

Investigação do Desempenho de Modelos de Acompanhamento Neural em Aplicações de Auxílio Auditivo Neuroassistido

Lucian S. Schiavon, José C. M. Bermudez e Márcio H. Costa

Resumo— Este trabalho investiga o impacto da redução do número de canais de eletroencefalograma no desempenho de modelos de classificação do tipo *match-mismatch*, utilizados em acompanhamento neural da fala. Foi avaliada uma arquitetura baseada em convoluções dilatadas, considerando diferentes números de canais e durações dos segmentos de entrada. Os resultados indicam queda de desempenho com a diminuição do número de canais, o que pode ser compensado pelo aumento da janela de observação. Incrementos estruturais ao modelo não compensaram a perda de desempenho. Os resultados obtidos evidenciam as limitações dos modelos apresentados na literatura para aplicação em aparelhos auditivos com controle neuroassistido.

Palavras-Chave— Acompanhamento neural, EEG, Aparelhos auditivos.

Abstract— This study investigates the impact of reducing the number of electroencephalogram channels on the performance of *match-mismatch* classification models used for neural speech tracking. A dilated convolution-based architecture was evaluated, considering different numbers of channel and input segment durations. The results indicate a decrease in performance with fewer channels, which can be mitigated by increasing the observation window. Structural enhancements to the model did not compensate for the performance loss. These findings highlight the limitations of current literature models for application in neuro-steered hearing aids.

Keywords— Neural tracking, EEG, hearing aids.

I. INTRODUÇÃO

O sistema auditivo humano possui a capacidade inerente de interpretar cenários acústicos complexos, direcionando a atenção para uma única fonte sonora em meio a múltiplos emissores e suprimindo os estímulos concorrentes. Essa faculdade é denominada efeito coquetel (*cocktail-party effect*) [1]. Para indivíduos com deficiência auditiva, contudo, essa capacidade pode ser substancialmente reduzida.

Apesar dos avanços em dispositivos de assistência auditiva, como aparelhos auditivos e implantes cocleares, que amplificam os sinais auditivos, a seleção acurada e o realce de uma fonte sonora alvo em ambientes acusticamente desafiadores ainda constituem um desafio em aberto na literatura.

Estudos recentes na área de neurociência têm demonstrado que é possível decodificar o foco da atenção auditiva a partir de sinais neurais, como aqueles obtidos por eletroencefalografia (EEG), em ambientes com múltiplas fontes sonoras [2]. Os métodos desenvolvidos para esse propósito são denominados

Lucian S. Schiavon, José C. M. Bermudez e Márcio H. Costa, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis-SC, E-mails: lucianschiavon@gmail.com; j.bermudez@ieee.org; costa@eel.ufsc.br.

de decodificação de atenção auditiva (AAD – *Auditory Attention Decoding*) [3].

Em complemento aos estudos que envolvem múltiplas fontes sonoras, abordagens baseadas em uma única fonte de fala também têm sido exploradas. Essa linha de estudo busca quantificar o alinhamento temporal entre o estímulo auditivo e a resposta cerebral, fenômeno conhecido como acompanhamento neural (*neural tracking*) [4]. O acompanhamento neural da fala apresenta aplicações tanto na modelagem dos mecanismos de processamento auditivo no cérebro, quanto como medida objetiva da capacidade de detecção, audição ou compreensão da fala.

Nesse contexto, modelos computacionais são utilizados com dois objetivos principais: prever o sinal de EEG a partir de características extraídas da fala (*forward modeling*) ou reconstruir essas características a partir do EEG (*backward modeling*). A correlação entre os sinais previstos (ou reconstruídos) e suas respectivas referências (características da fala ou EEG) é comumente adotada como métrica de desempenho [5]. Além da correlação, outros métodos também têm sido utilizados para medir o acompanhamento neural, como as tarefas de classificação do tipo *match-mismatch* (MM) [6]. Esse método consiste em classificar a sincronização (*match*) ou dessincronização (*mismatch*) de um segmento de EEG com um segmento da fala. A acurácia obtida nessa tarefa pode ser utilizada como uma métrica alternativa para quantificar o acompanhamento neural.

