

Impacto da Taxa de Amostragem em Redes Neurais Convolucionais para BCIs baseadas em SSVEP

Alan Floriano
IFPR, Telêmaco Borba - PR, Brasil
alan.floriano@ifpr.edu.br

Erich Lacerda Malinowski
IFPR, Telêmaco Borba - PR, Brasil
erich.malinowski@ifpr.edu.br

Jair da Silva Peixe Filho
IFPR, Telêmaco Borba - PR, Brasil
jair.peixe@ifpr.edu.br

Gregory Vinícius Conon Figueiredo
IFPR, Telêmaco Borba - PR, Brasil
gregory.figueiredo@ifpr.edu.br

Paulo Ricardo de Souza Silva
IFPR, Telêmaco Borba - PR, Brasil
paulo.silva@ifpr.edu.br

Jailton Junior de Sousa Coelho
IFPR, Telêmaco Borba - PR, Brasil
jailton.coelho@ifpr.edu.br

Resumo—Brain-Computer Interfaces (BCIs) based on Steady-State Visual Evoked Potentials (SSVEPs) have shown great potential for applications that assist in communication and device control for individuals with motor impairments. Recently, Convolutional Neural Networks (CNNs) have significantly improved the accuracy of SSVEP detection, enhancing real-time interaction in BCI systems. An important factor that can influence signal processing in a BCI is the sampling rate, which impacts both signal resolution and computational efficiency. This study investigates the impact of different sampling rates on the CNN approach for SSVEP-based BCIs. The well-established compact EEGNet architecture was employed to evaluate three sampling rates: 256, 128, and 64 Hz. The analysis was conducted using an EEG dataset containing 12 visual stimuli, selected from a frequency range commonly employed in BCI systems (9.25 to 14.75 Hz, step size of 0.5 Hz). Results indicate that a 64 Hz sampling rate provides a significant reduction in computational cost and memory usage, while maintaining classification accuracy. These findings demonstrate that the optimal choice of sampling rate can make the CNN more efficient, providing valuable insights into the design of more optimized SSVEP-based BCIs for practical applications.

Keywords—BCI; SSVEP; Sampling Rate.

Resumo—Interfaces Cérebro-Computador (BCIs) baseadas em Potenciais Evocados Visuais de Regime Permanente (SSVEPs) têm mostrado grande potencial para aplicações que auxiliam na comunicação e controle de dispositivos para indivíduos com deficiências motoras. Recentemente, Redes Neurais Convolucionais (CNNs) melhoraram significativamente a precisão da detecção de SSVEPs, aprimorando a interação em tempo real nos sistemas BCI. Um fator importante que pode influenciar o processamento de sinais em uma BCI é a taxa de amostragem, que impacta tanto a resolução do sinal quanto a eficiência computacional. Este estudo investiga o impacto de diferentes taxas de amostragem na abordagem CNN para BCIs baseadas em SSVEPs. A arquitetura compacta EEGNet, bem estabelecida, foi utilizada para avaliar três taxas de amostragem: 256, 128 e 64 Hz. A análise foi conduzida utilizando um conjunto de dados EEG contendo 12 estímulos visuais, selecionados de uma faixa de frequências comumente empregada em sistemas BCI (9,25 a 14,75 Hz, com um passo de 0,5 Hz). Os resultados indicam que uma taxa de

amostragem de 64 Hz proporciona uma redução significativa no custo computacional e no uso de memória, enquanto mantém a acurácia da classificação. Esses achados demonstram que a escolha ótima da taxa de amostragem pode tornar a CNN mais eficiente, fornecendo insights valiosos para o design de BCIs baseadas em SSVEPs mais otimizadas para aplicações práticas.

Palavras-chave—ICC; SSVEP; Frequência de Amostragem.

I. INTRODUÇÃO

Potenciais Evocados Visuais de Regime Permanente (SSVEPs) são respostas cerebrais geradas por estímulos visuais que piscam em frequências específicas [1], [2]. Esses sinais, registrados via EEG, apresentam componentes oscilatórios na frequência do estímulo e/ou suas harmônicas [3], [4]. Devido à sua consistência entre indivíduos [5], [6], os SSVEPs são amplamente utilizados em Interfaces Cérebro-Computador (BCIs) para comunicação em tempo real [7]. A Figura 1 mostra uma BCI baseada em SSVEP.




