

**SISTEMA DE
RECONHECIMENTO
EMOCIONAL VIA
ELETROENCEFALOGRAMA
E INTELIGÊNCIA ARTIFICIAL
APLICADO A JOGOS
DIGITAIS**

**EMOTION RECOGNITION SYSTEM USING ELECTROENCEPHALOGRAPHY
AND ARTIFICIAL INTELLIGENCE APPLIED TO DIGITAL GAMES**

Ciências Exatas e da Terra, Engenharias • 01/06/2026

REGISTRO DOI: [10.70773/revistatopicos/780262381](https://doi.org/10.70773/revistatopicos/780262381)

Ricardo Victor Marques Sampaio Pinheiro¹

Siomara Dias da Rocha²

RESUMO

Este trabalho investiga a integração de técnicas de reconhecimento emocional baseadas em sinais de eletroencefalografia (EEG) a jogos digitais adaptativos. O objetivo consiste em desenvolver um sistema capaz de classificar estados emocionais nas dimensões de arousal e valence e utilizar essas previsões para adaptação dinâmica das mecânicas de jogo. Para isso, foi utilizado o dataset GAMEEMO, composto por registros de EEG de 28 participantes durante sessões de jogos digitais, adquiridos por 14 canais com frequência de amostragem de 128 Hz. A extração de características foi realizada por meio do método de Welch com janelamento Hamming, permitindo a obtenção de potências espectrais em diferentes bandas de frequência, assimetrias hemisféricas e estatísticas descritivas, totalizando 105 características por janela de análise. Para a classificação emocional, foram empregados os algoritmos Support Vector Machine (SVM) para a dimensão de arousal e Random Forest para valence. O sistema foi integrado a um jogo 2D desenvolvido na engine Godot por meio de comunicação WebSocket, possibilitando a adaptação automática de elementos da jogabilidade com base em quatro estados emocionais discretos. Os resultados demonstraram desempenho satisfatório na classificação da dimensão de arousal, alcançando coeficiente de determinação (R^2) de 0,368, enquanto a dimensão de valence apresentou maior complexidade de modelagem, com R^2 de 0,136. A arquitetura desenvolvida mostrou-se adequada para integração contínua entre o sistema de reconhecimento emocional e o ambiente de jogo. Conclui-se que a abordagem proposta é viável para aplicações de interfaces cérebro-computador voltadas ao entretenimento digital, contribuindo para o desenvolvimento de experiências adaptativas baseadas em estados afetivos.

Palavras-chave: Eletroencefalografia; Interface Cérebro-

Computador; Reconhecimento Emocional; Aprendizado de Máquina; Jogos Adaptativos.

ABSTRACT

This work investigates the integration of electroencephalography (EEG)-based emotion recognition techniques into adaptive digital games. The objective is to develop a system capable of classifying emotional states in the dimensions of arousal and valence and using these predictions to dynamically adapt game mechanics. For this purpose, the GAMEEMO dataset was employed, comprising EEG recordings from 28 participants during digital gaming sessions, acquired through 14 channels at a sampling rate of 128 Hz. Feature extraction was performed using Welch's method with Hamming windowing, allowing the computation of spectral power across different frequency bands, hemispheric asymmetries, and descriptive statistics, resulting in a total of 105 features per analysis window. For emotion classification, Support Vector Machine (SVM) was applied to the arousal dimension, while Random Forest was used for valence. The prediction system was integrated into a 2D game developed with the Godot Engine through WebSocket communication, enabling automatic adaptation of gameplay elements based on four discrete emotional states. The results demonstrated satisfactory performance for arousal classification, achieving a coefficient of determination (R^2) of 0.368, whereas the valence dimension presented greater modeling complexity, obtaining an R^2 value of 0.136. The proposed architecture proved suitable for continuous integration between the emotion recognition system and the game environment. It is concluded that the proposed approach is viable for brain-computer interface applications in digital entertainment, contributing to the development of adaptive gaming experiences based on affective

states.

Keywords: Electroencephalography; Brain-Computer Interface; Emotion Recognition; Machine Learning; Adaptive games.

1. INTRODUÇÃO

Nos últimos anos, a integração entre neurotecnologia e inteligência artificial tem ganhado destaque em aplicações envolvendo interfaces cérebro-computador (Brain-Computer Interfaces - BCI) (Samal; Hashmi, 2024). Essas interfaces possibilitam a interpretação de sinais neurais captados por meio da eletroencefalografia (EEG), técnica não invasiva utilizada para monitorar a atividade elétrica cerebral (McFarland; Wolpaw, 2017). Nesse contexto, o reconhecimento emocional baseado em EEG surge como uma área promissora, permitindo identificar padrões neurais associados a estados afetivos por meio de técnicas de inteligência artificial (Erat et al., 2024).

No setor de jogos digitais, a análise emocional dos jogadores apresenta potencial para o desenvolvimento de experiências mais imersivas e adaptativas. A identificação de estados emocionais possibilita ajustes dinâmicos em elementos da jogabilidade, como dificuldade, eventos e estímulos visuais, de acordo com o estado afetivo do usuário. Estudos recentes demonstram o crescente interesse na aplicação de sinais neurais em ambientes virtuais e jogos digitais, especialmente em pesquisas voltadas ao reconhecimento emocional e à interação homem-máquina (Lim; Teo, 2024; Patiño et al., 2025).

Diversas pesquisas já exploram bancos de dados públicos para o estudo de emoções via EEG. Entre os mais conhecidos estão o DEAP

dataset, que fornece sinais cerebrais coletados durante a exposição de participantes a estímulos audiovisuais (Koelstra et al., 2012b), e o GAMEEMO dataset, que utiliza jogos digitais como estímulo emocional, reunindo sinais neurais associados a estados como medo, relaxamento, tédio e diversão (Alakus et al., 2020). Esses conjuntos de dados permitem o treinamento de modelos capazes de classificar estados emocionais a partir da atividade cerebral.

Apesar dos avanços na área, grande parte das pesquisas permanece restrita a análises offline ou aplicações laboratoriais específicas. Além disso, muitos estudos envolvendo EEG concentram-se em aplicações médicas e assistivas, como controle de próteses e interfaces motoras (Altaheri et al., 2021), existindo ainda espaço para aplicações voltadas à adaptação dinâmica em jogos digitais.