Diversos modelos têm sido propostos na literatura para abordar o problema de MM, incluindo arquiteturas baseadas em redes neurais convolucionais (CNNs) [7], redes do tipo *Long Short-Term Memory* (LSTM) [8] e redes convolucionais dilatadas (*dilated CNNs*) [9]. Além das estruturas propostas, também têm sido exploradas diferentes representações extraídas do sinal de fala como entrada para os classificadores, tais como a envoltória temporal, o espectrograma [10] e a frequência fundamental [11], bem como características de ordem superior, incluindo informações lexicais e linguísticas [7].

Esses estudos têm impulsionado o interesse no conceito de dispositivos auditivos neuroassistidos (*neuro-steered hearing aids*) [12]. Informações neurais correlacionadas à fala apresentam uma oportunidade para a otimização de métodos avançados de redução de ruído ou de realce da fala guiada pelo estado de atenção auditiva ou de esforço de escuta do usuário.

No desenvolvimento de aparelhos auditivos com controle neuroassistido, é fundamental compreender a relação entre o estímulo de fala e o sinal de EEG de um ouvinte atento ao sinal auditivo. No entanto, grande parte dos estudos na área ainda desconsidera aspectos cruciais para a viabilidade em aplicações

práticas. Por exemplo, muitos trabalhos utilizam sinais de EEG adquiridos por meio de sistemas com 64 canais distribuídos ao longo do escalpo, o que não é factível em um cenário de uso cotidiano. Em aplicações reais, espera-se a utilização de um número reduzido de eletrodos, preferencialmente posicionados próximos à orelha do usuário. Uma das possíveis soluções nesse contexto é o uso do *Ear-EEG*, uma tecnologia que permite a aquisição de sinais neurais de forma mais discreta e compatível com dispositivos auditivos portáteis [13].

Este trabalho apresenta um estudo sobre o impacto da redução no número de canais de EEG utilizados como entrada para classificadores *match-mismatch*. O objetivo é avaliar se modelos de classificação amplamente utilizados na literatura mantêm desempenho satisfatório sob restrições realistas de aquisição, considerando aplicações em aparelhos auditivos com controle neuroassistido. Para tal, foi analisado o modelo baseado em redes convolucionais dilatadas proposto em [9]. A acurácia de classificação foi avaliada a partir da apresentação do EEG e das envoltórias de dois sinais de fala (um sincronizado e outro dessincronizado) ao classificador, considerando diferentes configurações e número de canais.

O trabalho foi organizado da seguinte forma: A Seção II apresenta uma discussão do problema *match-mismatch*. A Seção III especifica a arquitetura do modelo de classificação. A Seção IV detalha a metodologia utilizada, além do banco de dados empregado. A Seção V apresenta os resultados obtidos, os quais são discutidos na Seção VI. As conclusões sobre o trabalho estão na Seção VII.

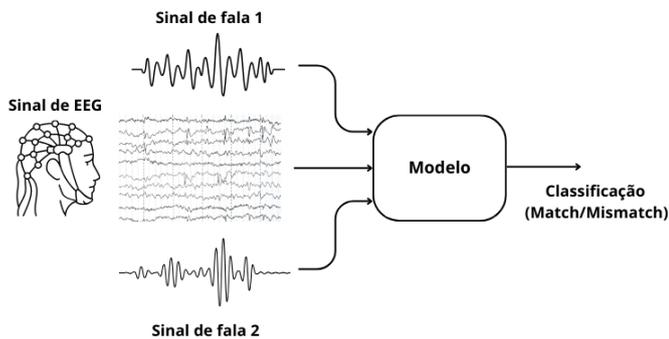


Fig. 1. Diagrama do problema de classificação *match-mismatch*.

