arXiv:2602.14071v2 [cs.OH] 5 Mar 2026

面向基于脑电图的驾驶疲劳识别的双向时序动态建模

Yip Tin Po*、Jianming Wang*、Yutao Miao、Jiayan Zhang、
Yunxu Zhao、Xiaomin Ouyang、Zhihong Li、Nevin L. Zhang

摘要—**驾驶疲劳是导致交通事故的重要因素，对道路安全构成严重威胁。脑电图（EEG）可直接测量神经活动，但基于脑电图的疲劳识别受到强烈非平稳性和不对称神经动力学的阻碍。为应对这些挑战，我们提出了 DeltaGateNet，这是一种新颖的框架，可显式捕获用于基于脑电图的驾驶疲劳识别的双向时间动态。我们的核心思路是引入双向增量模块，将一阶时间差分分解为正向和负向分量，从而能够显式建模不对称的神经激活与抑制模式。此外，我们设计了门控时间卷积模块，利用深度时间卷积和残差学习捕捉每个脑电通道的长期时间依赖关系，在保留通道特异性的同时增强时间表征的稳健性。在公开的 SEED-VIG 和 SADT 驾驶疲劳数据集上，针对被试内和受试者间评估设置开展的大量实验表明，DeltaGateNet 的表现始终优于现有方法。在 SEED-VIG 上，DeltaGateNet 的被试内准确率为 81.89%，受试者间准确率为 55.55%。在均衡 SADT 2022 数据集上，其被试内和受试者间准确率分别达到 96.81% 和 83.21%；在非均衡 SADT 2952 数据集上，其被试内准确率为 96.84%，受试者间准确率为 84.49%。这些结果表明，显式建模双向时间动态能够在不同被试和类别分布条件下实现稳健且具有泛化能力的性能。**

索引词—**驾驶疲劳识别，脑电图（脑电图），DeltaGateNet，双向增量，门控时间卷积**

I. 引言

DRIVING 驾驶疲劳被广泛认为是全球交通事故的主要诱因之一，尤其是在长时间、单调的驾驶场景中[1]。近期的大规模研究表明，疲劳导致的能力受损会使严重交通事故的风险增加数倍，对公共安全和交通运输系统构成重大威胁 [2]。与酒精影响或分心不同，疲劳是一种潜在且逐渐累积的认知状态，因此难以通过自我报告或事后分析进行可靠检测。因此，开发客观、实时且可靠的驾驶疲劳识别系统仍是一项关键但尚未解决的挑战。

现有的驾驶疲劳检测方法大致可分为非生理方法和生理方法[3]。行为分析、车辆动力学监测和基于计算机视觉的方法等非生理技术通常容易受到环境条件影响，且难以充分解读驾驶员的内部认知状态 [4],[5]。相比之下，生理方法——尤其是基于脑电图（EEG）的方法——能够更直接、客观地测量与警觉度和疲劳相关的神经活动。然而，许多基于脑电图的方法仍依赖手工设计的频谱特征或静态表征，无法充分刻画疲劳相关神经过程的时间演变 [6], [7]。尽管近期的深度学习模型展现出更强的表征学习能力，但大多数现有架构主要关注基于振幅的特征或通用时间建模，却在很大程度上忽略了神经动力学的双向特性以及脑电图记录中固有的通道间独立性 [8], [9]。

前述限制主要源于脑电数据复杂的时间特性，这些特性为可靠识别驾驶疲劳带来了重大挑战。首先，脑电数据具有显著的非平稳性，疲劳表现为缓慢且不规则的时间变化，而非突发的状态转变 [10]。其次，与疲劳相关的脑机制存在显著的双向不对称性，因为警觉性下降与代偿性神经激活并不遵循对称的时间模式 [11], [12]。第三，实际驾驶应用通常依赖数量有限的脑电通道，这限制了空间信息，并要求更加注重稳健的通道特异性时间建模 [13], [14]。这些限制共同制约了当前基于脑电图的疲劳识别技术的效率与泛化能力，尤其是在真实世界和跨受试者应用场景中。

