

Análise de Sinais Cerebrais para Detecção de Níveis de Atenção em Jogos Digitais

**Carla Estefany Caetano Silva ¹, Daniela Gorski Trevisan ¹,
Débora Christina Muchaluat Saade ¹**

¹Instituto de Computação – Universidade Federal Fluminense (UFF)
Niterói – Rio de Janeiro – RJ – Brazil

carlaestefany@id.uff.br, debora@midiacom.uff.br, daniela@ic.uff.br

Abstract. *This study proposes the use of brain signals for detection and analysis of focus of attention in 4 games using mouse and touchpad. The approach used uses the Bitalino device to capture brain waves and Wavelet decompositions and spectrogram analysis to detect different levels of attention. Results identified a mean baseline reference of 55% and indicated that games without a time limit helped to increase the attention of the participants over time, while others had difficulty maintaining focus, regardless of the device used. The findings highlight the possibility of designing interactive technologies that foster greater engagement and consider the natural dynamics of human attention.*

Resumo. *Este estudo propõe o uso de sinais cerebrais para detecção e análise de foco de atenção em 4 jogos utilizando mouse e touchpad. A abordagem utilizada recorre ao dispositivo Bitalino para capturar as ondas cerebrais e decomposições de Wavelets e análises de espectrogramas para detectar diferentes níveis de atenção. Resultados identificaram um baseline médio de referência de 55% e indicaram que jogos sem tempo limite ajudaram a aumentar a atenção dos participantes ao longo do tempo, enquanto outros apresentaram dificuldade em manter o foco, independentemente do dispositivo utilizado. As descobertas destacam a possibilidade de projetar tecnologias interativas que promovam maior engajamento e considerem a dinâmica natural da atenção humana.*

1. Introdução

A atenção desempenha um papel vital em nossas vidas diárias, sendo essencial para o desempenho eficaz em atividades acadêmicas, profissionais e pessoais. Transtornos de atenção, como o Transtorno de Déficit de Atenção e Hiperatividade (TDAH), afetam milhões de pessoas em todo o mundo. Métodos tradicionais de avaliação de atenção, embora eficazes, muitas vezes enfrentam desafios como a acessibilidade limitada e a complexidade dos procedimentos [Feijão and Galvão 2007].

Nos últimos anos, a área de interface cérebro-computador (BCI - *Brain-Computer Interface*) tem avançado consideravelmente com o uso de redes neurais e técnicas de *deep learning*, que permitem a classificação de estados cognitivos, como níveis de atenção, com alta precisão. Essas ferramentas demonstram um grande potencial ao identificar padrões complexos na atividade cerebral, sendo amplamente empregadas para tarefas como classificação de atenção e análise de funções cognitivas. Exemplos incluem o uso de modelos híbridos, como CNN (*Convolutional Neural Network*) e LSTM (*Long*

Short-Term Memory), que alcançam elevados níveis de acurácia ao processar sinais de EEG (eletroencefalograma) [Hassan et al. 2020]. Métodos de extração de características, como a Transformada Wavelet, também têm sido explorados em conjunto com algoritmos de aprendizado de máquina, como demonstrado em [Imah et al. 2021], otimizando a classificação em diversos contextos.

Embora existam poucos trabalhos recentes que abordem a detecção de atenção utilizando exclusivamente técnicas de processamento de sinal, é possível que estudos mais antigos tenham explorado essa abordagem. No entanto, a tendência atual parece favorecer o uso de redes neurais para a classificação. Neste contexto, este trabalho tem o intuito de detectar a atenção de indivíduos através de suas ondas cerebrais utilizando somente o canal Fp1 do sistema 10-20 [Klem 1999] conectado no dispositivo Bitalino [PLUX Wireless Biosignals 2021], sem o uso de redes neurais. Para entender, analisar e explicar como esse padrão pode ser encontrado, foram criados quatro jogos digitais para estimular a atenção dos participantes enquanto suas ondas cerebrais eram registradas. Além disso, também foram analisados indivíduos que usaram *mouse* e indivíduos que usaram *touchpad* para interagir com os jogos. A abordagem proposta faz uso de decomposições de Wavelets e análises de espectrogramas para detectar o nível de atenção. Como principais contribuições, destacam-se:

- Geração de base de dados pública para níveis atenção¹
- Detecção de nível de atenção com o uso de dispositivo de baixo custo
- Facilitar o desenvolvimento de futuras interações cérebro-computador disponibilizando os dados deste estudo ao público.