Figura 1. Diagrama de uma BCI baseada em SSVEP: 1) O sujeito observa um estímulo piscando na frequência f_A . 2) Os sinais EEG são registrados. 3) As características, como picos em f_A e harmônicas, são extraídas. 4) As características são classificadas e convertidas em comandos.

Nos últimos anos, os avanços tecnológicos e melhorias nas técnicas de processamento de sinais facilitaram a exploração de aplicações baseadas em BCI utilizando SSVEPs, variando desde o controle de dispositivos assistivos até sistemas de realidade virtual. Um dos principais desenvolvimentos na análise de sinais SSVEP é a aplicação de Redes Neurais Convolucionais (CNNs) [8], [9]. Essas redes atraíram atenção devido à sua capacidade de aprender automaticamente características relevantes a partir de dados brutos de EEG, incluindo padrões espaciais e temporais nos sinais, tornando-as particularmente eficazes em sistemas BCI [10], [11].

Outro fator importante na análise do processamento de sinais é a taxa de amostragem. Taxas de amostragem mais altas oferecem maior resolução temporal e informações de sinal mais detalhadas, mas também aumentam as exigências computacionais, como o processamento de dados e o armazenamento. A Figura 2 mostra como a frequência de amostragem afeta a representação do sinal.




Figura 2. Sinal contínuo e sua representação com diferentes frequências de amostragem.

De acordo com o Teorema de Nyquist-Shannon, a taxa de amostragem deve ser pelo menos o dobro da maior frequência presente no sinal para evitar *aliasing* e garantir a reconstrução precisa do sinal [12]. No caso das BCIs baseadas em SSVEPs, a taxa de amostragem deve ser superior ao dobro da maior frequência usada para estímulos visuais, a fim de capturar com precisão a resposta elétrica do cérebro [13], [14]. Por outro lado, usar uma taxa de amostragem abaixo da taxa de Nyquist pode levar ao *aliasing*, distorcendo o sinal SSVEP e, potencialmente, comprometendo sua detecção. Portanto, a escolha da taxa de amostragem é particularmente importante em sistemas BCI em tempo real, pois pode influenciar vários fatores, como

uso de memória, tempo de inferência e treinamento para CNNs, e precisão de classificação.

Embora as CNNs sejam amplamente utilizadas para detecção de SSVEPs, o efeito da variação da taxa de amostragem sobre suas propriedades não foi amplamente estudado. Este estudo visa explorar como diferentes taxas de amostragem afetam o comportamento das CNNs na detecção de SSVEPs. O artigo continua com uma explicação dos materiais e métodos utilizados no desenvolvimento e avaliação do sistema. Em seguida, apresenta e discute alguns pontos-chave dos resultados.

II. MATERIAIS E MÉTODOS

A. Conjunto de Dados e Pré-processamento de Sinais

O conjunto de dados utilizado foi obtido a partir de um experimento BCI offline envolvendo 10 participantes saudáveis, conforme descrito em [15]. Os participantes sentaram-se a 60 cm de um monitor LCD de 27 polegadas (taxa de atualização de 60 Hz, resolução de 1280 × 800) em uma sala pouco iluminada. Eles visualizaram 12 estímulos piscando organizados em uma matriz de 4×3. As frequências de estimulação foram de 9,25 Hz a 14,75 Hz (com passo de 0,5 Hz) e apresentadas para cada estímulo em 4 segundos. Cada participante executou três sessões de treinamento e três sessões de teste. Para este estudo, as sessões de teste dos participantes foram utilizadas para avaliação da classificação. O conjunto de dados é composto por $n = 10$ participantes com 12 frequências de estímulos para cada um. Isso resultou em 180 amostras totais para o modelo.




Figura 3. Posições dos canais de EEG utilizados no conjunto de dados.

Os sinais de EEG foram adquiridos por meio de oito eletrodos ativos posicionados sobre as regiões occipital e parietal (Figura 3), onde as respostas SSVEP apresentaram as maiores amplitudes [16]. Para minimizar interferências, os dados foram filtrados em banda passante entre 9 e 30 Hz utilizando um filtro Butterworth, removendo componentes fora da faixa de frequência de interesse. O sinal original, armazenado a uma

taxa de 256 Hz, foi posteriormente reamostrado para 128 Hz e 64 Hz, permitindo a análise do impacto da taxa de amostragem no desempenho da CNN. Além disso, cada época de 4 segundos foi segmentada em janelas de 1 segundo para avaliação pela rede neural, conforme descrito em [17].