借鉴非平稳脑电图建模、非对称脑部处理和时间卷积网络方面的既有研究，关键见解在于，与神经活动的绝对幅度相比，驾驶疲劳更准确地由其时间演变来定义 [10]。脑电信号中的双向时间变化为注意力下降和大脑抑制机制提供了重要洞见。基于这些见解，我们提出了一种名为 Delta-GateNet 的新框架，通过双向增量模块直接建模双向时间动态，并捕获长期

*这些作者对本研究的贡献相同。

依赖关系。双向增量模块将时间变化拆分为正向和负向成分，使网络能够区分不对称的神经元激活与抑制模式。门控时间卷积模块通过逐深度时间卷积和残差学习，跟踪每个脑电通道的时间动态，在保持空间辨别性的同时累积长程时间信息。

在 SEED-VIG 和 SADT 这两个公开驾驶疲劳数据集上，分别采用被试内和被试间评估设置进行的全面研究，证明了所提出的 DeltaGateNet 的有效性和鲁棒性。在 SEED-VIG 数据集上，DeltaGateNet 的被试内准确率为 81.89%，被试间准确率为 55.55%。在均衡 SADT 2022 数据集上，所提出的方法的被试内和被试间准确率分别为 96.81% 和 83.21%。值得注意的是，在非均衡 SADT 2952 数据集上也取得了相近的性能，DeltaGateNet 的被试内准确率达到 96.84%，被试间准确率达到 84.49%。结果表明，显式建模双向时间动态和通道级时间依赖关系，有助于基于脑电图稳健且具有良好泛化能力地检测驾驶疲劳，即使面对不同的被试分布和类别不平衡情况也是如此。

本文的主要贡献总结如下：

- 我们提出了 DeltaGateNet，这是一种新颖的基于脑电图的驾驶疲劳识别框架，通过双向增量模块显式建模双向时间动态，并利用门控时间卷积模块捕获与疲劳相关的长期依赖关系，从而在脑电通道配置有限的情况下，有效实现通道级时间表征。

- 我们在两个公开的驾驶疲劳数据集 SEED-VIG 和 SADT 上进行了大量实验，分别采用被试内和受试者间评估设置。所提出的方法始终优于现有方法，并在类别分布均衡和不均衡的情况下均表现出稳健的性能。

- 为促进研究结果的可复现性并推动后续研究，DeltaGateNet 的实现将作为开源项目发布于 https://jianmingwang1998.github.io/DeltaGateNet/。代码将在论文录用后发布。

II. 相关工作

基于脑电图的驾驶疲劳识别本质上是一个时间建模问题，因为疲劳反映了认知状态随时间逐渐、累积且通常具有非对称性的退化。从建模角度来看，现有端到端的基于脑电图的驾驶疲劳识别方法，可以根据时间动态的表示与约束方式进行系统分类。从这一角度出发，以往研究可分为四种范式：（1）隐式时间聚合；（2）多尺度对称时间建模；（3）全局时间依赖建模；以及（4）轻量级生理受限时间建模。

A. 隐式时间聚合

早期用于基于脑电图的驾驶疲劳检测的深度学习方法，大多采用卷积神经网络，通过固定大小的时间卷积核和池化过程隐式捕获时间信息。在这些方法中，时间动态并未得到显式建模，而是在网络优化过程中被嵌入为潜在特征。代表性研究采用基于协方差的卷积神经网络，从脑电图时段中捕获通道间关系 [15]，或采用紧凑型卷积架构，从单通道或低密度脑电图记录中提取疲劳相关模式[16]。这些设计减少了对手工设计元素的依赖，并表现出令人满意的性能，尤其是在被试内评估场景中。

然而，隐式时间聚合假设，在有限的时间感受野内即可充分捕捉与疲劳相关的脑电图特征。对于驾驶疲劳而言，这一假设存在局限，因为驾驶疲劳会在长时间驾驶过程中持续且非线性地发展。因此，完全依赖隐式时间编码的模型往往对细微的警觉性转变不够敏感，在跨受试者评估中的鲁棒性也较低。

