去噪了，但并未改善：脑电去噪对下游任务的影响

鲍祥龙、王哲、王可文、金明*格里菲斯大学信息与通信技术学院，澳大利亚布里斯班 xianglong.bao@griffithuni.edu.au, {zhe.wang,k.wang}@griffith.edu.au, mingjinedu@gmail.com*通讯作者

arXiv:2611.29256v1 [cs.LG] 22 Nov 2026

摘要——头皮脑电图（脑电图）在输入下游模型前通常会先进行去噪，而去噪文献通常依据输出与干净参考波形的接近程度来评价方法。但真实的头皮脑电记录并不存在这样的参考：它是通过向被假定为干净的信号中添加伪迹模板合成的；即使能够实现精确分离，得到的也只是经容积传导模糊后的皮层活动，而非活动本身。因此，对该参考的保真度是一个无法验证的优化目标，而它能否预测任何下游收益，也几乎未受检验。本文报告了一项对此问题的审计。在固定癫痫发作检测流程、仅改变预处理阶段的条件下，我们发现，涵盖解析式、跨通道和有监督深度学习类别的五种标准去噪方法，均未能优于未处理信号，且大多数方法反而使其性能下降。为了说明这一阶段应当发挥什么作用，我们提出一种仅标签、无分类器探针，通过其在任务相关特征上诱导的可分性几何结构来评估变换，并将任何变化分解为类间距离项和类内散度项。对于一种确实能提升任务表现的变换，该探针发现，全部收益都来自类内散度约四分之一的降低，而类别分离在统计上没有变化。因此，下游模型受益于对任务相关结构的方差抑制，而波形保真度指标既无法衡量这一点，也不会对此给予奖励。

索引词—脑电图、信号去噪、生物医学时间序列

I. 引言

头皮脑电图（EEG）是皮层活动的一种退化观测。信号经颅骨和头皮进行容积传导后，底层神经源会变得模糊 [1],；来自眼睛、肌肉和记录环境的颅外干扰也会与神经内容重叠 [2]。因此，去噪几乎是脑电图处理流程中普遍存在的预处理阶段：它接收原始记录，并输出形状相同的信号，供下游模型作为输入。传统去噪器会分解多通道记录，并丢弃被判定为伪迹的成分 [3]–[5], 收缩小波展开 [6], 或拒绝方差超过校准统计量的片段 [7]。深度去噪器则以神经网络取代这些规则，该网络经过训练，能够根据受污染的记录回归出干净的记录 [8]–[11]。

几乎所有方法的开发和报告都围绕同一个目标：波形保真度，即去噪输出与干净参考之间的一致程度，通常用相对均方根误差或相关系数来衡量。难点在于，真实的头皮脑电记录并不存在这样的参考。深度去噪器通过合成来获得参考：将伪迹模板添加到记录中，而这些记录本身也只是被假定为干净的，因此神经网络学到的是设计者设定的腐蚀过程，而不是头皮实际产生的过程。传统去噪器不需要模板，但它们执行的分离是盲目的 [3] ，其结果也无法观测，因此只能依靠启发式方法标记成分，而真实标签无法对其进行检验。这两类方法都面临一个更根本的障碍：即便实现了精确分离，得到的仍是经容积传导模糊后的皮层活动 [1], [12]，而非活动本身。因此，即使从原理上说，也不存在可供验证的干净头皮目标。

无法验证的目标并不一定是错误的，但这确实意味着必须依赖某种外部检验。最自然的检验是去噪旨在服务的下游任务，而这恰恰是去噪文献最少报告的内容：方法通常根据对合成参考信号的保真度进行比较，随后便在假设两者变化趋势一致的前提下，将其部署于任务模型之前。本文将考察这一假设。

我们提出两项贡献。**(i)**我们报告了一项受控审计。在完全固定临床癫痫发作检测流程、仅改变预处理阶段的情况下，我们评估了五种标准去噪方法，涵盖解析型、跨通道型和有监督深度学习型方法。没有任何方法优于未处理信号；在二元 F1 和马修斯相关系数方面，每种方法的表现都低于未处理信号，而且有监督方法还直接破坏了发作期与发作间期窗口的排序。因此，采用这些方法对头皮信号进行去噪，并不足以帮助使用该信号的模型。**(ii)** 我们将仅基于标签的探测器of [13],形式化，该探测器描述预处理阶段在没有任何干净参考的情况下所做的事情。它在临床形态学描述符空间中测量任务类别之间的可分性，并将任何变化分解为类间距离项和类内散度项，从而区分抑制干扰方差的阶段与放大类别结构的阶段。

