

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
BACHARELADO EM ENGENHARIA COMPUTACIONAL

João Stephan Silva Maurício

Relação entre Desempenho e Conforto em Interfaces Cérebro-Máquina:
Análise Paramétrica em Potenciais Evocados Visuais

Juiz de Fora
2025

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

de Souza, Gabriel H.

Relação entre Desempenho e Conforto em Interfaces Cérebro-Máquina :
Análise Paramétrica em Potenciais Evocados Visuais / João Stephan Silva
Maurício. – 2025.

48 f. : il.

Orientador: Gabriel Henrique de Souza

Coorientador: Heder Soares Bernardino

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal
de Juiz de Fora, Faculdade de Engenharia. Bacharelado em Engenharia
Computacional, 2025.

1. Interface Cérebro-Máquina. 2. Potenciais Evocados Visuais. 3.
Eletroencefalograma. I. de Souza, Gabriel H, orient. II. Bernardino, Heder
Soares, coorient. III. Título.

João Stephan Silva Maurício

Relação entre Desempenho e Conforto em Interfaces Cérebro-Máquina:
Análise Paramétrica em Potenciais Evocados Visuais

Trabalho de conclusão de curso apresentado
a Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do grau de bacharel em Engenha-
ria Computacional. Área de concentração:
Multidisciplinar

Orientador: Prof. Me. Gabriel Henrique de Souza

Coorientador: Prof. Dr. Heder Soares Bernardino

Juiz de Fora

2025

João Stephan Silva Maurício

Relação entre Desempenho e Conforto em Interfaces Cérebro-Máquina:
Análise Paramétrica em Potenciais Evocados Visuais

Trabalho de conclusão de curso apresentado
a Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do grau de bacharel em Engenharia
Computacional. Área de concentração:
Multidisciplinar

Aprovada em (dia) de (mês) de (ano)

BANCA EXAMINADORA

Prof. Me. Gabriel Henrique de Souza - Orientador
Universidade Federal de Juiz de Fora

Prof. Dr. Heder Soares Bernardino - Coorientador
Universidade Federal de Juiz de Fora

Prof. Dr. Leonardo Goliatt da Fonseca
Universidade Universidade Federal de Juiz de Fora

Prof. Dr. Rodrigo Barbosa de Santis
Universidade Universidade Federal de Juiz de Fora

Para Érica e José.

AGRADECIMENTOS

Gostaria de agradecer ao meu pai e à minha mãe, José e Érica, que nunca deixaram nada faltar para mim em nenhuma circunstância e sempre me apoiaram e me amaram incondicionalmente.

Gostaria de agradecer a todos os meus amigos do coração, que sempre estiveram ao meu lado, me ajudando a viver e a aproveitar a vida.

Gostaria de agradecer à minha namorada, Pietra, que me faz sentir extremamente amado, o que considero necessário para todo ser humano neste planeta.

Gostaria de agradecer aos meus orientadores, Heder e Gabriel, que me iluminaram com conhecimento e me auxiliaram na jornada que foi este trabalho.

Gostaria de agradecer ao Grupo de Educação Tutorial da Engenharia Computacional, que me proporcionou experiências incríveis na faculdade.

E, por fim, gostaria de agradecer à Universidade Federal de Juiz de Fora, pelo excelente ambiente acadêmico e corpo docente, que foram essenciais para a minha formação.

“A vida se move muito rápido. Se você não parar e olhar em volta de vez em quando, pode perdê-la.” (Ferris Bueller, em *Curtindo a Vida Adoidado*, de John Hughes, 1986).

RESUMO

Interfaces Cérebro-Máquina (BCI) possuem uma variada gama de aplicações como o controle de mãos robóticas, reabilitação de pacientes com membros paralisados por acidentes vasculares cerebrais, treinamento atencional para indivíduos com déficit de atenção e controle de interfaces de comunicação alternativa. Cada aplicação envolve o reconhecimento de um conjunto de atividades cerebrais diferentes, como a Imaginação Motora (MI), atenção e Potenciais Evocados Visuais em Regime Estacionário (SSVEP). Nesse trabalho, será estudado o paradigma SSVEP, esses sinais surgem após estímulos visuais em frequências definidas que geram ondas sincronizadas no cérebro. A classificação das ondas geradas em suas frequências respectivas permite o uso desses sistemas para controle de interfaces contínuas ou discretas apenas com o foco visual do sujeito. Esses sistemas tem uma vantagem pois usualmente não é necessário nenhum treinamento do modelo para seu funcionamento, ao contrário de modelos para Imaginação Motora ou atenção. Embora possuam altas acurácias e taxas de transferência de informação (ITR), essas aplicações geram grande fadiga visual aos usuários. Essa fadiga é assunto recorrente em trabalhos de aplicação do SSVEP, porém poucas análises são feitas com relação à escolha das frequências levando em consideração o conforto. Por esse motivo, este trabalho analisa diferentes janelas de tempo e frequência com relação ao desempenho do modelo e ao conforto médio dos sujeitos. Além disso, a análise considerando diferentes quantidades de alvos possibilita avaliar a usabilidade do modelo em diversas aplicações, como sistemas de digitação, controle de braços mecânicos e interação em jogos digitais. Adicionalmente, a análise focada no ITR permitiu identificar um conjunto de parâmetros que se destacam tanto em conforto quanto em desempenho, oferecendo opções que podem priorizar a eficiência do sistema ou a experiência do usuário.

Palavras-chave: interfaces cérebro-máquina; potenciais evocados visuais em regime estacionário; eletroencefalograma.

ABSTRACT

Brain-Computer Interfaces (BCIs) have a wide range of applications, such as controlling robotic hands, rehabilitating patients with limb paralysis caused by strokes, attention training for individuals with attention deficit, and controlling alternative communication interfaces. Each application involves recognizing different sets of brain activities, such as Motor Imagery (MI), attention, and Steady-State Visual Evoked Potentials (SSVEP). In this study, the SSVEP paradigm will be analyzed. These signals arise after visual stimuli at specific frequencies, generating synchronized brain waves. Classifying the generated waves into their respective frequencies enables the use of these systems for controlling continuous or discrete interfaces solely through the subject's visual focus. These systems have an advantage, as they typically do not require any model training for operation, unlike models for Motor Imagery or attention. Although they achieve high accuracy and Information Transfer Rates (ITR), these applications induce significant visual fatigue in users. This fatigue is a recurring topic in SSVEP application studies; however, few analyses consider frequency selection concerning user comfort. For this reason, this study examines different time and frequency windows concerning the model's performance and the subjects' average comfort. Furthermore, analyzing different target quantities allows the evaluation of the model's usability in various applications, such as typing systems, mechanical arm control, and interaction in digital games. Additionally, an analysis focused on ITR identified a set of parameters that stand out in both comfort and performance, providing options that can prioritize either system efficiency or user experience.

Keywords: brain-computer interfaces; steady-state visually evoked potentials; electroencephalogram.

LISTA DE ILUSTRAÇÕES

Figura 1	– Gravação de um <i>dataset</i> BCI.	19
Figura 2	– Fluxo geral para classificação de um sinal cerebral.	21
Figura 3	– Fluxo para classificação de um sinal cerebral neste trabalho.	22
Figura 4	– Sistema de posicionamento de eletrodos 10-10.	23
Figura 5	– Exemplo de digitador SSVEP.	25
Figura 6	– Ilustração do funcionamento do CCA entre o sinal cerebral e um sinal de referência.	26
Figura 7	– Ilustração do funcionamento geral do CCA entre o sinal cerebral e os sinais de referência.	27
Figura 8	– Ilustração das diferentes amplitudes de estímulo do <i>dataset</i> utilizado.	28
Figura 9	– Eletrodos escolhidos para o experimento.	30
Figura 10	– Acurácia e conforto para diferentes quantidades de alvos com estímulo de baixa amplitude.	33
Figura 11	– Acurácia e conforto para diferentes quantidades de alvos com estímulo de alta amplitude.	34
Figura 12	– Gráficos de Pareto para diferentes tamanhos de janela.	35
Figura 13	– ITR e conforto para diferentes quantidades de alvos com estímulo de baixa amplitude.	41
Figura 14	– ITR e conforto para diferentes quantidades de alvos com estímulo de alta amplitude.	42
Figura 15	– Gráficos de Pareto para ITR.	43

LISTA DE TABELAS

Tabela 1 – Frequências em cada sessão.	29
Tabela 2 – Pontos não dominados para dois alvos.	36
Tabela 3 – Pontos não dominados para quatro alvos.	37
Tabela 4 – Pontos não dominados para oito alvos.	38
Tabela 5 – Pontos não dominados para dezesseis alvos.	39
Tabela 6 – Pontos não dominados para ITR.	44

LISTA DE ABREVIATURAS E SIGLAS

BCI	Interface Cérebro-Máquina
MI	Imaginação Motora
SSVEP	Potenciais Evocados Visuais em Regime Estacionário
AVC	Acidente Vascular Cerebral
TDAH	Transtorno de Déficit de Atenção com Hiperatividade
EEG	Eletroencefalograma
CCA	Análise de Correlação Canônica
FBCCA	Análise de Correlação Canônica com Filtro Passa-Banda
ITR	Taxa de Transferência de Informação

