

基于EEG的言语想象编码范式和解码算法研究综述

杨帮华 甘安安 郭文彬 邝 帅

上海大学机电工程与自动化学院 上海 200444

摘要 脑电 (Electroencephalogram, EEG) 为言语想象脑机接口 (Brain-Computer Interface, BCI) 提供了核心解码基础, 使言语障碍患者无须外周神经与肌肉通路即可实现人机交互, 在失语症康复与隐蔽通信等领域具有重要潜力。本文系统综述了EEG言语想象BCI的编码范式与解码算法进展: 在编码方面, 言语想象的神经模式与言语执行高度重叠, 主要涉及Broca区、Wernicke区等语言网络节点, 想象内容涵盖音位、音节、字词和句子, 范式设计常借助多模态刺激与重复任务以提升信号可分性。解码方面, 传统两阶段方法 (特征提取+分类) 受限于特征工程依赖与跨被试泛化能力弱的问题; 端到端深度学习通过直接处理原始EEG时空序列, 实现特征与分类联合优化, 提升了解码效率。新兴方法融合自然语言处理与预训练语言模型, 利用语义上下文实现句子层级解码, 为复杂语言重建提供新路径。当前挑战包括解码精度不足与跨被试泛化性差, 未来需结合少样本学习、多模态融合, 并推动EEG与大语言模型协同, 以促进临床应用。

关键词 言语想象; EEG; 编码范式; 解码算法; 语言模型

A Review of EEG-Based Speech Imagery Encoding Paradigms and Decoding Algorithms

Yang Bang-hua, Gan An-an, Guo Wen-bin, Kuang Shuai

School of Mechatronic Engineering And Automation, Shanghai University, Shanghai 200444, China

Abstract: Electroencephalogram (EEG) provides the core decoding foundation for speech imagery brain-computer interfaces (BCI), enabling individuals with speech impairments to achieve human-computer interaction without relying on peripheral nerves and muscle pathways. It holds significant potential in areas such as aphasia rehabilitation and covert communication. This article systematically reviews advances in neural encoding paradigms and decoding algorithms for EEG-based speech imagery BCI: In terms of encoding, the neural patterns during speech imagery highly overlap with those during speech execution, primarily involving key nodes of the language network such as Broca's area and Wernicke's area. The imagined content spans phonemes, syllables, words, and sentences. Paradigm design often employs multimodal stimuli and repetitive tasks to enhance signal separability. Regarding decoding, traditional two-stage methods (feature extraction + classification) are limited by their dependence on feature engineering and poor cross-subject generalization. End-to-end deep learning models directly process raw spatiotemporal EEG sequences, achieving joint optimization of feature extraction and classification, which significantly improves decoding efficiency. Emerging approaches integrate natural language processing and pre-trained language models, leveraging semantic context to achieve sentence-level decoding and offering new pathways for complex language reconstruction. Current key challenges include insufficient decoding accuracy and poor cross-subject generalization. Future efforts should incorporate few-shot learning frameworks to enhance model generalization, integrate multimodal data to deepen the understanding of neural mechanisms underlying EEG, and promote synergy between EEG signals and large language models to advance practical clinical applications.

Keywords: Speech Imagery, EEG; Encoding Paradigms; Decoding Algorithms; Language Models

1 引言

脑机接口 (Brain Computer Interface, BCI) 作为一种前沿的人机交互技术, 旨在绕开外周神经与肌肉, 直接实现大脑与

外部设备间的信息交流与控制^[1]。BCI技术的快速发展为神经科学、医疗康复、助残技术等多个领域带来了革命性的进展。其中, 基于脑电 (Electroencephalogram, EEG) 的言语想象BCI作

*[基金项目] 国家自然科学基金资助项目 (62376149) .

为一种新兴的通信方式，受到了广泛的关注。当前BCI发展出运动想象、稳态视觉诱发电位、事件相关电位等多种主流编码范式^[2]。其中运动想象的实质是大脑主动想象自身肢体执行某种特定动作的过程，言语想象则是想象某个特定词在内心发声的过程，二者大脑加工的过程类似，只是参与脑区有所不同，都是通过主动想象任务在大脑加工后产生不同身体部位（上下肢/唇舌喉）的协调动作，运动想象得到了较多的关注和研究^[3-4]，言语想象作为新型主动式BCI正逐步成为脑机接口领域备受瞩目的研究范式^[5]。