对于确实改善任务的变换，全部增益都归因于类内散度约四分之一的降低，而类别分离在统计上没有变化。根据这些证据，下游模型受益于对任务相关结构中的方差进行抑制，而这并不是波形保真度评分所衡量的内容。

II. 为什么无法验证波形保真度

将感兴趣的神经活动表示为潜在过程 $s(t)$。头皮电极观测到

$$x(t) \;=\; A\,s(t) \;+\; \zeta(t), \tag{1}$$

其中， A 表示信号经由大脑皮层与头皮之间组织层的容积传导， [1] 而 ζ 则汇集了由眼睛、肌肉和记录环境带来的颅外干扰 [2]。去噪器是一个映射 h ，它返回形状相同的 $\tilde{x} = h(x)$，旨在使其比 x更接近神经内容。

式（1）的两个性质妨碍了对 h进行任何基于保真度的评估。首先，分解过程不可观测：仅凭 x，无法明确地将 ζ 与 As 分离，因此恢复第一项是一个盲源分离问题，其解永远不会显现 [3], ，而且无法在真实记录中衡量给定的 h 在多大程度上实现了这一目标。其次，也是更根本的一点，目标本身无法实现： A 是非单射的，因此即使预言机能够精确去除 ζ，留下的仍会是 As，即 s 的模糊图像，而非 s [1]、[12]。对于头皮脑电记录，不存在任何能以神经过程为正确输出的操作，因此也就没有可据以定义保真度的参照。

基准测试通过构造参照来解决这一问题。将一段被认为是干净的记录指定为 x_{clean}，以受控的信噪比向其中添加伪迹模板，得到x_{noisy}，再拟合 h，并根据h（x_{noisy}）与 x_{clean} [8]的一致程度进行评分。这样一来，目标就有了明确的定义，但这只是转移了问题，而非回答问题。评分现在衡量的是 h 对既定损坏模型的逆变换效果，而 x_{clean} 会继承这一假设未能察觉的所有污染；此外，根据上述论证，它无论如何仍只是模糊的观测。因此，去噪器即使取得很高的保真度评分，也未必对任何使用其输出的对象更有用；而且，保真度评分本身并不能揭示它是否变得更有用。

这并不是说以保真度为训练目标的去噪器毫无价值，而是说保真度不能作为最终评判标准。第三节和第四节提供了两种外部评估：下游任务，以及预处理所诱导的可分性几何结构。

III. 仅标签可分性探针

下游任务才是重要的评判标准，但单凭任务得分只能说明预处理阶段是否有所助益，却无法说明它做了什么；而且，得分还会受到该阶段与其上训练的模型之容量和归纳偏置的共同影响。因此，我们还需要第二种评估方式：它独立于任何训练好的模型，无需干净参考，并能以易于解读的形式报告影响。以下探针改编自 [13], ，符合这些要求；它只需要任务本身已有的类别标签。

特征空间。我们将每个信号窗口映射为六种长期用于临床脑电图分析的形态学描述符：线长 [14],，这是经典的癫痫发作生物标志物；三个Hjorth参数——活动、迁移率和复杂性 [15]；峰度 [16]；以及过零率 [17]。这些描述符固定不变、易于解释且计算开销低，并且都不是通过学习得到的，因此探针无法调整自身以偏袒某种特定方法。

可分性指数。设 $\mu_{\text{ict}}, \mu_{\text{int}}$ 为该特征空间中的类别质心，σ^2_{ict},σ^2_{int} 为它们的类内离散度。我们通过标准化均值差来衡量类间可分性——即 Cohen's d [18]，等价于信号检测理论中的灵敏度指数 [19],

$$d = \frac{\|\mu_{\text{ict}} - \mu_{\text{int}}\|}{\sqrt{\frac{1}{2}\left(\sigma^2_{\text{ict}} + \sigma^2_{\text{int}}\right)}} = \frac{\Delta_{\text{between}}}{\bar{\sigma}_{\text{within}}}. \tag{2}$$

