazes, particularmente pela sua capacidade de lidar com dados complexos, desbalanceados e com múltiplas variáveis correlacionadas. Esses achados reforçam o potencial de aplicações baseadas em ML para o desenvolvimento de estratégias pedagógicas adaptativas, personalizadas e baseadas em evidências fisiológicas.

Em linhas gerais, os resultados confirmam a viabilidade do uso de modelos preditivos para analisar e antecipar o engajamento estudantil com base em dados fisiológicos. Modelos como RF e *Gradient Boosting* se destacam como alternativas eficazes, particularmente pela sua capacidade de lidar com dados complexos, desbalanceados e com múltiplas variáveis correlacionadas. Nesse sentido, estudos prévios têm demonstrado o potencial de algoritmos baseados em *ensemble*, como RF, *XGBoost* e *LightGBM*, na detecção precisa de estresse e emoções por meio de sinais fisiológicos coletados por sensores vestíveis. Por exemplo, Gedam, Dutta e Jha (2025) desenvolveram um modelo de baixo custo baseado em sensores conectados

a microcontroladores Arduino, alcançando 97,5% de acurácia em testes em tempo real para detecção de estresse mental, com latência inferior a 1,2s. Zhou, Chen e Lei (2022) propuseram um modelo explicável para reconhecimento de emoções, combinando o algoritmo *LightGBM* com a técnica SHAP, demonstrando desempenho superior na classificação emocional a partir de dados fisiológicos esparsamente rotulados.

Complementarmente, Kang et al. (2023) identificaram correlações relevantes entre estresse e desempenho acadêmico, utilizando sinais como EDA, HR e ST, e destacaram o valor de estratégias baseadas em estresse ótimo para maximizar o rendimento. Já Sepanloo et al. (2025) utilizaram algoritmos de *stacking* com validação cruzada para classificar o estresse de estudantes em ambientes de realidade mista, alcançando 98% de acurácia, o que reforça a aplicabilidade de modelos robustos em cenários educacionais.

4.6 ANÁLISE COMPARATIVA COM ESTUDOS DA LITERATURA

Os resultados obtidos neste estudo demonstram forte consonância com as evidências previamente relatadas na literatura científica. Em especial, os padrões observados na EDA no contexto de metodologias de aprendizagem ativa reforçam sua validade como indicador sensível do engajamento acadêmico, conforme demonstrado por McNeal et al. (2020), que observaram aumento da EDA em estudantes durante atividades em grupo e redução em momentos de escuta passiva, destacando o potencial dos biossensores como ferramentas formativas no ensino de ciências biológicas em ambientes de aprendizagem ativa. Resultados similares foram relatados por Darnell e Krieg (2019), Kozanitis (2023) e Stuldreher e Brouwer (2025), que identificaram elevação da EDA em contextos pedagógicos baseados em metodologias ativas, sugerindo sua associação com maior atenção e envolvimento dos estudantes.

Entre os 50 estudantes analisados, 48 apresentaram valores medianos de EDA mais elevados durante atividades de aprendizagem ativa, o que corrobora a hipótese de que tais abordagens promovem maior ativação do sistema nervoso simpático, responsável por processos fisiológicos associados à atenção e ao envolvimento cognitivo. Essa interpretação é corroborada por Villanueva et al. (2018) e Horvers et al. (2021), cujos estudos demonstraram que a EDA aumenta durante tarefas que exigem processamento cognitivo ativo e engajamento emocional, reforçando sua utilidade como marcador fisiológico em ambientes educacionais.

Em relação à HR e à ST, os achados empíricos também se alinham às tendências identificadas em estudos anteriores. No caso da HR, observou-se que 43 dos 50 estudantes

apresentaram elevações medianas durante a aprendizagem ativa, reforçando a associação entre esse tipo de metodologia e estados de maior excitação fisiológica. Conforme evidenciado por Ladino Nocua et al. (2021) e Khan et al. (2019), variações na HR durante atividades ativas refletem alterações no estado de excitação e esforço mental, sendo consistentes com a ativação do sistema nervoso autônomo simpático.

Por outro lado, os dados de ST revelaram uma tendência oposta, 44 estudantes apresentaram valores medianos mais elevados durante o ensino tradicional. Este resultado, em consonância com a literatura, sugere que a redução da temperatura periférica pode estar relacionada ao aumento do engajamento em contextos mais desafiadores, como aqueles promovidos pelas estratégias ativas, dado que a vasoconstrição periférica é uma resposta típica à ativação simpática. Esse padrão foi previamente relatado por Quintero e Bolkhovsky (2019), que observaram uma correlação entre temperatura cutânea, EDA e desempenho cognitivo, sugerindo um papel termorregulatório na função executiva e no engajamento durante atividades cognitivas intensas.

Adicionalmente, no que se refere à capacidade preditiva dos estados de engajamento com base em variáveis fisiológicas, os resultados confirmam a viabilidade do uso de modelos de ML. Em particular, os algoritmos RF e *Gradient Boosting* demonstraram desempenho superior, destacando-se por sua robustez na manipulação de dados complexos, desbalanceados e multivariados. Tais achados estão em consonância com os estudos de Gao et al. (2025) e Ponce-Naranjo et al. (2023), que aplicaram modelos de ML a dados fisiológicos, incluindo EDA, HR e ST, para prever estados emocionais e cognitivos, destacando a acurácia do algoritmo RF em contextos pedagógicos complexos.

Tais modelos emergem, portanto, como ferramentas promissoras para o monitoramento contínuo e a antecipação de estados de engajamento em ambientes educacionais mediados por tecnologia. Nesse sentido, a proposta de Pérez et al. (2018) demonstra a viabilidade da integração de dispositivos vestíveis comerciais com sistemas de análise automática, permitindo a coleta de dados fisiológicos em tempo real, com potencial aplicação no apoio a decisões pedagógicas em contextos de ensino superior.

5 CONSIDERAÇÕES FINAIS

5.1 CONCLUSÕES

A presente pesquisa teve como propósito central investigar as correlações entre as variações nas respostas fisiológicas, EDA, HR e ST, de estudantes universitários em distintos contextos educacionais, a fim de desenvolver e validar modelos preditivos baseados em algoritmos de ML, voltados à antecipação de padrões fisiológicos associados ao engajamento estudantil. Para tal, foram delineados objetivos específicos que permitiram analisar o comportamento dessas variáveis em atividades pedagógicas variadas, explorar suas associações com diferentes níveis de engajamento e avaliar o desempenho de técnicas de ML na modelagem preditiva desses estados.

Os achados empíricos revelaram forte convergência com a literatura científica recente, reforçando a validade da EDA como um marcador sensível das respostas autonômicas em ambientes de aprendizagem ativa. A maior parte dos estudantes apresentou elevações de EDA durante tarefas ativas, o que está em linha com estudos que associam tais respostas à ativação simpática. Entretanto, é importante destacar que níveis muito elevados de excitação fisiológica podem caracterizar hiperativação simpática, condição que, em vez de favorecer, pode suprimir a atenção e o processamento cognitivo. A HR também apresentou tendência ascendente nessas condições, embora com menor consistência, corroborando pesquisas que a relacionam a estados de esforço mental. Em contrapartida, os dados de ST mostraram valores médios mais altos em contextos tradicionais, enquanto valores mais baixos nas atividades ativas podem indicar maior atividade simpática periférica, associada a situações de maior demanda cognitiva e emocional.

Complementarmente, os modelos preditivos desenvolvidos a partir das variáveis fisiológicas, com destaque para os algoritmos RF e *Gradient Boosting*, demonstraram elevada acurácia na antecipação de estados de engajamento, evidenciando a aplicabilidade de abordagens de ML em ambientes educacionais mediados por tecnologia. Tais resultados reforçam a viabilidade do uso de biossensores e sistemas inteligentes como instrumentos de apoio ao planejamento pedagógico, contribuindo para uma educação mais responsiva, adaptativa e centrada no estudante.

Entretanto, é importante reconhecer as limitações desta pesquisa. A definição operacional de “engajamento” adotada restringiu-se a parâmetros fisiológicos, sem incorporar métricas de desempenho acadêmico ou indicadores comportamentais complementares. Além disso, a presença de artefatos nos sinais e a influência de fatores externos, como movimento,

temperatura ambiente, estados emocionais e fadiga, podem ter afetado a consistência das medidas. O próprio desenho experimental, conduzido em condições controladas e com amostra delimitada, também impõe restrições à generalização dos achados.

Assim, esta investigação reafirma o potencial das tecnologias vestíveis e da inteligência artificial na promoção de práticas educacionais inovadoras e baseadas em evidências, ao mesmo tempo em que aponta caminhos para pesquisas futuras que considerem medidas multimodais mais amplas e contextos experimentais diversificados, visando à melhoria contínua do ensino superior.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, recomenda-se a ampliação das investigações envolvendo sinais fisiológicos em ambientes escolares, considerando os desafios inerentes ao monitoramento contínuo. Resultados de pesquisas anteriores apontaram para a viabilidade dessas medições, mas também destacaram dificuldades, como sinais inválidos decorrentes de mau posicionamento dos sensores e ruídos de quantização. Nesses casos, o uso de ferramentas automáticas de pré-processamento é fundamental para assegurar maior clareza dos traçados, evitando interpretações equivocadas que podem surgir de diferenças entre dispositivos e contextos de coleta.