II. PROBLEMA DE CLASSIFICAÇÃO *MATCH-MISMATCH*

No problema de classificação *match-mismatch*, o modelo recebe três entradas: um segmento de EEG, um trecho de fala temporalmente alinhado com o EEG (*match*), e um segundo trecho de fala não alinhado (*mismatch*). A tarefa do modelo é identificar qual dos dois segmentos de fala está associado ao sinal de EEG apresentado. A acurácia de classificação é utilizada como métrica de acompanhamento neural do modelo [4]. A Fig. 1 ilustra o problema.

Com base nos experimentos descritos em [4], o processo de treinamento do modelo deve observar orientações específicas que favoreçam a generalização da relação entre os segmentos dos sinais de EEG e os segmentos correspondentes de fala. Uma dessas orientações consiste em selecionar segmentos de fala não alinhados temporalmente com o sinal de EEG (*mismatch*) que estejam próximos, no tempo, aos segmentos

alinhados (*match*), ilustrado na Fig. 2. Essa proximidade aumenta a dificuldade da tarefa de classificação, exigindo maior capacidade discriminativa do modelo. Tipicamente, adota-se um intervalo de 1 segundo entre os segmentos de fala considerados [14].

Adicionalmente, cada segmento do sinal de fala deve ser utilizado uma vez como *match* e outra como *mismatch* durante o treinamento. Essa estratégia impede que o modelo aprenda associações indevidas entre características específicas do sinal de fala e os rótulos de classe, sem considerar efetivamente a informação proveniente do sinal de EEG.

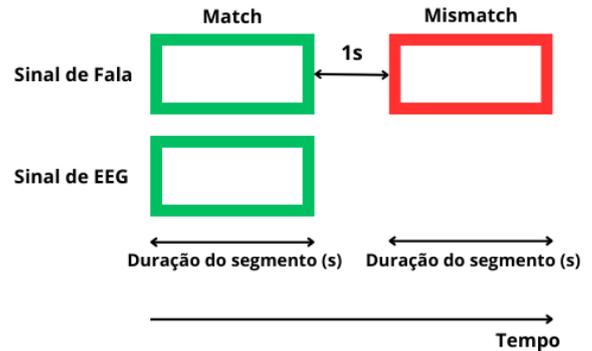


Fig. 2. Associação do segmento do sinal de EEG com os segmentos do sinal de fala no problema de classificação *match-mismatch*.

III. ARQUITETURA DO MODELO

A Fig. 3 apresenta a arquitetura do modelo de classificação proposto em [9], a qual serviu como base para o desenvolvimento de diversas abordagens subsequentes aplicadas ao problema de MM [10] [15] [16].

Primeiramente, os sinais dos canais de EEG são combinados e redimensionados por meio de uma camada de convolução espacial unidimensional com 8 filtros e tamanho de kernel igual a K_s . Em seguida, são aplicadas N camadas convolucionais dilatadas, com tamanho de kernel K_d e 16 filtros, tanto aos segmentos do sinal de EEG quanto aos segmentos dos sinais de fala.

Em uma convolução dilatada, os elementos do kernel não são adjacentes entre si, havendo espaçamentos regulares entre eles. Essa característica permite ampliar o campo receptivo de cada filtro sem a necessidade de aumentar o número de parâmetros do modelo [9]. O fator de dilatação D é um hiperparâmetro que controla o espaçamento entre os elementos do kernel, influenciando a extensão do campo de recepção da convolução.

Após cada camada convolucional, é empregada uma função de ativação do tipo ReLU (*Rectified Linear Unit*), adicionando não linearidade no processamento. As duas versões do segmento do sinal de fala (referente aos casos *match* e *mismatch*) compartilham os mesmos pesos nas camadas convolucionais.