Diante desse cenário, este trabalho propõe o desenvolvimento de um sistema de reconhecimento emocional baseado em sinais de EEG e inteligência artificial aplicado a jogos digitais, utilizando datasets públicos para treinamento e classificação emocional. Além disso, propõe-se o desenvolvimento de um jogo capaz de responder dinamicamente aos estados emocionais identificados, buscando proporcionar experiências mais imersivas e personalizadas ao jogador

2. FUNDAMENTAÇÃO TEÓRICA OU REVISÃO DA LITERATURA

Neurotecnologia

A neurotecnologia consiste no desenvolvimento e aplicação de tecnologias capazes de monitorar, analisar ou interagir com o sistema nervoso. Esse campo integra conhecimentos provenientes da neurociência, engenharia biomédica e ciência da computação,

viabilizando soluções voltadas tanto para aplicações clínicas quanto para contextos experimentais e interativos (Williamson, 2019).

As aplicações da neurotecnologia abrangem áreas como reabilitação médica, monitoramento cognitivo, interfaces cérebro-computador e sistemas de interação humano-computador. Nos últimos anos, o avanço dessas tecnologias também ampliou sua presença em aplicações voltadas ao entretenimento digital e ao reconhecimento de estados mentais e emocionais.

Interface Cérebro-Computador

As interfaces cérebro-computador (Brain-Computer Interfaces - BCI ou Brain-Machine Interfaces - BMI) consistem em sistemas capazes de estabelecer comunicação direta entre a atividade neural e dispositivos computacionais, permitindo que sinais cerebrais sejam interpretados como comandos sem a necessidade de vias musculares periféricas. Essas interfaces representam um dos principais avanços da neurotecnologia, integrando conhecimentos de neurociência, engenharia biomédica e ciência da computação (Wolpaw; Wolpaw, 2012).

As BCIs podem ser classificadas em invasivas e não invasivas de acordo com o método de aquisição dos dados neurais. As BCIs invasivas envolvem a implantação neurocirúrgica de eletrodos diretamente no tecido cerebral, possibilitando alta resolução espacial e melhor qualidade do sinal. Contudo, esse tipo de abordagem apresenta riscos associados ao procedimento cirúrgico, como danos no tecido cerebral e infecções, sendo geralmente restrito a aplicações médicas específicas (Lebedev; Nicolelis, 2017).

Por outro lado, as BCIs não invasivas utilizam sensores posicionados externamente ao crânio, como ocorre na eletroencefalografia (EEG), que capta a atividade elétrica cerebral por meio de elétrodos fixados no couro cabeludo. Embora apresentem menor resolução espacial em comparação às técnicas invasivas, essas abordagens destacam-se pela segurança, menor custo e ampla aplicabilidade em contextos clínicos, experimentais e interativos (Lebedev; Nicolelis, 2017).

Entre as técnicas não invasivas, o EEG é uma das mais utilizadas em pesquisas envolvendo reconhecimento de estados cognitivos e emocionais devido à sua elevada resolução temporal e viabilidade prática. Dessa forma, o EEG constitui uma ferramenta central no desenvolvimento de sistemas baseados em BCI (Wolpaw; Wolpaw, 2012).

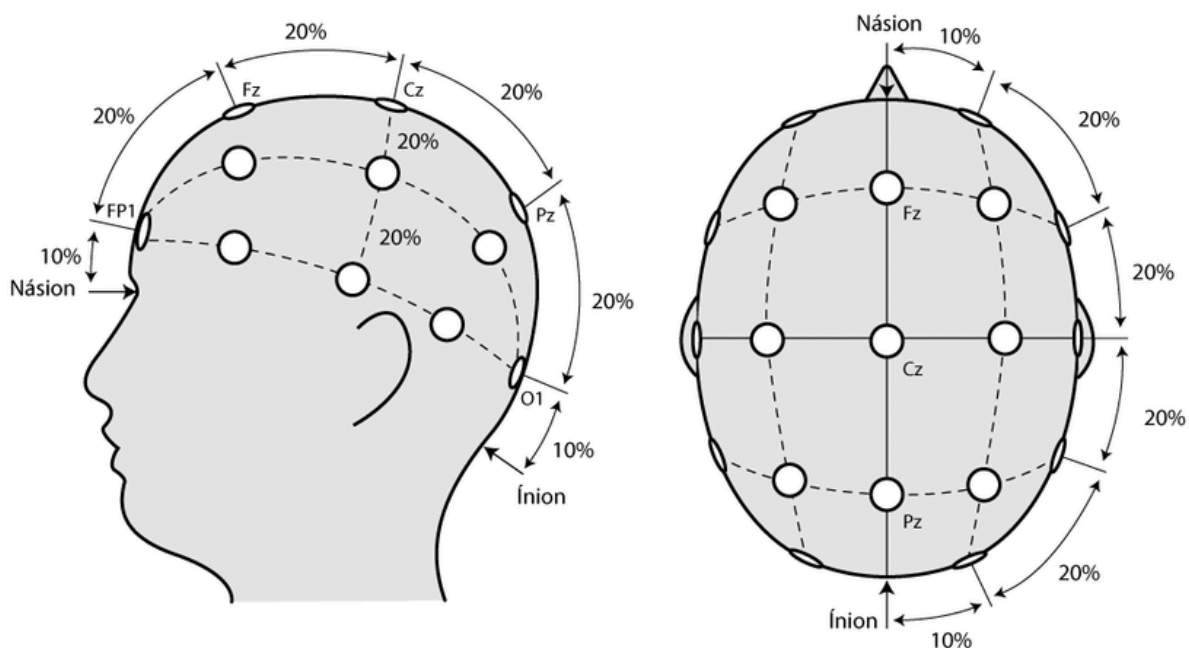
Eletroencefalograma (EEG)

O cérebro é responsável pelo controle das atividades cognitivas, motoras e emocionais do ser humano, sendo essas atividades realizadas por meio de sinais cerebrais gerados a partir dos impulsos elétricos dos neurônios (Wagh; Vasanth, 2019). Um dos métodos capazes de captar esses sinais é o eletroencefalograma (EEG), considerado uma das técnicas mais acessíveis e práticas para monitoramento da atividade cerebral, podendo, em alguns casos, ser utilizado fora de ambientes laboratoriais com equipamentos e softwares adequados.