Outro aspecto relevante diz respeito à lacuna existente entre o monitoramento e a aplicação pedagógica. Embora muitas medições consigam indicar o estado dos estudantes, poucas oferecem feedback em tempo real ou se adaptam às necessidades individuais, em contraste com abordagens mais consolidadas em ambientes clínicos. Futuras pesquisas podem explorar o desenvolvimento de sistemas que não apenas monitorem, mas também retroalimentem o processo de ensino, ajustando estratégias pedagógicas de acordo com os níveis de engajamento identificados.

Também se faz necessária a ampliação da análise sobre a relação entre atividades e métodos de ensino e o nível de engajamento dos estudantes, investigando como diferentes práticas pedagógicas modulam respostas fisiológicas. Ademais, fatores externos como condições ambientais, atividade física prévia, sono e estados emocionais podem comprometer a confiabilidade das medidas de HR e ST, conforme observado por Terriault et al. (2021), devendo ser controlados em protocolos futuros.

Outro ponto importante refere-se ao tamanho limitado de amostras em estudos anteriores (por exemplo, Cain & Lee, 2016), que restringe a generalização dos achados. Investigações em

maior escala são necessárias para validar os resultados e identificar padrões mais robustos. Por fim, as questões éticas relacionadas ao uso de dispositivos vestíveis em contextos educacionais demandam maior atenção, especialmente no que se refere à privacidade dos estudantes, à segurança dos dados e ao consentimento informado.

De forma complementar, sugere-se ainda a incorporação de variáveis neurológicas, como o EEG, que podem aprofundar a compreensão dos estados de engajamento estudantil por meio da correlação entre indicadores fisiológicos e neurológicos. A integração entre dados de EEG e variáveis fisiológicas pode oferecer uma visão mais abrangente e precisa dos mecanismos cognitivos e emocionais subjacentes à aprendizagem, possibilitando o desenvolvimento de modelos preditivos multimodais mais robustos. Pesquisas nessa direção poderão contribuir significativamente para o avanço da neuroeducação e para a criação de sistemas inteligentes capazes de adaptar, em tempo real, estratégias pedagógicas às necessidades cognitivas dos estudantes.

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**, Neuilly-sur-Seine, v. 31, n. 6, p. 2499-2511, 2023.
- ABU ZHAIR, L. M. Prediction of student's performance by modelling small dataset size. **International Journal of Educational Technology in Higher Education**, New York, v. 16, n. 27, 2019.
- AL-ALWANI, A. A combined approach to improve supervised e-learning using multi-sensor student engagement analysis. **American Journal of Applied Sciences**, Mesa, v. 13, n. 12, p. 1377-1384, 2016.
- AL-SHABANDAR, R.; HUSSAIN, A.; LAWS, A.; KEIGHT, R.; LUNN, J.; RADI, N. Machine learning approaches to predict learning outcomes in massive open online courses. **International Joint Conference on Neural Networks (IJCNN)**, Anchorage, p. 713-720, 2017.
- AMARAL, J. A. A.; FREGNI, F. Applying neuroscience concepts to enhance learning in an online project-based learning centered course. **Journal of Problem-Based Learning in Higher Education**, Aalborg East, v. 9, n. 2, p. 142-159, 2021.
- ANANTHAN, S.; GAO, N.; SALIM, F. D. Understanding physiological responses of students over different courses. *In*: ACM INTERNATIONAL SYMPOSIUM ON WEARABLE COMPUTERS (ISWC '24), p. 1–7, 2024, Melbourne. **Proceedings of the 2024 [...]**. New York: Association for Computing Machinery, 2024.
- ANUSHA, A. S.; SUKUMARAN, P.; SARVESWARAN, V.; SUREES KUMAR, S.; SHYAM, A.; AKL, T. J.; PREEJITH, S. P.; SIVAPRAKASAM, M. Electrodermal activity based pre-surgery stress detection using a wrist wearable. **IEEE Journal of Biomedical and Health Informatics**, Piscataway, 2019.
- ATCHISON, J. S.; CHESEBROUGH, C.; AGARTAN, L.; BERNARD, A. H.; KATZ-BUONINCINTRO, J.; CHRYSIKOU, E. G. Preliminary results of a pilot study of students' phenomenological and psychophysiological reactions in engineering design. **American Society for Engineering Education Proceedings**, Columbus, 2023.
- BÜHLER, B.; BOZKIR, E.; DEININGER, H.; GOLDBERG, P.; GERJETS, P.; TRAUTWEIN, U.; KASNECI, E. Detecting aware and unaware mind wandering during lecture viewing: a multimodal machine learning approach using eye tracking, facial videos and physiological data. *In*: INTERNATIONAL CONFERENCE ON MULTIMODAL INTERACTION, 2024, 26., San Jose. **Proceedings of the [...]**. New York: Association for Computing Machinery, 2024.
- BZDOK, D.; KRZYWINSKI, M.; ALTMAN, N. Machine learning: supervised methods. **Nat Methods**, London, v. 15, p. 5–6, 2018.

- CAIN, R.; LEE, V. R. Measuring electrodermal activity to capture engagement in an afterschool maker program. *In: ANNUAL CONFERENCE ON CREATIVITY AND FABRICATION IN EDUCATION*, 6., 2016, Stanford. **Proceedings of the [...]**. New York: Association for Computing Machinery, 2016.
- CAN, Y. S.; CHALABIANLOO, N.; EKIZ, D.; ERSOY, C. Continuous stress detection using wearable sensors in real life: algorithmic programming contest case study. **Sensors**, Basel, v. 19, n. 8, p. 1849, 2019.
- CAPALONGA, F.; WILDNER, M. C. S. Usando as metodologias ativas na educação profissional: identificação, compreensão e análise nas percepções dos estudantes. **Revista Destaques Acadêmicos**, Lajeado, v. 10, n. 4, p. 148-161, 2018
- CARUELLE, D.; GUSTAFSSON, A.; SHAMS, P.; LERVIK-OLSEN, L. The use of electrodermal activity (EDA) measurement to understand consumer emotions – a literature review and a call for action. **Journal of Business Research**, Athens, v. 104, p. 146–160, 2019.
- CHEAHA, D.; BASOR, N.; KUMARNSIT, E.; KIRIRAT, P.; CHONGCHEAWCHAMNAN, M.; SAMERPHOB, N. EEG neural substrates of cognitive engagements for research-based learning with contemplative education in young children. **Trends in Sciences**, Nakhon Si Thammarat, v. 21, n. 6, p. 7679, 2024.
- CHOWDHURY, A. K.; TJONDRENEGORO, D.; CHANDRAN, V.; ZHANG, J.; TROST, S. G. Prediction of relative physical activity intensity using multimodal sensing of physiological data. **Sensors**, Basel, v. 19, n. 20, p. 4509, 2019.
- COBO, M. J.; LÓPEZ-HERRERA, A. G.; HERRERA-VIEDMA, E.; HERRERA, F. Science mapping software tools: Review, analysis, and cooperative study among tools. **Journal of the American Society for Information Science and Technology**, New York, v. 62, n. 7, p. 1382-1402, 2011.
- COHEN, J. **Statistical power analysis for the behavioral sciences**. 2nd ed., Abingdon: Routledge, 2013.
- COLARES, M. A. M.; MELLO, J. M.; VIDOTTI, A. P.; SANT'ANA, D. M. G. 5. Human anatomy teaching methodologies strategies to reduce difficulties and provide a better teaching process. **Arquivos do MUDI**, Maringá, v. 23, n. 3, p. 140-160, 2019.
- DARNELL, D. K.; KRIEG, P. A. Student engagement, assessed using heart rate, shows no reset following active learning sessions in lectures. **PLoS ONE**, San Francisco, v. 14, n. 12, p. e0225709, 2019.
- DARVISHI, A.; KHOSRAVI, H.; SADIQ, S.; WEBER, B. Neurophysiological measurements in higher education: a systematic literature review. **International Journal of Artificial Intelligence in Education**, Dordrecht, v. 32, p. 413-453, 2022.
- OLIVEIRA, M. B.; SILVA, L. C. T.; CANAZARO, J. V.; CARVALHIDO, M. L. L.; SOUZA, R. R. C. D.; NETO, J. B.; RANGEL, D. P. Hybrid teaching in Brazil after covid-19 pandemic. **Brazilian Journal of Development**, Curitiba, v. 7, n. 1, p. 918-932, 2021.