LISTA DE SÍMBOLOS

X	Sinal de EEG com 3 dimensões (trial, eletrodo, tempo)
Y_f	Sinais de referência
S	Frequência de amostragem
E	Número de eletrodos
T	Número de amostras temporais
N_h	Número de harmônicos
f	Frequência de estímulo
ρ_f	Coefficiente de correlação
W_x, W_y	Vetores de peso da Análise de Correlação Canônica (CCA)
N	Número de alvos possíveis
P	Acurácia da classificação

SUMÁRIO

1	INTRODUÇÃO	13
2	TRABALHOS RELACIONADOS	15
3	INTERFACE CÉREBRO-MÁQUINA	19
3.1	ELETROENCEFALOGRAMA	23
3.2	POTENCIAIS EVOCADOS VISUAIS EM REGIME ESTACIONÁRIO	24
4	ANÁLISE DE CORRELAÇÃO CANÔNICA	26
5	DATASET	28
6	EXPERIMENTOS	30
6.1	RESULTADOS	32
7	CONCLUSÃO	45
	REFERÊNCIAS	47

1 INTRODUÇÃO

Interfaces Cérebro-Máquina (BCI) desempenham um papel fundamental ao fornecer uma alternativa às entradas de comandos tradicionais de sistemas eletrônicos. Essa alternativa é essencial para pessoas incapazes de utilizar os métodos convencionais (1). Por sua importância, a área está em constante evolução e seus métodos e paradigmas são cada vez mais elaborados. As BCIs possuem diversos paradigmas, dentre alguns exemplos temos Imaginação Motora (MI), atenção, Potenciais Evocados Visuais em Regime Estacionário (SSVEP) e P300, cada um explorando diferentes padrões de atividade neural. Suas aplicações variam, indo do uso na reabilitação de pacientes que perderam os movimentos de membros por conta de acidentes vasculares cerebrais (AVC) (2), melhoria na atenção de indivíduos com autismo ou transtorno de déficit de atenção e hiperatividade (TDAH) (3), controle de dispositivos apenas com o foco visual e comunicação alternativa (4)(5).

O funcionamento das BCIs baseia-se em gravar o sinal cerebral de um sujeito, classificá-lo e realizar o comando específico para a classe encontrada. As aplicações em comunicação alternativa utilizando SSVEP e P300 comumente utilizam o eletroencefalograma (EEG) para coleta do sinal elétrico cerebral. Os SSVEPs são ondas ressonantes cerebrais geradas por estímulos visuais em frequências predefinidas. Cada frequência é associada com um comando e estes são dispostos, por exemplo, em um monitor de computador. Com o foco visual do sujeito no comando desejado, o estímulo visual é gerado na mesma posição e assim os potenciais são gerados, gravados e classificados, permitindo a execução da tarefa. Essa seleção de comandos pode também ser feita de forma contínua, com estímulos constantes e o foco visual do sujeito variando entre diferentes possibilidades. Os modelos de classificação para sinais SSVEP geralmente não necessitam treinamento, como a Análise de Correlação Canônica (CCA), mas alguns aspectos do modelo podem ser aprimorados com um filtro passa-banda como o CCA com filtro passa-banda (FBCCA) (6), e um treinamento pode ser feito para ajustar os pesos de cada banco de filtros, melhorando a detecção dos sinais SSVEP. Além disso, abordagens baseadas em aprendizado de máquina, como redes neurais, podem ser utilizadas para refinar a classificação, especialmente quando combinadas com técnicas de extração de características avançadas (7).

Porém, existe um grande desafio para aplicações SSVEP. Os estímulos visuais geram altos níveis de fadiga visual e desconforto nos sujeitos (8). Muitos trabalhos discutem essa problemática e testam frequências que são menos incômodas. Outros trabalhos gravaram, além dos sinais cerebrais, para cada frequência, uma nota entre 0 e 5 dada pelos sujeitos com relação a conforto, percepção da tela piscando e preferência. Entretanto, mesmo quando discutido, o conforto não é o foco principal da análise, e seu peso na avaliação dos parâmetros utilizados é arbitrário.

Dentre as métricas utilizadas para medir a eficácia de modelos BCI-SSVEP estão a

acurácia e a taxa de transferência de informação (ITR). Enquanto a acurácia diz apenas sobre o quanto o modelo acerta em suas classificações, o ITR se mostra mais robusto para analisar modelos de SSVEP e seus sistemas, como, por exemplo, sistemas digitadores de comunicação alternativa. O ITR fornece uma medida que se ajusta ao número de alvos utilizados, à janela de tempo utilizada e à própria acurácia média do modelo.

Considerando essas métricas e o desafio entre balancear desempenho e conforto do usuário, este trabalho tem como objetivo analisar um *dataset* de sinais SSVEP integrando análises de desempenho e conforto. Com essa integração, busca-se estudar uma maneira de encontrar os melhores parâmetros para um possível experimento *online*, de forma que sejam feitas as melhores escolhas desde um foco em desempenho até a priorização da experiência do usuário. Para isso, foram testadas quatro diferentes janelas de tempo com todas as possíveis janelas de frequência sequenciais para 2, 4, 8 e 16 alvos. As análises para diferentes números de alvos permitem fazer escolhas com relação à usabilidade do modelo para diferentes sistemas SSVEP. Assim, para um digitador, poderão ser escolhidos os parâmetros para 8 alvos com o melhor ITR considerando um limite de desconforto do usuário. Ou, para sistemas de controle mais críticos com foco na acurácia, pode-se escolher parâmetros de menos alvos, como 2 ou 4, que forneçam uma performance mais sólida, deixando de lado o peso do conforto do usuário.

É importante ressaltar que essa abordagem de análise combinando desempenho e conforto do usuário é uma novidade na literatura, visto que a maior parte dos trabalhos se concentra apenas na otimização dos modelos em termos de acurácia e ITR, sem considerar de maneira sistemática o impacto do desconforto visual.

Nos experimentos realizados, os resultados demonstraram que melhorias na ITR puderam ser alcançadas exclusivamente pela exploração de diferentes parâmetros, sem a necessidade de mudanças estruturais nos modelos de classificação. Isso reforça a importância da escolha criteriosa dos parâmetros de estímulo e processamento do sinal, permitindo um melhor desempenho sem comprometer o conforto do usuário.

2 TRABALHOS RELACIONADOS

Este capítulo apresenta uma revisão dos principais trabalhos relacionados às interfaces cérebro-máquina (BCI) voltadas para sistemas de digitação e paradigmas SSVEP. Foram considerados como trabalhos relacionados aqueles que abordam a evolução dos sistemas BCI, as metodologias para extração e classificação de sinais, os desafios relacionados ao conforto do usuário e estratégias de otimização de parâmetros para experimentos online. Além disso, incluímos pesquisas que forneceram conjuntos de dados relevantes para análise e validação de métodos.

Em (9), são revisados digitadores em três diferentes paradigmas de BCI: P300, SSVEP e MI. Cada paradigma possui um funcionamento único, portanto, diferentes estruturas para digitadores podem ser propostas. São analisados então diversos digitadores que tiveram êxito na área seu funcionamento e *layout*. Essa análise permite para pesquisadores futuros a construção de sistemas com melhores interfaces e usabilidades. No trabalho é feita uma taxonomia dos diferentes digitadores incluindo ainda uma quarta categoria: dos digitadores híbridos de diferentes paradigmas. Como fatores característicos nessa taxonomia são analisadas as modalidades de operação do sistema, a dependência de foco visual, a modalidade de seleção, os diferentes tipos de estímulos e se possuía um sistema de seleção de palavras. Além da taxonomia os sistemas eram comparados quantitativamente e qualitativamente. Quantitativamente, foram analisados o número de sujeitos nos experimentos, a média de ITR/tempo de digitação e a acurácia média. Já qualitativamente é analisada a experiência do usuário e a facilidade do uso do mesmo, ressaltando os pontos positivos e negativos de cada modelo geralmente dados pelos usuários como *feedback*. Entretanto, o conforto não é sistematicamente abordado, deixando o foco para o desempenho dos sistemas estudados. Como conclusão, o trabalho ressalta a importância de estudos como este para a construção de sistemas cada vez melhores. É debatida também a necessidade de mais experimentos com sujeitos afligidos por condições que impedem sua comunicação, uma vez que tais sujeitos seriam o ponto de final de sistemas como esse.