B. Arquitetura da CNN

Este estudo utilizou a arquitetura compacta EEGNet para classificação de SSVEP [17]. O modelo foi escolhido devido à sua eficácia bem estabelecida em aplicações de BCI, oferecendo um equilíbrio entre precisão de classificação e baixa complexidade computacional [8]. Esta rede neural processa dados EEG no domínio do tempo por meio de uma série de camadas convolucionais que extraem características temporais e espaciais, seguidas por normalização e pooling para aumentar a eficiência do aprendizado e reduzir o sobreajuste (*overfitting*). Além disso, o modelo utiliza convoluções separáveis para minimizar a complexidade computacional, mantendo a capacidade de capturar padrões relevantes. A arquitetura completa da rede é apresentada na Figura 4.

O modelo foi configurado de forma semelhante ao trabalho de [17], com $F_1 = 96$ e $F_2 = 96$ definindo o número de filtros convolucionais, e $D = 1$ como o multiplicador de profundidade para convoluções separáveis. O tamanho da entrada da rede foi definido como $Channels \times Samples$, onde $Channels$ representa o número de canais EEG e $Samples$ refere-se ao número de pontos de tempo na janela de entrada. Para uma janela de 1 segundo com uma frequência de amostragem de 256 Hz, tanto $Samples$ quanto o $kernel\ length$ foram definidos como 256. Da mesma forma, para outras taxas de amostragem, como 128 Hz ou 64 Hz, o número de amostras e o comprimento do kernel foram ajustados de acordo. O modelo foi implementado utilizando os frameworks TensorFlow e Keras.

C. Treinamento do Modelo

O modelo CNN foi avaliado utilizando um procedimento de validação cruzada *leave-one-subject-out*. Neste arranjo, os dados de nove participantes foram usados para o treinamento, enquanto os dados do décimo participante foram reservados para o teste. Isso garantiu que os modelos fossem treinados sem utilizar qualquer dado do participante de teste, permitindo uma avaliação imparcial de suas capacidades de generalização. O processo foi repetido de forma iterativa até que os dados de cada participante tivessem sido usados como conjunto de teste uma vez. Esta abordagem avaliou o desempenho do modelo em um contexto independente do usuário, eliminando a necessidade de calibração individual.

O treinamento foi realizado com uma taxa de aprendizado de 0,001 e um tamanho de lote de 32. O otimizador Adam foi utilizado para a otimização, e a função de entropia cruzada foi




Figura 4. Arquitetura compacta da EEGNet.

utilizada como métrica de perda. Para prevenir o *overfitting*, foi aplicada a técnica de early stopping. O treinamento foi limitado a um máximo de 100 épocas, mas foi interrompido antecipadamente caso a perda de validação não melhorasse após 15 épocas consecutivas. Os pesos do modelo correspondentes à época com a menor perda de validação foram salvos e usados para o teste final, garantindo um desempenho ideal nos dados de teste.

D. Métricas de Avaliação

O desempenho do sistema foi avaliado utilizando as seguintes métricas: Acurácia, Taxa de Transferência de Informação (ITR) [1], Uso de Memória e Operações de Ponto Flutuante por




Figura 5. Acurácia e ITR para as taxas de amostragem avaliadas.




Figura 6. Tamanho da memória e FLOPs para as taxas de amostragem avaliadas.

segundo (FLOPs) [18]. Essas métricas fornecem uma avaliação equilibrada tanto do desempenho do BCI quanto da eficiência computacional.

- Acurácia representa a proporção de tentativas classificadas corretamente, calculada como a razão entre o número de classificações corretas e o número total de tentativas.
- ITR mede a quantidade de informação transmitida por

unidade de tempo, calculada como:

$$\text{ITR (bits/min)} = \frac{60}{T} \left[\log_2(N) + P \log_2(P) + (1 - P) \log_2 \left(\frac{1 - P}{N - 1} \right) \right]_{(1)}$$

onde T é a duração da tentativa (em segundos), N é o número de alvos, e P é a precisão da classificação em formato decimal.