- DI LASCIO, E.; GASHI, S.; SANTINI, S. Unobtrusive assessment of students' emotional engagement during lectures using electrodermal activity sensors. **Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies**, Washington, v. 2, n. 3, p. 103:1-103:21, 2018.
- DIAS-LIMA, A.; SILVA, M. C.; RIBEIRO, L. C. V.; BENDICHO, M. T.; GUEDES, H. T. V.; LEMAIRE, D. C. Evaluation, teaching and active methodologies an experience as part of the curricular component mechanisms of aggression and defense of the medicine course of Universidade do Estado da Bahia, Brazil. **Revista Brasileira de Educação Médica**, Brasília, v. 43, n. 2, p. 216-224, 2019.
- DOMÍNGUEZ-JIMÉNEZ, J. A.; CAMPO-LANDINES, K. C.; MARTÍNEZ-SANTOS, J. C.; DELAHOZ, E. J.; CONTRERAS-ORTIZ, S. H. A machine learning model for emotion recognition from physiological signals. **Biomedical Signal Processing and Control**, Den Haag, v. 55, p. 101646, 2020.
- DONTHU, N.; KUMAR, S.; MUKHERJEE, D.; PANDEY, N.; LIM, W. M. How to conduct a bibliometric analysis: An overview and guidelines. **Journal of Business Research**, New York, v. 133, p. 285-296, 2021.
- DOUDS, T. L. **The predictive relationship between student engagement scores and pass/fail rates of a credit recovery course among high school students**. 2018. fl. 95. Tese (Doutorado em Educação) – Liberty University, Lynchburg, 2018.
- DRACHEN, A., NACKE, L. E., YANNAKAKIS, G., & PEDERSEN, A. L. Psychophysiological correlations with gameplay experience dimensions. **arXiv**, Ithaca, 2010.
- ELIOT, J. A. R.; HIRUMI, A. Emotion theory in education research practice: an interdisciplinary critical literature review. **Educational Technology Research and Development**, Washington, v. 67, n. 5, p. 1065-1084, 2019.
- FEBRIANTORO, W.; GAUTHIER, A.; CUKUROVA, M. The promise of physiological data in collaborative learning: a systematic literature review. In: **Lecture Notes in Computer Science**. Cham: Springer, 2023.
- FIORINI, L.; MANCIOPPI, G.; SEMERARO, F.; FUJITA, H.; CAVALLO, F. Unsupervised emotional state classification through physiological parameters for social robotics applications. **Knowledge-Based Systems**, Amsterdam, 2019. p. 105217.
- GAO, M.; CHEN, J.; LONG, Y.; XU, X.; ZHANG, Y. Make silence speak for itself: a multi-modal learning analytic approach with neurophysiological data. **arXiv preprint**, arXiv:2507.21063, 2025. Disponível em: <<https://arxiv.org/abs/2507.21063>>. Acesso em: 22 jun. 2025.
- GAO, N.; SHAO, W.; RAHAMAN, M. S.; SALIM, F. D. n-Gage: predicting in-class emotional, behavioural and cognitive engagement in the wild. **Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies**, New York, v. 4, n. 3, 2020.

GEDAM, S.; DUTTA, S.; JHA, R. Análise do estresse mental em estudantes indianos por meio de tecnologias vestíveis e algoritmos avançados de aprendizado de máquina. **Scientific Reports**, London: Nature Publishing Group, v. 15, p. 20610, 2025.

GENTRUP, S.; LORENZ, G.; KRISTEN, C.; KOGAN, I. Self-fulfilling prophecies in the classroom: Teacher expectations, teacher feedback and student achievement. **Learning and Instruction**, Reino Unido, 66, 2020.

GERŠAK, G.; DRNOVŠEK, J. Electrodermal activity patient simulator. **PLoS ONE**, San Francisco, v. 15, n. 2, p. e0228949, 2020.

GHANNAM, R.; CURIA, G.; BRANTE, G.; KHOSRAVI, S.; FAN, H. Implantable and wearable neuroengineering education: a review of postgraduate programmes. **IEEE Access**, Piscataway, v. 8, p. 212395-212407, 2020.

GJORESKI, M.; GAMS, M.; LUŠTREK, M.; GENC, P.; GARBAS, J. U.; HASSAN, T. Machine learning and end-to-end deep learning for monitoring driver distractions from physiological and visual signals. **IEEE Access**, Piscataway, v. 8, p. 70590-70601, 2020.

GONZÁLEZ-DÍEZ, I.; VARELA, C.; SÁIZ-MANZANARES, M. C. The use of integrated multichannel records in learning studies in higher education: a systematic review of the last 10 years. **Computers**, Basel, v. 13, n. 4, p. 96, 2024.

GOUSSAIN, B. G. C. S.; MOURA, R. A.; LUCHE, J. R. D.; ANDRADE, H. S.; SILVA, M. B. Enhancing learning with physiological measures: a systematic review of applications in neuroeducation. *In*: INTERNATIONAL CONFERENCE ON COMPUTER SUPPORTED EDUCATION, 17., 2025, Porto. **Proceedings of the 17th International Conference on Computer Supported Education – Volume 1**. [S.l.]: SCITEPRESS, 2025. p. 111-122. ISBN 978-989-758-746-7. ISSN 2184-5026.

GRAY, C. C.; PERKINS, D. Utilizing early engagement and machine learning to predict student outcomes. **Computers & Education**, Oxford, v. 131, p. 22-32, 2019.

HAMMOND, H.; ARMSTRONG, M.; THOMAS, G. A.; DALMAIJER, E. S.; BULL, D. R., & GILCHRIST, I. D. Narrative predicts cardiac synchrony in audiences. **Scientific Reports**, London, v. 14, 2024.

HASHKY, A.; RHEAULT, B.; AHSAN, A. R.; BENDA, B.; AUDINO, T.; LONNEMAN, S.; RAGAN, E. D. Multi-modal user modeling for task guidance: a dataset for real-time assistance with stress and interruption dynamics. **IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)**, Piscataway, 2024.

HELLAS, A.; IHANTOLA, P.; PETERSEN, A.; AJANOVSKI, V. V.; GUTICA, M.; HYNINEN, T.; KNUTAS, A.; LEINONEN, J.; MESSOM, C.; NAM LIAO, S. Predicting academic performance: a systematic literature review. *In*: ANNUAL ACM CONFERENCE ON INNOVATION AND TECHNOLOGY IN COMPUTER SCIENCE EDUCATION – ITiCSE, 23., 2018, Larnaca. **Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education**. New York: ACM, 2018. 25 p.

HERNANDEZ-DE-MENENDEZ, M.; MORALES-MENENDEZ, R. Technological innovations and practices in engineering education: a review. **International Journal on Interactive Design and Manufacturing (IJIDeM)**, Cham: Springer, v. 13, n. 3, p. 713-728, 2019.

HORVERS, A.; TOMBENG, N.; BOSSE, T.; LAZONDER, A. W.; MOLENAAR, I. Detecting emotions through electrodermal activity in learning contexts: a systematic review. **Sensors**, Basel, v. 21, n. 21, p. 7869, 2021.

HUSSAIN, M.; ZHU, W.; ZHANG, W.; ABIDI, S. M. R.; ALI, S. Using machine learning to predict student difficulties from learning session data. **Artif Intell Rev**, Cham: Springer, 2018.

IATRELLIS, O.; SAVVAS, I. K.; FITSILIS, P.; GEROGIANNIS, V. C. A two-phase machine learning approach for predicting student outcomes. **Education and Information Technologies**, Cham: Springer, 2020.

ICHIBA, T., SUZUKI, M., ARITAKE-OKADA, S., & UCHIYAMA, M. Periocular skin warming elevates the distal skin temperature without affecting the proximal or core body temperature. **Scientific Reports**, London, v. 9, 2019.

IMRAN, M.; LATIF, S.; MEHMOOD, D.; SHAH, M. S. Student academic performance prediction using supervised learning techniques. **International Journal of Emerging Technologies in Learning (iJET)**, Kassel, v. 14, n. 14, 2019.

JAMAL, K. M.; KAMIOKA, E. Emotions detection scheme using facial skin temperature and heart rate variability. **MATEC Web of Conferences**, Les Ulis, v. 277, p. 02037, 2019.

JIANG, T.; GRADUS, J. L.; ROSELLINI, A. J. Supervised machine learning: a brief primer. **Behav Ther**, New York, v. 51, n. 5, p. 675-687, 2020.

JUKIEWICZ, M.; MARCINKOWSKA, J. Analysis of electrodermal signal features as indicators of cognitive and emotional reactions - comparison of the effectiveness of selected statistical measures. **Sensors**, Basel, v. 25, n. 11, 2025.

KANG, W.; KIM, S.; YOO, E.; KIM, S. **Predição de notas de exames de estudantes com base em sinais fisiológicos**. arXiv preprint, arXiv:2301.12051, 2023. Disponível em: <<https://arxiv.org/abs/2301.12051>>. Acesso em: 27 abr. 2025.

KANNA, S.; VON ROSENBERG, W.; GOVERDOVSKY, V.; CONSTANTINIDES, A. G.; MANDIC, D. P. Bringing wearable sensors into the classroom: a participatory approach. **IEEE Signal Processing Magazine**, Piscataway, v. 35, n. 3, p. 110-116, 2018.

KASSAB, S. E.; RATHAN, R.; TAYLOR, D. C. M.; HAMDY, H. O impacto do ambiente educacional no engajamento dos estudantes e no desempenho acadêmico na educação em profissões da saúde. **BMC Medical Education**, London, v. 24, n. 1278, 2024.