Este artigo está organizado da seguinte forma. A Seção 2 apresenta a revisão da literatura, abrangendo conceitos fundamentais e trabalhos relacionados à detecção de atenção, com ênfase nas diferenças entre métodos baseados em inteligência artificial, diferente da abordagem deste estudo, que utiliza exclusivamente o processamento de sinais e a análise de padrões. A Seção 3 discute a metodologia, incluindo a descrição dos jogos utilizados, os testes de atenção associados, o procedimento de coleta de dados e o detalhamento do processamento e da análise dos sinais para a detecção do padrão de atenção. Os resultados do estudo são então apresentados na Seção 4. Finalmente, a Seção 6 traz a conclusão, onde são discutidas as contribuições, limitações do trabalho e os trabalhos futuros, propondo possíveis desdobramentos para aprimorar a pesquisa na área.

2. Revisão da literatura

A base de dados EEGMAT [Zyma et al. 2019], disponível no PhysioNet [Goldberger et al. 2000] apresenta registros de EEG obtidos com o sistema Neurocom EEG de 23 canais durante tarefas aritméticas mentais. Os sinais foram capturados em uma taxa de amostragem de 500 Hz, utilizando o sistema internacional 10/20 [Klem 1999] para posicionamento dos eletrodos. A tarefa consistia na subtração serial de números de 4 e 2 dígitos fornecidos oralmente. Participaram 36 indivíduos, divididos em grupos de baixo e bom desempenho, com critérios rigorosos de inclusão e exclusão relacionados a fatores como

¹Os dados utilizados neste estudo estão disponíveis mediante solicitação e podem ser fornecidos conforme os critérios de compartilhamento estabelecidos. Para acessá-los, contacte os autores por email.

acuidade visual, saúde mental e ausência de dependência química. Cada participante possui dois registros de EEG (pré e durante a tarefa), fornecidos em formato EDF, oferecendo um rico conjunto de dados para análise de padrões associados à atenção e cognição.

Segundo [Kaji et al. 2020], foi constatado que o uso de EEG pode identificar declínios nas funções cognitivas, como memória e cálculos mentais, especialmente entre motoristas idosos. O estudo utilizou um dispositivo simples para medir EEGs e comparou as funções cognitivas de jovens e idosos, revelando variações significativas nas ondas cerebrais durante diferentes tarefas cognitivas.

Os autores de [Hassan et al. 2020] desenvolveram um sistema para reconhecer níveis de atenção humana a partir de sinais de EEG. Os níveis de atenção foram: atento, neutro, feliz e estado chato. Os autores propuseram uma CNN (Rede Neural Convolucional) juntamente com uma rede LSTM, ou seja, um modelo híbrido, para classificar as funções cognitivas dos indivíduos. Foi alcançada 89% de acurácia, onde os indivíduos assistiram a vídeos e fizeram cálculos matemáticos.

No estudo de [Imah et al. 2021], os autores investigaram a eficácia de diferentes algoritmos de aprendizado de máquina na classificação da atenção conjunta de indivíduos com Transtorno do Espectro Autista (TEA) utilizando dados de EEG. Atenção Conjunta Iniciada (IJA - *Initiated Joint Attention*) refere-se à capacidade de uma pessoa direcionar a atenção de outra para um objeto ou evento. E a Atenção Conjunta Respondida (RJA - *Responded Joint Attention*) refere-se à capacidade de uma pessoa responder à atenção de outra. Os resultados mostraram que o método *Generalized Relevance Learning Vector Quantization* (GRLVQ) apresentou o melhor desempenho, superando outros algoritmos como SVM e *Random Forest*, especialmente quando combinado com a extração de características via Transformada Wavelet.

O estudo de [Amaral et al. 2017] teve como objetivo desenvolver e avaliar a viabilidade de um novo paradigma de BCI, baseado na resposta P300 e integrado a um ambiente de realidade virtual, para treinar habilidades de atenção conjunta em indivíduos com TEA. Três sistemas de EEG foram testados (g.Mobilab+, g.Nautilus e V-Amp com actiCAP Xpress), com o g.Nautilus destacando-se em precisão, conforto e rapidez. O estudo utilizou um paradigma dividido em duas fases: identificação de foco de atenção com o classificador Naive-Bayes utilizado para classificar os eventos de atenção conjunta com base nos sinais P300 detectados. E interação com um avatar virtual usando um componente automático do BCI que identifica a presença de sinais P300 durante a interação, proporcionando feedback em tempo real e demonstrando eficácia na classificação de atenção conjunta.

O diferencial do presente trabalho está no uso do Bitalino, um dispositivo de baixo custo, acessível e amplamente aplicável em diferentes contextos, especialmente na pesquisa acadêmica. Em contraste com os estudos anteriores, que utilizaram sistemas convencionais de EEG hospitalar, como Neurocom ou g.Nautilus, esses aparelhos são significativamente mais caros, possuem múltiplos canais de coleta e exigem uma infraestrutura complexa. Por outro lado, este trabalho adota uma abordagem mais simplificada, empregando apenas um canal de coleta para realizar a análise de padrões de atenção, sem depender de equipamentos sofisticados.