- O Uso de Memória quantifica a quantidade de memória necessária durante o treinamento e a inferência.
- FLOPs indicam a complexidade computacional do sis-

tema, medindo o número de operações de ponto flutuante necessárias para uma única passagem para frente através da rede neural.

III. RESULTADOS

A Figura 5 apresenta os resultados de acurácia média e ITR obtidos com as três taxas de amostragem. Observa-se que a acurácia permanece estável entre as diferentes configurações, com variações marginais inferiores a 2% entre 256 Hz e 64 Hz. A ITR também seguiu a mesma tendência, mantendo valores próximos mesmo com o uso de dados menos densos. Isso indica que, do ponto de vista da eficiência informacional, a taxa mais baixa ainda é suficiente para sustentar uma comunicação viável em tempo real, o que é essencial em aplicações práticas de BCI.

Já a Figura 6 apresenta os dados relativos ao uso de memória e à quantidade de operações de ponto flutuante exigidas para uma inferência completa no modelo. Nesse caso, as diferenças entre as taxas de amostragem foram mais expressivas. A taxa de 64 Hz resultou em uma economia significativa de memória. O mesmo padrão foi observado nos FLOPs, refletindo diretamente a diminuição do número de amostras processadas por janela de tempo. Essa queda substancial no custo computacional reforça a viabilidade da utilização de sistemas com menor capacidade de hardware, sem prejuízo na performance de classificação.

Esses resultados confirmam que é possível reduzir o volume de dados de entrada para a CNN sem afetar de forma significativa a acurácia ou a eficiência da comunicação, ao mesmo tempo em que se obtém ganhos substanciais em termos de economia de recursos computacionais. Tal equilíbrio é altamente desejável em sistemas embarcados, vestíveis ou em aplicações contínuas, onde o uso eficiente de memória e energia é determinante para a autonomia do sistema.

IV. DISCUSSÃO

Os resultados obtidos neste estudo reforçam a importância da escolha apropriada da taxa de amostragem em sistemas BCI baseados em SSVEP, especialmente quando integrados a arquiteturas de redes neurais convolucionais. A análise comparativa entre as taxas de 256 Hz, 128 Hz e 64 Hz demonstrou que é possível reduzir significativamente o custo computacional do sistema sem comprometer a acurácia da classificação. Essa constatação é particularmente relevante para aplicações que exigem operação em tempo real, nas quais a eficiência computacional constitui um fator determinante para a viabilidade prática do sistema.

A taxa de 64 Hz apresentou o melhor equilíbrio entre desempenho e consumo de recursos, resultando em menor uso de memória e redução expressiva nas operações de ponto flutuante durante a inferência. Esse comportamento decorre do fato de que taxas de amostragem mais baixas implicam em

menor volume de dados a serem processados pela rede. Essa redução impacta diretamente o tempo de execução, a latência do sistema e o consumo de energia, aspectos fundamentais em cenários com restrição de hardware ou em aplicações móveis e vestíveis, nas quais a autonomia energética é essencial.

O desempenho consistente entre as diferentes taxas de amostragem sugere que a quantidade adicional de informação potencialmente capturada em frequências mais altas de amostragem não foi determinante para a acurácia do classificador neste contexto. Esse achado está em alinhamento com a literatura que discute a robustez dos SSVEPs como paradigma de BCI, mesmo utilizando menores frequências de amostragem [19]–[21]. No entanto, essa conclusão deve ser ponderada com base nas características individuais dos usuários. Assim, a generalização dos resultados requer cautela e análise individualizada em estudos futuros.

Observa-se também uma convergência com estudos realizados em outros domínios. Saha et al. [22] investigaram a redução da taxa de aquisição de dados em modelos de aprendizado de máquina voltados à classificação de séries temporais para o reconhecimento de atividades humanas. Os autores demonstraram que a diminuição da taxa de amostragem resultou em significativa economia de RAM, energia e latência, sem prejuízo na acurácia dos modelos. Assim como nos resultados observados neste estudo com sinais EEG, esses achados reforçam a viabilidade de estratégias de otimização baseadas na redução da taxa de amostragem em sistemas com recursos computacionais limitados.