Em (5) uma introdução é feita acerca das interfaces de digitação, passando brevemente pelo fluxo de funcionamento desses sistemas, sobre a região cerebral onde são adquiridos os sinais, os métodos de detecção e classificação desses sinais e as usuais métricas de desempenho utilizadas. Após isso, o foco da revisão é direcionado para estudos de sistemas SSVEP e seus paradigmas de digitação, sejam eles puramente baseados em SSVEP ou também híbridos. Os sistemas de digitação são descritos seguindo uma ordem cronológica o que traz grande robustez à análise, pois permite verificar a evolução dos sistemas. Essa linha do tempo mostra as diferentes combinações e variações de interface dos digitadores e métodos de classificação. Cada sistema é listado e comparado com relação ao número de comandos e alvos, as frequências utilizadas para estímulo, número e tipo de sujeitos, acurácia e ITR. Além de verificar essas métricas quantitativas é discutido sobre a

experiência de usuário em cada sistema, balanceando a análise com relação à eficiência. O trabalho ainda debate alguns pontos que foram considerados desafios no paradigma SSVEP, como a falta de comparação entre diferentes paradigmas, a falta de pesquisas com relação a fatores influenciadores no desempenho dos sistemas e a falta de pesquisas relacionadas à fadiga visual. O artigo propõe uma série de melhorias possíveis, como a proposição de uma métrica fixa para quantização de experiência de usuário num geral. Outras sugestões são feitas no âmbito de melhoria da eficiência dos sistemas, como: melhorar funções de previsão de palavras, usar métodos avançados para classificação dos sinais, preparar meticulosamente os ambientes de experimentos de modo a evitar interferência externa e otimizar métodos de calibração para selecionar os melhores parâmetros para cada sujeito.

Em (10) é feita uma revisão abrangente dos componentes em sistemas de digitação em BCI. Os primeiros componentes analisados são os digitadores e os quatro paradigmas possíveis, comparando suas vantagens e desvantagens. O trabalho compara em seguida os extratores das características dos sistemas. Dentre os extratores são analisados aqueles que extraem características do domínio temporal (geralmente utilizados em paradigmas P300), extratores no domínio de frequência (focados para sinais SSVEP), extratores no domínio tempo-frequência e extratores baseados em aprendizado profundo. Levantando a problemática da dimensionalidade das características extraídas dos sistemas, o artigo ainda comenta sobre os métodos de otimização de características que podem ser utilizados. Como último componente abordado têm-se os classificadores que podem ser divididos em três categorias: não supervisionados, semi-supervisionados e supervisionados. O trabalho ressalta pesquisas feitas para cada uma das categorias e subcategorias de componentes. São citadas como melhorias possíveis o uso de sistemas que ajustariam seus parâmetros automaticamente baseado em um *feedback* do usuário. Além disso, novamente é citada a necessidade de se melhorar e analisar os sistemas com relação à fadiga visual do usuário e aprimorar os algoritmos de previsão de palavras.

Em (11) é apresentado o CCA como uma alternativa para classificação de sinais SSVEP. Como comparação é utilizado o método de Análise da Densidade Espectral de Potência (PDSA). Além disso é apresentada uma alternativa à proposta de *scalp-patch* utilizando o CCA para seleção dos eletrodos a serem utilizados no método. Para os experimentos, são utilizados 9 classes e 8 eletrodos para captação do sinal cerebral e 7 tempos totais de *trials*, indo de 0.75 segundos até 2.25 segundos com passo de 0.25 segundos. Nas acurácias médias obtidas o CCA ultrapassa o PSDA em todos os tempos, com pico de 75%, enquanto o pico do PSDA não ultrapassa 70%. Com relação ao conforto, o trabalho apenas discute o fato de que reduzir o tempo necessário para atingir uma acurácia satisfatória pode evitar a fadiga visual uma vez que reduziria o tempo necessário de estímulo do usuário.

Em (12) o método CCA é novamente estudado. No trabalho, um *dataset* de SSVEP é utilizado *offline* para estudar os melhores parâmetros de um experimento *online*. O

dataset possuía 6 sujeitos que gravaram testes com 6 frequências, variando de 13-18Hz com passo de 1Hz. Os testes *offline* foram feitos para determinar três parâmetros: os eletrodos utilizados, o número de harmônicos na geração das frequências-alvo e a janela temporal. Como conclusão, verificou-se que o número de harmônicos não influenciou na precisão obtida ao longo do tempo ($p > 0.1$) e a janela de 2 segundos já provia uma acurácia satisfatória para um teste *online*, aproximando-se dos 80%. Para os experimentos *online* o CCA atinge um ITR médio de 58 bits/min. A importância do trabalho se dá por ser um complemento dos estudos do CCA, envolvendo uma análise dos melhores parâmetros para uso prático. Entretanto, no trabalho nenhuma comentário é feito com relação à fadiga visual dos usuários tanto nos experimentos *offline* quanto nos experimentos *online*.

Em (6), seguindo a popularidade do CCA em sistemas SSVEP-BCI, é proposto o CCA com Filtro Passa-Banda (FBCCA). O FBCCA aplica práticas de filtragem de bandas de frequência para aumentar o desempenho do modelo. Em um teste com 40 classes o FBCCA se sai melhor que o CCA tanto em testes *offline* com um *dataset* de 12 sujeitos, quanto em um teste *online* com 10 sujeitos, aumentando em até 15% a acurácia e aumentando o ITR em até 40 bits/min. A importância desse trabalho se deve por melhorar um método que já era extensamente utilizado e robusto, facilitando suas aplicações práticas e desempenho. No entanto, o trabalho utiliza uma faixa de frequências conhecida por ser desconfortável e nenhuma análise é feita com relação ao conforto.

Em (13) um *dataset* com dados de BCI é fornecido com frequências que variam entre 1 e 60Hz com passo de 1Hz para 30 sujeitos saudáveis. O trabalho detalha os experimentos e especificações técnicas para garantir sua viabilidade como um *dataset* robusto que pode ser utilizado para diversos estudos no paradigma SSVEP. Além dos dados de sinais cerebrais o trabalho fornece dados de conforto coletados dos sujeitos após cada estímulo. Para um teste do *dataset* é utilizado o FBCCA como método de classificação e o método é testado em para três diferentes faixas de quatro alvos (baixa, de 2 a 5Hz, média, de 12 a 15Hz e alta, de 40 a 43Hz). Os resultados obtidos em acurácia são positivos, com acurácia média acima de 80% e atingindo picos de ITR acima de 60 bits/min. Além da análise somente pela acurácia e ITR, o artigo analisa o conforto do usuário, porém de forma arbitrária. No artigo, dois sistemas de pontuação são utilizados. O primeiro sistema estabelece uma ponderação com razão 7:3, atribuindo 70% do peso à acurácia da classificação e 30% à experiência do usuário. Isso significa que, independentemente dos valores individuais desses fatores, a pontuação composta sempre será calculada com essa proporção fixa. Já o segundo sistema de pontuação utiliza um critério baseado em um limiar: se a acurácia da classificação for inferior a 70%, a pontuação é determinada exclusivamente pela acurácia (peso de 1:0); caso contrário, a pontuação passa a ser determinada apenas pela experiência do usuário (peso de 0:1). Esse método dá prioridade à acurácia quando ela é baixa, mas, uma vez atingido o nível de 70%, o foco passa a ser totalmente na experiência do usuário. Embora seja um avanço na avaliação combinada do desempenho da classificação

e da experiência do usuário, esse sistema de pontuação apresenta algumas limitações. Primeiro, a escolha dos pesos (7:3 no primeiro caso e a divisão rígida no segundo) pode ser arbitrária e não necessariamente refletir a importância real desses fatores para todos os usuários. Além disso, a abordagem baseada em limiar do segundo sistema pode levar a descontinuidades na pontuação, onde pequenas variações na acurácia (por exemplo, de 69% para 71%) resultam em mudanças abruptas na métrica composta. Por fim, esses métodos não consideram possíveis interações entre acurácia e experiência do usuário, que podem variar dependendo do paradigma de BCI utilizado.


Em conclusão, embora os trabalhos revisados forneçam uma análise abrangente dos sistemas BCI voltados para digitação e paradigmas SSVEP, a maioria deles foca predominantemente no desempenho dos sistemas, como acurácia e ITR, e nas métricas quantitativas de eficácia. No entanto, a análise do conforto do usuário, um aspecto crucial para o sucesso de tais sistemas, especialmente considerando seu uso a longo prazo, como ferramenta de comunicação, é frequentemente negligenciada. O desconforto visual, a fadiga e a experiência do usuário são mencionados, mas de maneira superficial ou arbitrária. Para a construção de sistemas de BCI realmente eficientes e utilizáveis, é essencial que futuras pesquisas integrem de forma mais robusta a análise de conforto, equilibrando-o com os parâmetros de desempenho, para garantir a viabilidade de uso constante e sustentável por parte de indivíduos com necessidades de comunicação assistiva.

3 INTERFACE CÉREBRO-MÁQUINA

BCIs são interfaces que permitem a comunicação direta entre o cérebro e um sistema eletrônico, utilizando exclusivamente a atividade cortical, sem envolver os neurônios motores responsáveis pelo controle dos músculos (2)(14). A partir dessa conexão cérebro-máquina, surgem diversos paradigmas. Além daqueles voltados para o controle e a seleção de comandos por meio de sinais cerebrais, há também paradigmas focados na modulação da atividade cerebral, como na recuperação de movimentos em pessoas que sofreram um AVC (15) ou na melhoria da atenção em indivíduos com autismo (3). Comumente, sistemas BCI necessitam de treinamento para seu uso por um indivíduo. Geralmente o treinamento é feito com dados gravados com o sujeito alvo para uso. Esse processo é bem tedioso e alguns trabalhos focam nessa questão, utilizando técnicas de aumento de dados ou transferência de aprendizado para diminuir o tempo gasto nesta etapa (16). Os modelos que geralmente requerem treinamento não apenas aprendem a classificar um sinal cerebral em diferentes categorias, mas também se ajustam às particularidades de cada indivíduo. Isso é essencial, pois cada cérebro possui uma disposição única de sinais cerebrais. Entretanto, alguns paradigmas não necessitam de treinamento. Isso acontece no caso do SSVEP pois os possíveis alvos de classificação são sinais previamente conhecidos e construídos artificialmente para classificação.

