

Decodificação de Atenção Auditiva com Ear-EEG: Uma Revisão Sistemática da Literatura

Isabela Mary Sasaki e Silva
Universidade Tecnológica Federal do Paraná (UTFPR)
Departamento Acadêmico de Eletrotécnica (DAELT)
Curitiba, Paraná, BRA

Fábio Pires Itturriet
Universidade Tecnológica Federal do Paraná (UTFPR)
Programa de Pós-Graduação em Engenharia Biomédica
(PPGEB), Curitiba, Paraná, BRA

Wemerson Delcio Parreira
Pontifícia Universidade Católica de Campinas
(PUC-Campinas), Escola Politécnica
Campinas, SP, BRA

Renata Coelho Borges
Universidade Tecnológica Federal do Paraná (UTFPR)
Programa de Pós-Graduação em Engenharia Biomédica
(PPGEB), Curitiba, Paraná, BRA

ABSTRACT

Ear-EEG technology has emerged as a promising solution for discreet and comfortable brain monitoring, with potential applications in areas such as auditory attention decoding (AAD), brain-computer interfaces, and smart assistive devices. This work presents a systematic literature review focused on the application of ear-EEG for auditory attention detection, investigating methods and technologies developed. In addition, we have discussed the main technical limitations and gaps in the literature, highlighting the challenges associated with accurate AAD. The results indicate a growing interest in the area, so future research should focus on standardizing preprocessing techniques and exploring low-cost, efficient devices and algorithms for signal acquisition and analysis.

KEYWORDS

Ear-EEG, Auditory attention decoding, RSL

1 INTRODUÇÃO

A eletroencefalografia (EEG) é uma técnica consolidada na neurociência amplamente utilizada para monitoramento e análise de atividade elétrica cerebral. Com os sinais captados por meio de eletrodos posicionados na superfície do couro cabeludo pode-se fazer diagnósticos clínicos, estudos sobre o sono, neurociência cognitiva, Interfaces Cérebro-Computador (*Brain-Computer Interface* – BCI), entre outros [1]. No entanto, apesar várias aplicações, essa técnica apresenta desafios significativos, como a necessidade de adotar práticas padronizadas e criteriosas para o manuseio dos eletrodos (método 10-20), uso de gel condutor e estruturas laboratoriais específicas, o que compromete o conforto, limita o uso prolongado e reduz sua aplicabilidade em contextos rotineiros [2].

Diante desse cenário, o ear-EEG (eletroencefalografia de orelha) vem surgindo como uma tecnologia promissora. Essa técnica permite o monitoramento da atividade cerebral a partir de sinais coletados por eletrodos posicionados na superfície auricular [3]. Desde sua introdução [4], o ear-EEG tem sido explorado como uma alternativa mais prática ao EEG tradicional, com potencial para monitoramento neural em tempo real e contínuo em ambientes cotidianos [5]. A inovação dessa abordagem está na possibilidade de se adquirir informações cerebrais sem a necessidade de eletrodos distribuídos sobre o escalpo, normalmente posicionados por profissionais habilitados. A facilidade da aplicação por usuários sem necessidade de assistência especializada é uma das características que tornam o

ear-EEG particularmente adequado para cenários de vida real, em que a discrição e o conforto são essenciais.

As aplicações do ear-EEG incluem, entre outras, o monitoramento de crises epilépticas [6], a detecção de convulsões focais [7], o monitoramento do sono [8], ou mesmo operações de rotina para profissionais em setores de alta responsabilidade, como motoristas e pilotos [3]. Em sistemas auditivos, por exemplo, essa tecnologia pode melhorar a experiência auditiva, especialmente em ambientes ruidosos, ao decodificar automaticamente os sons de interesse (*Auditory Attention Decoding* – AAD) e, em alguns casos, filtrar ruídos de fundo indesejáveis [9].

Entretanto, a viabilidade dessa tecnologia ainda enfrenta desafios importantes. A variabilidade dos sinais capturados em ambientes urbanos dinâmicos, bem como a necessidade de otimização dos algoritmos de processamento para que sejam compatíveis com dispositivos de baixo consumo, representam obstáculos significativos para sua utilização [10].