O EEG é um método de interface cérebro-computador não invasivo, ou seja, não requer implantes cirúrgicos para sua utilização. A coleta dos sinais neurais é realizada por meio de elétrodos posicionados ao

longo do couro cabeludo, possibilitando a detecção dos impulsos elétricos gerados pelos neurônios (McFarland; Wolpaw, 2017), como apresentado na Figura 1.

Figura 1: Posição dos eletrodos no escalpo.



Fonte: Rodrigues (2018)

Para reconhecer as emoções de um indivíduo, as ondas cerebrais são analisadas de acordo com suas faixas de frequência, as quais apresentam variações associadas a diferentes estados mentais e emocionais, compondo padrões neurais que podem ser utilizados para inferência emocional. Essas ondas são representadas em ciclos por segundo ou hertz (Hz) e são divididas em cinco faixas principais: Delta (~0.5-4 Hz), Theta (4-7 Hz), Alpha (8-13 Hz), Beta (14-30 Hz) e Gamma (>30 e normalmente <100 Hz) (Urigüen; Garcia-Zapirain, 2015). Na Tabela 1 são apresentados os estados mentais geralmente associados a cada faixa de frequência.


Tabela 1: Classificação das ondas cerebrais e suas associações típicas.

Onda	Frequência (Hz)	Estados mentais associados
Delta	0.5 – 4	Sono profundo, processos de regeneração e estados de inconsciência.
Theta	4 – 7	Sonolência, estágios iniciais do sono, imaginação, criatividade e processamento emocional.
Alpha	8 – 13	Relaxamento leve, calma e estado de vigília tranquila.
Beta	14 – 30	Atenção, pensamento ativo, foco, tomada de decisão e estado de alerta.
Gamma	30 – 100	Processamento cognitivo elevado, integração sensorial, percepção e memória de trabalho.

Fonte: Elaborado pelos autores (2026)

Na Figura 2, observa-se o comportamento das frequências correspondentes a cada faixa.

Figura 2: Ritmos de sinais cerebrais.



(a) Brain Rhythms

Fonte: Urigüen e Garcia-Zapirain (2015)

Segundo estudos recentes de classificação emocional via EEG, a atividade elétrica medida no couro cabeludo representa a soma de potenciais pós-sinápticos em regiões neurais específicas e, ao ser transformada no domínio da frequência e combinada com técnicas de aprendizado de máquina, permite a inferência de estados emocionais. Essa abordagem demonstra que não há uma correspondência direta entre uma única faixa de frequência e uma emoção específica. Em vez disso, padrões extraídos de múltiplas bandas de frequência servem de base para a classificação de estados afetivos por modelos supervisionados (Prakash; Poulouse, 2025).

Emoções e Modelos de Representação Emocional

As emoções podem ser descritas por diferentes modelos teóricos presentes na literatura psicológica e neurocientífica. Entre as abordagens mais conhecidas está o modelo discreto, que propõe a existência de emoções básicas universais, como alegria, tristeza, raiva e medo (Ekman, 1992). Esse modelo categoriza as emoções em estados distintos e bem definidos, sendo amplamente utilizado em estudos comportamentais.

Entretanto, para aplicações computacionais e de reconhecimento emocional, especialmente aquelas baseadas em sinais fisiológicos como o EEG, modelos dimensionais têm sido mais frequentemente empregados. O modelo circumplexo proposto por Russell (1980) organiza as emoções em um espaço bidimensional definido pelos eixos de valência e arousal. A valência representa o grau de positividade ou negatividade da emoção, enquanto o arousal indica o nível de ativação fisiológica associado ao estado emocional (Russell, 1980).

Esse modelo dimensional permite representar emoções de forma contínua, tornando-se particularmente adequado para aplicações de reconhecimento emocional automatizado, como aquelas baseadas em interfaces cérebro-computador. Bases de dados amplamente utilizadas na literatura, como GAMEEMO (Alakus et al., 2020) e DEAP (Koelstra et al., 2012b), utilizam essa representação para rotular estados emocionais em estudos envolvendo EEG.

Reconhecimento de emoções via EEG com Inteligência Artificial

A inteligência artificial (IA) tem sido amplamente empregada em tarefas de reconhecimento de padrões complexos em diferentes áreas do conhecimento. Entre suas abordagens mais utilizadas

destaca-se o aprendizado de máquina (Machine Learning), que consiste em técnicas capazes de identificar padrões em dados e realizar previsões ou classificações com base em exemplos previamente rotulados (Mitchell, 1997).

No contexto do reconhecimento emocional, algoritmos de aprendizado de máquina são frequentemente utilizados para analisar sinais fisiológicos, como aqueles obtidos por meio da eletroencefalografia (EEG). Esses sinais apresentam características complexas e não lineares, tornando difícil sua interpretação direta por métodos tradicionais. Dessa forma, técnicas de aprendizado de máquina são aplicadas para extrair padrões relevantes associados a diferentes estados emocionais (Lotte et al., 2018).

Em geral, sistemas baseados em interfaces cérebro-computador seguem um pipeline composto por etapas de pré-processamento do sinal, extração de características e classificação (Bashashatiet al., 2007). No contexto do reconhecimento emocional baseado em EEG, essas etapas são utilizadas para identificar padrões associados a diferentes estados afetivos, sendo comum o uso de algoritmos de classificação supervisionada, como máquinas de vetores de suporte (SVM), redes neurais artificiais, Random Forest e modelos de aprendizado profundo (Koelstra et al., 2012a; Lotte et al., 2018).

Jogos Digitais Adaptativos

Jogos digitais adaptativos são sistemas capazes de ajustar dinamicamente elementos do jogo com base no comportamento do jogador, com o objetivo de melhorar a experiência de uso e manter o engajamento. Uma das abordagens mais conhecidas nesse contexto é o Dynamic Difficulty Adjustment (DDA), que

consiste na adaptação automática do nível de dificuldade do jogo de acordo com o desempenho do jogador (Hunicke, 2005). Um exemplo conhecido é o jogo Resident Evil 4 (2005), no qual a dificuldade é ajustada automaticamente conforme o desempenho do jogador.