Por fim, destaca-se o potencial impacto desses resultados na engenharia de sistemas BCI portáteis. A possibilidade de executar uma CNN eficiente com dados amostrados a 64 Hz amplia substancialmente o escopo de aplicações práticas. Isso viabiliza a integração de BCIs a dispositivos de baixo custo, como microcontroladores, possibilitando soluções de alta mobilidade, acessibilidade e baixo consumo energético. Tais avanços contribuem para a ampliação do uso de BCIs para além de ambientes clínicos ou laboratoriais, promovendo maior inclusão e qualidade de vida para pessoas com deficiências motoras.

V. LIMITAÇÕES E TRABALHOS FUTUROS

Embora os resultados do presente estudo sejam promissores, é necessário destacar algumas limitações que podem influenciar a interpretação e a aplicabilidade dos achados. Em primeiro lugar, a avaliação realizada utilizou dados de experimentos conduzidos em ambiente controlado, com iluminação reduzida, ausência de ruídos elétricos externos e estímulos apresentados em condições ideais. Em aplicações no mundo real, como em ambientes domésticos ou públicos, a presença de interferências eletromagnéticas e variações de luminosidade pode impactar

negativamente a qualidade do sinal EEG. A eficácia do sistema com taxas de amostragem reduzidas nesses cenários mais adversos ainda precisa ser rigorosamente validada.

Além disso, embora o modelo tenha sido avaliado utilizando validação cruzada *leave-one-subject-out*, o número de participantes do experimento ($n = 10$) ainda é relativamente limitado. É recomendável, portanto, que estudos futuros explorem populações mais heterogêneas, incluindo diferentes faixas etárias, condições neurológicas e níveis de familiaridade com BCIs. Essa ampliação poderá revelar variações interindividuais significativas na resposta aos estímulos e na adaptação às taxas de amostragem mais baixas.

VI. CONCLUSÃO

Este estudo investigou o impacto da taxa de amostragem na eficiência e desempenho de redes neurais convolucionais aplicadas à classificação de sinais SSVEP em sistemas BCI. Utilizando a arquitetura EEGNet e um conjunto de dados com múltiplos estímulos visuais, foram avaliadas três taxas de amostragem (256 Hz, 128 Hz e 64 Hz), considerando métricas de acurácia, taxa de transferência de informação, uso de memória e custo computacional.

Os resultados evidenciaram que a taxa de amostragem exerce influência direta na complexidade do sistema, mas não compromete significativamente a performance de classificação quando reduzida até 64 Hz. Essa configuração apresentou o melhor compromisso entre precisão e eficiência computacional, permitindo a redução expressiva no uso de memória e no número de operações de ponto flutuante, sem perdas relevantes em termos de acurácia e ITR. Essa constatação reforça o potencial de uso de BCIs com CNNs em dispositivos de baixo custo, portáteis ou embarcados, ampliando sua viabilidade para aplicações práticas fora do ambiente laboratorial. Futuramente, pretende-se expandir esta análise para diferentes arquiteturas de rede, populações mais heterogêneas e ambientes operacionais não controlados