B. 多尺度对称时间建模

为缓解固定时间感受野带来的局限，后续研究提出了显式多尺度时间建模方法。全卷积网络和Inception风格架构采用具有不同卷积核尺寸的并行时间卷积，以捕捉多个时间分辨率下的脑电图波动 [17], [18]。InceptionTime及其相关版本体现了这一范式，可同时建模短期波动和长期时间模式。残差时间卷积网络通过跳跃连接提升训练稳定性并促进特征传播，在各种时间序列分类任务中表现稳健 [17], [19]。

尽管多尺度时间建模提升了对异质时间模式的表征能力，但这些方法主要以对称方式处理时间变化，侧重于基于振幅的特征提取。因此，它们未能明确捕捉时间演变的双向特征，例如神经活动逐渐增强或减弱；这些变化与疲劳累积和警觉性下降密切相关。

C. 全局时间依赖建模

近年来，Transformer 和视觉Transformer等基于注意力的架构已被引入脑电图分析，以显式建模长程时间依赖关系。借助自注意力机制，这些模型能够捕捉相距较远的时间点和通道之间的交互。混合卷积神经网络–Transformer框架将局部卷积特征提取与全局注意力建模相结合 [20]，而基于ViT的方法则将脑电信号重新表示为图块序列或时频表示 [21]。

尽管全局依赖模型表现力强，但通常需要大规模数据集，并会带来显著的计算开销。此外，现有的大多数基于注意力的方法旨在学习通用的时间关系，却未显式编码时间变化的双向性，也未能保留通道级时间独立性。这些局限降低了它们在基于脑电图的驾驶疲劳识别中的实用性，尤其是在涉及通道数有限的可穿戴设备且数据可用性受限的真实场景中。

D. 轻量级生理约束时间建模

与此同时，一系列研究聚焦于轻量级且具有生理动机的脑电网络，以在性能、可解释性与计算效率之间取得平衡。EEGNet是一个代表性示例，它通过深度卷积与可分离卷积将空间与时间特征学习解耦，在显著降低模型复杂度的同时取得了具有竞争力的性能 [22]。后续研究通过调整时间卷积核尺寸、归一化策略和池化操作，将此类紧凑架构适配于疲劳相关任务 [23]。

尽管这些模型非常适合实时与可穿戴应用，但其时间建模能力在很大程度上仍是隐式的，并受预定义架构假设的约束。特别是，它们并未显式建模长时间驾驶疲劳中固有的非对称或双向时间动态，从而限制了其稳健刻画非平稳警觉性下降的能力。

III. 方法

本节提出了一种新颖的机器学习模型，擅长基于未经处理的原始脑电信号进行驾驶疲劳检测。我们的模型 DeltaGateNet 的概览如图 1 所示。具体而言，该模型由三个模块组成。首先，双向增量不包含可学习参数，但能够帮助简单模型学习脑电信号的深层表示，这一点将在第五节“实验结果”中验证。其次，信号被送入门控时间卷积模块，进一步提取和精炼脑电信号，并转换为维度为 H 的时间编码向量。最后，脑电信号被送入多层感知机进行处理和分类，输出与类别数量相对应的疲劳预测头。

A. 双向差分表示

在此模块中，我们旨在提取每个脑电输入通道的时间导数。对于每个脑电输入通道，算法计算 $\Delta x(t)$，如下式所示：

$$\Delta x(t) = x(t) - x(t-1) \quad \forall t \in \{1, 2, \ldots, T-1\}$$

其中，T 表示输入中的时间步数。这近似于脑电信号的时间微分，后者用于测量离散差分。它像高通滤波器一样突出快速变化，去除未经处理和未滤波的脑电信号中普遍存在的缓慢漂移和偏移。随后，时间导数经过修正线性单元处理，从而有效地将正微分与负微分分离，形成两个形状为 $x \in \mathbb{R}^{B \times C \times T}$ 的张量，其中 B 表示批量大小，C 表示脑电图输入通道的数量，T 表示时间步数。修正线性单元可由以下公式描述：