言语产生是典型自上而下的层级化认知加工过程，涉及从言语概念表征到发音动作编码的多阶段转化。其中，发音运动的执行主要依赖舌唇构音位置与喉部发音方式协同调控。神经影像学研究发现，言语想象作为内心语言的神经活动模式与外显语言产生的核心脑区（Broca区、Wernicke区等）存在显著耦合^[6-7]。该认知过程具有自发涌现特性，无须刻意训练即可激活，用户体验友好且认知负荷低^[8]。基于上述特性，言语想象BCI技术在失语症康复、隐蔽通信、自适应教学及无障碍人机交互等领域展现出重要应用价值^[9]。

言语想象BCI的核心挑战之一是如何准确识别和解码大脑中由内在语言活动产生的电信号^[10-13]。与传统的言语识别系统相比，基于EEG的言语想象解码不仅面临着信号质量较差、噪声干扰严重的问题，还需要应对个体差异较大的难题^[12-15]。因此，如何提高EEG信号的解码精度，尤其是在面对不同个体或不同实验环境下的挑战时，成为了该领域研究的关键课题^[14-16]。

在此背景下，本综述旨在综述当前基于EEG言语想象BCI技术的编码范式与解码算法的研究进展，并探讨其面临的挑战及未来发展方向。通过对相关文献的分析与总结，我们将进一步了解该领域的最新动态及其在实际应用中的潜力与局限^[16-17]。

2 编码范式

EEG凭借便携性优势支持多样化言语想象编码范式设计，如何构建高效实验范式以最大化激活言语相关脑区神经特征成为核心挑战。

2.1 EEG在言语想象BCI中的优势和局限

言语想象过程独立于肌肉运动，有效避免了肌肉运动带来的信号干扰，为大脑信号的采集提供了理想条件^[5]。在大脑信号采集领域常用的模态如表1所示，包括EEG、脑磁图（MEG）、皮层脑电图（ECoG）、功能磁共振成像（fMRI）

以及功能近红外光谱技术（fNIRS）^[18]。

EEG在研究言语想象方面具有独特优势。其具备良好的时间分辨率，能够契合言语想象中多层次加工、连续且快速变化的特性。此外，EEG的非侵入性保证了被试在测试过程中的舒适度与安全性，其便携性则使其能够灵活适应不同个体在言语想象时所展现出的独特神经活动模式^[19]。基于这些优势，EEG被广泛应用于探究大脑在言语想象过程中的神经活动机制，能够有效捕捉发音动作的编码特征，为深入理解言语想象的神经基础提供了关键数据支持^[20]。

尽管EEG在实时监测脑活动方面具有重要价值，但也存在一定局限性。首先，它难以精确定位损伤的具体位置或来源，可能影响诊断准确性和治疗规划；其次，肌肉运动和噪声等外部因素会导致EEG记录不准确，降低其可靠性；最后，头皮和颅骨形成的自然滤过作用限制了EEG对深层脑结构的可视化能力，从而制约了其诊断效能。这些局限性表明，需要结合其他成像方式和诊断方法，以全面了解神经系统疾病。

2.2 言语想象的神经基础

由于EEG的空间分辨率较低，言语想象的神经基础研究主要采用与fMRI技术结合的研究范式，以满足对相关脑区高空间分辨率定位的需求。

Liwicki等^[21]公开了一个包含4名健康被试的EEG和fMRI双模态言语想象数据集。通过对EEG数据的分析发现，EEG信号能有效反映言语想象相关的神经活动，在视觉词语刺激呈现后0~500 ms内，可观察到包含P300、N400等与语言加工相关的典型ERP成分，且不同参与者呈现出一致性模式；ICA分解后的拓扑图揭示了不同语义类别词语（社会类与数字类）引发的脑区激活差异，尤其中央区域激活显著，且同一独立成分对不同词语的响应模式不同，体现了SI中语义加工的神经特异性；表明EEG可为内隐言语解码提供高时间分辨率的可靠信号，结合fMRI能更全面地揭示其神经机制。

言语想象的神经机制与实际言语产生过程高度重叠，但也有其独特性。除了上述异步EEG-fMRI的研究，Zhang等^[22]通过同步EEG-fMRI技术，对32名健康男性参与者在言语想象和言语执行任务中的脑活动进行分析。言语想象的EEG源活动定位于左中央前回、左辅助运动区和左壳核；与言语执行相比，想象任务中左壳核的事件锁定激活更早（峰值262 ms vs 1170 ms），左中央前回和左辅助运动区的事件锁定激活则始终较弱且无特有激活；在0.5~30Hz频率范围内，想象任务在上述三个区域及多数不显著区域的功率谱密度（PSD）均弱于执行任