REFERÊNCIAS

- [1] R. Abiri, S. Borhani, E. W. Sellers, Y. Jiang, and X. Zhao, "A comprehensive review of eeg-based brain-computer interface paradigms," *Journal of neural engineering*, vol. 16, no. 1, p. 011001, 2019.
- [2] A. Floriano, D. Delisle-Rodriguez, P. F. Diez, and T. F. Bastos-Filho, "Assessment of high-frequency steady-state visual evoked potentials from below-the-hairline areas for a brain-computer interface based on depth-of-field," *Computer methods and programs in biomedicine*, vol. 184, p. 105271, 2020.
- [3] A. Floriano, V. L. Carmona, P. F. Diez, and T. F. Bastos-Filho, "A study of ssvep from below-the-hairline areas in low-, medium-, and high-frequency ranges," *Research on Biomedical Engineering*, vol. 35, pp. 71–76, 2019.
- [4] X. Gu, Z. Cao, A. Jolfaei, P. Xu, D. Wu, T.-P. Jung, and C.-T. Lin, "Eeg-based brain-computer interfaces (bcis): A survey of recent studies on signal sensing technologies and computational intelligence approaches and their applications," *IEEE/ACM transactions on computational biology and bioinformatics*, vol. 18, no. 5, pp. 1645–1666, 2021.
- [5] B. Allison, T. Luth, D. Valbuena, A. Teymourian, I. Volosyak, and A. Graser, "Bci demographics: How many (and what kinds of) people can use an ssvep bci?" *IEEE transactions on neural systems and rehabilitation engineering*, vol. 18, no. 2, pp. 107–116, 2010.
- [6] C. Guger, B. Z. Allison, B. Großwindhager, R. Prückl, C. Hintermüller, C. Kapeller, M. Bruckner, G. Krausz, and G. Edlinger, "How many people could use an ssvep bci?" *Frontiers in neuroscience*, vol. 6, p. 169, 2012.
- [7] H. Rivera-Flor, D. Gurve, A. Floriano, D. Delisle-Rodriguez, R. Mello, and T. Bastos-Filho, "Cca-based compressive sensing for ssvep-based brain-computer interfaces to command a robotic wheelchair," *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1–10, 2022.
- [8] Z. Al-Qaysi, A. Albahri, M. Ahmed, R. A. Hamid, M. Alsalem, O. Albahri, A. Alamoodi, R. Z. Homod, G. G. Shaye, and A. M. Duhaim, "A comprehensive review of deep learning power in steady-state visual evoked potentials," *Neural Computing and Applications*, pp. 1–24, 2024.
- [9] B. J. Edelman, S. Zhang, G. Schalk, P. Brunner, G. Müller-Putz, C. Guan, and B. He, "Non-invasive brain-computer interfaces: State of the art and trends," *IEEE Reviews in Biomedical Engineering*, 2024.
- [10] A. Craik, Y. He, and J. L. Contreras-Vidal, "Deep learning for electroencephalogram (eeg) classification tasks: a review," *Journal of neural engineering*, vol. 16, no. 3, p. 031001, 2019.
- [11] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, "Deep learning-based electroencephalography analysis: a systematic review," *Journal of neural engineering*, vol. 16, no. 5, p. 051001, 2019.
- [12] A. Akan and L. F. Chaparro, *Signals and systems using MATLAB®*. Elsevier, 2024.
- [13] M. Teplan *et al.*, "Fundamentals of eeg measurement," *Measurement science review*, vol. 2, no. 2, pp. 1–11, 2002.
- [14] M. Weiergräber, A. Papazoglou, K. Broich, and R. Müller, "Sampling rate, signal bandwidth and related pitfalls in eeg analysis," *Journal of neuroscience methods*, vol. 268, pp. 53–55, 2016.
- [15] M. Nakanishi, Y. Wang, Y.-T. Wang, and T.-P. Jung, "A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials," *PLoS one*, vol. 10, no. 10, p. e0140703, 2015.
- [16] A. Floriano, P. F. Diez, and T. Freire Bastos-Filho, "Evaluating the influence of chromatic and luminance stimuli on ssveps from behind-the-ears and occipital areas," *Sensors*, vol. 18, no. 2, p. 615, 2018.
- [17] N. Waytowich, V. J. Lawhern, J. O. Garcia, J. Cummings, J. Faller, P. Sajda, and J. M. Vettel, "Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials," *Journal of neural engineering*, vol. 15, no. 6, p. 066031, 2018.
- [18] G. Menghani, "Efficient deep learning: A survey on making deep learning models smaller, faster, and better," *ACM Computing Surveys*, vol. 55, no. 12, pp. 1–37, 2023.
- [19] Y. Liu, X. Jiang, T. Cao, F. Wan, P. U. Mak, P.-I. Mak, and M. I. Vai, "Implementation of ssvep based bci with emotiv epoc," in *2012 IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS) Proceedings*. IEEE, 2012, pp. 34–37.
- [20] Y.-P. Lin, Y. Wang, and T.-P. Jung, "Assessing the feasibility of online ssvep decoding in human walking using a consumer eeg headset," *Journal of neuroengineering and rehabilitation*, vol. 11, no. 1, p. 119, 2014.
- [21] B. Wittevrongel and M. M. Van Hulle, "Frequency-and phase encoded ssvep using spatiotemporal beamforming," *PLoS one*, vol. 11, no. 8, p. e0159988, 2016.
- [22] B. Saha, R. Samanta, S. K. Ghosh, and R. B. Roy, "Efficiency redefined: Impact of reducing data acquisition rate for optimized tinyml in resource-constrained iot devices," in *2025 17th International Conference on Communication Systems and Networks (COMSNETS)*. IEEE, 2025, pp. 842–846.