Embora não necessite de treinamento, a gravação de um *dataset* para experimentos *offline* com SSVEP segue um fluxo igual a gravação de *dataset* para outros paradigmas. O processo de gravação de um *dataset* é ilustrado na Figura 1.

Figura 1 - Processo de gravação de sinais cerebrais para N blocos com M *trials*. No exemplo cada *trial* possui um total de 7 segundos de duração.



Fonte: Elaborada pelo autor (2025).

Como pode ser visto, um *trial* começa com uma indicação para o sujeito da ação a ser tomada ou de que o estímulo irá acontecer, essa indicação é comumente chamada de *cue*. No caso do SSVEP, para cada *trial*, o período de atividade visto na imagem é a exposição do sujeito a um estímulo luminoso na frequência selecionada aleatoriamente dentre um dos possíveis alvos. Em outros paradigmas, como por exemplo, o de imaginação motora, a atividade consiste no sujeito imaginar o movimento do órgão indicado na *cue*.

Após o estímulo, há um tempo de descanso até o início do próximo *trial*. Especialmente em SSVEP, esse tempo de descanso é crucial para evitar a fadiga visual do sujeito.

Os equipamentos de coleta de sinais cerebrais podem ser invasivos ou não-invasivos. Os invasivos, mesmo possuindo maior precisão espacial e menos ruído, são mais complexos de implementar e apresentam riscos associados à cirurgia, como infecções e rejeição pelo organismo. Já os não-invasivos, embora tragam muito mais segurança em sua aplicação, possuem muito mais ruído. Dentre os equipamentos não-invasivos o EEG é o único que coleta sinais elétricos. O sinal coletado pelo aparelho é armazenado em uma estrutura tridimensional, onde a primeira dimensão representa os *trials*, a segunda corresponde aos eletrodos e a terceira ao tempo. Além desses sinais é armazenada em outra estrutura a etiqueta de cada *trials*, ou seja, a frequência do estímulo, para sistemas SSVEP, ou o órgão indicado para o sujeito imaginar movimentando. Em sistemas que necessitam de treinamento, antes de seu teste, os dados são separados em treino e teste. Aqueles separados para treino serão usado para treinar o modelo BCI. Já os dados de teste são utilizados para avaliar as métricas do modelo treinado verificando se o mesmo classificou os sinais cerebrais nas categorias corretas. O modelo usado para classificação neste trabalho não necessita de treinamento, dessa forma, todos os dados são utilizados para teste.

O processo de processamento e classificação de um sinal EEG segue as seguintes etapas:

1. Pré-processamento

- a) **Reamostragem:** ajuste da taxa de amostragem dos dados.
- b) **Eliminação de *trials*:** remoção de *trials* ruidosos ou de baixa qualidade.
- c) **Remoção de eletrodos:** exclusão de eletrodos menos relevantes, considerando que diferentes áreas corticais desempenham funções específicas.
- d) **Janelamento:** segmentação do sinal para o período mais relevante à realização da tarefa ou à classificação do modelo.

2. Filtragem


- a) **Filtragem temporal:** remoção de ruídos indesejados, como com filtros passa-banda para seleção de frequências de interesse e filtros de rejeição para frequências de ruído conhecidas.
- b) **Filtragem espacial:** minimização da interferência entre eletrodos, reduzindo a correlação entre sinais vizinhos.

3. Extração de características

- a) **Extração de características:** redução da dimensionalidade do sinal de um *trial*, tornando o processamento mais eficiente e melhorando a relação entre o número de características e a quantidade de *trials*.
 - b) **Seleção de características:** refinamento do conjunto extraído, priorizando as características mais relevantes para a classificação.
4. **Classificação:** identificação do comando associado ao sinal por meio da análise das características extraídas.

O fluxo pode ser ilustrado de forma geral conforme visto na Figura 2.

Figura 2 - Fluxo geral para classificação de um sinal cerebral.




Fonte: Elaborada pelo autor (2025).

Nem todas essas etapas necessitam estar em um sistema BCI, mas descrevem em termos gerais a grande maioria dos processos que um sinal de EEG pode passar até sua classificação. Considerando isso, a Figura 3 ilustra o sistema utilizado neste trabalho.

Como o teste feito é *offline* a fonte de dados é um *dataset* de sinais cerebrais. Pelo mesmo motivo, a ação tomada ao final da classificação é apenas a contabilização se a classificação foi correta ou não e o tempo levado para classificar. Comumente, em testes *online* de SSVEP a ação é a seleção de um caractere em um digitador ou a execução de algum outro comando associado à frequência classificada. Neste trabalho, a extração de características e classificação são feitas pelo CCA que será descrito no Capítulo 4. A

Figura 3 - Fluxo para classificação de um sinal cerebral neste trabalho.



Fonte: Elaborada pelo autor (2025).

parte de filtragem já foi realizada na coleta dos dados, que foram utilizados de um *dataset* da literatura que será melhor descrito no Capítulo 5. Como pré-processamento temos a remoção de eletrodos e janelamento que será melhor descrita no Capítulo 6.

3.2 POTENCIAIS EVOCADOS VISUAIS EM REGIME ESTACIONÁRIO


Os Potenciais Evocados Visuais em Regime Estacionário são respostas elétricas do cérebro geradas por estímulos visuais periódicos e repetitivos. Quando uma pessoa fixa o olhar em um estímulo luminoso periódico, seu córtex cerebral responde com oscilações elétricas na mesma frequência ou em algum dos harmônicos dessa frequência. Esses potenciais são amplamente explorados em BCI por conta da robustez, rápida detecção e fácil utilização dos sistemas baseados nesse paradigma, além disso, em vários casos não necessitando de nenhum treinamento do modelo de classificação. Inicialmente, há uma ativação do córtex visual primário que ativa em sincronia as células neurais responsáveis pelo processamento da visão. Esse sinal é então propagado para outras regiões do cérebro, como o córtex visual secundário e terciário e, região parieto-occipital, que pode ser gravada com o eletroencefalograma.

A detecção desses estímulos costuma ser dividida em três faixas: baixa (menos de 12Hz), média (12-30Hz) e alta frequência (30Hz adiante) (13). Frequências baixas comumente geram respostas mais fortes entretanto mais desconfortáveis para o usuário. A faixa média permite um maior balanceamento entre conforto e resposta neuronal detectável. Enquanto a faixa alta reduz bastante a fadiga ocular mas a resposta cerebral é menor. A classificação rápida e acurada do sinal de resposta cerebral a estímulos visuais gera uma gama de aplicações para SSVEPs. Uma delas é a área de comunicação alternativa. Pessoas com paralisia severa podem utilizar BCIs baseados em SSVEPs para se comunicar mantendo o olhar fixo em áreas de uma interface que permite a escolha de letras ou palavras, essas interfaces são conhecidas como digitadores ou *spellers*. Na Figura 5 temos um exemplo de como os digitadores funcionam.

Esse poder de escolha baseado apenas no foco visual permite também o controle de dispositivos como cadeiras de rodas, robôs ou braços mecânicos (18). Além dessas aplicações, existe uma área focada no desenvolvimento de jogos controlados por SSVEPs que permitem novas experiências imersivas, interagindo com o ambiente virtual somente com sua atenção visual (19).

Além do SSVEP, existe o paradigma P300 que pode ser baseado em outros estímulos sensoriais. O P300 e SSVEPs são comumente estudados em comparação para uso em comunicação alternativa (10). Enquanto o P300 gera menos fadiga visual ele exige atenção e uma certa adaptação do usuário, o SSVEP é mais intuitivo para o usuário e permite uma resposta contínua e rápida. O P300, devido às suas características, é comumente utilizado para seleção discreta, como na escolha de letras em um teclado virtual. Já o SSVEP, além de ser utilizado em comandos discretos, pode ser ajustado para seleção contínua de comandos, o que oferece a gama mais ampla de aplicações mencionadas anteriormente.

Figura 5 - Exemplo de digitador SSVEP com 6 alvos e 2 fases. Inicialmente cada coluna oscilará com uma frequência específica permitindo a escolha da coluna. Na segunda fase, cada célula da coluna escolhida oscilará com frequências específicas. Dessa forma, 36 diferentes escolhas podem ser feitas com apenas 6 frequências.



Fonte: Elaborada pelo autor (2025).