KATMADA, A.; CHATZAKIS, M.; APOSTOLIDIS, H.; MAVRIDIS, A.; STYLIANIDIS, P. An adaptive serious neuro-game using a mobile version of a bio-feedback device. In: INTERNATIONAL CONFERENCE ON INTERACTIVE MOBILE COMMUNICATION

TECHNOLOGIES AND LEARNING – IMCL, 2015, Thessaloniki. **Proceedings** [...]. Thessaloniki: IEEE, Piscataway, 2015. p. 416-420.

KHAN, T. H.; VILLANUEVA, I.; VICIOSO, P.; HUSMAN, J. Exploring relationships between electrodermal activity, skin temperature, and performance during. *In: FRONTIERS IN EDUCATION CONFERENCE – FIE*, 2019, Covington. **Proceedings** [...]. Piscataway: IEEE, 2019. p. 1-5.

KIM, A. Y.; JANG, E. H.; KIM, S.; CHOI, K. W.; JEON, H. J.; YU, H. Y.; BYUN, S. Automatic detection of major depressive disorder using electrodermal activity. **Scientific Reports**, London, v. 8, n. 1, p. 1-10, 2018.

KLEIN, K.; CALABRESE, J.; AGUIAR, A.; MATHEW, S.; AJANI, K.; ALMAJID, R.; AARONS, J. Evaluating active lecture and traditional lecture in higher education. **Journal on Empowering Teaching Excellence**, Logan, v. 7, n. 2, art. 6, 2023.

KOZANITIS, A. Comparing real-time student situational engagement in traditional and active learning classrooms using non-invasive electrodermal measurements. *In: INTERNATIONAL MULTI-CONFERENCE ON COMPLEXITY, INFORMATICS AND CYBERNETICS – IMCIC*, 14., 2023, Winter Garden. **Proceedings of the 14th International Multi-Conference on Complexity, Informatics and Cybernetics – IMCIC**. [S.l.]: [s.n.], 2023. p. 133-138.

LADINO NOCUA, A. C.; CRUZ GONZALEZ, J. P.; CASTIBLANCO JIMENEZ, I. A.; GOMEZ ACEVEDO, J. S.; MARCOLIN, F.; VEZZETTI, E. Assessment of cognitive student engagement using heart rate data in distance learning during COVID-19. **Education Sciences**, Basel, v. 11, n. 9, p. 540, 2021.

LEE, B.; MULDER, K. Instructional video design: investigating the impact of monologue- and dialogue-style presentations. *In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS – CHI '20*, 2020, New York. *Proceedings of the CHI Conference on Human Factors in Computing Systems*. New York: ACM, 2020. p. 1-12.

LEE, H.; MANDALAPU, V.; KLEINSMITH, A.; GONG, J. Distinguishing anxiety subtypes of English language learners towards augmented emotional clarity. *In: BITTENCOURT, I. I. et al. (Eds.). Artificial Intelligence in Education – AIED 2020*. (Lecture Notes in Artificial Intelligence, v. 12164). Cham: Springer Nature Switzerland AG, 2020. p. 157-161.

LEE, V. R. Youth engagement during making: using electrodermal activity data and first-person video to generate evidence-based conjectures. **Information and Learning Sciences**, Bingley, v. 122, n. 3/4, p. 270-291, 2021.

LEE, V. R.; FISCHBACK, L.; CAIN, R. A wearables-based approach to detect and identify momentary engagement in afterschool Makerspace programs. **Contemporary Educational Psychology**, Oxford, v. 59, p. 101789, 2019.

LEI, H.; CUI, Y.; ZHOU, W. Relações entre engajamento estudantil e desempenho acadêmico: uma meta-análise. **Social Behavior and Personality: an international journal**, Palmerston North, v. 46, n. 3, p. 517–528, 2018.

LODERER, K.; PEKRUN, R.; LESTER, J. C. Beyond cold technology: a systematic review and meta-analysis on emotions in technology-based learning environments. **Learning and Instruction**, Oxford, v. 70, p. 101162, 2020.

LU, Y.; ZHANG, S.; ZHANG, Z.; XIAO, W.; YU, S. A framework for learning analytics using commodity wearable devices. **Sensors**, Basel, v. 17, n. 6, p. 1382, 2017.

LUCHE, J. R. D.; FREITAS, C. R.; GOUSSAIN, B. G. C. S.; SILVA, M. B. "PhysioActiveLearning", **Mendeley Data**, Amsterdam, 2025.

LUI, Y.; DU, S. Psychological stress level detection based on electrodermal activity. **Behavioural Brain Research**, Oxford, v. 341, p. 50-53, 2018.

MCNEAL, K. S.; ZHONG, M.; SOLTIS, N. A.; DOUKOPOULOS, L.; JOHNSON, E. T.; COURTNEY, S.; ALWAN, A.; PORCH, M. Biosensors show promise as a measure of student engagement in a large introductory biology course. **CBE—Life Sciences Education**, Bethesda, v. 19, n. 4, 2020.

MAGGIO, L. A.; COSTELLO, J. A.; NORTON, C.; DRIESSEN, E. W.; ARTINO JR, A. R. Knowledge syntheses in medical education: a bibliometric analysis. **Perspectives on Medical Education**, London, v. 10, n. 2, p. 79-87, 2021.

MALATHI, D.; DORATHI JAYASEELI, J. D.; MADHURI, S.; SENTHILKUMAR, K. Electrodermal activity based wearable device for drowsy drivers. **Journal of Physics: Conference Series**, Bristol, v. 1000, 2018.

MIFSUD, T., MODESTINI, C., MIZZI, A., FALZON, O., CASSAR, K., & MIZZI, S. The effects of skin temperature changes on the integrity of skin tissue: a systematic review. **Advances in Skin & Wound Care**, Philadelphia, v. 35, n. 11, p. 555–565, 2022.

MIGUEL, P. A. C.; FLEURY, A.; MELLO, C. H. P.; NAKANO, D. N.; LIMA, E. P.; TURRIONI, J. B.; HO, L. L.; MORABITO, R.; MARTINS, R. A.; SOUSA, R.; COSTA, S. E. G.; PUREZA, V. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 2. ed. Rio de Janeiro: Elsevier Editora Ltda, 2012.

NAICKER, N.; ADELIYI, T.; WING, J. Linear support vector machines for prediction of student performance in school-based education. **Mathematical Problems in Engineering**, London, v. 2020, p. 1-7, 2020.

NOURBAKHSN, N.; WANG, Y.; CHEN, F.; CALVO, R. A. Using galvanic skin response for cognitive load measurement in arithmetic and reading tasks. *In: AUSTRALIAN COMPUTER-HUMAN INTERACTION CONFERENCE – OZCHI*, 24-30 nov. 2012, Melbourne. **Proceedings [...]**. Melbourne: ACM, 2012. p. 420-429.

OFORI, F.; MAINA, E.; GITONGA, R. Using machine learning algorithms to predict students' performance and improve learning outcome: a literature based review. **Journal of Information and Technology**, Nairobi, v. 4, n. 1, p. 23-45, mar. 2020.

PANG, Y.; JUDD, N.; O'BRIEN, J.; BEN-AVIE, M. Predicting students' graduation outcomes through support vector machines. *In: IEEE FRONTIERS IN EDUCATION*

CONFERENCE – FIE, 2017, Indianapolis. **Proceedings** [...]. Piscataway: IEEE, 2017. p. 1-8.

PAVANI, M.; TEJA, A. R.; NEELIMA, A.; BHAVISHYA, G.; SUKRUTHA, D. S. Prediction of student outcome in educational sector by using decision tree. **International Journal for Technological Research in Engineering**, Ahmedabad, v. 4, n. 8, p. 1191-1193, abr. 2017.

PÉREZ, F. de A.; SANTOS-GAGO, J. M.; CAEIRO-RODRÍGUEZ, M.; FERNÁNDEZ IGLESIAS, M. J. Evaluation of commercial-off-the-shelf wrist wearables to estimate stress on students. **Journal of Visualized Experiments**, Cambridge, v. 136, p. e57590, 2018.

PIJEIRA-DÍAZ, H. J.; DRACHSLER, H.; KIRSCHNER, P. A.; JÄRVELÄ, S. Profiling sympathetic arousal in a physics course: How active are students? **Journal of Computer Assisted Learning**, Hoboken, v. 34, n. 5, p. 1-12, 2018.

POH, M. Z.; SWENSON, N. C.; PICARD, R. W. A Wearable sensor for unobtrusive, long-term assessment of electrodermal activity. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 57, n. 5, p. 1243-1252, 2010.

POLYZOU, A.; KARYPIS, G. Feature extraction for classifying students based on their academic performance. *In*: INTERNATIONAL CONFERENCE ON EDUCATIONAL DATA MINING – EDM, 11., 2023, Worcester. **Proceedings** [...]. Worcester: [s.n.], 2023. p. 356-362.