该指标在处理前后分别针对每位受试者计算，然后在受试者之间进行配对检验，因此每位受试者都作为自身的对照，不会引入受试者之间的变异。

分解。 公式（2）的价值在于，它是两个可以分别测量的量之比，因此，对于任何使该比值升高的处理阶段，都可以追问其如何实现。只有两种途径。它可能增加分子 Δ_{between}，使类别质心彼此分离；我们称之为模式分离，这正是放大类别特异性结构的操作所产生的效果。或者，它可能减小分母 $\bar{\sigma}_{\text{within}}$，使每个类别更集中于其质心周围；我们称之为噪声抑制，这正是去除与标签不相关的变异的操作所产生的效果。分别报告这两个项，可以将不透明的改进转化为关于机制的说明。这一区分在临床上很重要：放大其认定为病理性内容的处理阶段，与抑制所有不携带标签信息的内容的处理阶段，是性质不同的对象，具有不同的失效模式。

性质。 该探测器不需要干净参考，因为它从不将输出与目标进行比较；不需要经过训练的分类器，因为它直接读取特征空间；也不需要进行自身拟合。因此，它的成本足够低，可以对每种候选方法运行；不会被仅仅适合某个特定下游架构的方法钻空子；并且它是任务得分的补充，而非替代。

IV. 审计

A. 设置

流程。 所有实验均使用同一流程，即 [13], ，其中预处理阶段是唯一的自由组件。任务是在 CHB-MIT [20],这一来自波士顿儿童医院的儿科头皮脑电数据库上进行癫痫发作检测；我们保留了 22 名患者，排除了一名通道数据无法读取的患者和一次重复记录 [21]。记录采用 18 通道纵向双极导联，以 256Hz 采集，并按 1s 步长分割为 4s 时间窗；如果某个时间窗与临床医生标注的癫痫发作重叠至少 50%，则将其标记为发作期。评估采用受试者相关的留一记录交叉验证：在同一患者的其余记录上进行训练，因此被留出的记录中的任何时间窗都不会泄漏到训练中。这样可得到每位患者的得分分布，从而支持全文所使用的跨患者配对检验。下游模型为 EEGWaveNet [21]，这一卷积式癫痫发作检测器，按照其原始方案进行训练，并且从未获知其输入经过何种预处理。

指标。 癫痫发作数据严重不平衡，发作间期背景时间窗的数量远远多于发作期时间窗，因此，即使检测器

表 I 使用 EEGWAVENET 作为主体模型，在 CHB-MIT 上进行下游癫痫发作检测。每一行仅在流程中一个固定位置所用的预处理上有所不同；主体模型、其训练方案、交叉验证划分和指标始终相同。分数为 22 位患者的平均值，数据如 [13] 所示。

预处理	BF1	Sn	Pr	平衡准确率	马修斯相关系数	受试者工作特征曲线下面积
无（原始信号）	0.681	0.717	0.706	0.852	0.688	0.955
小波阈值处理	0.657	0.733	0.654	0.852	0.662	0.955
ASR	0.667	0.732	0.690	0.848	0.674	0.953
ICA	0.661	0.697	0.705	0.841	0.671	0.956
EEGdenoiseNet（眼电）	0.604	0.651	0.630	0.817	0.611	0.945
EEGdenoiseNet（肌电）	0.626	0.661	0.650	0.823	0.631	0.939
阳性对照	**0.749**	**0.776**	**0.774**	**0.882**	**0.754**	**0.972**

主要预测背景，传统准确率也会接近 100%。因此，我们报告六项在类别不平衡时仍具参考价值且不受多数类主导的指标：发作期类别的二元 F1（BF1）、灵敏度（Sn）、精确率（Pr）、平衡准确率（BAcc）、马修斯相关系数（MCC）和受试者工作特征曲线下面积（AUROC）。

受审查的去噪器。 我们评估了五种去噪器，涵盖了脑电去噪所涉及的各类方法。小波阈值处理 [6]将每个通道展开到小波基上，根据最精细尺度估计噪声水平，并将低于通用阈值的系数收缩；其字典是解析构造的，而非通过学习获得。伪迹子空间重建(ASR) [7]根据每段记录中方差较低的部分进行校准，并重建方差超过阈值的成分。独立成分分析(ICA) [4] 将每段记录分解为相互独立性最大的成分，并丢弃峰度表明其为伪迹的成分 [5]。这三种方法均为无监督方法。*EEGdenoiseNet* [8] 则采用有监督方法；按照基准测试自身的方案，针对每种伪迹类型分别训练一个神经网络，我们使用基准测试中的配对数据，在受控信噪比下训练其新型卷积神经网络，分别处理眼部（EOG）和肌源性（EMG）污染，从而得到两种受审查的去噪器。