殊人群)的分类准确率达72%~88%;其中, Gamma 波段(与高级认知功能相关)包含57%的最重要特征, Alpha 和 Beta 波段分别占12%和31%,证实了言语想象任务BCI的有效性及其Gamma波段的关键作用,四个音节也为后续的“Back”“Forward”“Left”和“Right”单词的分类奠定了研究基础。

Nieto等^[10]招募了10名无BCI经验的西班牙语母语者,让参与者在发音、想象、可视化三种条件下完成西班牙语四个单词(“arriba”“abajo”“derecha”“izquierda”,对应“上/下/右/左”)的想象任务,用64导联设备采集EEG数据。研究发现,不同条件下脑电活动在事件相关电位、时频表征等方面存在差异。并公开了数据集。Merola等^[30]根据这一数据集计算出EEG的均值、Hjorth复杂度、香农熵等统计特征并赋予对应标签,对比了随机森林、SVM、KNN三种模型分类效果,其中SVM模型准确率最高,在特定被试中达35.3%,随机森林和KNN分别为29.7%和31.4%。

Lee等^[31]探讨了想象语音和视觉意象作为BCI通信直觉范式的解码特性,22名被试对12个医院常用词/短语进行任务执行,采用CSP进行特征提取以及结合径向基函数(RBF)核的SVM进行分类,分析发现:高频波段(30~125Hz)在13类分类中表现最优[想象语音:(39.73±5.64%)]。Broca区、Wernicke区及听觉皮层的解码性能更优;随着类别数量增加,解码性能适度下降,但所有被试均超过置信水平。

Pan等^[32]开展了包含26个英文字母和5个标点符号的多字符分类研究,使用32通道EEG设备记录7名受试者的31种语音意象内容,利用小波散射变换(WST)提取特征,通过核主成分分析(KPCA)降维,将降维后的特征输入极端梯度提升(XGBoost)分类器,并经超参数调优。在多字符分类任务中取得了出色的结果,可视化发现相似字符能有效聚类。

传统两阶段解码算法因对人工特征工程依赖性强、跨被试泛化性能差及高阶神经振荡时空特征表征能力不足等固有缺陷,严重制约言语想象脑机接口系统的解码效能。

3.2 端到端深度学习解码

随着深度学习的兴起,越来越多的研究致力于开发端到端深度学习框架,以提升言语想象任务的解码性能。

Lee等^[33]针对BCI中因数据量少、分类性能低而难以实际应用的现状,提出了基于孪生神经网络编码器的端到端框架。该框架直接使用原始EEG信号,通过孪生网络学习类间距离(缩小同类样本距离、扩大异类样本距离),使用k-NN分类器,对

6个西班牙语想象单词(arriba、abajo等)进行分类。结果显示,6类分类准确率达(31.40±2.73%),显著优于传统方法(如CSP+RF、CNN等),证明孪生网络能从少量数据中提取判别特征。

Han等^[34]旨在提高其对未知受试者的泛化能力从而改善深度学习解码性能。以DeepConvNet为基础模型,提出一种少样本/零样本的独立于受试者的元学习框架。结果显示该框架在文献[26]中数据集上表现出色(31.15%),零样本模型性能良好,少样本微调后更优,且稳定性好。该元学习框架有效提升了解码性能,并在留一被试法基础上证明其具有一定的泛化性。

Macias等^[35]使用含有如7所示元音/a和/u/两类的DaSalla数据集^[25],提出基于胶囊神经网络的CapsVI模型,通过计算卷积核数量、利用熵技术寻找相关特征等设计模型架构。结果显示CapsVI与其他方法对比在元音想象任务分类中表现最佳。该模型能有效识别元音想象模式,且训练和推理时间满足实时应用需求。

刘晓龙等^[36]选取临床场景下的,词语“帮帮我”“坐起来”“翻身”作为三类任务设计了中文言语想象范式,采集了15名健康受试者的EEG数据,提出了一种通道注意力多尺度卷积神经网络(CAM-Net)解码算法,融合多尺度时间卷积与不对称空间卷积来提取词语脑电的多维特征,并引入通道注意力机制与双向长短期记忆网络来进行通道加权和时序依赖关系捕捉。在三分类任务中,CAM-Net模型达到了48.54%的分类准确率;在二分类任务中,最高分类准确率为64.17% (“坐起来”与“翻身”)。