Esse tipo de adaptação busca equilibrar o nível de desafio e as habilidades do jogador, conceito relacionado à teoria do flow, proposta por Csikszentmihalyi (1990), segundo a qual o engajamento é maximizado quando há equilíbrio entre desafio e capacidade (Csikszentmihalyi, 1990).

Para viabilizar essas adaptações, jogos adaptativos utilizam técnicas de modelagem do jogador, que analisam dados gerados durante a interação, como desempenho e padrões de comportamento, permitindo ajustes dinâmicos em parâmetros como dificuldade e ritmo do jogo (Yannakakis; Togelius, 2018).

3. METODOLOGIA

A metodologia desta pesquisa é estruturada em quatro etapas principais: aquisição dos dados neurais, preparação e organização dos dados, construção de um classificador de emoções humanas e desenvolvimento de um jogo digital capaz de interagir dinamicamente com os estados emocionais classificados pelo modelo de inteligência artificial.

Ferramentas de software utilizadas

A implementação do modelo de inteligência artificial e a análise dos dados neurais são realizadas utilizando o ambiente de desenvolvimento Spyder IDE 6.1.0 (Spyder Project Contributors,

2025), baseado na linguagem Python 3.13 (Python Software Foundation, 2025), amplamente utilizada em aplicações de ciência de dados. Nesse ambiente, são empregadas as bibliotecas Scikit-learn 1.7 (Pedregosa et al., 2011), responsável pelo treinamento e avaliação dos modelos de classificação, além das bibliotecas SciPy (Virtanen et al., 2020) e Matplotlib (Hunter, 2007), utilizadas no processamento e visualização dos sinais de eletroencefalografia (EEG).

Para o desenvolvimento do jogo digital, é utilizada a engine Godot (Godot Engine Community, 2025) em conjunto com a plataforma .NET 9.0.2 (Microsoft, 2025) e a linguagem C#, permitindo a implementação da lógica do jogo e dos elementos adaptativos. Adicionalmente, a ferramenta Aseprite 1.3.15 (Aseprite, 2025) é utilizada para a criação dos elementos gráficos em estilo pixel art.

Aquisição dos dados do EEG

Os dados utilizados nesta pesquisa foram obtidos a partir do GAMEEMO dataset, uma base de dados pública desenvolvida para estudos de reconhecimento emocional utilizando sinais de eletroencefalografia (EEG). O conjunto de dados foi construído a partir de experimentos realizados com 28 participantes submetidos a sessões de jogos digitais, com o objetivo de capturar sinais neurais associados a diferentes estados emocionais (Alakus et al., 2020).

Durante os experimentos, os participantes jogaram quatro jogos distintos projetados para estimular emoções específicas, como tédio, calma, medo e diversão. Os sinais neurais coletados durante as sessões foram registrados por dispositivos de EEG e posteriormente

disponibilizados no dataset juntamente com os rótulos emocionais correspondentes.

Nesta pesquisa, os sinais presentes no GAMEEMO são utilizados como base para o treinamento e avaliação do modelo de reconhecimento emocional, possibilitando a investigação da aplicação de inteligência artificial em sistemas adaptativos voltados a jogos digitais.

Pré-processamento dos sinais EEG

O GAMEEMO dataset disponibiliza os sinais de EEG previamente pré-processados, incluindo etapas de remoção de artefatos realizadas pelos autores da base de dados (Alakus et al., 2020). Dessa forma, nesta pesquisa foram utilizados diretamente os sinais disponibilizados pelo dataset, não sendo necessária a aplicação manual de técnicas adicionais de remoção de ruídos ou artefatos.

Após a obtenção dos dados, foram realizadas etapas complementares de preparação para análise computacional, incluindo organização das amostras, separação dos rótulos emocionais e adequação dos dados para utilização nos modelos de aprendizado de máquina.

Além disso, os dados foram divididos em conjuntos de treinamento e teste, permitindo a avaliação do desempenho do classificador emocional desenvolvido nesta pesquisa.

Extração de características

A extração de características foi implementada utilizando a biblioteca SciPy para processamento de sinais digitais. O processo

foi estruturado em três etapas principais: Segmentação temporal, análise espectral por meio do método de Welch (Welch, 1976) e cálculo de características derivadas.

Os sinais de EEG foram segmentados em janelas temporais de 30 segundos, correspondendo a 3.840 amostras considerando a taxa de amostragem de 128Hz do GAMEEMO dataset. Para cada janela, foram processados individualmente os sinais dos 14 canais de EEG disponíveis (AF3, AF4, F3, F4, F7, F8, FC5, FC6, O1, O2, P7, P8, T7, T8).

Para cada canal, foi aplicado o método de Welch para estimativa da densidade espectral de potência, utilizando segmentos com janelamento de Hamming e sobreposição de 50%. A partir da densidade espectral, foram calculadas as potências em cinco bandas de frequência; delta, theta, alpha, beta e gamma.

As potências obtidas foram normalizadas como potências relativas, calculadas como a proporção de cada banda em relação à potência total do sinal. Essa normalização garante que a soma das potências de todas as bandas seja igual a 1, tornando as características invariantes à amplitude absoluta do sinal.

Além das potências espectrais por canal, foram calculadas características de assimetria hemisférica, definidas como a diferença entre as potências relativas dos eletrodos homólogos dos hemisférios direito e esquerdo. Foram computadas assimetrias para cinco pares de eletrodos (AF3-AF4, F3-F4, FC5-FC6, T7-T8, P7-P8) em cada uma das cinco bandas de frequência, totalizando 25 características de assimetria.

Por fim, foram extraídas medidas estatísticas agregadas para cada banda de frequência, calculando a média e o desvio padrão das

potências relativas ao longo de todos os 14 canais, resultando em 10 características estatísticas.

O vetor final de características contém 105 valores por janela temporal: 70 potências relativas (5 bandas \times 14 canais), 25 assimetrias hemisféricas (5 bandas \times 5 pares) e 10 estatísticas agregadas (5 bandas \times 2 medidas).

Treinamento do classificador

O treinamento do classificador emocional foi realizado utilizando os vetores de características extraídos dos sinais de EEG. Os dados foram divididos em conjuntos de treinamento e teste seguindo uma abordagem sujeito-independente, garantindo que os modelos fossem avaliados em participantes não vistos durante o treinamento.