阳性对照。 仅报告失败的审计无法区分“没有任何方法能改善这项任务”和“这些去噪器无法改善这项任务”。因此，我们纳入一种已知能改善该流程的变换，将其置于相同位置，并使其输出与输入形状相同 [13], ，在第四节 C 中用它来探究有益的处理阶段会产生什么作用。它刻意不是去噪器：它从未经过移除任何伪迹的训练，也不优化任何保真度准则。它是一种带有残差向量量化瓶颈的卷积编码器-解码器，属于为神经音频编解码器开发 [22] 、后来应用于脑信号的模型 [23]„其量化方式是将每个潜在步与四个各含 256 个条目的残差码本进行匹配。这里有两项重要特性。首先，它是在 SWEC 数据库中 16 名术前癫痫患者的颅内脑电图上拟合的 [24], ，这种模态能够观测皮层活动，且污染少得多，因为电极绕过了主要的头皮传导路径 [25], [26]；因此，它在拟合期间从未接触过头皮脑电记录，也不需要干净的头皮目标。其次，它随后被冻结，按通道应用，且从不针对任务进行调优，因此它是一种固定变换，与五种经审计的去噪器完全相同。

B. 没有经过审计的去噪器能够改善任务

表 I 报告了审计结果。五种方法中没有一种优于原始信号。每一种方法在二元 F1 和马修斯相关系数这两个最不宽容于检测器在两类错误之间进行权衡的指标上都低于原始信号；对于有监督的两种方法而言，这一差距并非微不足道：与完全不进行处理相比，它们的二元 F1 分别下降了 0.077 和 0.055。

无监督方法和有监督方法的失败形态不同，而受试者工作特征曲线下面积一列将二者区分开来。小波阈值处理、ASR 和独立成分分析的受试者工作特征曲线下面积与原始信号相差不超过 0.002，因此它们几乎没有改变模型对发作期与发作间期窗口的排序方式；它们改变的是工作点所处的位置，这一点可从精确率一列看出：小波阈值处理牺牲了 0.052 的精确率，换取 0.016 的灵敏度。这三种方法对于任务而言几乎不起作用：它们移除了检测器原本没有利用的方差，却也牺牲了一部分检测器确实利用的方差。有监督方法的表现更差，使受试者工作特征曲线下面积分别下降 0.010 和 0.016，从而破坏了排序本身，而这一点无法通过任何阈值恢复。这正是第 II 节所预见的情况：一个旨在逆转书面描述的损坏模型而训练的神经网络，针对一个不仅无法验证、而且在此处明显错位的标准进行了优化，因为它学会移除的、被归因于眼电或肌源性污染的结构，与检测器原本利用的结构发生了重叠。

相比之下，阳性对照改善了每一项指标：二元 F1 提高 0.068，马修斯相关系数提高 0.066，受试者工作特征曲线下面积也有所上升，因此即使消除了任何阈值效应，这种提升依然存在。因此，这项任务并非无法从预处理中获益。这个变换与五种去噪器的区别并不在于它更擅长去除伪迹：它完全不接触头皮数据，也不优化任何保真度准则。下一小节将探讨它实际做了什么。

C. 有效阶段实际发挥的作用

我们按照第 III 节的方法，对阳性对照逐位患者进行探测，涵盖相同的 22 位患者和相同的时间窗。在联合六描述符空间中，可分性从原始信号上的 d =0.93 上升至 $d = 1.26$ ，增幅为 35%；根据 Wilcoxon 符号秩检验，这种提升在患者间具有统计学显著性，达到 $p < 10^{-6}$ 。该效应并非由某一个描述符单独驱动：如图 2 所示，六个描述符各自均显著改善，其中线长、Hjorth 活动度和峰度达到 $p < 0.001$，Hjorth 复杂度和过零率达到 $p < 0.01$，Hjorth 移动度达到 $p < 0.05$。