3. Metodologia

3.1. Desenvolvimento dos Jogos

Esta seção descreve como cada jogo criado funciona e a que teste psicológico de atenção ele está associado. Testes psicológicos de atenção são ferramentas psicológicas utilizadas para avaliar diferentes aspectos da atenção, como a capacidade de manter o foco, responder rapidamente a estímulos e alternar entre diferentes tarefas. O objetivo desses jogos é estimular a concentração do usuário para detectar padrões de atenção não encontrados ao analisar bases de dados abertas, as séries de EEG registradas durante tarefas aritméticas mentais [Zyma et al. 2019] não apresentaram padrões relevantes para os propósitos deste trabalho.

Foi feita uma coleta de dados utilizando jogos voltados para a atenção e concentração. Os jogos foram criados utilizando a linguagem de programação *Python* [Python Core Team 2019] utilizando a biblioteca *Pygame*. Os jogos desenvolvidos no *Pygame* foram desenhados para desafiar a atenção dos participantes, a Figura 1 apresenta os quatro jogos desenvolvidos, o Jogo do Reflexo, Escolher Número/Cor, Conectar Números e Jogo das Cores.



Figura 1. Jogos desenvolvidos para avaliação da atenção.

No Jogo do Reflexo, uma bolinha vermelha aparece na tela e o usuário precisa clicar nela. Conforme ele clica, a bolinha muda de lugar. O usuário tem dez segundos para clicar no maior número possível de bolinhas. Este jogo é baseado no teste de atenção concentrada, que avalia a capacidade de manter o foco em um estímulo específico e responder rapidamente. Um exemplo de teste que mede essa habilidade é o **teste de atenção seletiva** [MacLeod 1991].

O Jogo Escolher Número/Cor consiste em dez fases. Nas fases pares, aparece uma instrução pedindo para o usuário clicar em um número de uma cor específica, sorteada aleatoriamente. Nas fases ímpares, o usuário pode clicar em qualquer número da cor sorteada. Não há limite de tempo para concluir cada fase. Este jogo é baseado no **teste de Stroop**, que mede a capacidade de inibir respostas automáticas e manter o foco em estímulos relevantes, como identificar a cor da tinta de uma palavra, mesmo que a palavra represente uma cor diferente [Stroop 1935].

O Jogo Conectar Números possui 3 fases. O usuário precisa clicar nos números que aparecem na tela em ordem crescente para passar de fase. Os números de 1 a 5 estão espalhados aleatoriamente na tela. Este jogo é baseado no **teste de trilhas coloridas (Trail Making Test)**, que avalia a velocidade de processamento, a flexibilidade cognitiva e a capacidade de alternar a atenção entre diferentes tarefas [Reitan 1958].

No Jogo das Cores, uma grade de quadrados coloridos aparece na tela e uma cor é sorteada. O usuário precisa clicar no quadrado da cor sorteada. O jogo dura vinte

segundos e quanto mais rápido o usuário clicar nas cores, mais acertos ele terá. Este jogo é baseado no *Symbol Digit Modalities Test*, que avalia a rapidez de processamento e a atenção visual, exigindo que os participantes façam associações rápidas entre símbolos e números [Smith 1982].

3.2. Procedimento de coleta de dados

As sessões de coleta ocorreram em um ambiente controlado e fechado, onde os participantes foram instruídos a jogar os jogos desenvolvidos no Pygame. Todos os participantes jogaram os jogos na mesma ordem, começando pelo Jogo dos Reflexos e finalizando no Jogo das Cores, conforme a Figura 1. Os participantes demoraram aproximadamente 5 minutos para finalizar todo o experimento. Antes do início dos jogos e após o término, foi coletado um intervalo de 10 segundos de dados enquanto os usuários estavam em repouso, sem realizar nenhuma atividade específica. Esses dados foram utilizados como linha de base para comparar e isolar a atividade cerebral durante o jogo, permitindo uma análise mais precisa das variações induzidas pelos estímulos dos jogos.

Um grupo de 12 participantes foi recrutado voluntariamente no Instituto de Computação da Universidade para participar do experimento de coleta de dados com eletroencefalograma. Eles foram informados sobre a opção de participar apenas do experimento ou também fornecer seus dados para pesquisa, com todos os participantes concordando com ambos. As medidas éticas seguiram as diretrizes éticas da Universidade, incluindo a obtenção de consentimento por meio de um Termo de Consentimento Livre e Esclarecido. Os participantes tiveram ciência e garantia de confidencialidade e anonimato dos dados fornecidos, bem como da concordância em disponibilizar os dados em base pública de forma anônima. Além disso, os participantes foram informados de que poderiam se retirar da coleta de dados a qualquer momento sem causar nenhum tipo de ônus para a pesquisa.