Foram utilizadas 88 gravações de 22 participantes do GAMEEMO dataset (S01-S22), sendo 80 gravações dos participantes S01 a S20 destinadas ao treinamento e 8 gravações dos participantes S21 e S22 reservadas para teste. Essa divisão simula condições realistas de uso, onde o sistema deve generalizar para novos usuários.

Previamente ao treinamento, todas as características foram normalizadas utilizando padronização Z-score (média = 0, desvio padrão = 1), calculada exclusivamente sobre o conjunto de treinamento e posteriormente aplicada ao conjunto de teste, evitando vazamento de informação.

O problema de reconhecimento emocional foi modelado como duas tarefas de regressão independentes: predição de arousal (ativação) e predição de valence (valência), ambas em escala de 1 a 5. Essa

abordagem dimensional permite representar emoções em um espaço bidimensional contínuo.

Foram treinados e comparados três algoritmos de aprendizado de máquina: Random Forest, Support Vector Machine (SVM) e Gradient Boosting. O Random Forest foi configurado com 100 estimadores, profundidade máxima de 10 níveis e mínimo de 5 amostras por divisão. O SVM utilizou kernel RBF com parâmetro de regularização $C = 1.0$ e $\epsilon = 0.1$. O Gradient Boosting foi configurado com 100 estágios, profundidade máxima de 5 e taxa de aprendizado de 0.1.

Para cada algoritmo, foram treinados dois modelos independentes (arousal e valence), totalizando seis modelos avaliados. A seleção foi baseada no desempenho no conjunto de teste, utilizando como métricas o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Determinação (R^2). O MAE foi adotado como critério principal por sua interpretabilidade direta em relação à escala emocional.

Os modelos finais selecionados foram Support Vector Machine para arousal (MAE = 0.767, RMSE = 0.953, $R^2 = 0.368$) e Random Forest para valence (MAE = 0.803, RMSE = 1.039, $R^2 = 0.136$). Esses valores indicam que as previsões desviam, em média, aproximadamente 0.77 e 0.80 pontos da avaliação real em uma escala de 1 a 5. O R^2 de 0.368 para arousal e 0.136 para valence demonstram capacidade moderada de explicação da variância, consistente com os desafios inerentes ao reconhecimento emocional via EEG reportados na literatura.

Desenvolvimento do jogo adaptativo

O jogo digital desenvolvido consiste em uma experiência de plataforma 2D em estilo pixel art, implementada na engine Godot utilizando a linguagem C#. O jogador controla um personagem que deve eliminar inimigos (zumbis) em um cenário de plataforma com elementos de perigo ambiental (lava) e obstáculos verticais. O personagem possui três mecânicas básicas: movimento lateral, pulo e disparo de projéteis.

O sistema de adaptação emocional foi projetado para modificar dinamicamente diversos parâmetros do jogo com base nas previsões de arousal e valence fornecidas pelo classificador de emoções.

As emoções foram mapeadas em quatro quadrantes do modelo circumplexo: triste/entediado (baixo arousal, baixa valence), calmo/pacífico (baixo arousal, alta valence), excitado/feliz (alto arousal, alta valence) e raivoso/estressado (alto arousal, baixa valence).

Para cada quadrante emocional, foram implementadas adaptações específicas:

- Estado Triste/Entediado (arousal < 3, valence < 3): O jogo reduz significativamente a velocidade de execução, tornando o movimento do personagem e dos inimigos mais lentos. Adicionalmente, é ativado um sistema de regeneração gradual de vida, incentivando o jogador a permanecer engajado mesmo em estado emocional negativo.

- Estado Calmo/Pacífico (arousal < 3, valence ≥ 3): O jogo opera em parâmetros neutros, com velocidades padrão e mecânicas balanceadas.

– Estado Excitado/Feliz (arousal ≥ 3 , valence ≥ 3): O personagem recebe aumento de velocidade de movimento e incremento no dano dos projéteis, intensificando a experiência de jogo e aproveitando o estado emocional positivo e energizado do jogador. A regeneração de vida permanece ativa.

– Estado Raivoso/Estressado (arousal ≥ 3 , valence < 3): O jogo aplica modificações visuais e mecânicas intensas: o cenário de fundo assume tonalidade vermelha, a câmera apresenta tremor contínuo leve (screen shake), tanto o personagem quanto os inimigos têm suas velocidades aumentadas, e o dano dos projéteis é incrementado, refletindo a intensidade emocional elevada.

A integração entre o sistema de reconhecimento emocional e o jogo foi implementada através de comunicação em tempo real via protocolo WebSocket. O sistema Python executa em servidor local (localhost:8765), processando continuamente os sinais de EEG em janelas de 30 segundos. Para cada janela processada, o sistema extrai características, realiza a predição de arousal e valence utilizando os modelos treinados, e transmite os valores preditos ao jogo através de mensagens JSON estruturadas.

No lado do jogo, um script (GameManager.cs) estabelece conexão WebSocket com o servidor Python ao iniciar a aplicação. O script permanece em escuta aguardando atualizações emocionais, que são recebidas a cada 30 segundos. Ao receber uma nova predição, o sistema interpreta os valores de arousal e valence, determina o quadrante emocional correspondente e aplica imediatamente as adaptações programadas aos parâmetros do jogo.

Essa arquitetura cliente-servidor permite que o jogo responda dinamicamente ao estado emocional inferido do jogador, criando uma experiência adaptativa que se ajusta em tempo real conforme as variações emocionais detectadas através dos sinais de EEG.

4. RESULTADOS E DISCUSSÕES OU ANÁLISE DOS DADOS

Desempenho dos modelos de classificação

Os três algoritmos de aprendizado de máquina avaliados apresentaram desempenho variado para predição de arousal e valence. A Tabela 2 apresenta as métricas de desempenho obtidas por cada modelo no conjunto de teste.

Tabela 2: Desempenho dos modelos de classificação emocional no conjunto de teste.