Este trabalho apresenta uma Revisão Sistemática da Literatura (RSL) para identificar as técnicas de processamento de sinais mais eficazes e relevantes para a aplicação de ear-EEG em AAD, além de explorar as lacunas na literatura que limitam a implementação prática dessa tecnologia. Apresenta-se como resultado inicial a resposta à seguinte pergunta de pesquisa: “Quais são os métodos e tecnologias usados para decodificação da atenção auditiva por meio de sinais earEEG?”

2 METODOLOGIA

Para o desenvolvimento desta RSL, foi utilizada a plataforma ParSifal (*Perform Systematic Literature Reviews*), que oferece recursos que podem facilitar e agilizar as etapas do processo de revisão. A estrutura organizada em três fases principais — planejamento, condução e resultados — contribuiu significativamente para alcançar os resultados desejados.

2.1 Planejamento

Na fase de planejamento foi adotado um protocolo detalhado que incluiu a definição do objetivo da pesquisa, a elaboração da tabela PICOC, a formulação das questões de pesquisa e a seleção de palavras-chave e sinônimos. Também foram definidas a sequência de busca, as bases de dados a serem consultadas e os critérios de inclusão e exclusão dos estudos.

O objetivo da pesquisa foi definido como “Identificar as pesquisas recentes que utilizam os sinais de EEG na superfície auricular e

as técnicas para identificar estado de atenção auditiva”. Quanto à elaboração da estratégia PICOC, este processo seguiu a estrutura apresentada na Tabela 1.

Tabela 1: Descrição da estratégia PICOC.

Ac.	Definição	Descrição
P	<i>Population</i>	Indivíduos monitorados com earEEG em estudos de atenção auditiva
I	<i>Intervention</i>	Uso de earEEG para detectar e monitorar atenção auditiva
C	<i>Comparison</i>	EEG tradicional, métodos comportamentais ou ausência de comparador
O	<i>Outcomes</i>	Viabilidade e limitações técnicas do earEEG
C	<i>Context</i>	Cenários controlados ou reais

As palavras-chave e sinônimos definidas para conduzir a pesquisa assumiram o seguinte formato: (“*Ear EEG*” OR “*EEG in the ear*” OR “*ear electroencephalography*” OR “*in ear EEG*”) AND (“*auditory attention*” OR “*attention state*” OR “*focused attention*” OR “*selective attention*”). A *string* resultante foi aplicada nas bases de dados apresentadas na Tabela 2.

Para a seleção inicial dos artigos, foram estabelecidos critérios de inclusão e exclusão, com o objetivo de identificar os estudos mais relevantes para a pesquisa: (i) critérios de inclusão: (a) EEG registrado na superfície auricular; (b) utilização de earEEG para detecção do estado de atenção; (c) artigos publicados entre 2019 e 2025; (ii) critérios de exclusão: (a) estudos fora do escopo ou da área de interesse; (b) estudos secundários; (c) artigos indisponíveis. As questões de pesquisa, cruciais para a conclusão da RSL, foram respondidas usando os dados extraídos dos artigos e estão organizadas na Tabela 3.

Tabela 2: Bases de dados.

Ordem	Questão
ACM Digital	http://dl.acm.org/
Begell Digital	http://dl.begellhouse.com/
Engineering Village	https://engineeringvillage.com/
IEEE Xplore	http://ieeexplore.ieee.org/
PubMed	http://ncbi.nlm.nih.gov/pubmed
ScienceDirect	http://sciencedirect.com/
Scopus	http://scopus.com
Springer	http://springer.com/
The Lancet	https://thelancet.com/
Web of Science	https://webofknowledge.com/

2.2 Condução

Após a etapa de planejamento, foi iniciada a busca nas bases selecionadas previamente (Tabela 2). O Portal de Periódicos da CAPES foi utilizado para acessar as bases, com login institucional por meio da Comunidade Acadêmica Federada (CAFe).

Inicialmente, foram escolhidas 10 bases para realizar a busca utilizando a *string*. Entretanto, na primeira rodada observou-se que as bases de dados Begell Digital e The Lancet apresentaram inúmeras dificuldades na utilização de seus mecanismos. A base ACM Digital retornou apenas uma revisão sistemática e Springer

Tabela 3: Perguntas de pesquisa.