分解该指标，可以回答任务得分无法回答的问题。图 1 分别报告了公式（2）的两个项。类间质心距离 Δ_{between} 在统计上没有变化：处理后，发作期和发作间期活动之间的距离并未比处理前更远。类内散度 $\bar{\sigma}_{\text{within}}$ 下降了约四分之一，在 $p < 0.001$ 水平上具有统计显著性；仅这一项就足以解释 d 的全部上升，这与公式（2）的比值关系一致。因此，从第 III 节所述的意义上说，这种变换纯粹是噪声抑制器，而非模式增强器。它并没有

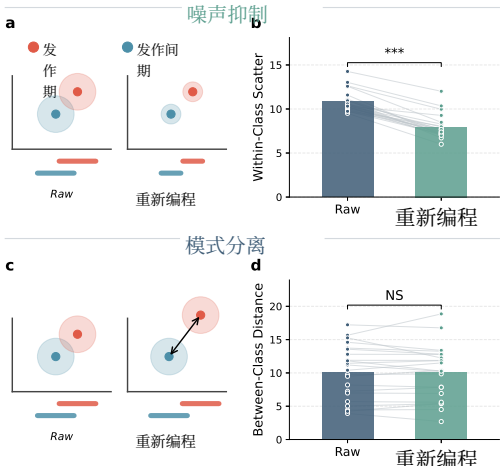

图 1. 对 22 位患者在阳性对照下的可分性变化进行分解。**(a, b)** 噪声抑制：类内散度 $\bar{\sigma}_{\text{within}}$ 下降约四分之一。**(c,d)** 模式分离：类间质心距离 Δ_{between} 没有变化。坐标轴标签：原始 表示未处理信号，重新编程 表示阳性对照的输出。圆点代表各位患者，并以线连接不同条件下的结果； $^{***}p < 0.001$, NS = 表示差异不显著，采用跨患者 Wilcoxon符号秩检验。改编自 [13]。

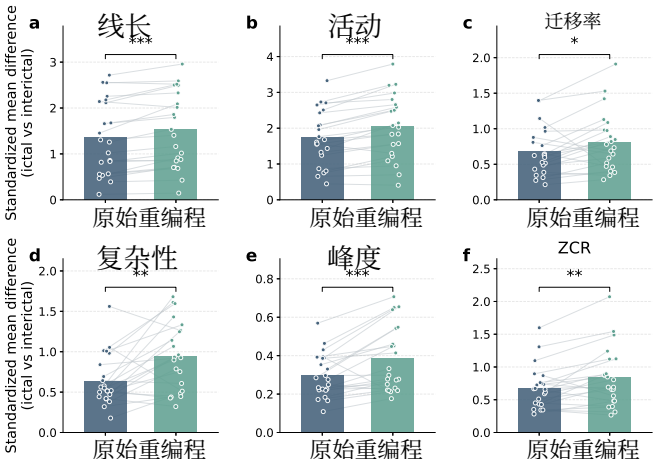

图 2. 阳性对照前后各描述符的可分性。每个面板对应一个形态学描述符，每个圆点表示一位患者在发作期与发作间期窗口之间的标准化均值差，并以线连接不同条件下的结果（重新编程 表示阳性对照输出）。六项指标均显著改善（$^{*}p < 0.05$、 $^{**}p < 0.01$、 $^{***}p < 0.001$），因此整体增益广泛存在，并非由某一项统计量单独带来。改编自 [13]。

让癫痫发作看起来更像癫痫发作；它只是让每个类别内部更加一致，削弱那些会增大类内散度、却不携带标签信息的变化，同时保留了区分类别的结构。

这对于临床流程而言，是一种令人安心的机制。若某个阶段通过拉开质心来提高可分性，就会重塑下游诊断所依据的证据，并以最难察觉的方式失效：让临界窗口看起来更明确地属于它所偏好的类别；而仅缩小 $\bar{\sigma}_{\text{within}}$ ，并不意味着对任何单个窗口作出这样的判断。

D. 讨论

综合来看，这两种读出揭示了去噪文献未曾指出的一点。阳性对照之所以有用，是因为它降低了任务相关特征的类内散度；而保真度评分无法衡量这一属性：保真度是针对每个时间窗、相对于参考波形计算的，并不会考虑一组时间窗相对于任务类别结构的分布情况，而收益恰恰出现在这一方面。更糟的是，这两个目标可能相互冲突。以最大化与逐窗参考信号的一致性为目标的去噪器，会因保留参考信号中的每一种波动而得到奖励，包括会增大 $\bar{\sigma}_{\text{within}}$ 的受试者特异性和会话特异性变异；而有助于任务的操作，则会舍弃这些变异。五种经审计的去噪器并非没有做好本职工作；它们所做的工作，其目标从未经过核查，以确认是否符合流程的实际需求。