PONCE-NARANJO, D.; CALDERÓN-GURUBEL, J. E.; GONZÁLEZ-DÍAZ, K. A.; LÓPEZ-ANDRADE, A. D.; MARTÍNEZ-GIORGETTI, J. E.; RIVERA-CERROS, E. A.; RAMÍREZ MORENO, M. A.; RUIZ-RAMÍREZ, J. A. Evaluation of feature extraction methods using portable biometric sensors in entrepreneurial activities. *In*: WORLD ENGINEERING EDUCATION FORUM – WEEF, 2023, Monterrey. **Proceedings** [...]. [S.l.]: [s.n.], 2023. p. 1-7.

POTTER, L.; SCALLON, J.; SWEGLE, D.; GOULD, T.; OKUDAN KREMER, G. Establishing a link between electrodermal activity and classroom engagement. *In*: IISE ANNUAL CONFERENCE, 2019, Ames. **Anais** [...]. Ames: Industrial and Manufacturing Systems Engineering, Iowa State University, 2019. p. 988-993.

QIN, Y. Artificial intelligence technology-driven teacher mental state assessment and improvement method. **International Journal of Information and Communication Technology Education**, Hershey, v. 20, n. 1, 2024.

QUINTERO, H. F. P.; BOLKHOVSKY, J. B. Machine learning models for the identification of cognitive tasks using autonomic reactions from heart rate variability and electrodermal activity. **Behav. Sci.**, Basel, 2019.

QUINTERO, H. F. P.; DIMITROV, T.; MOUTRAN, A.; PARK, S.; CHON, K. H. Analysis of reproducibility of noninvasive measures of sympathetic autonomic control based on electrodermal activity and heart rate variability. **IEEE Access**, Piscataway, v. 7, p. 22523-22531, 2019.

QUINTERO, H. F. P.; FLORIAN, J. P.; ORJUELA-CAÑÓN, A. D.; ALJAMA-CORRALES, T.; CHARLESTON-VILLALOBOS, S.; CHON, K. H. Power spectral density analysis of electrodermal activity for sympathetic function assessment. **Annals of Biomedical Engineering**, New York, v. 44, n. 10, p. 3124-3135, 2016a.

QUINTERO, H. F. P.; FLORIAN, J. P.; ORJUELA-CAÑÓN, A. D.; CHON, K. H. Highly sensitive index of sympathetic activity based on time-frequency spectral analysis of electrodermal activity. **American Journal of Physiology-Regulatory, Integrative and Comparative Physiology**, Bethesda, v. 311, n. 3, p. R582-R591, 2016b.

RASHIDI, H. H.; ALBAHRA, S.; ROBERTSON, S.; TRAN, N. K.; HU, B. Common statistical concepts in the supervised Machine Learning arena. **Frontiers in Oncology**, Lausanne, 2023.

RASTROLLO-GUERRERO, J. L.; GÓMEZ-PULIDO, J. A.; DURÁN-DOMÍNGUEZ, A. Analyzing and predicting students' performance by means of machine learning: a review. **Applied Sciences**, Basel, v. 10, n. 3, p. 1042, 2020.

REID, C.; KEIGHREY, C.; MURRAY, N.; DUNBAR, R.; BUCKLEY, J. A novel mixed methods approach to synthesize EDA data with behavioral data to gain educational insight. **Sensors**, Basel, v. 20, n. 23, p. 6857, 2020.

RODIC-TRMCIC, B.; STANOJEVIC, G.; SAPIC, R.; LABUS, A.; BOGDANOVIC, Z. Wearable solution for assessing physiological arousal towards students' interest and engagement in the classroom. *In*: INTERNATIONAL CONFERENCE ON VIRTUAL LEARNING – ICVL, 11., 2016, Belgrade. **Proceedings** [...]. Belgrade: University of Belgrade, 2016. p. 215-220.

RODRÍGUEZ-ARCE, J.; LARA-FLORES, L.; PORTILLO-RODRÍGUEZ, O.; MARTÍNEZ-MÉNDEZ, R. Towards an anxiety and stress recognition system for academic environments based on physiological features. **Computer Methods and Programs in Biomedicine**, Oxford, v. 190, p. 105408, 2020.

ROMAN, C.; ELLWANGER, J.; BECKER, G. C.; SILVEIRA, A. D.; MACHADO, C. L. B.; MANFROI, W. C. Active teaching-learning methodologies in the teaching health process in Brazil a narrative review. **Clin Biomed Res.**, Porto Alegre, v. 37, n. 4, p. 349-357, 2017.

SÁNCHEZ-CARRACEDO, F.; TREPAT, E.; BARBA-VARGAS, A. Successful engineering lecturing based on neuroscience. **International Journal of Engineering Education**, Dublin, v. 37, n. 1, p. 115-132, 2021.

SÁNCHEZ-REOLID, R.; LÓPEZ, M. T.; FERNÁNDEZ-CABALLERO, A. Machine learning for stress detection from electrodermal activity: a scoping review. **Preprints**, Albacete, 2020.

SANTOS, A. L. C.; SILVA, F. V. C.; SANTOS, L. G. T.; FEITOSA, A. A. F. M. A. Difficulties caught by professors from the professional master's program in biology teaching for the use of active methodologies in public network schools in paraíba. **Brazilian Journal of Development**, Curitiba, v. 6, n. 4, p. 21959-21973, abr. 2020.

SCHNEIDER, B.; DICH, Y.; RADU, I. Unpacking the relationship between existing and new measures of physiological synchrony and collaborative learning: a mixed methods study. **International Journal of Computer-Supported Collaborative Learning**, Champ: Springer, 15, n. 2, p. 89-113, 2020.

SCHOBER, P.; BOER, C.; SCHWARTE, L. A. Correlation coefficients: appropriate use and interpretation. **Anesthesia & Analgesia**, Philadelphia, v. 126, n. 5, p. 1763-1768, 2018.

SEPANLOO, K.; SHEVELEV, D.; SON, Y-J.; ARAS, S.; HINTON, J.E. Avaliação das respostas fisiológicas ao estresse em estudantes de enfermagem por meio de treinamento com realidade mista. **Sensors**, Basel, v. 25, n. 10, p. 3222, 2025.

SHANTHINI, A.; VINODHINI, G.; CHANDRASEKARAN, R. M. Predicting students' academic performance in the university using meta decision tree classifiers. **Journal of Computer Science**, Estados Unidos da América, v. 14, n. 5, p. 654-662, 2018.

SHARMAA, V., PRAKASHB, N. R., KALRA, P. Audio-video emotional response mapping based upon electrodermal activity vivek. **Biomedical Signal Processing and Control**, Oxford, 47, 324–333, 2019.

SHENGXIN, T.; CHUN, L.; BRYAN, E. Shepherd between- and within-cluster spearman rank correlations. **Statistics in Medicine**, Hoboken, v. 44, n. 3-4, p. 10-20, 2025.

SIMJANOSKA, M.; GUSEV, M.; RISTOV, S.; BOGDANOVA, A. M. Intelligent student profiling for predicting e-assessment outcomes. *In: IEEE GLOBAL ENGINEERING EDUCATION CONFERENCE – EDUCON*, 2014, Istanbul. **Proceedings [...]**. Piscataway: IEEE, 2014. p. 616-622.

SONG, W., ZHONG, F., CALAUTIT, J. K., & LI, J. Exploring the role of skin temperature in thermal sensation and thermal comfort: A comprehensive review. **Energy and Built Environment**, Beijing, 2024.

STULDREHER, I. V.; BROUWER, A. M. Monitoring audience engagement using electrodermal activity during an inaugural lecture. **PLOS ONE**, San Francisco, v. 20, n. 6, 2015.

STULDREHER, I. V.; MAASLAND, E.; BOTTENHEFT, C.; VAN ERP, J. B. F.; BROUWER, A. M. Physiological synchrony in electrodermal activity predicts decreased vigilant attention induced by sleep deprivation. **Frontiers in Neuroergonomics**, Lausanne, v. 4, 2023.

SWAMINATHAN, S.; TANTRI, B. R. Confusion matrix-based performance evaluation metrics. **African Journal of Biomedical Research**, Ibadan, v. 27, n. 4, p. 4023–4031, 2024.

TERRIAULT, P.; KOZANITIS, A.; FARAND, P. Use of electrodermal wristbands to measure students' cognitive engagement in the classroom. *In: CANADIAN ENGINEERING EDUCATION ASSOCIATION CONFERENCE – CEEA-ACEG21*, 2021, UPEI. **Proceedings [...]**. UPEI, 2021. p. 1-8.