Li等^[37]聚焦于双语复杂语义静默阅读EEG信号解码,在26天内收集了1名被试的9个英语短语(EP)、7个英语句子(ES)、10个汉语短语(CP)和7个汉语句子(CS)的静默阅读EEG信号,提出自适应图注意力卷积网络(AGACN)进行分类。结果显示,AGACN在EP、ES、CP、CS上的最高分类准确率分别达54.70%、62.26%、44.55%、57.14%,优于现有方法,证明了双语复杂语义EEG信号解码的可行性。

Jiang等^[38]提出了功能性区域时空Transformer(FAST)模型,该模型结合卷积神经网络与Transformer架构,能有效提取EEG信号的时空特征。研究构建了包含57名右利手英语母语者想象5个词组时的大规模言语EEG数据集,实验显示FAST在采用留一被试法预训练方式下的隐性言语解码中性能优于多种基线模型(微调后准确率达34.7%),且通过特征可视化揭示

了额叶和颞叶区域在言语想象中的显著激活，为 EEG 言语解码提供了首个可解释证据。

端到端的深度学习解码框架大大提升了言语想象的解码性能，多数研究的特征提取依赖于卷积层，并结合当时的State-Of-The-Art模型长处于框架中，但模型的泛化性并没有得到验证。部分研究开始基于留一被试法进行训练，以学习跨被试的泛化特征，但现有深度学习框架在言语想象范式上取得的精度还远不能满足BCI系统应用需求。

3.3 融合NLP技术的新兴模型解码

在侵入式研究中，Metzger等^[39]利用RNN模型学习ECoG特征与语音实现了高精度的语音，到文本转换，融合自然语言处理（NLP）技术为言语想象的解码开辟了新路径。

Défossiez等^[40]通过创新方法突破传统局限，采用对比学习训练模型，结合预训练语音模型wav2vec 2.0的自监督表征，设计多参与者联合训练的卷积架构，整合4个公开数据集（含175名参与者）进行验证。结果显示，Brennan数据集top-10准确率为25.7%，Broderick数据集达17.7%，但均显著高于随机基线（<1%）。研究证实了对比学习、预训练语音表征和多参与者架构的有效性，揭示解码主要依赖词汇和语境语义表征，为无需脑部手术的语言解码提供了可行路径。

Duan等^[41]提出了一种将脑电图（EEG）信号转换为文本的创新框架DeWave，其核心在于引入离散编码序列（discrete codex），通过量化变分编码器将EEG信号转化为离散表示，无需眼动追踪等事件标记即可实现转换。其优势包括：①通过文本—EEG对比对齐训练，在原始EEG波形上实现无标记翻译；②通过不变离散编码减少个体EEG差异的干扰。该框架虽然在发表后声明存在数据泄露问题，但其解码思路为后续研究提供了新的见解。

以融合NLP技术为代表的新兴模型，利用NLP模型（如

参考文献：

[1] WOLPAW J R, BIRBAUMER N, MCFARLAND D J, et al. Brain-computer interfaces for communication and control[J]. *Clinical Neurophysiology*, 2002, 113(6): 767-791.
[2] MILLAN J R, RENKENS F, MOURIÑO J, et al. Brain-machine interfaces, human-machine interfaces, and machine-machine interfaces[J]. *Frontiers in Neuroscience*, 2010, 4: 1-10.
[3] QIN Y, LI J Y, ZHANG R, et al. M-FANet: multi-feature attention convolutional neural network for motor imagery decoding[J]. *IEEE Transactions on Neural Systems and Rehabilitation*

BERT、GPT）通过预训练学习语言的深层语义结构，可实现连续文本的解码。因此EEG到言语的跨模态融合成了目前突破传统解码模型瓶颈的关键。

4 总结

本综述围绕基于EEG的言语想象BCI技术，梳理了其编码范式与解码算法的研究进展，可总结如下。

在编码范式方面，言语想象的神经基础研究多结合EEG与fMRI技术，前者凭借高时间分辨率捕捉P300、N400等与语言加工相关的ERP成分，后者则通过高空间分辨率定位Broca区、Wernicke区等核心脑区，共同揭示了言语想象与外显言语产生在神经机制上的重叠性与独特性（如左壳核在想象任务中激活更早）。想象内容遵循语言加工层级，从音位/音节、字词逐步扩展至句子，刺激方式中视听同步提示结合多次重复提示可强化激活效果。