由此得出的建议简单且成本低廉。对于任务流程中提出的去噪，应在其他条件均固定的流程下，至少报告一个下游任务评分，并使用公式（2）的双项读出，该读出仅需要类别标签。后者可以区分这样两个阶段：一个是抑制干扰因素的阶段，另一个是制造类别结构的阶段；仅凭保真度评分或任务评分无法看出这种区别。

局限性。 审计范围有意设置得较窄，以便将预处理作为唯一的自由变量：一个任务、一个语料库和一个下游架构。表 I 中的排序是否适用于其他任务，尤其是类别结构有所不同的非病理性任务，仍有待研究。我们将探测器应用于原始信号和阳性对照；若对每个接受审计的去噪器都运行该探测器，便可判断它们的失败是否具有共同的几何特征。此外，该方法评估的是一个为临床可解释性而选定的固定六描述符空间，因此某个阶段可能通过这些描述符无法表达的结构发挥作用。

V. 结论

我们在一个固定的临床癫痫发作检测流程中审计了五种标准头皮脑电去噪方法，发现没有一种优于未处理信号；有监督的方法甚至直接拉低了无阈值排序。由于这些方法优化的保真度目标无法在真实头皮脑电记录上得到验证，我们提出了一种仅依赖标签、与分类器无关的探测器，通过预处理阶段所诱导的可分性几何结构来分析该阶段。在一种确实有帮助的变换中，探测器将全部增益归因于类内散布约四分之一的减少，而类别分离没有变化。因此，下游模型受益于对任务相关结构的方差抑制，而保真度指标既无法衡量，也不会对此给予奖励。

伦理与生成式人工智能的使用。 所有记录均来自公共语料库，已去标识化，并依据其来源机构的伦理批准和数据使用协议发布；本分析不会解码任何私人心理内容。大语言模型助手仅用于提高文字表述的清晰度，并协助进行 LaTeX 格式排版；它未生成任何思想、方法或结果。