$$ReLU(x) = \max(0, x)$$

随后，沿输入通道维度拼接这两个张量，得到形状为 $\in \mathbb{R}^{B \times 2 \cdot C \times T}$ 的单个张量。鉴于导数特征已成功应用于音频信号处理，以捕捉时间动态 [24]，，我们将这一方法应用于脑电图分析。通过明确向网络提供分离后的正、负一阶微分，模型得以直接获取神经信号的双向趋势。脑对语音反应的研究发现，加入语音包络的半波整流导数可显著提高预测准确率 [25]。这表明，明确编码变化方向有助于下游建模。这些导数特征编码了快速波动及其极性，使网络能够分别学习上升波与下降波各自不同且互补的模式。由此得到的潜在表示更为稳健，也更不易受脑电图动态中受试者间差异的影响，因为模型关注的是基本时间形态，而非绝对振幅。

B. 门控时间卷积

门控机制在卷积序列模型中得到了充分的理论和实证支持。其基本思想是让卷积层通过学习得到的门控来调节输出，从而控制信息流。已有研究证明，基于门控线性单元的卷积神经网络比 ReLU 或双曲正切网络收敛更快，且困惑度更低 [26]。类似地，WaveNet[27] 和 Graph-WaveNet [28]采用门控膨胀卷积来捕捉长程依赖，从而提升音频与交通预测的性能。这启发我们设计一个模块，利用 GELU 激活函数所具备的选择性滤波特性。我们推测，其内在的随机门控行为能够根据幅值平滑地保留或抑制信息，因此尤其适合从含噪的非平稳脑电图输入中提取有意义的神经振荡。

在双向增量模块之后，门控时间卷积作为主要的特征提取模块。首先，将从双向增量模块传递而来的尺寸为 $x \in \mathbb{R}^{B \times 2 \cdot C \times T}$ 的张量通过卷积核大小为 1 的逐深度卷积进行投影。这会将信号投影到一个新的特征空间，其中 $x \in \mathbb{R}^{B \times 2 \cdot C \cdot D \times T}$，而 D 表示隐藏维度的数量。因此，可以为每个独立通道学习更深层的特征表示。