3.2.1. Coleta e dispositivo utilizado

Foi usado o dispositivo modular Bitalino que é de baixo custo para aquisição de sinais fisiológicos, como eletroencefalograma (EEG), eletrocardiograma (ECG), eletromiograma (EMG), entre outros. Os dados são transmitidos via Bluetooth (o canal de transmissão padrão da plataforma), a aquisição dos dados pode ser feita pelo *software OpenSignals (r)evolution* [Batista et al. 2019]. Este trabalho utilizou apenas os dados de EEG.

Foi utilizado o Bitalino para registrar sinais de EEG de 12 indivíduos, dos quais 2 eram mulheres e 10 eram homens. A idade média dos participantes foi de $\bar{x} = 23$ anos, com desvio padrão $\sigma = 2,45$. Do total, 2 eram estudantes de mestrado e 9 de graduação, todos do curso de Ciência da Computação, além de 1 estudante de História. Os participantes realizavam tarefas desempenhadas especificamente para ativar a atenção. Os sinais foram coletados utilizando o canal A0, com uma taxa de amostragem ajustada para 1000 Hz, e os eletrodos no canal Fp1 do sistema 10–20 [Klem 1999]. Os participantes foram divididos em dois grupos: em um grupo, os participantes usaram um *mouse* e, no outro, usaram o *touchpad* (*mouse* do notebook). Foram aplicados os mesmos métodos de processamento e análise utilizados na base de dados aberta para assegurar a consistência.

3.2.2. Processamento dos dados

Para a análise dos dados, realizamos o processamento apresentado na Figura 2, com os seguintes passos realizados:

- **Escolha do canal:** Inicialmente foi escolhido analisar apenas o canal frontal Fp1 do sistema 10-20 [Klem 1999] para possíveis comparações entre outras bases e dados próprios.
- **Janelamento:** Os dados foram analisados a cada 200 milissegundos.
- **Filtros:** Foram utilizados filtros passa-alta com frequência de corte de 0,5 Hz e filtros passa-baixa com frequência de corte de 50 Hz para atenuar frequências indesejadas [Gonzalez and Woods 2009].
- **Separação:** Os dados foram separados em segmentos de 200 milissegundos, divididos em 5 partes iguais de 40 pontos
- **Análise de Componentes Independentes (ICA):** ICA foi aplicado para eliminar artefatos provenientes de movimento ocular, atividade muscular e pulsação cardíaca. O ICA foi aplicado para 5 componentes utilizando as 5 partições feitas anteriormente [Comon 1994].
- **Junção:** Após a utilização do ICA, são retornadas as 5 componentes independentes referentes a cada partição feita, então essas partições foram reunidas novamente para voltar ao tamanho da série original de 200 pontos.
- **Transformada de Wavelet:** Foi aplicada a transformada de Wavelet utilizando a família Daubechies Db 10, com 9 níveis de decomposição, para decompor os sinais em componentes de tempo e frequência [Ramos et al. 2017].
- **Transformada de Wavelet Contínua (CWT):** Posteriormente, aplicou-se a Transformada de Wavelet Contínua utilizando a Wavelet Morlet Complexa (CMOR) nos coeficientes resultantes da Daubechies. A CWT foi utilizada para decompor ainda mais os sinais de EEG, permitindo a identificação de características temporais e freqüenciais específicas [Torrence and Compo 1998].
- **Espectrogramas:** Foram gerados espectrogramas [Mallat 2008] para visualizar a distribuição de potência ao longo do tempo utilizando os coeficientes da Wavelet Daubechies e da Wavelet CWT. Os espectrogramas tiveram seus valores normalizados de 0 a 256, e separados em 5 faixas (1 = [0,31], 2 = [32,76], 3 = [77, 153], 4 = [154, 204], 5 = [205, 256] e apresentados tamanhos de 256x256 pixels.

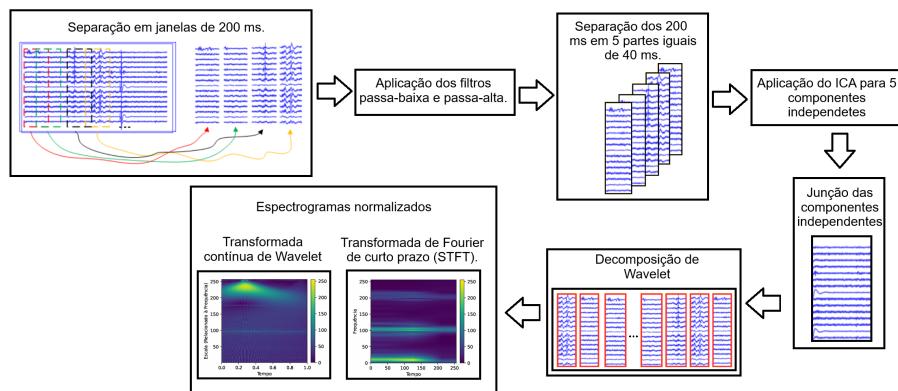


Figura 2. Processamento aplicado nos dados de eletroencefalograma (EEG).