4 ANÁLISE DE CORRELAÇÃO CANÔNICA

A Análise de Correlação Canônica é um método estatístico multivariado e foi proposto para uso de reconhecimento de sinais SSVEP em (11). Esse método é utilizado quando se espera a existência de correlação entre dois grupos de variáveis, mas não se deseja calcular a correlação cruzada entre todas elas. O objetivo da CCA é encontrar um par de combinações lineares desses grupos de variáveis, de forma que a correlação entre as variáveis canônicas seja maximizada. Considerando duas variáveis multidimensionais X e Y e as combinações lineares $x = X^T W_x$ e $y = Y^T W_y$. A CCA irá encontrar os vetores de peso W_x e W_y que maximizam a correlação entre x e y . Esse peso é encontrado resolvendo o problema:

$$\max_{W_x, W_y} \rho(x, y) = \frac{E[x^T y]}{\sqrt{E[x^T x]E[y^T y]}} = \frac{E[W_x^T X Y^T W_y]}{\sqrt{E[W_x^T X X^T W_x]E[W_y^T Y Y^T W_y]}} \quad (4.1)$$

O valor máximo de ρ é a correlação canônica máxima entre as variáveis, e as projeções x e y são chamadas variáveis canônicas. Uma esquematização do processo do CCA está ilustrada na Figura 6.

Figura 6 - Ilustração da análise de correlação canônica entre o sinal cerebral e um sinal de referência. Após a transformação para variáveis canônicas, uma correlação simples é executada entre ambas.



Fonte: Elaborada pelo autor (2025).

No contexto de BCI a variável X_i representa o sinal cerebral do i -ésimo trial com dimensões $E \times T$, onde E é o número de eletrodos e T é o número de amostras temporais. Já Y_f representa os sinais de referência gerados para cada frequência f de estímulo, com dimensões $2N_h \times T$, onde N_h é o número de harmônicos. Dado um conjunto de frequência de estímulo $f_1, f_2, \dots, f_K$ cada Y_f é construído da seguinte forma:


$$Y_f = \begin{pmatrix} \sin(2\pi ft) \\ \cos(2\pi ft) \\ \vdots \\ \sin(2\pi N_h ft) \\ \cos(2\pi N_h ft) \end{pmatrix} \quad (4.2)$$

e t é dado por:

$$t = \frac{1}{S}, \frac{2}{S}, \dots, \frac{T}{S} \quad (4.3)$$

onde S é a frequência de amostragem. Para cada sinal cerebral X_i a CCA é aplicada em relação a cada Y_f correspondente às possíveis frequências de estímulo. Como resultado, obtém-se um conjunto de coeficientes de correlação ρ_f . O comando do sujeito é então considerado a frequência f_k cujo sinal de referência Y_f resultou na maior correlação dentre todos. Uma ilustração do funcionamento do método pode ser vista na Figura 7.

Figura 7 - Ilustração do uso do CCA para classificação de sinais cerebrais. O sinal cerebral X é comparado com os sinais de referência de cada frequência alvo, aquela com a qual o sinal EEG possuir uma maior correlação é a escolhida.




Fonte: Elaborada pelo autor (2025).

5 DATASET

Historicamente, a captura de sinais SSVEP foi amplamente realizada utilizando estímulos visuais gerados por diodos emissores de luz (LEDs). No entanto, com o avanço da tecnologia, o uso de monitores LCD tornou-se mais comum nesse tipo de experimento. O conjunto de dados utilizado neste trabalho foi originalmente apresentado por (13), no qual os estímulos visuais foram gerados por um monitor com taxa de atualização de 240 Hz. Como diferencial, as gravações do dataset foram realizadas com duas diferentes amplitudes de oscilação luminosa: uma de alta amplitude e outra de baixa amplitude. Na Figura 8 temos uma ilustração da diferença entre as variações de estímulo.

Figura 8 - Diferença da amplitude dos estímulos. O estímulo oscila discretamente, na imagem temos as fases intermediárias do estímulo. Em alta amplitude o estímulo varia de preto ao branco, enquanto a baixa amplitude oscila de um cinza escuro para um cinza claro.



Fonte: Elaborada pelo autor (2025).

Os dados foram coletados de 30 sujeitos, dos quais 16 eram mulheres, todos saudáveis e com visão normal ou corrigida para normal. Os experimentos ocorreram ao longo de quatro sessões, nas quais as frequências dos estímulos eram distribuídas aleatoriamente conforme apresentado na Tabela 1. Em cada sessão, foram gravados 12 blocos, cada um com 30 *trials*, sendo que entre os blocos houve períodos de descanso de 1 a 10 minutos, a fim de evitar e aliviar a fadiga visual.

No experimento, cada *trial* teve duração de 7 segundos, com o primeiro segundo indicando o início do novo *trial*, seguido de 5 segundos de estímulo e, ao final, 1 segundo de descanso. O EEG utilizado foi o *Neuroscan Synamps2*, que registrou os sinais de 64 eletrodos de acordo com o padrão internacional 10/20, com taxa de amostragem de 1000Hz. Para o pré-processamento, foi aplicado um filtro de faixa embutido de 50Hz, junto com um filtro passa-banda variando de 0.1Hz a 100Hz. Além disso, os *trials* foram recortados para incluir apenas o intervalo de estímulo (5 segundos), mais 0.14 segundos adicionais

Tabela 1 – Frequências em cada sessão.

Sessões	Frequências
1	1, 5, 9, ..., 57Hz
2	2, 6, 10, ..., 58Hz
3	3, 7, 11, ..., 59Hz
4	4, 8, 12, ..., 60Hz


Fonte: Adaptada de (13).

após o estímulo, devido à latência do sistema visual. Ao final das gravações, os dados estavam organizados em 2 condições de amplitude, 64 eletrodos, 5140 pontos de tempo, 60 frequências e 12 blocos. Em adição aos dados de sinais cerebrais um dataset extra foi fornecido com avaliações subjetivas de cada sujeito com relação ao conforto, percepção do piscar da tela e preferência. Essa avaliação era uma nota entre 0 e 5 para cada frequência e amplitude de oscilação.

6 EXPERIMENTOS

Para realização dos experimentos, primeiramente selecionou-se os eletrodos que seriam utilizados. Os eletrodos [Pz, PO3, PO4, PO5, PO6, POz, Oz, O1 e O2] foram selecionados dentre os 64 disponíveis com base em (13), concentrando-se exclusivamente nas regiões occipitais, parieto-occipitais e parietais do cérebro. Esses eletrodos são mostrados na Figura

Figura 9 - Eletrodos selecionado para o experimento em azul. Todos obedecem o sistema de posicionamento 10-10.



Fonte: Adaptada de (17).

Além disso, o número de harmônicos para o CCA do mesmo trabalho foi utilizado com $N_h = 10$. Foram utilizados 4 diferentes tamanhos de janelas de frequência, com 2, 4, 8 e 16 alvos. Cada uma dessas janelas foi testada para todos os intervalos possíveis no intervalo de 1 a 60Hz. Dessa forma, a janela de tamanho 4, por exemplo, foi testada nos intervalos 1 a 4Hz, 2 a 5Hz, até eventualmente 57 a 60Hz. Além disso, 4 diferentes janelas de tempo foram testadas, cada *trial* foi classificado para janelas de 0 a 0.5s, 0 a 1s, 0 a 1.5s e 0 a 2s.

Como métricas foram utilizadas as acurácias médias, o conforto médio e ITR. O ITR mede a eficiência na transmissão de informações de BCI. Ele quantifica essa transferência de informação em *bits* por minuto. Seu cálculo é feito seguindo:

$$ITR = \left(\log_2 N + P \log_2 P + (1 - P) \log_2 \frac{1 - P}{N - 1} \right) \times \frac{60}{T} \quad (6.1)$$

Como definido em (14), N é o número de alvos possíveis, P é a acurácia da classificação e T é o tempo até a decisão de um comando. O tempo até a decisão portanto deve considerar o tempo total utilizado do *trial* adicionado do tempo para classificação. A consideração do tempo para classificação é importante neste trabalho, uma vez que, ao variar os intervalos de tempos de *trial* utilizados e o número de possíveis alvos, o tempo para classificação varia.

Toda a implementação do código foi realizada em Python, versão 3.12.4¹. Para a leitura de *datasets* BCI, utilizou-se uma implementação desenvolvida pelo próprio autor para o pacote *bciflow*². O classificador CCA foi implementado com o uso da biblioteca de aprendizado de máquina *scikit-learn* (20). Os experimentos foram executados em uma máquina equipada com um processador Intel Core i5-11400F de 11^a geração e 16 GB de memória RAM.

¹ Disponível em: <https://github.com/stephanJoao/tcc>.

² Disponível em: <https://github.com/lab-hc/bciflow>.


6.1 RESULTADOS

As primeiras visualizações que podem ser feitas para analisar os resultados são com relação a acurácia do modelo. Para verificarmos o comportamento dessa métrica, os gráficos serão separados por tipo de estímulo e número de alvos, e podem ser vistos nas Figuras 10 e 11. Nesses gráficos, o eixo x representa as diferentes janelas de frequências utilizadas de forma sequencial, dessa forma, para quatro alvos, por exemplo, temos o valor para os alvos de 1 a 4Hz, 2 a 5Hz e assim por diante. Nos gráficos, são traçadas também as linhas de conforto médio dos usuários para os alvos da janela de frequência respectiva. Além disso, uma linha tracejada é traçada representando a acurácia esperada para um sistema aleatório, essa linha pode ser interpretada como a acurácia mínima a ser atingida.