接下来，模型堆叠两个残差层块，以实现稳定训练，并使模型能够优化特征而

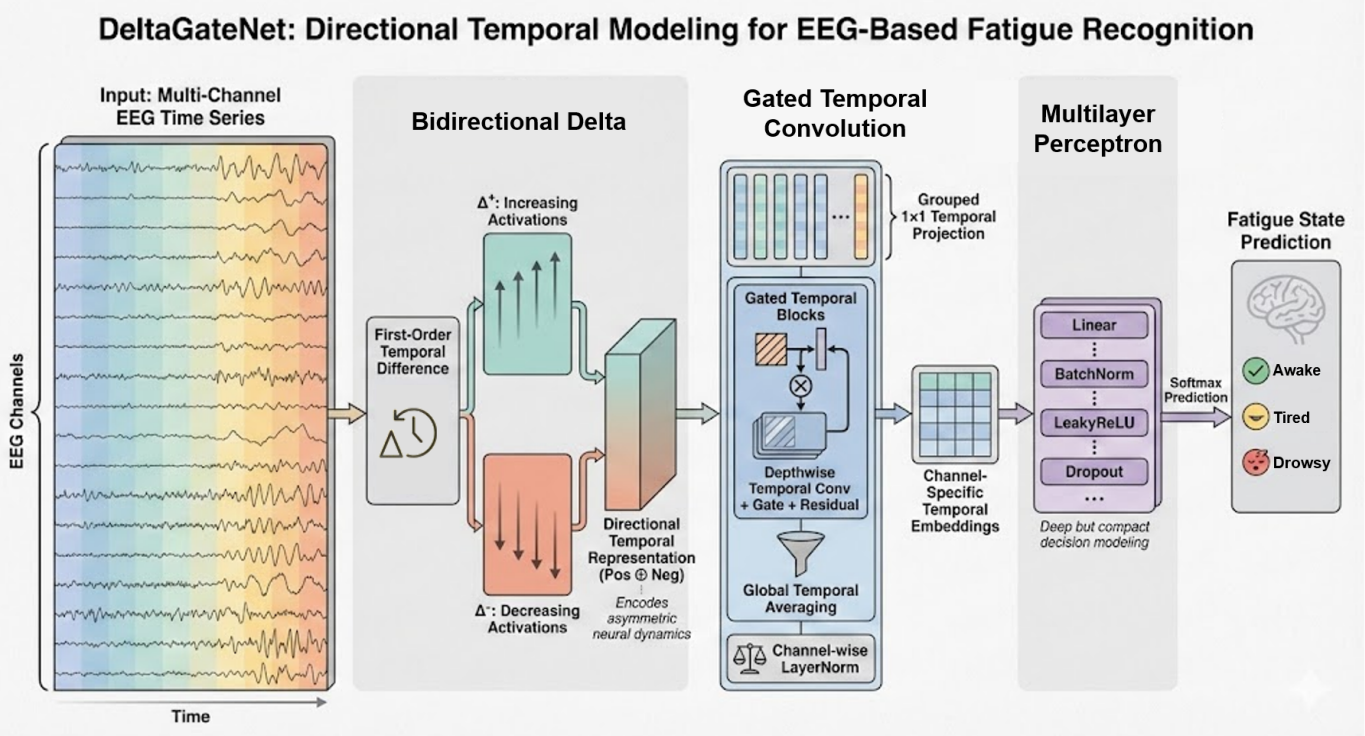


图 1. 所提出的 DeltaGateNet 概览。DeltaGateNet 是一种包含三个主要组件的简单结构。第一阶段是双向增量模块，用于计算跨时间步的微分。第二阶段是门控时序卷积块，用于编码时序特征，并利用软门控机制选择激活。第三阶段中，编码后的时序特征图被输入多层感知机，由其生成分别代表预测类别的三个概率。需要注意的是，在大多数实验设置和数据集中，随着时间推移，疲劳等级会同步增加，因为受试者在实验接近结束时更容易变得疲倦。

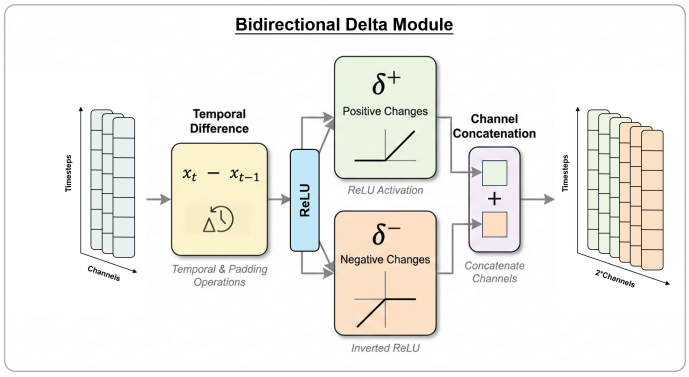


图 2. 双向增量模块计算一阶时序差分，用于近似疲劳所编码的脑电数据微分，因为疲劳会体现在随时间发生的变化中。该模块利用 ReLU激活函数，将变化分为正负差分，从而保留更丰富的时序信息，以供进一步处理。