Ordem	Questão
1	Quais são os métodos e tecnologias usados para detecção da atenção auditiva por meio de sinais earEEG?
2	Como os sinais de ear-EEG têm sido utilizados para identificar e monitorar o foco auditivo?
3	Quais abordagens de processamento de sinais são mais eficazes para análise de dados de earEEG na detecção de atenção auditiva?
4	Quais são as principais limitações técnicas associadas ao uso de earEEG na detecção de atenção auditiva?

não retornou nenhum artigo, somente livros/capítulos de livros. A busca nas bases restantes retornou 39 artigos publicados entre os anos de 2019 e 2024, com distribuição apresentada na Figura 1.

Antes de prosseguir na etapa de análise, foi realizado um processo de verificação e remoção dos artigos duplicados — 19 artigos foram categorizados como duplicados e então removidos —, que é automatizado pela própria ferramenta Parsifal. Após a aplicação dos critérios de inclusão/exclusão restaram 8 artigos para etapa de análise.




Figura 1: Sumário da distribuição dos artigos.

3 RESULTADOS

Técnicas de pré-processamento como filtragem passa-banda foram amplamente utilizadas nos estudos para limitar frequências específicas e melhorar a qualidade do sinal. Paul et al. (2021) [11] e Jeong et al. (2020) [12] adotaram as faixas de 4-40Hz e 1-50Hz, respectivamente. Nogueira et al. (2019) [13] e Holtze et al. (2022) [9] restringiram os sinais à faixa de 2Hz a 8Hz. Já Hölle et al. (2021) [14], Hölle et al. (2023) [15] e Geravanchizadeh et al. [16] variaram nas faixas de frequência de 0,1-10Hz, 0,1-25Hz e 0,5-70Hz, respectivamente. Os sinais utilizados foram captados de diversas formas, com destaque para as configurações de cEEGrid (*Convenient Around-The-Ear Electrode Array*), com 10 eletrodos por orelha [9, 13–15, 17], enquanto outros utilizaram eletrodos secos intra-auriculares, com o objetivo de melhorar a portabilidade [11, 12, 16].

A classificação dos estados de atenção variou conforme os artigos. Em [16] foram utilizados métodos de *machine learning*, como KNN (*K-Nearest Neighbour*) e SVM (*Support Vector Machine*), alcançando acurácias de 92,83% e 80,29%, respectivamente. O uso de *Echo State Networks* (ESN) aproximou a precisão do earEEG à do EEG tradicional, com acurácia de 81,16% em [12]. Em [9, 13] foi adotado o mTRF (*multivariate-Temporal Response Function*), com acurácias de 82,59% e 59,79%, respectivamente. Os estudos [9, 13] combinaram mTRF com a transformada de Hilbert para obter os

envelopes temporais dos estímulos auditivos. A análise de ERPs (*Event-Related Potentials*) foi implementada nos estudos [14, 15, 17], enquanto os estudos [14, 17] complementaram a análise com ASR (*Artifact Subspace Reconstruction*) para capturar respostas neurais em ambientes reais.

Todos os estudos relataram limitações da técnica de ear-EEG, como baixa relação sinal-ruído, variabilidade inter-sujeitos e a interferência de artefatos fisiológicos. A dificuldade com a relação sinal-ruído nos dispositivos com eletrodos secos foi mencionada em [11, 15]. Como esperado, o desempenho das técnicas se mostrou inferior se comparado ao EEG tradicional [13]. A variabilidade entre os sujeitos também impacta diretamente na acurácia dos algoritmos [12, 14, 16]. Para minimizar esse efeito, [9, 13] utilizaram algoritmos personalizados, mas os estudos alertam para a complexidade computacional dos métodos usados. Em cenários reais, [14, 15, 17] relataram desafios com artefatos causados por movimentos, enfatizando a necessidade de uma melhor fixação dos eletrodos para gravações prolongadas e robustez contra movimentos.

Vale ressaltar que [14, 17] têm um enfoque na análise dos estímulos auditivos em cenários reais. Suas respectivas técnicas de processamento são apresentadas, mas estes estudos não colaboram de forma eficiente para esta revisão, que visa investigar métodos para decodificação de atenção auditiva.