Após as transformações não lineares, o sinal de EEG é comparado às duas versões do sinal de fala por meio da métrica de similaridade de cosseno, permitindo quantificar a correspondência entre os sinais. Por fim, os valores de

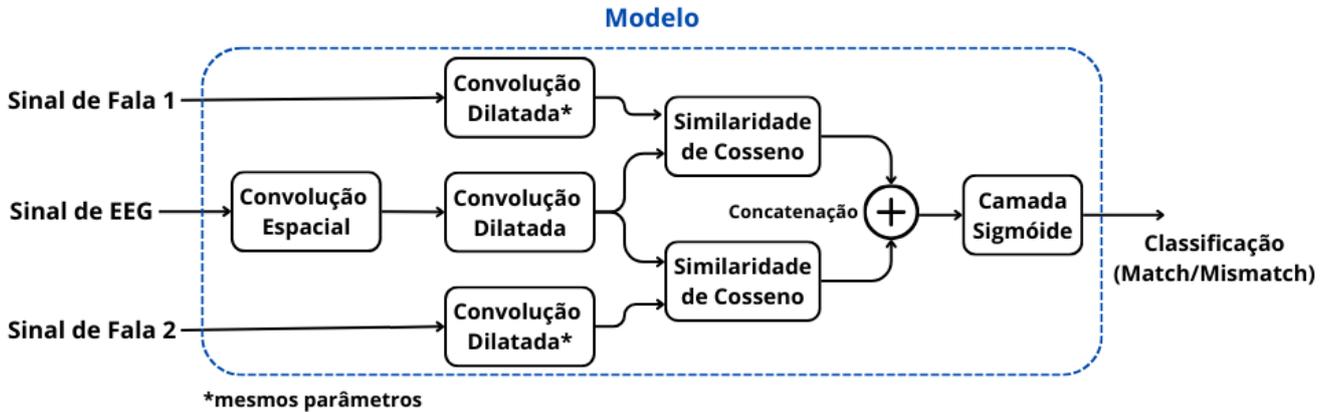


Fig. 3. Arquitetura do modelo de classificação utilizando redes convolucionais dilatadas.

similaridade obtidos são utilizados como entrada para um único neurônio com função de ativação sigmoide, o qual produz a predição referente ao segmento de fala correspondente ao sinal de EEG.

IV. METODOLOGIA

Neste trabalho, foi realizada uma avaliação de desempenho do modelo ilustrado na Fig. 3, no contexto do problema de *match-mismatch*. Além disso, investigou-se o impacto da redução do número de canais de EEG utilizados como entrada para o classificador, com o objetivo de analisar a robustez do modelo frente a um cenário mais realístico para aplicação em aparelhos auditivos.

Tanto os experimentos quanto a implementação do modelo foram conduzidos em linguagem *Python*, utilizando a biblioteca *TensorFlow-Keras*. Na sequência, são descritos o banco de dados empregado, os experimentos realizados e apresentados detalhes sobre a implementação e treinamento do modelo.

A. Banco de Dados

O conjunto de dados utilizado neste trabalho [17] é composto por sinais de EEG adquiridos de 85 adultos jovens, todos nativos do idioma holandês e com audição dentro dos padrões de normalidade. Durante o experimento, cada participante realizou entre 8 e 10 sessões, com duração aproximada de 15 minutos por sessão. A ordem de apresentação dos estímulos foi realizada de forma aleatória para cada indivíduo, com o objetivo de evitar vieses e promover maior diversidade na exposição aos estímulos.

Os estímulos auditivos consistiram em narrativas de um único locutor. Foram utilizados trechos de podcasts e audiolivros. O conjunto de dados disponibiliza tanto os estímulos de fala apresentados aos participantes quanto as respostas neurais correspondentes, registradas via EEG durante a escuta. No total, o banco contém 157 horas de dados paralelos, ou seja, pares sincronizados de estímulo de fala e resposta de EEG.

Os sinais de EEG foram adquiridos com uma frequência de amostragem de 8192 Hz, em uma cabine acústica com isolamento sonoro e blindagem eletromagnética, utilizando o sistema comercial *Biosemi ActiveTwo*, com 64 canais ativos. Os eletrodos de Ag/AgCl foram posicionados no escalpo de acordo com o sistema internacional 10-20 (Fig. 4).