Nos gráficos é evidente que quanto mais tempo é utilizado, melhores são as acurácias. Percebe-se também pelos gráficos a relação inversa entre conforto e acurácia no paradigma SSVEP. Isso ocorre por diversos fatores neurofisiológicos e perceptuais. Estímulos visuais mais desconfortáveis (como algumas faixas de frequência e maior amplitude do estímulo) tendem a gerar respostas neurais mais fortes (8). Esse resultado também pode ser visto ao analisar o gráficos para os estímulos de alta amplitude na Figura 11, nos quais o desempenho se mostra melhor do que para a mesma quantidade de alvos com estímulo de baixa amplitude. Nas janelas que usam a frequência 50Hz como alvo, conseguimos ver uma degradação da métrica. Isso ocorre pois, como dito no Capítulo 5, um filtro de faixa de 50Hz foi aplicado para remover interferências da corrente alternada detectada no sistema elétrico ao redor. Esse filtro afeta não só as frequências de 50Hz como as frequências vizinhas, gerando essa degradação. Essa queda de desempenho é mais visível para os resultados de estímulos de alta amplitude principalmente na Figura 11a.

Outro resultado é o fato de que, com o aumento no número de alvos, a acurácia se reduz. Ainda assim, mesmo com essa diminuição, o sistema mantém-se com acurácias acima do mínimo esperado. Porém, o aumento do número de alvos aumenta a quantidade de informação transferida como também permite o uso do sistema para diferentes aplicações. Pela definição do ITR (Equação 6.1) a quantidade de informação transmitida é dada por $\log_2 N$. Dessa forma, para 2 alvos, a quantidade de informação transmitida é 1 *bit* enquanto para 16 alvos são 4 *bits*. As consequências desse aumento de informação serão vistas ao analisarmos o ITR do sistema. Já considerando a gama de aplicações, mais alvos permitem mais usos. Diversos digitadores baseados em SSVEPs utilizam 2 ou 3 fases para a digitação de um caractere (9). Considerando o uso de 8 alvos e 2 fases, por exemplo, é possível atingir 64 diferentes opções. Logo, é possível cobrir todo o alfabeto, numerais e ainda fornecer opções previstas de palavras completas que aceleram a comunicação.


Figura 10 - Acurácia e conforto para diferentes quantidades de alvos com estímulo de baixa amplitude.




(a) Dois alvos.



(b) Quatro alvos.




(c) Oito alvos.




(d) Dezesesseis alvos.

Fonte: Elaborada pelo autor (2025).


Figura 11 - Acurácia e conforto para diferentes quantidades de alvos com estímulo de alta amplitude.




(a) Dois alvos.



(b) Quatro alvos.



(c) Oito alvos.




(d) Dezesseis alvos.

Fonte: Elaborada pelo autor (2025).


Para uma análise mais rigorosa dos dados obtidos, podemos utilizar os gráficos de Pareto para cada tamanho de janela de alvos. Essa abordagem permite identificar as soluções que apresentam um compromisso entre os dois objetivos de interesse. Geralmente, a solução utópica em um gráfico de Pareto corresponde a um ponto localizado no canto inferior esquerdo. Para adequar nossos resultados a essa análise, realizamos uma transformação das métricas originais. O conforto é convertido em desconforto, definido como a diferença entre a nota máxima e o valor de conforto registrado. Da mesma forma, a acurácia é transformada em erro médio. Dessa maneira, os melhores resultados são aqueles que minimizam simultaneamente o desconforto e o erro médio.

Na Figura 12, os pontos exibidos representam as métricas para diferentes combinações dos parâmetros utilizados, dividindo-os apenas por número de alvos. Os pontos mais escuros no gráfico correspondem às soluções não dominadas, ou seja, aquelas para as quais não há outra solução que seja simultaneamente melhor em ambas as métricas. Isso permite uma análise mais objetiva dos pares (desconforto, erro médio) que representam as alternativas mais eficientes dentro do conjunto de soluções avaliadas.


Figura 12 - Gráficos de Pareto para diferentes tamanhos de janela.




(a) Janela de dois alvos.



(b) Janela de quatro alvos.



(c) Janela de oito alvos.



(d) Janela de dezesseis alvos.

Fonte: Elaborada pelo autor (2025).

As Tabelas 2, 3, 4 e 5 apresentam os parâmetros correspondentes as soluções não dominadas. Uma tendência observada tanto nas tabelas quanto nos gráficos é que, inicialmente, são os estímulos de baixa amplitude aparecem entre as soluções. No entanto, à medida que o desconforto aumenta, os estímulos de alta amplitude passam a superar aqueles de baixa amplitude em termos de desempenho, indicando uma relação entre intensidade do estímulo e eficácia dos resultados.

Tabela 2 – Pontos não dominados para dois alvos.

Amplitude	Alvos	Tempo (ms)	Desconforto	Erro
Baixa	(48, 49)	2000	0.32	0.44
Baixa	(47, 48)	2000	0.38	0.36
Baixa	(41, 42)	2000	0.53	0.33
Alta	(48, 49)	2000	0.73	0.32
Baixa	(36, 37)	2000	0.87	0.21
Alta	(47, 48)	2000	0.87	0.20
Alta	(43, 44)	2000	1.12	0.15
Baixa	(33, 34)	2000	1.23	0.14
Alta	(39, 40)	2000	1.28	0.11
Alta	(38, 39)	2000	1.62	0.08
Baixa	(27, 28)	2000	1.77	0.08
Alta	(37, 38)	2000	1.85	0.05
Alta	(36, 37)	2000	1.98	0.03
Baixa	(7, 8)	2000	2.08	0.03
Alta	(34, 35)	2000	2.45	0.02
Baixa	(15, 16)	2000	2.55	0.02
Alta	(33, 34)	2000	2.72	0.02
Alta	(32, 33)	2000	2.90	0.01
Alta	(31, 32)	2000	3.05	0.01
Alta	(26, 27)	2000	3.23	0.01
Alta	(27, 28)	2000	3.27	0.00
Alta	(22, 23)	2000	3.55	0.00
Alta	(17, 18)	2000	3.63	0.00

Tabela 3 – Pontos não dominados para quatro alvos.

Amplitude	Alvos	Tempo (ms)	Desconforto	Erro
Baixa	(47, 50)	2000	0.42	0.71
Baixa	(46, 49)	2000	0.45	0.62
Baixa	(45, 48)	2000	0.50	0.60
Baixa	(41, 44)	2000	0.55	0.56
Baixa	(40, 43)	2000	0.58	0.54
Baixa	(38, 41)	2000	0.73	0.50
Baixa	(37, 40)	2000	0.83	0.48
Baixa	(36, 39)	2000	0.88	0.45
Alta	(46, 49)	2000	0.92	0.41
Baixa	(35, 38)	2000	0.98	0.41
Baixa	(34, 37)	2000	1.03	0.36
Alta	(45, 48)	2000	1.05	0.34
Alta	(44, 47)	2000	1.12	0.33
Alta	(43, 46)	2000	1.17	0.29
Alta	(42, 45)	2000	1.22	0.28
Alta	(41, 44)	2000	1.27	0.25
Baixa	(31, 34)	2000	1.31	0.25
Alta	(40, 43)	2000	1.32	0.23
Alta	(39, 42)	2000	1.35	0.20
Alta	(38, 41)	2000	1.46	0.18
Alta	(37, 40)	2000	1.57	0.15
Alta	(36, 39)	2000	1.80	0.11
Alta	(35, 38)	2000	1.98	0.08
Alta	(34, 37)	2000	2.22	0.06
Alta	(33, 36)	2000	2.42	0.05
Alta	(32, 35)	2000	2.68	0.04
Alta	(31, 34)	2000	2.88	0.03
Alta	(28, 31)	2000	3.17	0.03
Alta	(27, 30)	2000	3.24	0.02
Alta	(26, 29)	2000	3.26	0.02
Alta	(21, 24)	2000	3.51	0.01
Alta	(20, 23)	2000	3.52	0.01

Tabela 4 – Pontos não dominados para oito alvos.