Modelo	Arousal			Valen	
	MAE	RMSE	R2	MAE	RMS
Random Forest	0.770	1.019	0.277	0.803	1.031
SVM	0.767	0.953	0.368	0.950	1.105
Gradient Boosting	1.049	1.262	-0.108	0.890	1.164

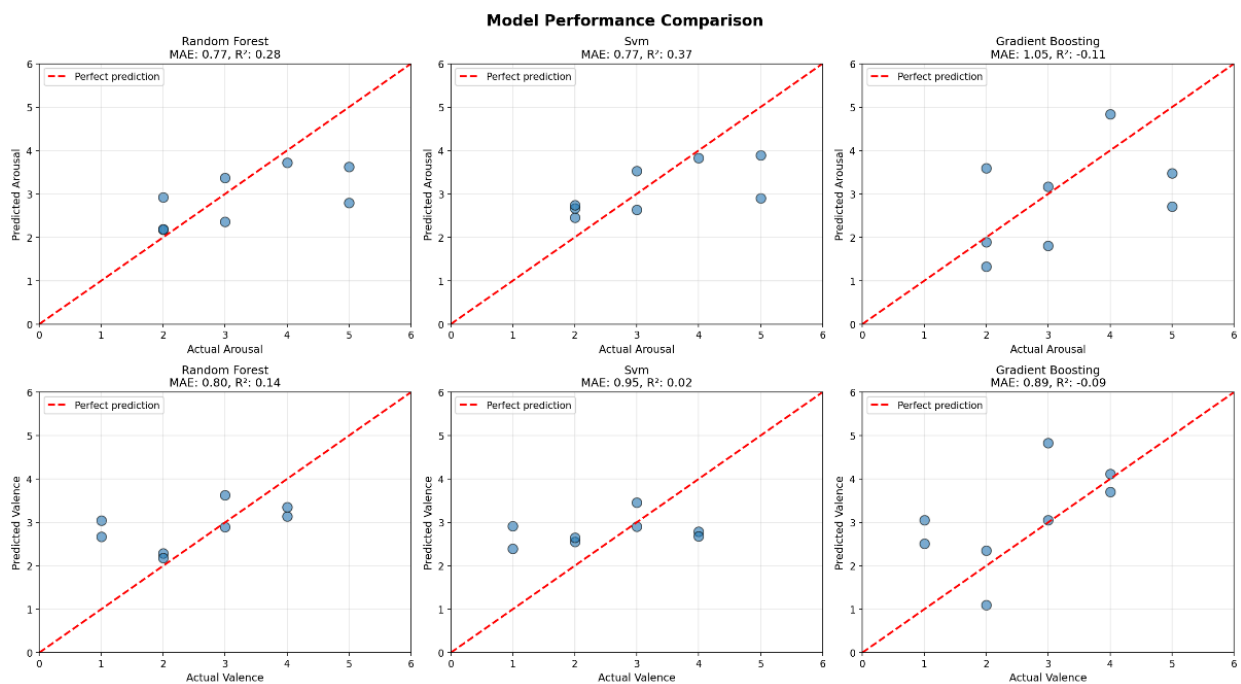
⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/sistema-de-reconhecimento-emocional-via-eletroencefalograma-e-inteligencia-artificial-aplicado-a-jogos-digitais?noblockage>

Fonte: Elaborado pelos autores(2026)

Conforme observado na Tabela 2, o Support Vector Machine apresentou o melhor desempenho para predição de arousal, com MAE de 0.767 e R2 de 0.368, indicando capacidade moderada de explicação da variância emocional. Para valence, o Random Forest obteve o menor erro (MAE = 0.803), embora com R2 de apenas 0.136, refletindo a maior dificuldade na predição dessa dimensão emocional.

A Figura 3 ilustra visualmente a comparação entre os valores preditos e os valores reais para cada modelo avaliado.

Figura 3: Comparação de desempenho entre os três algoritmos de aprendizado de máquina



Fonte: Elaborado pelos autores(2026).

Na Figura 3, observa-se que o SVM apresenta pontos mais concentrados à linha de predição perfeita para arousal, evidenciando sua superioridade nessa dimensão. Para valence, embora o Random Forest tenha obtido o menor MAE, nota-se maior dispersão dos pontos, indicando variabilidade nas predições.

O Gradient Boosting apresentou desempenho inferior, com valores negativos de R2 para ambas as dimensões, indicando que suas previsões foram menos precisas que a simples utilização da média dos valores de treinamento. Esse resultado sugere possível overfitting ou inadequação dos hiperparâmetros utilizados para este conjunto de dados específico.

Os valores de MAE obtidos (0.767 para arousal e 0.803 para valence) indicam que as previsões desviam, em média, aproximadamente 0.77 e 0.80 pontos da avaliação real em uma escala de 1 a 5.

O R2 de 0.368 para arousal e 0.136 para valence demonstram capacidade moderada de explicação da variância, consistente com os desafios inerentes ao reconhecimento emocional via EEG reportados na literatura (Lotte et al., 2018)

Integração e funcionamento do sistema adaptativo

O sistema integrado foi testado utilizando dados de EEG dos participantes S21 ao S22 do conjunto de teste. Durante as sessões de teste, o classificador emocional processou continuamente os sinais cerebrais em janelas de 30 segundos, transmitindo as previsões de arousal e valence ao jogo via protocolo WebSocket.

O jogo demonstrou capacidade de resposta dinâmica às previsões emocionais, adaptando seus parâmetros conforme o estado emocional inferido. A Figura 4 apresenta o jogo operando no estado emocional Calmo/Pacífico (arousal < 3, valence > 3).

Figura 4: Interface do jogo no estado emocional Calmo/Pacífico. Observa-se o cenário com paleta de cores padrão, indicando o estado emocional em seu estado padrão.



Fonte: Elaborado pelos autores(2026)

Nesse estado, o personagem apresentou velocidade de movimento e dano de projéteis em seu estado padrão, refletindo a adaptação do jogo ao estado emocional calmo do jogador.

A Figura 5 apresenta o estado Raivoso/Estressado (arousal 3, valence < 3), onde o sistema aplicou efeitos visuais intensos (fundo vermelho e shake de câmera) além de incrementar tanto a velocidade de movimento quanto o dano dos projéteis, refletindo a adaptação do jogo ao estado emocional de alta energia e valência negativa detectado pelo sistema

Figura 5: Interface do jogo no estado emocional Raivoso/Estressado. Nota-se a alteração da paleta de cores para tonalidade, caracterizando a resposta visual do sistema à detecção de emoções de alta ativação e valência negativa.