B. Pré-processamento

Os sinais de EEG foram submetidos a um filtro Butterworth passa-altas de primeira ordem, com frequência de corte de 0,5 Hz. A fase foi equalizada por meio da utilização do filtro nas direções direta e reversa. Em seguida, os sinais foram reamostrados de 8192 para 1024 Hz. Os artefatos produzidos pelo piscar dos olhos foram atenuados utilizando um filtro de Wiener multicanal, conforme descrito em [18]. Após a remoção de artefatos, os sinais de EEG foram referenciados à média comum dos eletrodos. Por fim, os dados foram novamente reamostrados para 64 Hz, resultando em um sinal com banda passante de 0,5 a 32 Hz.

Os sinais de fala, originalmente amostrados a 48 kHz, foram processados por um banco de filtros do tipo *gammatone* com 28 bandas de saída, cobrindo a faixa de frequência de 50 Hz a 5 kHz. As saídas foram submetidas a um procedimento de retificação de onda completa e elevadas à potência de 0,6, com o objetivo de obter envoltórias comprimidas em cada banda. Em seguida, foi calculada a média, amostra a amostra, dessas envoltórias para gerar uma única forma de onda, a qual foi reamostrada para 64 Hz [19].

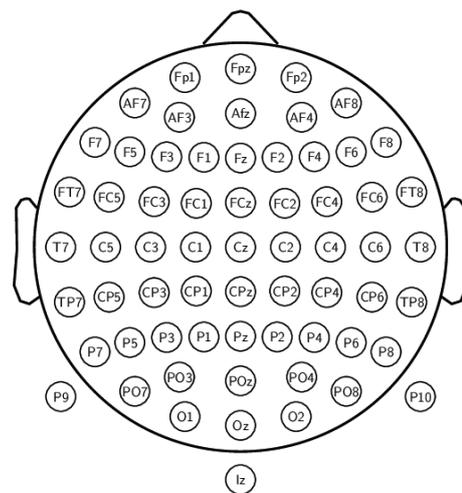


Fig. 4. Posicionamento dos 64 eletrodos de captação de EEG de acordo com o sistema internacional 10-20.

C. Implementação e Treinamento do Modelo

Os valores dos hiperparâmetros do modelo foram baseados nos experimentos realizados em [9].

Na camada de convolução espacial, foi utilizado um kernel de tamanho $K_s = 1$. Em sequência, foram utilizadas 3 camadas convolucionais dilatadas ($N = 3$), com kernel de tamanho $K_d = 3$ em cada uma delas. Diferentes fatores de dilatação foram utilizados em cada uma das camadas. A primeira camada utilizou $D_1 = 1$, a segunda camada $D_2 = 3$ e a terceira camada $D_3 = 9$.

O modelo foi treinado com o otimizador Adam e taxa de aprendizado igual a 0,001. A função de perda adotada foi a entropia cruzada binária (*binary cross-entropy*), definida por

$$L = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (1)$$

onde \hat{y} é a probabilidade da classe prevista e y é o rótulo da classe verdadeira. O treinamento foi realizado por até 40 épocas, com uso do critério de parada antecipada (*early stopping*) baseado na perda de validação, adotando-se um fator de paciência igual a 5.

Os modelos foram treinados com segmentos de entrada de 5 segundos, de forma independente aos participantes. Os dados foram separados em 80% para o conjunto de treinamento, 10% para o conjunto de validação e 10% para o de teste. Para a etapa de avaliação, foram consideradas durações dos segmentos de teste iguais a 1, 2, 4, 5, 10 e 20 segundos. Como o modelo treinado não impõe uma limitação fixa ao tamanho da entrada, foi possível utilizar o mesmo modelo para segmentos de diferentes durações na fase de teste.

D. Canais do EEG

O modelo proposto foi avaliado em quatro configurações distintas quanto ao número e à localização dos eletrodos: (i) utilização de todos os 64 canais disponíveis; (ii) utilização de 6 canais, sendo três localizados próximos à orelha esquerda (FT7, T7 e TP7) e três próximos à orelha direita (FT8, T8 e TP8); (iii) utilização de 4 canais (FT7, T7, FT8 e T8), excluindo TP7 e TP8 pois os canais apresentam menor influência na região temporal [17]; e (iv) utilização de apenas 2 canais (T7 e T8).