Amplitude	Alvos	Tempo (ms)	Desconforto	Erro
Baixa	(47, 54)	2000	0.48	0.84
Baixa	(42, 49)	2000	0.50	0.75
Baixa	(41, 48)	2000	0.52	0.73
Baixa	(40, 47)	2000	0.57	0.72
Baixa	(39, 46)	2000	0.62	0.70
Baixa	(38, 45)	2000	0.65	0.68
Baixa	(37, 44)	2000	0.69	0.65
Baixa	(36, 43)	2000	0.72	0.63
Baixa	(35, 42)	2000	0.81	0.60
Baixa	(34, 41)	2000	0.88	0.56
Baixa	(33, 40)	2000	0.99	0.53
Baixa	(32, 39)	2000	1.06	0.49
Alta	(42, 49)	2000	1.08	0.47
Baixa	(31, 38)	2000	1.15	0.45
Alta	(41, 48)	2000	1.16	0.42
Alta	(40, 47)	2000	1.22	0.38
Alta	(39, 46)	2000	1.26	0.36
Alta	(38, 45)	2000	1.34	0.32
Alta	(37, 44)	2000	1.42	0.28
Alta	(36, 43)	2000	1.56	0.24
Alta	(35, 42)	2000	1.67	0.21
Alta	(34, 41)	2000	1.84	0.17
Alta	(33, 40)	2000	1.99	0.14
Alta	(32, 39)	2000	2.24	0.12
Alta	(31, 38)	2000	2.43	0.09
Alta	(30, 37)	2000	2.60	0.09
Alta	(29, 36)	2000	2.78	0.08
Alta	(28, 35)	2000	2.93	0.06
Alta	(27, 34)	2000	3.06	0.05
Alta	(26, 33)	2000	3.12	0.05
Alta	(25, 32)	2000	3.21	0.04
Alta	(24, 31)	2000	3.26	0.04
Alta	(22, 29)	2000	3.38	0.03
Alta	(21, 28)	2000	3.40	0.03
Alta	(20, 27)	2000	3.44	0.03
Alta	(19, 26)	2000	3.46	0.03
Alta	(18, 25)	2000	3.52	0.02
Alta	(16, 23)	2000	3.54	0.01
Alta	(17, 24)	2000	3.54	0.01

Tabela 5 – Pontos não dominados para dezesseis alvos.

Amplitude	Alvos	Tempo (ms)	Desconforto	Erro
Baixa	(45, 60)	2000	0.53	0.91
Baixa	(41, 56)	2000	0.54	0.88
Baixa	(40, 55)	2000	0.54	0.87
Baixa	(39, 54)	2000	0.55	0.86
Baixa	(38, 53)	2000	0.57	0.84
Baixa	(37, 52)	2000	0.60	0.83
Baixa	(36, 51)	2000	0.61	0.81
Baixa	(35, 50)	2000	0.66	0.79
Baixa	(34, 49)	2000	0.69	0.74
Baixa	(33, 48)	2000	0.76	0.71
Baixa	(32, 47)	2000	0.82	0.69
Baixa	(31, 46)	2000	0.88	0.67
Baixa	(30, 45)	2000	0.95	0.65
Baixa	(29, 44)	2000	1.01	0.62
Baixa	(28, 43)	2000	1.09	0.59
Baixa	(27, 42)	2000	1.16	0.57
Alta	(37, 52)	2000	1.25	0.57
Baixa	(26, 41)	2000	1.26	0.54
Alta	(36, 51)	2000	1.32	0.53
Baixa	(25, 40)	2000	1.35	0.52
Alta	(35, 50)	2000	1.37	0.49
Alta	(34, 49)	2000	1.46	0.41
Alta	(33, 48)	2000	1.58	0.37
Alta	(32, 47)	2000	1.73	0.34
Alta	(31, 46)	2000	1.85	0.31
Alta	(30, 45)	2000	1.97	0.30
Alta	(29, 44)	2000	2.10	0.27
Alta	(28, 43)	2000	2.24	0.24
Alta	(27, 42)	2000	2.36	0.21
Alta	(26, 41)	2000	2.48	0.19
Alta	(25, 40)	2000	2.60	0.16
Alta	(24, 39)	2000	2.75	0.16
Alta	(23, 38)	2000	2.88	0.14
Alta	(22, 37)	2000	2.99	0.12
Alta	(21, 36)	2000	3.09	0.11
Alta	(20, 35)	2000	3.18	0.10
Alta	(19, 34)	2000	3.26	0.09
Alta	(18, 33)	2000	3.32	0.09
Alta	(17, 32)	2000	3.38	0.08
Alta	(16, 31)	2000	3.40	0.07

Além das observações anteriores, é importante destacar que todos os pontos não dominados nos gráficos correspondem a testes com janelas de tempo de 2 segundos. Esse resultado era esperado para a acurácia, pois janelas maiores fornecem mais dados para a

classificação.

Além disso, os gráficos estão organizados de acordo com o tamanho da janela de frequências utilizada. Essa separação foi feita porque, conforme observado nos resultados anteriores, sistemas com menos alvos tendem a apresentar maior acurácia. Caso todas as janelas fossem exibidas em um único gráfico, os pontos Pareto-ótimos corresponderiam exclusivamente aos testes com dois alvos.

Nos gráficos apresentados, observa-se que, a partir de um determinado limiar de desconforto, as melhores acurácias estão associadas aos estímulos de menor amplitude. No entanto, nesses casos, o desempenho geral é reduzido, o que pode comprometer a aplicabilidade do modelo.

Essa análise possibilita a definição de limites mínimos aceitáveis para o conforto do usuário e para a acurácia do sistema. Dessa forma, a escolha da janela de tempo e da amplitude do estímulo pode ser orientada pelos pontos não dominados que atendam aos critérios estabelecidos.


Ao analisarmos os resultados sob a métrica do ITR, observamos que alguns padrões previamente identificados na acurácia começam a se inverter. Como o ITR mede a taxa de transferência de informação do sistema em *bits* por minuto, um aumento no número de alvos resulta em um maior número de bits transmitidos por instrução.

Além disso, a redução da janela de tempo impacta diretamente no ITR, pois diminui o intervalo necessário para a execução de um comando, acelerando a transmissão de informações. Essa análise evidencia cenários em que pode ser vantajoso aumentar o número de alvos, mesmo que isso reduza a acurácia, pois a taxa de informação transmitida por unidade de tempo ainda pode ser maior, compensando eventuais erros de classificação.


As Figuras 13 e 14 ilustram os valores de ITR para 2, 4, 8 e 16 alvos. Nesses gráficos, percebe-se que, mesmo com acurácia reduzida para tempos de 1 e 1.5 segundos, os valores de ITR superam os obtidos com janelas de 2 segundos. Em alguns casos, inclusive, a janela de 0.5 segundos apresenta um desempenho superior à de 2 segundos, demonstrando que tempos menores podem proporcionar maior eficiência na transmissão de informações.

Outro aspecto relevante é o aumento progressivo dos picos de ITR conforme cresce o número de alvos. Esse comportamento sugere que, dependendo do contexto de aplicação, a estratégia mais eficiente pode envolver um *trade-off* entre acurácia e taxa de transmissão de informação, onde a escolha da janela de tempo e do número de alvos deve considerar o objetivo final do sistema.


Figura 13 - ITR e conforto para diferentes quantidades de alvos com estímulo de baixa amplitude.




(a) Dois alvos.



(b) Quatro alvos.




(c) Oito alvos.




(d) Dezesseis alvos.

Fonte: Elaborada pelo autor (2025).


Figura 14 - ITR e conforto para diferentes quantidades de alvos com estímulo de alta amplitude.




(a) Dois alvos.



(b) Quatro alvos.



(c) Oito alvos.




(d) Dezesseis alvos.

Fonte: Elaborada pelo autor (2025).

Para a construção do gráfico de Pareto considerando o ITR, não é necessário separar os dados por número de alvos, pois essa métrica já incorpora as variáveis de acurácia, número de alvos e janelas de tempo utilizadas.

Diferentemente do gráfico de Pareto da acurácia, neste caso, o ITR não foi invertido, o que significa que o ponto ótimo encontra-se no canto superior esquerdo. A Figura 15 apresenta o gráfico de Pareto considerando todos os números de alvos possíveis, permitindo a identificação das configurações que maximizam a taxa de transferência de informação.

Figura 15 - Gráficos de Pareto para ITR, compilando todos os possíveis números de alvos.



Os pontos não dominados no gráfico de Pareto para o ITR podem ser vistos na Tabela 6. Os resultados mostram que a maioria dos pontos não dominados são de estímulos de amplitude alta (63,8%), já os estímulos de amplitude baixa representam 36,2% dos casos. Além disso, observa-se uma predominância dos testes feitos com 8 ou 16 alvos, que juntos correspondem a 76,6% dos dados. Na amplitude baixa, o desconforto varia entre 0.32 e 1.15, enquanto para amplitude alta, ele começa em 1.08 e pode atingir 3.40. Esses resultados evidenciam ainda mais a troca entre conforto e desempenho para esses sistemas. É evidente também que o aumento do número de classes influenciou positivamente o ITR, compensando a perda de acurácia.

Tabela 6 – Pontos não dominados para ITR.