参考文献

[1] P. L. Nunez 和 R. Srinivasan，《脑电场：脑电图的神经物理学》。牛津大学出版社，2006年。[2] J. A. Urigüen 和 B. Garcia-Zapirain，“脑电伪迹去除——现状与指南”，《神经工程学杂志》，第12卷，第3期，第031001页，2015年。[3] T.-P. Jung、S. Makeig、C. Humphries、T.-W. Lee、M. J. McKeown、V. Iragui 和 T. J. Sejnowski，“通过盲源分离去除脑电伪迹”，《心理生理学》，第37卷，第2期，第163–178页，2000年。[4] A. Hyvärinen 和 E. Oja，“独立成分分析：算法与应用”，《神经网络》，第13卷，第4–5期，第411–430页，2000年。[5] A. Delorme、T. Sejnowski 和 S. Makeig，“利用高阶统计量和独立成分分析增强脑电数据中的伪迹检测”，NeuroImage，第34卷，第4期，第1443–1449页，2007年。[6] D. L. Donoho 和 I. M. Johnstone，“通过小波收缩实现理想的空间自适应”，《生物统计学》，第81卷，第3期，第425–455页，1994年。[7] T. R. Mullen、C. A. Kothe、Y. M. Chi、A. Ojeda、T. Kerth、S. Makeig、T.- P. Jung 和 G. Cauwenberghs，“利用可穿戴干式脑电图进行实时神经影像与认知监测”，《IEEE生物医学工程汇刊》，第62卷，第11期，第2553–2567页，2015年。[8] H. Zhang、M. Zhao、C. Wei、D. Mantini、Z. Li 和 Q. Liu，“EEG- denoiseNet：用于脑电去噪深度学习解决方案的基准数据集”，《神经工程学杂志》，第18卷，第056057页，2021年，第5期。[9] C.-H. Chuang、K.-Y. Chang、C.-S. Huang 和 A.-M. Bessas，“利用 ART 增强脑机接口：一种用于重建多通道脑电信号的伪迹去除变换器”，NeuroImage，第310卷，第121123页，2025年。[10] X. Huang、C. Li、A. Liu、R. Qian 和 X. Chen，“EEGDfus：用于细粒度脑电去噪的条件扩散模型”，《IEEE生物医学与健康信息学杂志》，第29卷，第4期，第2557–2569页，2025年。[11] B. J. Choi、G. Milsap、C. A. Scholl、F. Tenore 和 M. Ogg，“用于神经时间序列滤波的定向对抗去噪自编码器（TADA）”，arXiv 预印本 arXiv:2501.04967，2025年。[12] J. Kayser 和 C. E. Tenke，“在脑电图/事件相关电位研究中使用头皮表面拉普拉斯算子的问题与注意事项：教程式综述”，《国际心理生理学杂志》，第97卷，第3期，第189–209页，2015年。[13] X. Bao、Y. Ding、Z. Li、N. Liu、K. Wang、Z. Wang 和 M. Jin，“ 颅内脑电图可以帮助脑电图：通过颅内先验改进临床头皮脑电分析”，arXiv 预印本 arXiv:2611.20435，2026年，被 KDD 2027 接收。[14] R. Esteller、J. Echauz、T. Tcheng、B. Litt 和 B. Pless，“线长：一种用于癫痫发作起始检测的高效特征”，载于《IEEE医学与生物学工程学会第23届年度国际会议论文集》，第2卷。IEEE，2001年，第1707–1710页。[15] B. Hjorth，“基于时域特性的脑电分析”，《脑电图与临床神经生理学》，第29卷，第3期，第306–310页，1970年。[16] S. S. Alam 和 M. I. H. Bhuiyan，“在经验模态分解域中利用高阶统计量检测癫痫发作与癫痫”，《IEEE生物医学与健康信息学杂志》，第17卷，第2期，第312–318页，2013年。[17] J. Pyrzowski、J.-E. Le Douget、A. Fouad、M. Siemi´nski、J. J.edrzejczak 和 M. Le Van Quyen，“过零模式揭示头皮脑电图中的细微癫痫样放电”，《科学报告》，第11卷，第4128页，2021年，第1期。[18] J. Cohen，《行为科学统计功效分析》，第2版。Lawrence Erlbaum Associates，1988年。[19] D. M. Green 和 J. A. Swets，《信号检测理论与心理物理学》。Wiley，1966 年。[20] A. H. Shoeb，“机器学习在癫痫发作起始检测与治疗中的应用”，博士学位论文，麻省理工学院，2009年。[21] P. Thuwajit、P. Rangpong、P. Sawangjai、P. Autthasan、R. Chaisaen、N. Banluesombatkul、P. Boonchit、N. Tatsaringkansakul、T. Sud- hawiyangkul 和 T. Wilaiprasitporn，“EEGWaveNet：基于多尺度卷积神经网络的脑电癫痫发作检测时空特征提取”，《IEEE工业信息学汇刊》，第18卷，第8期，第5547–5557页，2022年。[22] A. Défossez、J. Copet、G. Synnaeve 和 Y. Adi，“高保真神经音频压缩”，arXiv 预印本 arXiv:2210.13438，2022年。[23]F. S. Carzaniga, G. T. Hoppeler, M. Hersche, K. Schindler 和 A. Rahimi，《更洁净生物信号的价值：高保真神经压缩器实现从更洁净的颅内脑电图到噪声更大的脑电图的迁移》，载于第十三届国际学习表征会议，2025年。[在线]。网址：https://openreview.net/forum?id=b57IG6N20B [24] A. Burrello、L. Cavigelli、K. Schindler、L. Benini 和 A. Rahimi，《Laelaps：一种基于长期人体颅内脑电图记录、不会产生误报的高能效癫痫发作检测算法》，载于*2019*年欧洲设计、自动化与测试会议暨展览会*(DATE)*。IEEE，2019年，第752–757页。[25] T. Ball、M. Kern、I. Mutschler、A. Aertsen 和 A. Schulze-Bonhage，《同步记录的侵入式和非侵入式脑电图的信号质量》，*NeuroImage*，第46卷，第3期，第708–716页，2009年。[26] J. Parvizi 和 S. Kastner，《人类颅内脑电图的前景与局限》，*Nature Neuroscience*，第21卷，第4期，第474–483页，2018年。