解码算法领域，传统两阶段方法通过CSP、希尔伯特谱等提取特征，结合SVM、LDA等分类器，在音位/音节和字词分类中取得一定成果，但存在人工特征依性强、跨被试泛化差等局限。端到端深度学习方法直接处理原始EEG信号，孪生神经网络、元学习框架、CAM-Net等模型提升了解码性能，但泛化性仍需验证。此外，融合NLP技术的新兴模型通过跨模态融合为连续句子解码提供了新思路。

当前研究仍面临解码精度不足、跨被试泛化性差、高阶神经特征表征能力有限等挑战。未来需优化少样本/零样本学习框架以增强泛化性，并结合多模态技术（如EEG-fMRI）深入解析言语想象神经机制，进一步探索EEG与NLP模型的跨模态融合以及大预言模型对于言语想象任务的解码，推动该技术在失语症康复、隐蔽通信等领域的实际应用。

Engineering, 2024, 32: 401-411.

[4] RONG F, WANG Z Y, ZHANG Y, et al. Decoding multi-class motor imagery from unilateral limbs using eeg signals[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 3399-3409.
[5] 刘艳鹏, 龚安民, 丁鹏, 等. 基于言语想象的脑机交互关键技术[J]. *生物医学工程学杂志*, 2022, 39(3): 596-611.
[6] BINDER J R, FROST J A, HAMMEKE T A, et al. Human brain language areas identified by functional magnetic resonance imaging[J]. *Journal of Neuroscience*, 1997, 17(1): 353-362.

- [7] HICKOK G, POEPEL D. The cortical organization of speech processing[J]. *Nature Reviews Neuroscience*, 2007, 8(5): 393–402.
- [8] BLANKERTZ B, TOMIOKA R, LEMM S, et al. Optimizing spatial filters for robust eeg single-trial analysis[J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(10): 2458–2467.
- [9] ALDERSON-DAY B, FERNYHOUGH C, WEIS S, et al. The brain's conversation with itself: neural substrates of dialogic inner speech[J]. *Social Cognitive and Affective Neuroscience*, 2016, 11(1): 110–120.
- [10] NIETO N, PETERSON V, RUFINER L, et al. Thinking out loud, an open-access eeg-based bci dataset for inner speech recognition[J]. *Scientific Data*, 2022, 9(1): 52.
- [11] MINI P, GOPIKAKUMARI R. Eeg based direct speech bci system using a fusion of smrt and mfcc/lpcc features with ann classifier[J]. *Biomedical Signal Processing and Control*, 2021, 68: 102625.
- [12] JAHANIKIA S, YLMAZ D, JAYARAMAN R, et al. Implementing machine learning paradigms for decoding of inner speech commands: an eeg-bci study[J]. *IBRO Neuroscience Reports*, 2023, 15: S949.
- [13] WANG L, ZHANG X, ZHONG Y, et al. Analysis and classification of speech imagery eeg for bci[J]. *Biomedical Signal Processing and Control*, 2013, 8(6): 901–908.
- [14] JUHÁR J. A novel approach to eeg speech activity detection with visual stimuli and mobile bci[J]. *Applied Sciences*, 2021, 11(2): 674.
- [15] DHAGE S. Eeg-based covert speech decoding using random rotation extreme learning machine ensemble for intuitive bci communication[J]. *Biomedical Signal Processing and Control*, 2023, 80: 104379.
- [16] ERGÜZEN A. Enhancing speech impairment support: designing an eeg-based bci for turkish vowel recognition[J]. *Traitement Du Signal*, 2024, 41(3): 1205–1213.
- [17] BEGUM S. Towards imagined speech: identification of brain states from eeg signals for bci-based communication systems[J]. *Behavioural Brain Research*, 2024, 467: 115295.
- [18] 王勇丽, 葛胜男, HUANG L L, 等. 言语想象的神经机制[J]. *心理科学进展*, 2023, 31(4): 608–621.
- [19] CHU S Y, CHEN Y H, CHEN S A, et al. Eeg-fmri-based multimodal fusion system for analyzing human somatosensory network[C]//2024 International Conference on System Science and Engineering (ICSSE). Hsinchu: IEEE, 2024: 1–6.
- [20] LOTTE F, BOUGRAIN L, CICHOCKI A, et al. A review of classification algorithms for eeg-based brain-computer interfaces: a 10-year update[J]. *Journal of Neural Engineering*, 2018, 15(3): 031005.
- [21] SIMISTIRA LIWICKI F, VILAMALA M V, LINDEN D E J, et al. Bimodal electroencephalography-functional magnetic resonance imaging dataset for inner-speech recognition[J]. *Scientific Data*, 2023, 10: 378.
- [22] ZHANG W, ZHOU W, XIA X, et al. Revealing the spatiotemporal brain dynamics of covert speech compared with overt speech: a simultaneous eeg-fmri study[J]. *NeuroImage*, 2024, 293: 120629.
- [23] ZHANG Z, DING X, BAO Y, et al. Chisco: an eeg-based bci dataset for decoding of imagined speech[J]. *Scientific Data*, 2024, 11: 1265.
- [24] RAMAKRISHNAN A G, PANACHAKEL J T. Decoding covert speech from eeg – a comprehensive review[J]. *Frontiers in Neuroscience*, 2021, 15: 642251.
- [25] DASALLA C S, KAMBARA H, SATO M, et al. Single-trial classification of vowel speech imagery using common spatial patterns[J]. *Neural Networks*, 2009, 22(9): 1334–1339.
- [26] DENG S, SRINIVASAN R, LAPPAS T, et al. Eeg classification of imagined syllable rhythm using hilbert spectrum methods[J]. *Journal of Neural Engineering*, 2010, 7(4): 046006.
- [27] BRIGHAM K, KUMAR B V. Imagined speech classification with eeg signals for silent communication: a preliminary investigation into synthetic telepathy[C]//2010 4th International Conference on Bioinformatics and Biomedical Engineering. Chengdu: IEEE, 2010: 1–4.
- [28] NGUYEN C H, KARAVAS G K, ARTEMIADIS P. Inferring imagined speech using eeg signals: a new approach using riemannian manifold features[J]. *Journal of Neural Engineering*, 2017, 15(1): 016002.
- [29] JAHANGIRI A, SEPULVEDA F. The contribution of different frequency bands in class separability of covert speech tasks for bcis[C]//2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Jeju: IEEE, 2017: 2093–2096.
- [30] MEROLA N R, VENKATASWAMY N G, IMTIAZ M H. Can machine learning algorithms classify inner speech from eeg brain signals?[C]//2023 IEEE World AI IoT Congress (AllIoT). Seattle: IEEE, 2023: 466–470.
- [31] LEE S H, LEE M, LEE S W. Neural decoding of imagined speech and visual imagery as intuitive paradigms for bci communication[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28: 2647–2659.
- [32] PAN H, XIE J, ZHANG D, et al. A complete scheme for multi-character classification using eeg signals from speech imagery[J]. *IEEE Transactions on Biomedical Engineering*, 2024, 71(8): 2454–2462.