Amplitude	Número de alvos	Alvos	Tempo (ms)	Desconforto	ITR
Baixa	2	(48, 49)	500	0.32	2.60
Baixa	2	(47, 48)	500	0.38	4.86
Baixa	2	(49, 50)	500	0.45	7.59
Baixa	4	(40, 43)	1500	0.58	8.11
Baixa	8	(39, 46)	1500	0.62	8.29
Baixa	2	(39, 42)	1500	0.64	8.69
Baixa	2	(38, 45)	1500	0.65	9.48
Baixa	2	(37, 44)	1500	0.69	11.45
Baixa	8	(36, 43)	1500	0.72	13.06
Baixa	8	(35, 42)	1500	0.81	15.51
Baixa	16	(31, 46)	2000	0.88	17.18
Baixa	8	(34, 41)	2000	0.88	17.36
Baixa	16	(30, 45)	2000	0.95	18.00
Baixa	8	(33, 40)	1500	0.99	20.14
Baixa	16	(29, 44)	2000	1.01	20.95
Baixa	8	(32, 39)	1500	1.06	23.04
Alta	8	(42, 49)	2000	1.08	24.23
Baixa	8	(31, 38)	1500	1.15	26.17
Alta	8	(41, 48)	1500	1.16	29.90
Alta	8	(40, 47)	1500	1.22	33.93
Alta	8	(39, 46)	1500	1.26	37.96
Alta	8	(38, 45)	1500	1.34	42.30
Alta	8	(37, 44)	1500	1.42	48.82
Alta	8	(36, 43)	1500	1.56	53.45
Alta	8	(35, 42)	1500	1.67	60.39
Alta	8	(34, 41)	1000	1.84	66.17
Alta	16	(30, 45)	1000	1.97	69.08
Alta	8	(33, 40)	1000	1.99	74.78
Alta	16	(29, 44)	1000	2.10	76.29
Alta	8	(32, 39)	1000	2.24	82.09
Alta	16	(28, 43)	1000	2.24	83.92
Alta	16	(27, 42)	1000	2.36	91.46
Alta	16	(26, 41)	1000	2.48	98.00
Alta	16	(25, 40)	1000	2.60	104.18
Alta	16	(24, 39)	1000	2.75	110.63
Alta	16	(23, 38)	1000	2.88	116.54
Alta	16	(22, 37)	1000	2.99	120.66
Alta	16	(21, 36)	1000	3.09	124.44
Alta	16	(20, 35)	1000	3.18	128.80
Alta	16	(19, 34)	1000	3.26	133.76
Alta	16	(18, 33)	1000	3.32	137.16
Alta	16	(17, 32)	1000	3.38	141.58
Alta	16	(16, 31)	1000	3.40	141.76

Fonte: Elaborada pelo autor (2025).

7 CONCLUSÃO

O interesse acadêmico no uso de Interfaces Cérebro-Máquina (BCI) baseadas no paradigma SSVEP é amplamente consolidado, com diversos estudos publicados ao longo dos anos. No entanto, o uso prolongado desses sistemas é reconhecido por causar fadiga visual nos usuários. Apesar disso, a maioria das pesquisas na área concentra-se no aperfeiçoamento dos métodos de classificação e das interfaces, sem buscar um equilíbrio entre desempenho e conforto. Além disso, poucos trabalhos avaliam a experiência do usuário de forma mais abrangente. Diante desse cenário, este estudo analisou diferentes combinações de janelas temporais, número de alvos e amplitude do estímulo, permitindo uma avaliação detalhada de como esses fatores influenciam acurácia, ITR e conforto. A principal contribuição desta pesquisa foi a identificação de padrões que auxiliam na seleção dos parâmetros mais adequados para diferentes aplicações, considerando não apenas a eficiência do sistema, mas também a experiência do usuário.

Os resultados obtidos neste estudo reforçam a existência de um *trade-off* entre conforto e acurácia em sistemas SSVEP, bem como um equilíbrio a ser considerado entre acurácia e ITR. As análises realizadas mostram que a escolha dos parâmetros do sistema deve ser guiada pelo objetivo da aplicação, uma vez que diferentes configurações podem priorizar a precisão na classificação dos estímulos ou a eficiência na transmissão de informações.

Em aplicações que exigem alta confiabilidade na detecção do comando, como interfaces de controle para dispositivos assistivos, priorizar menor quantidade de alvos e tempos de janela maiores tende a resultar em maior acurácia, reduzindo erros na interpretação dos sinais cerebrais. Por outro lado, em cenários onde a rapidez na comunicação é essencial, como em sistemas de digitação baseados em SSVEP, aumento do número de alvos e redução da janela de tempo podem proporcionar um ITR mais elevado, garantindo uma maior taxa de informação transmitida por minuto, mesmo com um possível decréscimo na precisão.

Adicionalmente, os gráficos de Pareto apresentados destacam como diferentes combinações de amplitude do estímulo, tempo de janela e número de alvos impactam o desempenho do sistema, permitindo que a configuração ótima seja escolhida com base nos requisitos específicos de cada aplicação.

Apesar das contribuições deste estudo, algumas limitações devem ser reconhecidas, abrindo espaço para futuras melhorias e aprofundamentos. Uma das principais limitações foi a utilização exclusiva do CCA como método de classificação, sem explorar classificadores mais robustos que possam oferecer melhor desempenho sem comprometer a eficiência computacional. Além disso, o tempo de classificação poderia ser reduzido por meio de técnicas de paralelização, otimizações na implementação ou ajustes nos parâmetros do sistema, como redução da frequência de amostragem, diminuindo a quantidade de dados

processados. Outro aspecto que pode ser investigado é a seleção de eletrodos, testando diferentes combinações ou até mesmo reduzindo seu número para equilibrar desempenho e custo computacional.

Outro passo importante para futuras pesquisas é o desenvolvimento de um sistema de digitação baseado em SSVEP, aplicando as configurações mais promissoras identificadas neste trabalho. Além disso, a gravação de um *dataset* próprio permitiria um controle mais preciso sobre as condições experimentais, possibilitando ajustes customizados e refinamento dos parâmetros testados. Testes similares também podem ser conduzidos com outros *datasets* contendo diferentes frequências de estímulo, permitindo uma avaliação mais ampla da generalização dos resultados obtidos.

REFERÊNCIAS

- 1 LEE, M. B. et al. Brain-computer interfaces in quadriplegic patients. *Neurosurgery Clinics of North America*, v. 30, n. 2, p. 275 – 281, 2019.
- 2 WOLPAW, J. et al. Brain-computer interface technology: a review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, 2000.
- 3 CERVANTES, J.-A. et al. Social robots and brain-computer interface video games for dealing with attention deficit hyperactivity disorder: A systematic review. *Brain Sciences*, 2023.
- 4 KAPLAN, A. Y. et al. Adapting the p300-based brain-computer interface for gaming: A review. *IEEE Transactions on Computational Intelligence and AI in Games*, v. 5, n. 2, p. 141 – 149, 2013.
- 5 LI, M. et al. Brain-computer interface speller based on steady-state visual evoked potential: A review focusing on the stimulus paradigm and performance. *Brain Sciences*, v. 11, n. 4, 2021.
- 6 CHEN, X. et al. Filter bank canonical correlation analysis for implementing a high-speed ssvep-based brain-computer interface. *Journal of Neural Engineering*, v. 12, n. 4, p. 046008, 2015.
- 7 ALBAHRI, A. et al. A systematic review of using deep learning technology in the steady-state visually evoked potential-based brain-computer interface applications: Current trends and future trust methodology. *International Journal of Telemedicine and Applications*, 2023.
- 8 MOGHADAM, M. A.; MALEKI, A. Fatigue factors and fatigue indices in ssvep-based brain-computer interfaces: a systematic review and meta-analysis. *Frontiers in Human Neuroscience*, v. 17, 2023.
- 9 REZEIKA, A. et al. Brain-computer interface spellers: A review. *Brain Sciences*, 2018.
- 10 KUNDU, S.; ARI, S. Brain-computer interface speller system for alternative communication: A review. *IRBM*, v. 43, n. 4, p. 317–324, 2022.
- 11 LIN, Z. et al. Frequency recognition based on canonical correlation analysis for ssvep-based bcis. *IEEE Transactions on Biomedical Engineering*, v. 54, n. 6, p. 1172–1176, 2007.
- 12 BIN, G. et al. An online multi-channel ssvep-based brain-computer interface using a canonical correlation analysis method. *Journal of Neural Engineering*, v. 6, n. 4, p. 046002, 2009.
- 13 GU, M. et al. An open dataset for human ssveps in the frequency range of 1-60hz. *Scientific Data*, v. 11, n. 1, 2024.
- 14 WOLPAW, J. R. et al. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, v. 113, n. 6, p. 767–791, 2002.

- 15 ELASHMAWI, W. H. et al. A comprehensive review on brain–computer interface (bci)-based machine and deep learning algorithms for stroke rehabilitation. *Applied Sciences (Switzerland)*, v. 14, n. 14, 2024.
- 16 FARIA, G. et al. Analyzing data augmentation methods for convolutional neural network-based brain-computer interfaces. In: *Proceedings of the International Joint Conference on Neural Networks*. [S.l.: s.n.], 2022.
- 17 SOUZA, G. H. de et al. Eeg data for motor imagery brain-computer interface using low-cost equipment. *Latin American Data in Science*, 2023.
- 18 ANITHA, T. et al. Brain-computer interface for persons with motor disabilities - a review. *Open Biomedical Engineering Journal*, v. 13, p. 127 – 133, 2019.
- 19 PARAFITA, R. et al. A spacecraft game controlled with a brain-computer interface using ssvep with phase tagging. In: *SeGAH 2013 - Proceedings of the 2013 ACM SIGGRAPH Symposium on Video Games*. [S.l.]: ACM, 2013. p. 21–28.
- 20 PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.