- THAMMASAN, N.; STULDREHER, I. V.; SCHREUDERS, E.; GILETTA, M.; BROUWER, A. M. A usability study of physiological measurement in school using wearable sensors. **Sensors**, Basel, v. 20, n. 18, p. 5380, 2020.
- TING, K. M. Confusion matrix. *In*: SAMMUT, C.; WEBB, G. I. (eds.). **Encyclopedia of Machine Learning**. Boston, MA: Springer, 2011. p.260-260.
- TSIAKMAKI, M.; KOSTOPOULOS, G.; KOTSIANTIS, S.; RAGOS, O. Implementing AutoML in educational data mining for prediction tasks. **Applied Sciences**, Basel, v. 10, n. 1, p. 90, 2020.
- UNITED NATIONS. **Transforming our world: the 2030 Agenda for Sustainable Development. Sustainable Development Goals**, 2015. Disponível em: <<https://sustainabledevelopment.un.org>>. Acesso em: 21 jul. 2024.
- VILLANUEVA, I.; CAMPBELL, B. D.; RAIKES, A. C.; JONES, S. H.; PUTNEY, L. G. A multimodal exploration of engineering students' emotions and electrodermal activity in design activities. **Journal of Engineering Education**, Washington, 2018.
- VILLANUEVA, I.; DI STEFANO, M.; GELLES, L.; VICIOSO OSORIA, P.; BENSON, S. A race re-imaged, intersectional approach to academic mentoring: exploring the perspectives and responses of womxn in science and engineering research. **Contemporary Educational Psychology**, Estados Unidos da América, v. 59, 2019.
- VILLAREJO, M. V.; ZAPIRAIN, B. G.; ZORRILLA, A. M. A stress sensor based on galvanic skin response (GSR) controlled by ZigBee. **Sensors**, Basel, v. 12, n. 5, p. 6075-6101, 2012.
- WAKELAM, E.; JEFFERIES, A.; DAVEY, N.; SUN, Y. The potential for student performance prediction in small cohorts with minimal available attributes. **British Journal of Educational Technology**, Reino Unido, v. 51, n. 2, 2019.
- WALSH, K. R.; MAHESH, S. Exploratory study using machine learning to make early predictions of student outcomes. *In*: AMERICAS CONFERENCE ON INFORMATION SYSTEMS – AMCIS, 23., 2017, Boston. **Anais [...]**. Boston: [s.n.], 2017. p. 1-5.
- WANG, Y.; LIU, J. A self-developed smart wristband to monitor exercise intensity and safety in physical education class. *In*: INTERNATIONAL CONFERENCE OF EDUCATIONAL INNOVATION THROUGH TECHNOLOGY – EITT, 8., 2019, Biloxi. **Proceedings [...]**. Biloxi: IEEE, 2019. p. 160-164.
- YAN, L.; LIU, Y. An ensemble prediction model for potential student recommendation using machine learning. **Symmetry**, Basel, v. 12, n. 5, p. 728, 2020.
- YANG, J.; DEVORE, S.; HEWAGALLAGE, D.; MILLER, P.; RYAN, Q. X.; STEWART, J. Using machine learning to identify the most at-risk students in physics classes. **Physical Review Physics Education Research**, College Park, v. 16, n. 2, p. 020130, 2020.
- YOON, S.; SIM, J. K.; CHO, Y.-H. A flexible and wearable human stress monitoring patch. **Scientific Reports**, London, v. 6, p. 23468, 2016.

YOUSAFZAI, B. K.; HAYAT, M.; AFZAL, S. Application of machine learning and data mining in predicting the performance of intermediate and secondary education level students. **Education and Information Technologies**, Cham: Springer, 2020.

ZABRISKIE, C.; YANG, J.; DEVORE, S.; STEWART, J. Using machine learning to predict physics course outcomes. **Physical Review Physics Education Research**, College Park, v. 15, n. 2, p. 020120, 2019.

ZHANG, D.; ZHOU, L.; BRIGGS, R. O.; JR, J. F. N. Instructional video in e-learning: assessing the impact of interactive video on learning effectiveness. **Information & Management**, Amsterdam, v. 43, n. 1, p. 15–27, 2006.

ZHOU, F.; CHEN, T.; LEI, B. Reconhecimento emocional entre sujeitos com dados fisiológicos periféricos esparsamente rotulados utilizando ensembles de árvores explicáveis por SHAP. **IEEE Transactions on Human-Machine Systems**, Piscataway, 2022.

ZOHDI, H.; MÄRKI, J.; SCHOLKMANN, F.; WOLF, U. Cerebral, systemic physiological and behavioral responses to colored light exposure during a cognitive task: A SPA-fNIRS study. **Behavioural Brain Research**, Oxford, v. 462, 2024.

ZUPIC, I.; ČATER, T. Bibliometric methods in management and organization. **Organizational Research Methods**, Thousand Oaks, v. 18, n. 3, p. 429-472, 2015.

APÊNDICE A - ATIVIDADES PRÁTICAS

1) Cada haste (barra) do jogo possui 8,5 cm, ou seja, esse é o tamanho da “barra” que a empresa recebe para cortar as peças de diferentes tamanhos. Note que a cor ajudará a identificar o tamanho da peça, que também possui uma marcação em sua lateral.

O comprimento de cada peça e sua respectiva quantidade na demanda é dada por:


- 4 peças de 3,5 cm;
- 15 peças de 3;
- 5 de 2,5;
- 10 de 2 cm;
- 10 de 1,5;
- 4 peças de 1 cm.

Resolva utilizando os passos exatos da heurística ‘First Fit Decrease’; lembre-se que a heurística não garante a melhor solução, você deve seguir os passos mesmo que identifique outra oportunidade.

Caso você não consiga resolver pela heurística, solicite ao apoio uma instrução.

2) Existe pelo menos uma solução que utiliza apenas 13 barras, você deve tentar encontrar a combinação de uma dessas soluções.

Desta vez, não é necessário utilizar nenhum dos métodos da aula, inclusive, não é necessário desmontar toda a solução atual.



Entrada:

4 peças de 3,5 cm; 15 peças de 3 cm; 5 peças de 2,5; 10 peças de 2 cm;
10 peças de 1,5 cm; 4 peças de 1 cm

Pede-se:


1. Resolva utilizando a heurística ‘First Fit Decrease’;
2. Tente melhorar a última solução encontrada ($S^* = 13$).

APÊNDICE B - VARIÁVEL ALVO


Estudantes	Tempo (s)	Nota Final	Classes
1	505	5.7	Engajado
2	747	3.0	Desengajado
3	442	6.4	Engajado
4	380	7.1	Engajado
5	646	4.1	Desengajado
6	594	4.7	Desengajado
7	748	3.0	Desengajado
8	230	8.8	Engajado
9	414	6.7	Engajado
10	571	5.0	Engajado
11	363	7.3	Engajado
12	581	4.9	Desengajado
13	683	3.7	Desengajado
14	553	5.2	Engajado
15	754	2.9	Desengajado
16	583	4.8	Desengajado
17	420	6.7	Engajado
18	727	3.2	Desengajado
19	762	2.8	Desengajado
20	631	4.3	Desengajado
21	357	7.4	Engajado
22	559	5.1	Engajado
23	534	5.4	Engajado
24	838	2.0	Desengajado
25	889	1.4	Desengajado
26	923	1.0	Desengajado
27	924	1.0	Desengajado
28	214	9.0	Engajado
29	924	1.0	Desengajado
30	749	3.0	Desengajado
31	924	1.0	Desengajado
32	651	4.1	Desengajado
33	264	8.4	Engajado
34	464	6.2	Engajado
35	651	4.1	Desengajado
36	924	1.0	Desengajado
37	380	7.1	Engajado
38	856	1.8	Desengajado
39	606	4.6	Desengajado
40	329	7.7	Engajado
41	466	6.2	Engajado
42	536	5.4	Engajado
43	455	6.3	Engajado
44	310	7.9	Engajado
45	356	7.4	Engajado
46	496	5.8	Engajado
47	124	10.0	Engajado
48	474	6.1	Engajado
49	320	7.8	Engajado
50	293	8.1	Engajado