3.3. Detecção dos padrões de atenção

Foram gerados spectrogramas para os coeficientes de aproximação e de detalhe para todas as decomposições de Wavelet. Optou-se por utilizar os coeficientes de aproximação e a primeira decomposição que representa as ondas Gamas (30-100 Hz). A Figura 3 apresenta spectrogramas da primeira decomposição da transformada de Wavelet contínua (CWT):

- Wavelet Daubechies: A Figura 3 (b) mostra o gráfico da decomposição do sinal original usando a Wavelet. O eixo horizontal representa as amostras, e o eixo vertical representa o valor do sinal. A série possui esse padrão sazonal, e sem muitas oscilações de ruído, assim facilitando visualmente as mudanças de atenção ao longo do tempo.
- Gráfico CWT cA: O gráfico mostrado na Figura 3(a) é a transformada Contínua de Wavelet (CWT) do coeficiente de aproximação (cA) do sinal mostrado na Figura 3 (b). Observa-se um padrão onde as magnitudes mais altas (amarelas) aparecem com mais destaque na alteração do sinal, indicando picos de atenção durante esses períodos.

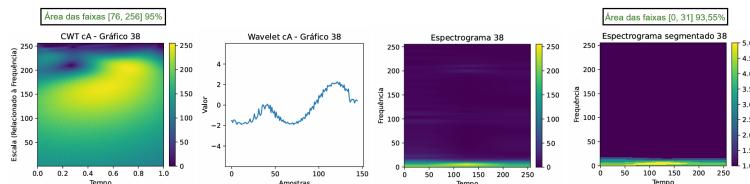


Figura 3. Espectrogramas da primeira decomposição da transformada de Wavelet Contínua (CWT) e seus coeficientes de aproximação (cA), utilizando a família Daubechies. Inclui a análise completa (a, b) e segmentada em faixas (c, d).

Analizando visualmente os spectrogramas, o padrão de atenção aparece em todas as decomposições, como é mostrado nas Figuras 4 e 5.

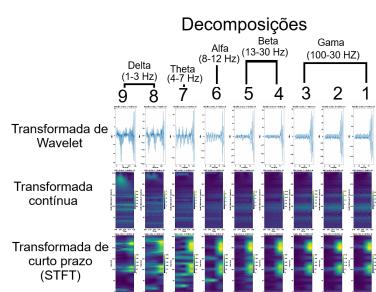


Figura 4. Nível de atenção não detectado.

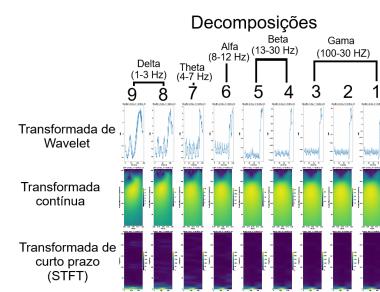


Figura 5. Nível de atenção mais alto detectado.

Esse padrão mais forte da alteração do sinal se apresenta em todas as 9 decomposições de Wavelet, na transformada contínua na cor amarela e na transformada STFT na cor de azul escuro. Veja a Figura 4 que apresenta esse padrão de atenção e a Figura 5 que apresenta um estado normal sem indícios de atenção. Comparando

essas decomposições e com base na literatura, optou-se em usar apenas a primeira decomposição de Wavelet que representa a onda Gama, onde é definido que o estado de atenção se encontra.

Para definir a atenção, percebeu-se que o padrão na série temporal na Figura 3 apresenta uma maior área de azul no espectrograma da Wavelet Daubechies e um amarelo intenso no espectrograma da Wavelet CWT (transformada contínua). Há casos em que existe o padrão azulado no espectrograma da Wavelet Daubechies (transformada de curto prazo), mas não há presença do hiper sinal de amarelo no espectrograma da Wavelet CWT. Assim, a atenção foi definida como,

$$A = Espec_{cwt} \times 0.70 + Espec_{Daubechies} \times 0.30 \quad (1)$$

onde, $Espec_{cwt}$ é a proporção de área do espectrograma da Wavelet CWT acima da faixa 3, variando entre [76, 256], e $Espec_{Daubechies}$ é a proporção de área azul do espectrograma da Wavelet Daubechies, representada pela faixa 1, variando entre [0, 31].

4. Resultados

Neste estudo, foram coletados dados de 12 voluntários que jogaram os jogos mencionados simultaneamente com a coleta do eletroencefalograma (EEG). Foram utilizadas técnicas de reconhecimento de padrões para detectar e analisar os padrões de atenção dos participantes, aplicando métodos de limpeza de dados, transformações, normalização e segmentação para criar os espectrogramas necessários. Os dados de atenção foram processados a cada 200 milissegundos para garantir análises sólidas durante os estados de repouso. Após identificar os padrões de atenção, foi avaliado o desempenho dos participantes nos jogos, comparando os resultados entre os grupos que usaram *mouse* e *touchpad*.