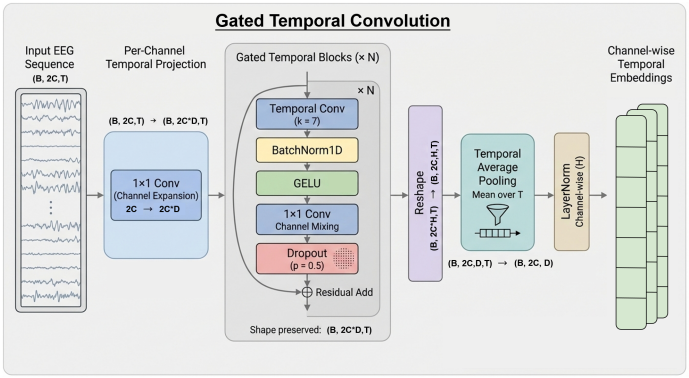


图 3. 门控时间卷积将微分投影到更高维的潜在空间，以提取更深层的信息，随后执行局部时间卷积来捕捉短期脑电信号。采用 GELU 激活函数和 1x1 逐通道卷积块来筛选需要传递的重要特征。残差块用于选择要放大或减弱的信号特征。

不丢失原始输入。每个残差块执行卷积核大小为 7、分组数为 $2 \cdot C \cdot D$ 的一维卷积，以提取每个通道深度的特征。由于卷积核大小为 1 x 7，因此它会提取各通道时间序列中的局部时间模式。随后进行批归一化操作，以防止特征发生内部协变量偏移。接着，使用 GELU门控选择最相关的特征进行激活。GELU 激活函数表示为：

$$\mathrm{GELU}(x) = x \cdot \Phi(x)$$

或更常见地近似为：

$$\mathrm{GELU}(x) \approx 0.5x \left(1 + \tanh\left(\sqrt{\frac{2}{\pi}}(x + 0.044715x^3)\right)\right)$$

采用了GELU 激活函数，因为高斯误差线性单元通常优于 ReLU 和 ELU 等传统激活函数。据报道，在计算机视觉、自然语言处理和语音任务中，GELU 的表现始终优于 ReLU/ELU。这些改进归因于 GELU 的平滑非线性特性，以及其在负输入下仍具有非零梯度

，这使其能够对信号进行更细致的门控[29]。随后，接入一个 1x1 卷积层，以混合不同特征通道。之后设置一个 dropout 层，以防止过拟合。

残差层有助于放大相关信号或减弱噪声信号 [30]。残差定义如下：

$$x \leftarrow x + f(x)$$

其中，x 是原始输入，$f(x)$是处理后的输入。当 $f(x)$与 x 对齐时，残差块会放大某些时间或通道维度的模式；由于 $f(x) \approx x$，因此$x \leftarrow 2x$，信号强度几乎翻倍。相反，如果 x与 $f(x)$呈负相关：

$$x + f(x) \approx 0$$

从而使较弱的信号强度在网络中传播 [31]。

经过残差块后，我们将张量重塑为 $x \in \mathbb{R}^{B\times 2\cdot C\times D\times T}$，这是一个四维张量。然后，我们沿时间维度进行平均池化，得到形状为 $x \in \mathbb{R}^{B\times 2\cdot C\times D}$的输出。因此，每个通道都有一个 D维特征向量，即时间嵌入，其中包含脑电信号的丰富表征。最后，对每个通道应用层归一化以提高稳定性。

总体而言，该模块将每个通道的序列转换为一组潜在特征 [32]。在脑电图分析中，沿时间维度进行的一维卷积能够自动学习滤波器组：它们可以直接从数据中建模带通滤波器和时间模式 [33]。卷积运算也可以解释为频域中的一种可学习滤波器 [32]，使网络能够突出节律性突发或缓慢漂移等模式。具体而言，逐通道卷积可确保每个电极独立处理，并聚焦于自身的时间结构。深度卷积层可以捕捉快速振荡，而更深层则将这些振荡整合为更广泛的趋势 [33]。通过端到端地学习这些特征，网络可以发现与疲劳相关的频率和波形模式，而无需显式计算傅里叶变换 [34]。

C. 多层感知机

在该模块中，大小为 $x \in \mathbb{R}^{B\times 2\cdot C\times H}$ 的池化特征被展平，形成大小为 $x \in \mathbb{R}^{B\times 2\cdot C\cdot H}$ 的张量。随后将这个二维张量输入由三个顺序连接的模块组成的多层感知机，每个模块均包含线性层、批归一化、带泄漏的线性整流函数和 Dropout 操作，生成对应于 k 个类别的 k 个逻辑值。然后，我们使用 $Softmax$ 将逻辑值转换为概率。Softmax 操作表示如下：