Para as configurações com 6 e 2 canais, foram conduzidos experimentos adicionais com o objetivo de compensar a perda de informação espacial por meio do aumento da capacidade do modelo de classificação. Especificamente, foram realizadas duas modificações estruturais. Na primeira, adicionou-se uma camada convolucional dilatada à arquitetura original, totalizando quatro camadas convolucionais, mantendo-se o mesmo tamanho de kernel previamente adotado ($K_s = 3$). Na segunda modificação, ampliou-se o número de filtros: na camada de convolução espacial, de 8 para 16; e nas camadas convolucionais dilatadas, de 16 para 32.

V. RESULTADOS

A Fig. 5 apresenta diagramas de caixa referentes à acurácia obtida no conjunto de teste, considerando diferentes durações de segmentos tanto da envoltória da fala quanto dos sinais de EEG utilizados na entrada do modelo. Cada cenário avaliado permite a comparação do desempenho do modelo em função da quantidade de canais de EEG empregados, abrangendo desde a

configuração com todos os canais disponíveis até o cenário mais restritivo, em que são utilizados apenas dois eletrodos - um posicionado sobre cada orelha (T7 e T8).

A Fig. 6 também mostra diagramas de caixa referentes à acurácia obtida no conjunto de teste, considerando diferentes durações de segmentos dos sinais utilizados na entrada do modelo. Neste caso, porém, são consideradas sete configurações distintas: (I) utilização dos 64 canais com a arquitetura original do modelo; (II) utilização de 6 canais com a arquitetura original; (III) utilização de 6 canais com a adição de uma camada convolucional dilatada; (IV) utilização de 6 canais com aumento do número de filtros em cada camada; (V) utilização de 2 canais com a arquitetura original; (VI) utilização de 2 canais com a adição de uma camada convolucional dilatada; e (VII) utilização de 2 canais com aumento do número de filtros em cada camada.

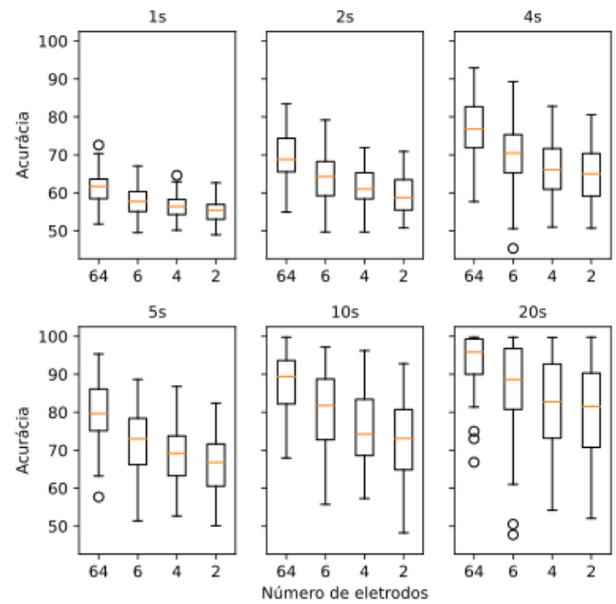


Fig. 5. Acurácia para diferentes durações de segmentos dos sinais de entrada do modelo em função da quantidade de canais de EEG empregados.