4.1. Resultados dos Testes Estatísticos

Os resultados do teste ANOVA foram utilizados para avaliar a variação da atenção média em estado de repouso. Para essa análise, foram coletados dados dos participantes em dois momentos: antes e após o experimento, considerando 10 segundos de cada período, totalizando 20 segundos por usuário. A taxa de amostragem foi de 1000 Hz, e os cálculos de atenção foram realizados a cada 200 ms, resultando em 100 pontos de atenção para cada usuário.

Embora o pressuposto de homogeneidade das variâncias (Tabela 1) e independência com o teste Qui-quadrado dos dados tenha sido atendido a um nível de 5% de significância, os testes de normalidade (Shapiro-Wilk) não indicaram normalidade, nem mesmo ao nível de significância de 1%. Esses resultados podem ser atribuídos ao tamanho reduzido das amostras, que impactaram a distribuição dos dados. Ainda assim, a ANOVA foi aplicada devido à sua robustez a desvios leves de normalidade, permitindo a análise das médias e a definição de limites para diferenciar o estado de repouso de momentos de atenção elevada.

Os intervalos de confiança globais, apresentados na Tabela 2, fornecem uma linha de base (baseline) sólida para o estado natural de repouso dos participantes. Valores dentro desse intervalo refletem o estado típico de desatenção ou repouso, enquanto valores

acima do limite superior indicam atenção elevada. O valor de 55% foi escolhido como baseline sendo o inteiro mais próximo da média dos valores dos intervalos de confiança da parte superior. Ele reflete o estado natural de repouso de todos os participantes, servindo como referência para identificar alterações nos níveis de atenção. Optou-se inicialmente à avaliação do grupo na totalidade para identificar quais jogos de uma maneira geral estimularam mais os participantes. Futuramente será realizada uma análise utilizando o baseline de cada indivíduo verificando o impacto dos jogos em cada um deles.

Tabela 1. Resultados dos Testes Estatísticos

Teste	Estatística	P-valor	Interpretação
Homoscedasticidade	0.4250	0.9923	Variâncias Homogêneas dos participantes.
ANOVA	1.0990	0.3383	Não Há Diferença entre as médias dos participantes.

Tabela 2. Intervalos de Confiança Globais

Reposo	Média	IC 99% [Inferior, Superior]
Antes do experimento	51.2793	[49.2244; 53.3342]
Depois do experimento	54.0311	[51.9556; 56.1066]
Combinado	52.6552	[51.1942; 54.1162]

4.2. Análise dos níveis de atenção

A Figura 6 apresenta o nível de atenção de todos os participantes em cada jogo, com e sem o uso do *mouse*. Como esperado, os níveis de atenção são geralmente baixos em relação ao baseline de 55%, refletindo a dificuldade natural de sustentar altos níveis de atenção por períodos prolongados. Estudos como o de [Hassan et al. 2020] indicam que a atenção tende a flutuar em ciclos, com picos ocorrendo em intervalos regulares de 1 a 2 segundos, observável nos dados apresentados. Esses picos podem estar associados a momentos específicos de maior engajamento ou desafio durante os jogos.

Por isso, as curvas referentes ao valores de atenção acima de 55% foram analisadas. De modo geral, o uso ou não do *mouse* não impactou tanto no aumento da atenção nos jogos, mas percebe-se que as frequências acima do nível de 55% foram superiores em todos os jogos. Pode-se notar também que os jogos de conectar números e o jogo das cores de modo geral estimulou os participantes que não usaram o *mouse* a acalçar níveis de atenção maiores, o que deixou a cauda do histograma mais constante. Diferentemente do jogo 1 (reflexo) e jogo 2 (escolher números/cor), que começaram com uma frequência alta no valor do baseline e foram diminuindo à medida que o nível de atenção aumenta.

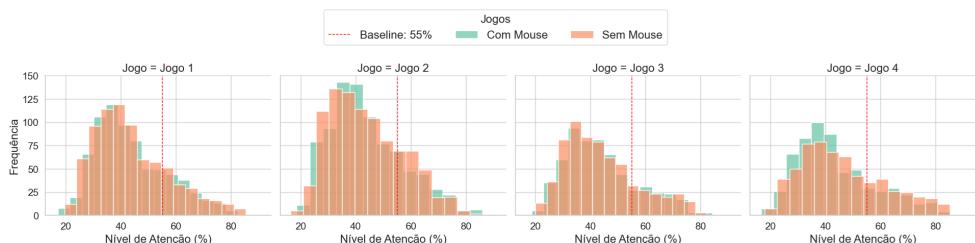


Figura 6. Histograma dos níveis de atenção em casa jogo segundo o uso ou não do mouse. Jogo 1 (Reflexo), Jogo 2 (Escolher Número e Cor), Jogo 3 (Conectar Números) e Jogo 4 (Cores).