- [33] LEE D Y, LEE M, LEE S W. Classification of imagined speech using siamese neural network[C]//2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Toronto: IEEE, 2020: 2979–2984.
- [34] NG H W, GUAN C. Subject-independent meta-learning framework towards optimal training of eeg-based classifiers[J]. *Neural Networks*, 2024, 172: 106108.
- [35] MACÍAS-MACÍAS J M, PALOMAR-VÁZQUEZ J, SEPULVEDA-CANO L M, et al. Interpretation of a deep analysis of speech imagery features extracted by a capsule neural network[J]. *Computers in Biology and Medicine*, 2023, 159: 106909.
- [36] 刘晓龙, 杨帮华, 甘安安, 等. 基于 CAM-Net 模型的中文词语语言想象脑电解码研究 [J]. *生物医学工程学杂志*, 2025, 42(3): 473–479.
- [37] LI C, ZHANG J, ZHANG D, et al. Decoding bilingual eeg signals with complex semantics using adaptive graph attention convolutional network[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 249–258.
- [38] JIANG M, DING Y, ZHANG W, et al. Decoding covert speech from eeg using a functional areas spatio-temporal transformer[J/OL]. *arXiv preprint*, 2025. DOI:
- [39] METZGER S L, LITTLEJOHN K T, SILVA A B, et al. A high-performance neuroprosthesis for speech decoding and avatar control[J]. *Nature*, 2023, 620: 1037–1046.
- [40] DÉFOSSEZ A, CAUCHETEUX C, RAPIN J, et al. Decoding speech perception from non-invasive brain recordings[J]. *Nature Machine Intelligence*, 2023, 5: 1097–1107.
- [41] DUAN Y, ZHOU J, WANG Z, et al. DeWave: discrete eeg waves encoding for brain dynamics to text translation[J/OL]. *arXiv preprint*, 202