Apesar de não terem sido identificados estudos no ano de 2024, dois artigos se mostram bastante relevantes para essa RSL. As duas referências analisadas, disponíveis no arXiv e ainda não publicadas, investigam o uso do ear-EEG para decodificação da atenção auditiva em cenários experimentais distintos. Zhu et al. (2024) [18] avaliam métodos como TRFs, reconstrução de estímulos e redes neurais profundas (*Spatiotemporal Attention Network* - STANet) em um dispositivo *ultrawearable* para identificar o foco de atenção em múltiplos falantes, atingindo 93,1% de precisão. O outro estudo, feito por Thornton et al. (2024) [19], apresenta uma comparação de métodos, como regressão linear, CNNs (*Convolutional Neural Network*) e CCA (*Canonical Correlation Analysis*), utilizando eletrodos secos intra-auriculares e de referência no FT7 (abaixo da têmpora esquerda). Os resultados indicam que algoritmos baseados em *on-set* envelopes superam os baseados em envelopes temporais, com acurácia média de 55%.

4 CONSIDERAÇÕES FINAIS

No geral, os estudos convergem para a conclusão de que o ear-EEG possui grande potencial para aplicações em dispositivos auditivos e monitoramento neural. No entanto, as limitações técnicas relacionadas à relação sinal-ruído, personalização dos algoritmos e artefatos de movimento sugerem que mais avanços são necessários. Melhorias sugeridas incluem a personalização dos métodos de classificação para diferentes indivíduos [13, 16], além do desenvolvimento de sensores mais robustos e confortáveis [15, 17].

A utilização de métodos como *machine learning* e redes de estado eco (ESN – *Echo State Network*) mostra resultados promissores, mas a complexidade computacional e a dependência de equipamentos caros e de alta precisão limitam a adoção dessas tecnologias em contextos de baixo custo. Dessa forma, a continuidade deste estudo se concentra na comparação de técnicas de baixo custo para AAD utilizando sinais de bancos de dados [20], com o objetivo de tornar o ear-EEG mais viável e aplicável em contextos diversos, permitindo

sua utilização em larga escala com maior confiabilidade e menor custo.