Fonte: Elaborado pelos autores(2026)

Durante esse estado, além das modificações visuais (fundo vermelho e screen shake), foram aplicados aumentos na velocidade do personagem e dos inimigos, bem como incremento no dano dos projéteis, intensificando a experiência de jogo de acordo com o estado emocional detectado.

O sistema demonstrou capacidade de transição fluida entre estados emocionais a cada intervalo de 30 segundos, com as adaptações sendo aplicadas de forma responsiva às previsões do classificador. A comunicação via WebSocket mostrou-se adequada para a aplicação, com latência imperceptível entre a previsão emocional e a aplicação das modificações no jogo.

Esses resultados evidenciam a viabilidade técnica da integração entre sistemas de reconhecimento emocional baseados em EEG e jogos digitais adaptativos, demonstrando que é possível criar experiências de jogo que respondem dinamicamente ao estado afetivo inferido do jogador em tempo real.

5. CONCLUSÃO/CONSIDERAÇÕES FINAIS

Este trabalho confirma a viabilidade da integração de técnicas de reconhecimento emocional baseadas em EEG a jogos digitais adaptativos, respondendo afirmativamente à questão de pesquisa proposta. Os três objetivos estabelecidos foram alcançados: o sistema desenvolvido foi capaz de classificar estados emocionais nas dimensões de arousal e valence, aplicar essas previsões para adaptação dinâmica das mecânicas de jogo e validar a arquitetura proposta utilizando participantes independentes ao conjunto de treinamento.

Os resultados obtidos indicam diferenças na capacidade de discriminação das dimensões emocionais a partir das características extraídas dos sinais de EEG. A dimensão arousal apresentou maior capacidade de classificação, enquanto valence demonstrou maior complexidade, demandando abordagens mais sofisticadas para sua modelagem. Nesse contexto, as assimetrias hemisféricas mostraram-se marcadores relevantes para a identificação de estados de ativação, contribuindo significativamente para o desempenho dos modelos utilizados.

Como contribuição prática, o trabalho apresenta um framework modular e reutilizável para aplicações de interfaces cérebro-computador em jogos digitais, composto por mecanismos de classificação emocional e adaptação dinâmica da jogabilidade. A arquitetura proposta permitiu a integração eficiente entre o sistema de análise emocional e o ambiente de jogo, possibilitando a utilização contínua das previsões emocionais para modificar elementos da experiência do usuário.

O estudo apresenta limitações relacionadas ao tamanho do conjunto de dados utilizado e ao número de participantes

empregados na validação do sistema integrado, fatores que restringem a generalização dos resultados para diferentes contextos e populações. Além disso, a capacidade moderada de explicação da variância observada, especialmente para a dimensão valence, sugere a necessidade de exploração de características adicionais e de abordagens alternativas de modelagem emocional.

Como trabalhos futuros, recomenda-se a realização de coletas de dados específicas para o contexto do jogo desenvolvido, a investigação de arquiteturas baseadas em aprendizado profundo para captura de padrões temporais mais complexos e a condução de estudos controlados com um número maior de participantes. Também se destaca a possibilidade de implementação de mecanismos de aprendizado online, permitindo a adaptação progressiva dos modelos às características individuais de cada usuário ao longo de múltiplas sessões.

Por fim, os resultados obtidos demonstram o potencial das interfaces cérebro-computador como ferramenta para personalização de experiências digitais baseadas em estados afetivos. Dessa forma, este trabalho contribui para a consolidação de aplicações de reconhecimento emocional em jogos digitais e estabelece bases para o desenvolvimento de sistemas interativos mais responsivos às necessidades emocionais dos usuários.

REFERÊNCIAS BIBLIOGRÁFICAS

ALAKUS, Talha Burak; GONEN, Murat; TURKOGLU, Ibrahim. Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO. *Biomedical Signal Processing and Control*, v. 60, 2020. Disponível em:

<https://doi.org/10.1016/j.bspc.2020.101951>. Acesso em: 18 setembro 2025.

ALTAHERI, Hamdi et al. Deep Learning Techniques for Classification of Electroencephalogram (EEG) Motor Imagery (MI) Signals: A Review. *Neural Computing and Applications*, v. 35, ago. 2021. Disponível em: <https://doi.org/10.1007/s00521-021-06352-5>. Acesso em: 31 julho 2025.

ASEPRITE. Aseprite Pixel-Art Tool. 2025. Disponível em: <https://www.aseprite.org/>. Acesso em: 20 maio 2026.

BASHASHATI, Ali et al. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, v. 4, n. 2, p. R32-R57, jul. 2007. Disponível em: <https://doi.org/10.1088/1741-2560/4/2/R03>. Acesso em: 14 setembro 2025.

CSIKSZENTMIHALYI, Mihaly. *Flow: The Psychology of Optimal Experience*. New York: Harper & Row, 1990. Acesso em: 20 fevereiro 2026

EKMAN, Paul. An Argument for Basic Emotions. *Cognition and Emotion*, v. 6, n. 3-4, p. 169-200, 1992. Disponível em: <https://doi.org/10.1080/02699939208411068>. Acesso em: 26 fevereiro 2026.

ERAT, Kübra et al. Emotion recognition with EEG-based brain-computer interfaces: a systematic literature review. *Multimedia Tools and Applications*, v. 83, p. 79647-79694, mar. 2024. Disponível em: <https://doi.org/10.1007/s11042-024-18259-z>. Acesso em: 31 julho 2025.

GODOT ENGINE COMMUNITY. Godot Engine. 2025. Disponível em: <https://godotengine.org/>. Acesso em: 20 maio 2026.

HUNICKE, Robin. The case for dynamic difficulty adjustment in games. ACM International Conference Proceeding Series, v. 265, p. 429-433, jun. 2005. Disponível em: <https://doi.org/10.1145/1178477.1178573>. Acesso em: 13 abril 2026.

HUNTER, J. D. Matplotlib: A 2D Graphics Environment. Computing in Science & Engineering, v. 9, n. 3, p. 90-95, 2007. Acesso em: 20 maio 2026

KOELSTRA, Sander et al. DEAP: A database for emotion analysis using physiological signals. IEEE Transactions on Affective Computing, v. 3, n. 1, p. 18-31, 2012. Disponível em: <https://doi.org/10.1109/T-AFFC.2011.15>. Acesso em: 23 setembro 2025.