A Figura 7A) ilustra a relação entre a quantidade de cliques e os níveis de atenção acima de 55% para dois jogos (Jogo 1 e Jogo 4), comparando os cenários com e sem o uso do *mouse*. Observa-se que, em ambos os jogos, as proporções de atenção dos participantes se mantiveram relativamente próximas ao longo do tempo. A presença de dois outliers influenciou negativamente a correlação, como mostra na Figura 7B), mas, sem eles, os dados indicariam ausência de correlação. Assim, conclui-se que esses dois jogos não foram eficazes para estimular a atenção dos participantes, independentemente do uso do *mouse*.

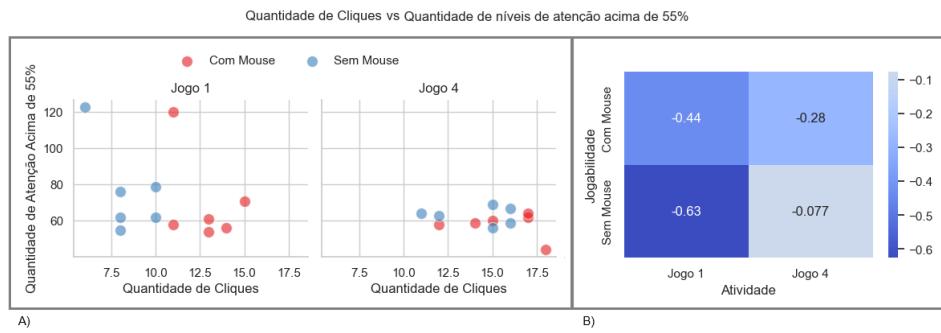


Figura 7. Relação entre cliques e níveis de atenção de cada participante utilizando ou não o *mouse* no Jogo 1 (Reflexo) e no Jogo 4 (Cores), que tinham limite de tempo e maior necessidade de cliques.

A Figura 8A) mostra que, independentemente do uso do *mouse*, os jogos 2 e 3 conseguiram estimular a atenção dos participantes ao longo do tempo. Já a Figura 8B) apresenta a correlação entre os níveis de atenção, os jogos e o tipo de jogabilidade. Observou-se que no jogo 2, somente com o uso do *mouse*, a correlação foi moderada, enquanto nas demais situações foi encontrada uma correlação positiva quase perfeita, evidenciando maior consistência nos níveis de atenção.

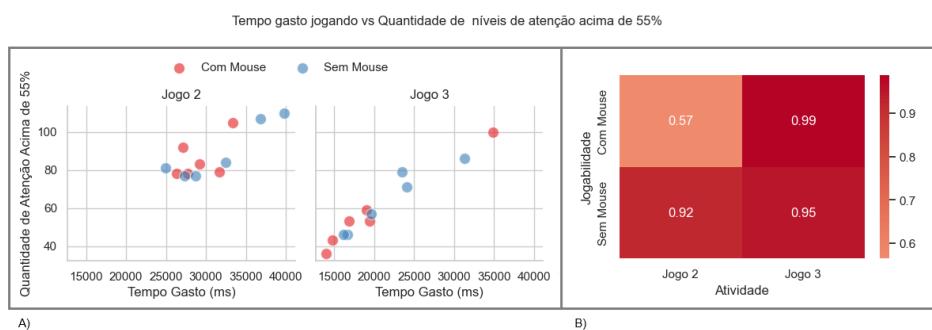


Figura 8. Relação entre o tempo gasto e níveis de atenção de cada participante utilizando ou não o *mouse* no Jogo 2 (Escolher Número/Cor) e Jogo 3 (Conectar Números), sem tempo limite definido, mas com a mesma quantidade de cliques.

5. Limitações

Este estudo apresenta algumas limitações. Não houve marcação explícita dos momentos de atenção dos participantes, seja em bancos de dados abertos ou na captura de dados

realizada, o que impediu o uso de redes neurais (aprendizagem supervisionada). Portanto, optou-se por uma abordagem exploratória, identificando padrões recorrentes após os estímulos do jogo. Apesar da pequena amostra de 12 participantes, os resultados demonstraram um padrão consistente para ambos. Estudos futuros com grupos maiores e mais diversos poderão expandir e validar esses achados.

6. Conclusão

Este trabalho analisou os padrões de atenção dos participantes, mostrando que a interação com o mouse ou o *touchpad* pode influenciar significativamente os níveis de atenção dos usuários. A escolha do valor baseline (55%) permitiu estabelecer uma referência confiável para identificar estados de atenção elevada. Os resultados indicaram que, enquanto alguns jogos favoreceram maior engajamento, outros apresentaram desafios para manter a atenção, independentemente do dispositivo utilizado. Além disso, os jogos sem tempo de término demonstraram um impacto positivo na sustentação da atenção dos participantes ao longo do tempo. Futuras pesquisas podem aprofundar a compreensão dos padrões de atenção. Esta abordagem pode ser aplicada na construção de sistemas automatizados para detecção de estados atencionais, contribuindo para avanços em ambientes educacionais, neurofeedback e interfaces cérebro-computador (BCI), ampliando sua aplicabilidade para diferentes cenários.