APÊNDICE C - SINAIS DE EDA


Estudante 1




Estudante 2




Estudante 4




Estudante 5




Estudante 6




Estudante 8




Estudante 9




Estudante 10




Estudante 11




Estudante 12




Estudante 13




Estudante 14




Estudiante 15




Estudiante 16




Estudiante 17




Estudiante 18




Estudiante 19




Estudiante 20




Estudiante 21




Estudiante 22




Estudiante 23




Estudiante 24




Estudiante 25




Estudiante 27




Estudiante 28




Estudiante 29




Estudiante 31




Estudiante 32




Estudiante 33




Estudiante 34




Estudiante 35




Estudiante 37




Estudiante 38




Estudiante 39

















Estudiante 40



Estudiante 41





■ Aprendizagem ativa ■ Tradicional

APÊNDICE D - MEDIÇÕES DE EDA


Estudante	Aprendizagem ativa				Tradicional				Diferença da Média	Diferença da Mediana
	Mín.	Máx.	Média	Mediana	Mín.	Máx.	Média	Mediana		
1	5,0	6,0	5,4	5,3	4,4	6,5	4,9	4,9	0,5	0,4
2	0,5	7,9	7,0	7,5	6,4	7,6	7,0	7,0	0,0	0,5
3	0,8	6,1	5,2	5,3	2,5	5,9	3,1	2,8	2,1	2,5
4	3,5	7,2	6,8	6,8	6,0	7,4	6,6	6,5	0,2	0,3
5	0,7	8,1	6,9	7,1	6,4	7,2	6,8	6,8	0,1	0,3
6	6,5	6,9	6,7	6,7	5,5	6,8	6,0	6,0	0,7	0,7
7	6,4	6,9	6,7	6,7	3,3	6,7	4,3	4,1	2,4	2,6
8	4,0	4,4	4,2	4,3	3,3	4,5	3,9	3,9	0,3	0,4
9	5,7	6,0	5,8	5,8	4,5	5,9	5,0	5,0	0,8	0,8
10	4,6	7,2	6,6	6,7	4,5	6,7	5,5	5,5	1,1	1,2
11	7,1	7,5	7,2	7,2	5,7	7,2	6,3	6,3	0,9	0,9
12	2,5	7,1	6,8	6,8	5,3	6,8	5,9	5,9	0,9	0,9
13	5,3	6,0	5,7	5,7	4,1	5,6	4,9	4,9	0,8	0,8
14	4,4	8,1	7,7	7,8	3,9	7,7	6,2	6,4	1,5	1,4
15	3,4	6,1	5,4	5,8	2,5	6,2	5,1	5,2	0,3	0,6
16	3,0	6,7	5,7	5,7	2,8	7,0	4,5	4,3	1,2	1,4
17	6,7	7,5	7,0	7,0	5,5	7,4	6,2	6,1	0,8	0,9
18	5,2	6,1	5,5	5,5	2,6	5,8	4,0	4,1	1,5	1,4
19	6,0	6,8	6,4	6,4	5,5	6,9	5,9	5,9	0,5	0,5
20	6,2	6,5	6,4	6,4	6,0	6,4	6,1	6,1	0,3	0,3
21	4,6	7,8	7,3	7,4	4,4	7,2	6,1	6,3	1,2	1,1
22	7,0	7,5	7,3	7,3	6,4	7,8	6,9	6,9	0,4	0,4
23	4,3	6,7	6,0	6,1	4,4	5,3	4,9	4,9	1,1	1,2
24	0,2	7,3	6,8	6,9	4,9	6,2	5,5	5,5	1,3	1,4
25	5,7	6,6	6,2	6,2	4,8	6,8	5,5	5,5	0,7	0,7
26	3,9	5,5	4,8	4,9	1,2	4,7	2,0	1,8	2,8	3,2
27	2,7	3,2	2,9	2,8	2,1	3,1	2,3	2,2	0,6	0,6
28	6,0	6,7	6,5	6,6	4,1	6,1	4,8	4,8	1,7	1,8
29	4,8	6,0	5,2	5,2	4,6	6,0	5,0	5,0	0,2	0,2
30	5,1	7,1	6,5	6,5	3,9	5,5	4,5	4,4	2,0	2,1
31	7,2	7,6	7,3	7,3	7,1	7,6	7,2	7,2	0,1	0,1
32	5,4	6,4	5,9	5,9	3,1	5,6	4,2	4,3	1,7	1,6
33	5,1	6,0	5,4	5,4	4,1	6,1	4,7	4,7	0,7	0,7
34	6,3	6,7	6,5	6,5	3,6	6,9	4,8	4,6	1,7	1,9
35	5,7	6,2	5,9	5,9	3,9	5,9	4,6	4,5	1,3	1,4
36	4,2	6,4	5,6	5,8	1,5	5,4	1,9	1,7	3,7	4,1
37	2,8	4,5	3,4	3,3	2,9	5,0	3,6	3,5	-0,2	-0,2
38	5,8	7,1	6,6	6,6	4,4	6,4	5,6	5,6	1,0	1,0
39	7,2	7,6	7,3	7,3	5,5	6,9	6,1	6,1	1,2	1,2
40	4,0	5,0	4,4	4,3	2,2	4,6	2,7	2,6	1,7	1,7
41	7,1	7,5	7,3	7,3	6,4	7,6	7,1	7,1	0,2	0,2

42	5,0	5,9	5,6	5,6	3,8	5,2	4,3	4,2	1,3	1,4
43	6,2	7,1	6,6	6,6	5,4	7,0	6,1	6,1	0,5	0,5
44	5,4	6,7	6,0	5,9	4,8	6,3	5,2	5,2	0,8	0,7
45	5,2	5,9	5,5	5,4	3,9	6,1	4,5	4,4	1,0	1,0
46	3,9	6,1	5,1	5,2	2,3	3,9	2,5	2,5	2,6	2,7
47	0,3	6,9	6,3	6,4	3,5	6,9	5,4	6,3	0,9	0,1
48	3,4	5,7	4,9	5,1	3,3	5,2	4,2	4,2	0,7	0,9
49	6,9	7,2	7,1	7,0	6,9	7,5	7,2	7,2	-0,1	-0,2
50	6,4	7,0	6,8	6,8	4,3	6,8	5,2	5,0	1,6	1,8


Nota: Valores negativos indicam que a média ou a mediana do método tradicional foi superior à da aprendizagem ativa.

APÊNDICE E - SINAIS DE HR


Estudante 1




Estudante 2




Estudante 3




Estudante 4




Estudante 5




Estudante 6




Estudante 7




Estudante 8




Estudante 10




Estudante 12
















Estudante 13




Estudante 14









Estudante 43




Estudante 44




Estudante 45




Estudante 46




Estudante 47




Estudante 48



Estudante 49



Estudante 50



■ Aprendizagem ativa ■ Tradicional

APÊNDICE F - MEDIÇÕES DE HR


Estudante	Aprendizagem ativa				Tradicional				Diferença da Média	Diferença da Mediana
	Mín.	Máx.	Média	Mediana	Mín.	Máx.	Média	Mediana		
1	57	116	75	79	57	88	73	79	2	0
2	47	121	72	78	47	120	71	78	1	0
3	58	125	81	80	48	119	74	79	7	1
4	49	123	80	80	57	120	78	80	2	0
5	58	125	80	80	45	120	72	78	8	2
6	40	126	90	80	48	122	79	80	11	0
7	57	110	74	79	57	119	75	79	-1	0
8	40	138	88	88	48	139	88	88	0	0
9	52	127	87	88	45	123	74	72	13	16
10	41	124	85	80	57	122	81	80	4	0
11	51	98	77	79	44	133	73	69	4	10
12	58	124	84	80	48	127	86	80	-2	0
13	46	131	90	89	60	137	90	89	0	0
14	40	127	88	81	59	128	87	80	1	1
15	51	137	93	90	48	131	85	87	8	3
16	58	124	84	80	59	125	85	80	-1	0
17	47	123	78	79	48	125	78	80	0	-1
18	53	125	85	87	51	139	78	79	7	8
19	60	129	95	81	58	134	101	114	-6	-33
20	51	136	83	86	50	126	76	77	7	9
21	45	118	86	85	51	138	89	85	-3	0
22	58	123	81	80	52	123	79	80	2	0
23	53	129	82	76	39	122	76	74	6	2
24	48	143	103	116	75	131	99	109	4	7
25	46	117	72	78	46	118	73	78	-1	0
26	33	138	85	86	51	135	91	89	-6	-3
27	49	130	89	88	51	129	89	89	0	-1
28	66	142	99	91	48	135	87	88	12	3
29	46	140	94	90	50	135	84	87	10	3
30	50	131	86	87	48	128	85	87	1	0
31	69	140	95	90	68	145	98	90	-3	0
32	62	138	91	89	67	133	91	89	0	0
33	61	131	90	89	55	133	87	88	3	1
34	40	126	76	71	36	117	68	65	8	6
35	50	129	85	87	39	126	83	86	2	1
36	62	132	89	88	54	131	87	88	2	0
37	58	139	92	89	43	136	89	89	3	0
38	58	111	83	85	52	120	83	86	0	-1
39	64	134	90	89	48	127	87	88	3	1
40	68	137	93	90	70	136	94	90	-1	0
41	52	126	83	86	50	130	84	87	-1	-1
42	44	131	83	86	56	121	77	75	6	11

43	50	118	83	86	52	123	82	86	1	0
44	53	132	88	87	51	131	84	87	4	0
45	53	140	92	89	50	140	93	90	-1	-1
46	36	129	79	76	43	122	79	75	0	1
47	77	120	85	80	59	124	84	80	1	0
48	44	90	62	61	44	101	59	59	3	2
49	50	124	89	92	42	135	90	88	-1	4
50	62	119	85	83	47	127	84	83	1	0


Nota: Valores negativos indicam que a média ou a mediana do método tradicional foi superior à da aprendizagem ativa.