LEBEDEV, Mikhail A.; NICOLELIS, Miguel A. L. Brain-machine interfaces: From basic science to neuroprostheses and neurorehabilitation. Physiological Reviews, v. 97, n. 2, p. 767-837, 2017. Disponível em: <https://doi.org/10.1152/physrev.00027.2016>. Acesso em: 25 fevereiro 2026.

LIM, Min; TEO, Jason. Predicting game-induced emotions using EEG, data mining and machine learning. Bulletin of the National Research Centre, v. 48, maio 2024. Disponível em: <https://doi.org/10.1186/s42269-024-01200-7>. Acesso em: 24 abril 2026.

LOTTE, Fabien et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. Journal of Neural Engineering, v. 15, n. 3, 2018. Disponível em:

<https://doi.org/10.1088/1741-2560/12/3/031001>. Acesso em: 12 março 2026

MCFARLAND, D. J.; WOLPAW, J. R. EEG-based brain-computer interfaces. *Current Opinion in Biomedical Engineering*, v. 4, p. 194-200, 2017. Disponível em: <https://doi.org/10.1016/j.cobme.2017.11.004>. Acesso em: 31 julho 2025.

MICROSOFT. .NET 9.0. 2025. Disponível em: <https://dotnet.microsoft.com/>. Acesso em: 20 maio 2026.

MITCHELL, Tom M. *Machine Learning*. New York: McGraw-Hill, 1997.

PATIÑO, Julian et al. Integration Between Serious Games and EEG Signals: A Systematic Review. *Applied Sciences*, 2025. Disponível em: <https://api.semanticscholar.org/CorpusID:276372504>. Acesso em: 06 fevereiro 2026.

PEDREGOSA, Fabian et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825-2830, 2011. Acesso em: 20 maio 2026.

PRAKASH, Anagha; POULOSE, Alwin. Electroencephalogram-based emotion recognition: a comparative analysis of supervised machine learning algorithms. *Data Science and Management*, v. 8, n. 3, 2025. Disponível em: <https://doi.org/10.1016/j.dsm.2024.12.004>. Acesso em: 05 fevereiro 2026.

PYTHON SOFTWARE FOUNDATION. *Python Language Reference*, version 3.13. 2025. Disponível em: <https://www.python.org/>. Acesso em: 20 maio 2026.

ROCHA, Isabella Lanes et al. Análise e interpretação de sinais neurais para utilização eletroeletrônica. Brazilian Journal of Development, v. 8, n. 7, p. 50429-50444, jul. 2022. Disponível em: <https://doi.org/10.34117/bjdv8n7-115>. Acesso em: 17 novembro 2025.

RODRIGUES, Paula Gabrielly. Extração de Características em Interfaces Cérebro-Máquina Utilizando Métricas de Redes Complexas. 2018. Tese (Doutorado) – Programa de Pós-Graduação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018. Disponível em: <https://doi.org/10.13140/RG.2.2.34910.13122>. Acesso em: 10 novembro 2025.

RUSSELL, James. A circumplex model of affect. Journal of Personality and Social Psychology, v. 39, n. 6, p. 1161-1178, dez. 1980. Disponível em: <https://doi.org/10.1037/h0077714>. Acesso em: 23 março 2026.

SAMAL, Priyadarsini; HASHMI, Mohammad Farukh. Role of machine learning and deep learning techniques in EEG-based BCI emotion recognition system: a review. Artificial Intelligence Review, v. 57, n. 3, 2024. Disponível em: <https://doi.org/10.1007/s10462-023-10690-2>. Acesso em: 17 setembro 2025.

SPYDER PROJECT CONTRIBUTORS. Spyder IDE. 2025. Disponível em: <https://www.spyder-ide.org/>. Acesso em: 20 maio 2026.

URIGÜEN, Jose Antonio; GARCIA-ZAPIRAIN, Begoña. EEG artifact removal - State-of-the-art and guidelines. Journal of Neural Engineering, v. 12, n. 3, 2015. Disponível em: <https://doi.org/10.1088/1741-2560/12/3/031001>. Acesso em: 26 novembro 2025.

VIRTANEN, Pauli et al. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. Nature Methods, v. 17, n. 3, p. 261-272, 2020. Acesso em: 20 maio 2026.

WAGH, Kalyani; VASANTH, K. Electroencephalograph (EEG) Based Emotion Recognition System: A Review. In: LECTURE NOTES IN NETWORKS AND SYSTEMS. Proceedings of the 6th ICIECE 2017. [S.l.]: Springer, 2019. p. 37-59. Disponível em: https://doi.org/10.1007/978-981-10-8204-7_5. Acesso em: 28 janeiro 2026.

WELCH, P. D. The Use of Fast Fourier Transform for the Estimation of Power Spectra. IEEE Transactions on Audio and Electroacoustics, v. AU-15, n. 2, p. 70-73, 1976. Acesso em: 21 maio 2026

WILLIAMSON, Ben. Brain Data: Scanning, Scraping and Sculpting the Plastic Learning Brain Through Neurotechnology. Postdigital Science and Education, v. 1, n. 1, p. 65-86, 2019. Disponível em: <https://doi.org/10.1007/s42438-018-0008-5>. Acesso em: 31 julho 2025.

WOLPAW, Jonathan R.; WOLPAW, Elizabeth Winter. Brain-Computer Interfaces: Principles and Practice. Oxford: Oxford University Press, 2012. Disponível em: <https://doi.org/10.1093/acprof:oso/9780195388855.001.0001>. Acesso em: 19 fevereiro 2026.

YANNAKAKIS, Georgios N.; TOGELIUS, Julian. Artificial Intelligence and Games. Cham: Springer, 2018. Acesso em: 14 abril 2026.

¹ Discente do Curso Superior de Engenharia de Software da Fundação Centro de Análise Pesquisa e Inovação Tecnológica –

FUCAPI, Manaus - AM. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Docente da Fundação Centro de Análise Pesquisa e Inovação Tecnológica – FUCAPI, Manaus - AM. E-mail: [acesse o artigo original para visualizar o e-mail](#)