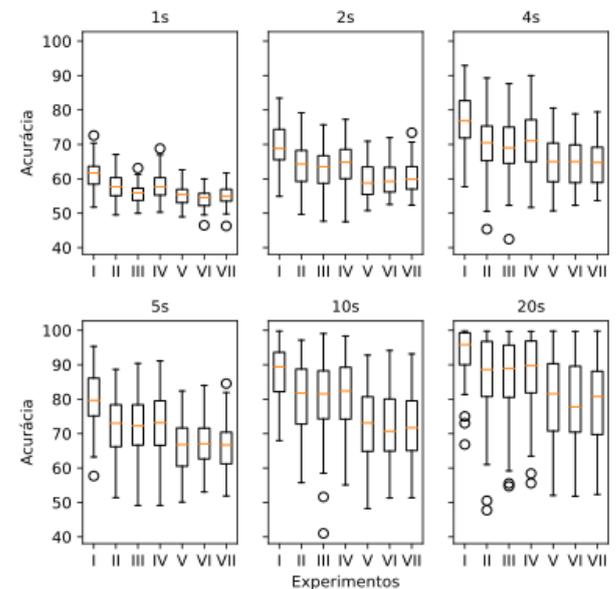


Fig. 6. Acurácia para diferentes durações de segmentos (s) dos sinais de entrada do modelo para cada um dos cenários analisados.

VI. DISCUSSÃO

A análise dos resultados apresentados na Fig. 5 e Fig. 6 revela que a acurácia do modelo aumenta à medida que se ampliam as janelas temporais dos segmentos utilizados como entrada. Esse comportamento é esperado, uma vez que segmentos mais longos contêm uma maior quantidade de informação tanto da envoltória da fala quanto dos sinais de EEG, o que favorece o processo de classificação.

Na Fig. 5, observa-se uma queda acentuada no desempenho do modelo à medida que se reduz o número de canais de EEG utilizados. Notavelmente, a redução de 64 para 6 canais resulta em uma perda de desempenho comparável à observada ao reduzir de 6 para apenas 2 canais. Note-se, entretanto, que o aumento da janela temporal reconstitui a perda de acurácia resultante da diminuição do número de canais. Esse comportamento sugere que a maior parte das informações relevantes para o acompanhamento neural do estímulo auditivo encontra-se associada à duração da janela de observação. Assim, a exclusão de canais tem impacto limitado sobre o desempenho do modelo, caso possa ser compensada com o aumento da janela temporal.

A Fig. 6 indica que o aumento da complexidade do modelo, seja por meio da adição de camadas convolucionais dilatadas ou pelo aumento no número de filtros e, conseqüentemente, no número de parâmetros treináveis, de aproximadamente 6 mil para cerca de 16 mil, não resultou em melhorias substanciais de desempenho nos cenários com menor número de canais. Esse resultado sugere que, quando a quantidade de informação disponível na entrada é limitada, o ganho obtido por meio do aumento da capacidade deste modelo em particular tende a não ser relevante.

Com base nos resultados obtidos, infere-se que a arquitetura utilizada - embora amplamente estudada e validada na literatura - pode não ser adequada para cenários práticos em que um número reduzido de canais de aquisição sinais de EEG está disponível e existem restrições ao tamanho da janela (atraso de processamento), principalmente em aplicações embarcadas de tempo real, como é o caso de aparelhos auditivos e implantes cocleares.

Apesar da relevância dos modelos de acompanhamento neural para a compreensão da relação entre a atividade cerebral e o estímulo auditivo, o impacto da redução do número de canais de EEG e da janela de observação evidencia a importância de alinhar o desenvolvimento desses modelos com os requisitos e restrições de aplicações reais, como no caso de dispositivos de auxílio à audição com controle neuroassistido.

VII. CONCLUSÕES

Este trabalho investigou o desempenho de um modelo de classificação do tipo *match-mismatch* baseado em convoluções dilatadas, considerando diferentes configurações em relação ao número de canais na aquisição de EEG e à duração da janela de observação. Os resultados demonstraram que a redução no número de canais compromete a acurácia do acompanhamento neural da fala. Além disso, mostrou-se que o aumento da complexidade do modelo analisado não é suficiente para mitigar a perda de desempenho causada pela limitação de dados de entrada. Essas constatações reforçam a necessidade de desenvolver modelos mais eficientes e adaptáveis a cenários

com aquisição de EEG restrita, como em aplicações de aparelhos auditivos com controle neuroassistido.