Como outros trabalhos futuros, pretende-se aprimorar a análise utilizando um baseline individualizado, permitindo a inclusão de indivíduos neurodivergentes, como pessoas com TEA e TDAH. Além disso, serão exploradas sessões de jogos mais longas, equilibrando tempo de interação e fadiga dos participantes. Planeja-se também incluir dados de ciclos respiratórios com acelerômetros ou com eletrocardiograma (batimentos cardíacos), visando aumentar a confiabilidade das análises. Por fim, pretende-se expandir esta metodologia para ambientes imersivos, possibilitando o estudo do impacto de diferentes estímulos sobre os níveis de atenção e relaxamento dos indivíduos.

7. Agradecimentos

Este trabalho foi parcialmente financiado pelo CNPq, CAPES, CAPES Print, FAPERJ, INCT-MACC, INCT-ICONIoT e FINEP.

Referências

- Amaral, C. P., Simões, M. A., Mouga, S., Andrade, J., and Castelo-Branco, M. (2017). A novel brain computer interface for classification of social joint attention in autism and comparison of 3 experimental setups: a feasibility study. *Journal of neuroscience methods*, 290:105–115.
- Batista, D., Plácido da Silva, H., Fred, A., Moreira, C., Reis, M., and Ferreira, H. A. (2019). Benchmarking of the bitalino biomedical toolkit against an established gold standard. *Healthcare Technology Letters*, 6(2):32–36.
- Comon, P. (1994). Independent component analysis, a new concept? *Signal Processing*, 36(3):287–314.
- Feijão, A. R. and Galvão, M. T. G. (2007). Ações de educação em saúde na atenção primária: revelando métodos, técnicas e bases teóricas. *Revista da Rede de Enfermagem do Nordeste*, 8(2):41–49.

- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., and Stanley, H. E. (2000). Physiobank, physitoolbox e physionet: Componentes de um novo recurso de pesquisa para sinais fisiológicos complexos. *Circulação [Online]*, 101(23):e215–e220.
- Gonzalez, R. and Woods, R. (2009). *Processamento Digital De Imagens*. ADDISON WESLEY BRA.
- Hassan, R., Hasan, M. S., Hasan, J., Jamader, M. R., Eisenberg, D., and Pias, T. (2020). Machine learning based human attention recognition from brain-eeg signals.
- Imah, E. M., Dewi, E. S., and Buditjahjanto, I. G. P. A. (2021). A comparative analysis of machine learning methods for joint attention classification in autism spectrum disorder using electroencephalography brain computer interface. *International Journal of Intelligent Engineering Systems*, 14(3).
- Kaji, Y., Yamamoto, Y., Kawata, J., Morimoto, J., and Fujisawa, S. (2020). Eeg variations during measurement of cognitive functions using biosignal acquisition toolkit. *Journal of Robotics and Mechatronics*, 32(4):753–760.
- Klem, G. H. (1999). The ten-twenty electrode system of the international federation. the international federation of clinical neurophysiology. *Electroencephalogr. Clin. Neurophysiol. Suppl.*, 52:3–6.
- MacLeod, C. M. (1991). Half a century of research on the stroop effect: An integrative review. *Psychological Bulletin*, 109(2):163–203.
- Mallat, S. (2008). *A Wavelet Tour of Signal Processing: The Sparse Way*. Academic Press, 3rd edition.
- PLUX Wireless Biosignals, S. (2021). *BITalino (r)evolution User Manual*. Available at <https://support.pluxbiosignals.com/wp-content/uploads/2021/11/bitalino-revolution-user-manual.pdf>.
- Python Core Team (2019). *Python: A dynamic, open source programming language*. Python Software Foundation. Python version 3.8.
- Ramos, R., Valdez-Salas, B., Zlatev, R., Wiener, M. S., and Rull, J. M. B. (2017). The discrete wavelet transform and its application for noise removal in localized corrosion measurements. *International Journal of Corrosion*, 2017.
- Reitan, R. M. (1958). *Validity of the Trail Making Test as an indicator of organic brain damage*, volume 8. Perceptual and Motor Skills.
- Smith, A. (1982). *Symbol Digit Modalities Test: Manual*. Western Psychological Services.
- Stroop, J. R. (1935). Studies of interference in serial verbal reactions. *Journal of Experimental Psychology*, 18(6):643–662.
- Torrence, C. and Compo, G. P. (1998). A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, 79(1):61–78.
- Zyma, I., Tukaev, S., Seleznov, I., Kiyono, K., Popov, A., Chernykh, M., and Shpenkov, O. (2019). Electroencephalograms during mental arithmetic task performance. *Data*, 4(1).