REFERÊNCIAS

- [1] Vytene Janiukstyte, Thomas W Owen, Umair J Chaudhary, Beate Diehl, Louis Lemieux, John S Duncan, Jane de Tisi, Yujiang Wang, and Peter N Taylor. Normative brain mapping using scalp EEG and potential clinical application. *Scientific Reports*, 13(1):13442, 2023. doi: 10.1038/s41598-023-39700-7.
- [2] Frank Gilliam, Ruben Kuzniecky, and Edward Faught. Ambulatory EEG monitoring. *Journal of Clinical Neurophysiology*, 16(2):111–115, 1999.
- [3] Netiwit Kaongoen, Jaehoon Choi, Jin Woo Choi, Haram Kwon, Chaeun Hwang, Guebin Hwang, Byung Hyung Kim, and Sungcho Jo. The future of wearable EEG: A review of ear-EEG technology and its applications. *Journal of neural engineering*, 2023. doi: 10.1088/1741-2552/acfdca.
- [4] David Looney, Cheolsoo Park, Preben Kidmose, Mike Lind Rank, Michael Ungstrup, Karin Rosenkranz, and Danilo P Mandic. An in-the-ear platform for recording electroencephalogram. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 6882–6885. IEEE, 2011. doi: 10.1109/IEMBS.2011.6091733.
- [5] Valentin Goverdovsky, Wilhelm Von Rosenberg, Takashi Nakamura, David Looney, David J Sharp, Christos Papavassiliou, Mary J Morrell, and Danilo P Mandic. Hearables: Multimodal physiological in-ear sensing. *Scientific reports*, 7(1):6948, 2017. doi: 10.1038/s41598-017-06925-2.
- [6] Miguel Bhagubai, Kaat Vandecasteele, Lauren Swinnen, Jaiver Macea, Christos Chatzichristos, Maarten De Vos, and Wim Van Paesschen. The power of ECG in semi-automated seizure detection in addition to two-channel behind-the-ear EEG. *Bioengineering*, 10(4):491, 2023. doi: 10.3390/bioengineering10040491.
- [7] McGregor Joyner, Sheng-Hsiou Hsu, Stephanie Martin, Jennifer Dwyer, Denise Fay Chen, Reza Sameni, Samuel H Waters, Konstantin Borodin, Gari D Clifford, Allan I Levey, et al. Using a standalone ear-EEG device for focal-onset seizure detection. *Bioelectronic Medicine*, 10(1):4, 2024. doi: 10.1186/s42234-023-00135-0.
- [8] Kaare B. Mikkelsen, Yousef R. Tabar, Hans O. Toft, Martin C. Hemmsen, Mike L. Rank, and Preben Kidmose. Self-applied ear-EEG for sleep monitoring at home. In *2022 44th Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, pages 3135–3138, 2022. doi: 10.1109/EMBC48229.2022.9871076.
- [9] Björn Holtze, Marc Rosenkranz, Manuela Jaeger, Stefan Debener, and Bojana Mirkovic. Ear-EEG measures of auditory attention to continuous speech. *Frontiers in Neuroscience*, 16:869426, 2022. doi: 10.3389/fnins.2022.869426.
- [10] Michael Thomas Knierim, Martin Georg Bleichner, and Pierluigi Realì. A systematic comparison of high-end and low-cost EEG amplifiers for concealed, around-the-ear EEG recordings. *Sensors*, 23(9):4559, 2023. doi: 10.3390/s23094559.
- [11] Akshay Paul, Gopabandhu Hota, Behnam Khaleghi, Yuchen Xu, Tajana Rosing, and Gert Cauwenberghs. Attention state classification with in-ear EEG. In *2021 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, pages 1–5. IEEE, 2021.
- [12] Dong-Hwa Jeong and Jaeseung Jeong. In-ear eeg based attention state classification using echo state network. *Brain sciences*, 10(6):321, 2020. doi: 10.3390/brainsci10060321.
- [13] Waldo Nogueira, Hanna Dolhopiatenko, Irina Schierholz, Andreas Büchner, Bojana Mirkovic, Martin G Bleichner, and Stefan Debener. Decoding selective attention in normal hearing listeners and bilateral cochlear implant users with concealed ear eeg. *Frontiers in neuroscience*, 13:720, 2019. doi: 10.3389/fnins.2019.00720.
- [14] Daniel Hölle, Joost Meekes, and Martin G Bleichner. Mobile ear-EEG to study auditory attention in everyday life: Auditory attention in everyday life. *Behavior Research Methods*, 53(5):2025–2036, 2021. doi: 10.3758/s13428-021-01538-0.
- [15] Daniel Hölle and Martin G Bleichner. Smartphone based ear electroencephalography to study sound processing in everyday life. *European Journal of Neuroscience*, 58(7):3671–3685, 2023. doi: 10.1111/ejn.16124.
- [16] Masoud Geravanchizadeh and Sahar Zakeri. Ear-EEG-based binaural speech enhancement (ee-bse) using auditory attention detection and audiometric characteristics of hearing-impaired subjects. *Journal of Neural Engineering*, 18(4):0460d6, 2021. doi: 10.1088/1741-2552/ac16b4.
- [17] Martin G. Bleichner. Studying individual noise disturbance using long term ear-EEG (electroencephalography) recordings in everyday life. In *23rd International Congress on Acoustics*, pages 3026–3032, 2019.
- [18] Haolin Zhu, Yujie Yan, Xiran Xu, Zhongshu Ge, Pei Tian, Xihong Wu, and Jing Chen. Using Ear-EEG to decode auditory attention in multiple-speaker environment, 2024. URL <https://arxiv.org/abs/2409.08710>.
- [19] Michael Thornton, Danilo Mandic, and Tobias Reichenbach. Comparison of linear and nonlinear methods for decoding selective attention to speech from ear-EEG recordings, 2024. URL <https://arxiv.org/abs/2401.05187>.
- [20] Michael Thornton, Tobias Reichenbach, and Danilo Mandic. Imperial college Ear-EEG dataset for auditory attention decoding, July 2024. URL <https://doi.org/10.5281/zenodo.10260082>.