REFERÊNCIAS

- [1] A. W. Bronkhorst, "The cocktail party phenomenon: A review of research on speech intelligibility in multiple-talker conditions", *Acta Acust. United Ac.*, v. 86, n. 1, p. 117-128, 2000.
- [2] J. O'Sullivan *et al.*, "Attentional selection in a cocktail party environment can be decoded from single-trial EEG", *Cereb. Cortex*, v. 25, n. 7, p. 1697-1706, 2014.
- [3] S. Geirnaert *et al.*, "Electroencephalography-based auditory attention decoding toward neurosteered hearing devices", *IEEE Signal Proc. Mag.*, v. 38, n. 4, p. 89-102, 2021.
- [4] C. Puffay *et al.*, "Relating EEG to continuous speech using deep neural networks: A review", *J. Neural Eng.*, v. 20, n. 4, p. 041003, 2023.
- [5] D. Lesenfans *et al.*, "Data-driven spatial filtering for improved measurement of cortical tracking of multiple representations of speech", *J. Neural Eng.*, v. 16, n. 6, p. 066017, 2019.
- [6] A. Cheveigné, M. Slaney, A. S. Fuglsang, J. Hjortkjaer, "Auditory stimulus-response modeling with a match-mismatch task", *J. Neural Eng.*, v. 18, n. 4, p. 046040, 2021.
- [7] C. Puffay *et al.*, "Robust neural tracking of linguistic speech representations using a convolutional neural network", *J. Neural Eng.*, v. 20, n. 4, p. 046040, 2023.
- [8] M. J. Monesi *et al.*, "Extracting different levels of speech information from EEG using an LSTM-Based model", in *Proc. InterSpeech*, 2021, p. 526-530.
- [9] B. Accou *et al.*, "Modeling the relationship between acoustic stimulus and EEG with a dilated convolutional neural network", in *Proc. Eur. Signal Process. Conf.*, 2021, p. 1175-1179.
- [10] M. Thornton, D. Mandic, T. Reichenbach, "Decoding envelope and frequency-following EEG responses to continuous speech using deep neural networks", *IEEE Open J. Signal Process.*, v. 5, p. 700-716, 2024.
- [11] C. Puffay *et al.*, "Relating the fundamental frequency of speech with EEG using a dilated convolutional network", in *Proc. InterSpeech*, 2022, p. 4038-4042.
- [12] S. Dasenbrock *et al.*, "A step towards neuro-steered hearing aids: Integrated portable setup for time-synchronized acoustic stimuli presentation and EEG recording", *Curr. Dir. Biomed. Eng.*, v. 7, n. 2, p. 855-858, 2021.
- [13] S. L. Kappel *et al.*, "Dry-contact electrode ear-EEG", *IEEE Trans. Biomed. Eng.*, v. 66, n. 1, p. 150-158, 2019.
- [14] M. J. Monesi *et al.*, "An LSTM based architecture to relate speech stimulus to EEG", in *Proc. ICASSP*, 2020, p. 941-945.
- [15] M. Borsdorf *et al.*, "Multi-head attention and GRU for improved match-mismatch classification of speech stimulus and EEG response", in *Proc. ICASSP*, 2023, p. 1-2.
- [16] M. J. Monesi *et al.*, "Auditory EEG decoding challenge for ICASSP 2023", *IEEE Open J. Signal Process.*, v. 5, p. 652-661, 2024.
- [17] B. Accou *et al.*, "SparrKULee: A speech-evoked auditory response repository of the KU Leuven, containing EEG of 85 participants", *Data*, v. 9, n. 8, p. 1-18, 2024.
- [18] B. Somers, T. Francart, A. Bertrand, "A generic EEG artifact removal algorithm based on the multi-channel Wiener filter", *J. Neural Eng.*, v. 15, n. 3, p. 036007, 2018.
- [19] W. Biesmans *et al.*, "Auditory-inspired speech envelope extraction methods for improved EEG-based auditory attention detection in a cocktail party scenario", *IEEE Trans. Neural Syst. Rehabil. Eng.*, v. 25, n. 5, p. 402412, 2017.