APÊNDICE G - SINAIS DE ST


Estudante 1




Estudante 2




Estudante 3




Estudante 4




Estudante 5




Estudante 6




Estudante 7




Estudante 8




Estudante 10




Estudante 11


















Estudante 12




Estudante 14







Estudiante 29




Estudiante 30




Estudiante 31




Estudiante 32




Estudiante 33




Estudiante 34




Estudiante 35




Estudiante 36




Estudiante 37




Estudiante 38




Estudiante 39




Estudiante 40




Estudante 41




Estudante 42




Estudante 43




Estudante 44




Estudante 45




Estudante 46



Estudante 47



Estudante 50



■ Aprendizagem ativa ■ Tradicional

APÊNDICE H - MEDIÇÕES DE ST

Estudante	Aprendizagem ativa				Tradicional				Diferença da Média	Diferença da Mediana
	Mín.	Máx.	Média	Mediana	Mín.	Máx.	Média	Mediana		
1	34,2	35,1	34,6	34,7	33,5	35,5	35,0	35,2	-0,4	-0,5
2	23,6	31,5	24,7	24,1	24,5	25,9	25,2	25,2	-0,5	-1,1
3	26,0	35,1	34,0	34,4	33,1	35,1	34,7	34,9	-0,7	-0,5
4	30,8	32,9	31,7	31,6	31,4	33,5	32,8	33,1	-1,1	-1,5
5	27,4	32,7	30,5	30,5	28,4	32,6	31,2	31,3	-0,7	-0,8
6	31,4	34,6	33,0	33,0	32,5	35,4	34,2	34,8	-1,2	-1,8
7	33,3	34,6	33,7	33,7	32,7	35,1	34,6	34,9	-0,9	-1,2
8	33,8	35,5	34,7	34,7	33,5	36,3	35,6	36,0	-0,9	-1,3
9	25,1	29,2	27,0	26,8	25,7	30,8	28,8	29,8	-1,8	-3,0
10	26,8	31,4	29,5	29,5	27,9	31,3	29,3	29,0	0,2	0,5
11	32,7	35,1	33,5	33,4	30,4	35,4	34,3	35,1	-0,8	-1,7
12	32,0	34,9	33,2	33,1	32,7	35,2	34,6	34,8	-1,4	-1,7
13	26,8	30,3	27,7	27,5	28,7	31,0	30,2	30,4	-2,5	-2,9
14	29,4	33,3	31,2	31,1	28,8	33,4	31,4	31,7	-0,2	-0,6
15	26,3	29,7	28,1	28,0	26,9	31,3	29,7	30,3	-1,6	-2,3
16	30,5	33,2	32,5	32,5	32,6	34,6	34,1	34,3	-1,6	-1,8
17	33,4	34,0	33,6	33,6	32,8	34,4	34,0	34,3	-0,4	-0,7
18	26,1	29,5	27,8	27,4	25,1	32,7	30,0	31,1	-2,2	-3,7
19	27,6	29,0	28,3	28,4	27,2	28,5	28,0	28,1	0,3	0,3
20	22,4	23,3	22,8	22,8	23,2	24,4	23,8	23,8	-1,0	-1,0
21	31,3	34,4	32,7	32,7	31,4	35,4	34,3	34,8	-1,6	-2,1
22	30,5	33,1	31,7	31,7	31,7	33,7	33,1	33,4	-1,4	-1,7
23	30,0	33,2	31,5	31,0	32,4	34,0	33,6	33,8	-2,1	-2,8
24	32,5	33,2	32,8	32,7	32,3	33,4	32,9	33,2	-0,1	-0,5
25	32,4	33,3	32,9	32,8	30,9	33,4	32,6	33,1	0,3	-0,3
26	30,7	33,2	31,5	31,2	31,5	33,6	32,9	33,2	-1,4	-2,0
27	31,6	34,0	32,8	32,7	32,0	33,5	33,1	33,2	-0,3	-0,5
28	31,3	32,8	32,0	31,9	31,4	32,9	32,5	32,6	-0,5	-0,7
29	28,8	32,4	30,0	29,6	25,5	32,4	29,0	29,4	1,0	0,2
30	29,8	31,8	30,8	30,7	28,0	32,1	30,6	31,0	0,2	-0,3
31	32,3	33,9	33,2	33,3	30,8	33,5	32,5	32,7	0,7	0,6
32	31,1	32,6	31,6	31,5	30,5	33,2	32,5	32,7	-0,9	-1,2
33	32,1	33,3	32,9	33,0	31,4	33,6	33,0	33,2	-0,1	-0,2
34	29,5	31,1	30,2	30,1	31,0	33,0	32,3	32,5	-2,1	-2,4
35	30,8	32,2	31,3	31,3	30,9	32,9	32,2	32,4	-0,9	-1,1
36	27,2	32,3	29,4	29,1	27,3	32,6	30,9	31,8	-1,5	-2,7
37	28,0	30,0	28,9	28,8	29,8	31,6	31,0	31,2	-2,1	-2,4
38	30,8	33,4	32,3	32,3	30,8	33,7	32,5	32,4	-0,2	-0,1
39	31,9	33,4	32,5	32,5	31,9	33,2	32,6	32,6	-0,1	-0,1
40	32,3	34,4	33,0	32,6	33,5	34,5	34,2	34,3	-1,2	-1,7
41	31,0	33,0	31,9	31,8	29,0	33,0	31,0	31,2	0,9	0,6
42	31,0	32,4	31,5	31,4	31,7	33,4	32,6	32,6	-1,1	-1,2

43	32,5	33,1	32,9	32,9	32,5	33,6	32,9	32,8	0,0	0,1
44	28,0	30,6	29,4	29,3	27,8	30,7	29,8	30,0	-0,4	-0,7
45	27,7	28,6	28,2	28,2	28,5	30,8	29,8	29,9	-1,6	-1,7
46	29,3	31,8	30,8	30,9	31,7	33,2	32,3	32,2	-1,5	-1,3
47	34,7	34,9	34,8	34,8	34,5	35,5	35,0	35,0	-0,2	-0,2
48	21,8	32,9	25,7	24,6	24,0	33,5	29,2	28,9	-3,5	-4,3
49	25,6	26,4	26,0	26,0	27,5	32,7	31,0	32,1	-5,0	-6,1
50	34,3	35,3	34,8	34,9	34,6	35,8	35,2	35,2	-0,4	-0,3

Nota: Valores negativos indicam que a média ou a mediana do método tradicional foi superior à da aprendizagem ativa.

APÊNDICE I - DADOS NORMALIZADOS

Estudantes	EDA T	HR T	ST T	EDA A	HR A	ST A
1	0.13	-2.98	-1.60	0.78	-1.93	-0.24
2	0.14	-1.32	-0.18	-5.16	-1.04	1.86
3	1.36	-2.32	-1.20	-0.61	1.00	-1.09
4	0.26	-1.58	-0.89	0.22	0.16	0.13
5	-0.04	-1.61	-0.24	-1.96	-0.11	-0.01
6	0.21	-1.42	-1.54	0.00	4.92	0.01
7	0.31	-1.85	-1.74	-0.08	-2.51	0.01
8	0.07	0.03	-2.14	-0.68	0.09	-0.10
9	0.13	0.17	-1.07	0.00	-0.06	0.26
10	-0.04	0.81	0.36	-0.48	2.36	-0.01
11	-0.04	0.55	-2.78	0.13	-0.19	0.47
12	-0.06	6.04	-0.85	0.38	2.05	0.23
13	-0.05	0.29	-0.78	-0.37	0.43	0.63
14	-0.27	6.68	-0.18	-0.57	3.57	0.09
15	-0.35	-0.49	-0.76	-1.95	0.71	0.06
16	0.23	5.45	-1.17	0.05	1.86	0.12
17	0.42	-0.88	-3.32	0.22	-0.55	0.15
18	-0.37	-0.05	-0.76	-0.18	-0.62	0.49
19	0.06	-1.40	-0.32	0.00	4.51	-0.51
20	0.00	-0.05	-0.14	-0.36	-0.51	0.22
21	-0.32	0.28	-1.29	-0.37	0.10	0.06
22	0.10	-0.56	-3.55	-0.13	1.23	-0.01
23	-0.23	0.33	-1.71	-0.32	0.67	0.74
24	0.15	-0.61	-2.70	-0.68	-2.14	0.56
25	0.14	-1.30	-1.73	0.32	-1.44	0.30
26	0.77	0.60	-0.86	-0.45	-0.27	0.89
27	0.59	-0.11	-1.46	0.77	0.33	0.09
28	-0.03	-0.44	-1.19	0.00	1.40	0.55
29	0.19	-0.77	-0.19	0.04	1.03	0.62
30	0.23	-0.48	-0.58	-0.05	-0.14	0.29
31	0.00	2.01	-0.56	0.00	1.82	-0.42
32	-0.18	0.70	-0.90	0.00	0.78	0.52
33	0.08	-0.33	-1.22	0.17	0.36	-0.57
34	0.35	0.21	-0.78	0.33	0.32	0.26
35	0.16	-0.84	-0.61	0.22	-0.47	0.21
36	0.88	-0.28	-1.32	-1.07	0.14	0.20
37	0.38	0.12	-0.85	0.38	1.06	0.11
38	-0.29	-0.56	-0.55	-0.36	-0.52	2.73
39	-0.11	-0.34	-0.02	0.00	0.44	0.08
40	0.34	1.24	-1.02	0.60	1.08	2.05
41	-0.30	-0.70	-0.48	0.01	-0.70	0.13
42	0.88	0.20	-0.03	-0.36	-0.63	0.89
43	-0.11	-0.67	0.48	0.27	-0.56	-0.40
44	0.17	-0.71	-0.64	0.31	0.14	0.08
45	0.18	0.94	-0.27	0.52	0.59	-0.12
46	0.24	0.87	0.48	-0.07	0.37	-0.24
47	-2.19	4.44	0.05	-1.48	4.91	0.35
48	-0.10	-0.11	0.18	-0.81	0.24	0.81
49	0.35	0.22	-2.12	0.00	-0.54	0.03
50	0.59	0.25	0.00	-0.55	0.47	-1.10