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

其中，i表示输出逻辑值中对应待计算输出概率的特定类别的索引。求和中的索引 j 遍历逻辑值向量中的所有元素，确保分母为每个输入元素指数值之和。

IV. 实验设计

A. 数据集

本研究使用两个用于警觉度估计的公开脑电图数据集：SEED-VIG 数据集和持续注意力驾驶任务（SADT）数据集。

1)SEED-VIG：SEED-VIG 数据集 [35] 是一个广泛使用的基于脑电图的驾驶疲劳检测基准数据集。数据采集自虚拟驾驶环境中的23名受试者（11名男性、12名女性，平均年龄23.3岁）。每位受试者均完成了一次约120分钟的驾驶试验，期间按照国际10–20系统，在17个电极通道上以200 Hz的采样率记录脑电信号。

疲劳等级根据通过眼动追踪眼镜测得的PERCLOS（眼睑闭合百分比）进行标注。具体而言，PERCLOS 值处于 $p \in (0,\ 0.35]$ 的样本标记为清醒，处于 $p \in (0.35,\ 0.7]$ 的样本标记为疲倦，处于 $p \in (0.7,\ 1]$ 的样本标记为困倦，其中 p 表示该时间间隔内的 PERCLOS [36] 值。本研究将每次试验划分为885个样本，每个样本包含8秒脑电数据。

2) 持续注意力驾驶任务（SADT）：SADT 数据集 [37] 于2019年发布，记录了受试者在近似真实的模拟驾驶环境中的驾驶员行为和脑活动。27名受试者执行了最长达90分钟的连续驾驶任务，期间车辆始终保持在车道中央。任务期间会定期出现车道偏离事件，要求驾驶员迅速作出反应，纠正车辆位置。

根据反应时间评估驾驶疲劳程度——即从车辆偏离车道到驾驶员作出纠正反应的时间间隔。该指标用于将每次试验标记为困倦或警觉。我们使用了该数据集的两个版本 [37]，一个包含来自11名受试者的2,952个样本 [38] 另一个包含来自11名受试者的2022个样本 [39]。每个样本包含30个通道采集的3秒脑电数据（在偏离事件发生前记录），采样率为 128 Hz。

B. 基线方法

为全面分析我们模型的性能，我们将其与八种基准模型进行了比较。这些模型包括旨在表征序列数据的时间序列分类模型、用于捕获脑电图数据深层表征的深度学习卷积神经网络模型，以及专门针对脑电数据进行调优的基于脑电图的模型。

1）时间序列分类模型：FCN Wang [40] 是一种稳健的基准架构，由三个依次排列的卷积块构成，卷积核大小分别为 8、5 和 3。此外，InceptionTime [41] 采用了六个堆叠的 Inception模块，其设计灵感源自 Inception V4架构。每个模块都整合了具有四种不同卷积核尺寸的并行卷积分支。此外，Resnet 1D Wang [40]采用了改进版的 FCN Wang，并加入了残差连接。在这一改进中，每个原始卷积块都扩展为三层，卷积核尺寸显著增大，分别为 64、128 和 256。

2）深度学习卷积神经网络与基于*Transformer*的模型：基于 ResNet 架构 [40]，XResnet101 模型 [42] 对其残差块进行了改进。为在降维过程中保留信息，下采样路径中加入了步幅为 2 的 2×2平均池化操作。视觉Transformer（ViT）将图像表示为一系列图块，并运用 Transformer 自注意力机制捕捉全局视觉关系，以理解图像 [43]。

3) 基于脑电图的模型：EEGNet [44] 采用深度卷积与可分离卷积，构建紧凑且灵活的网络架构，被广泛视为适用于多种脑电分类任务的最先进模型。改进版 TSception [45] 通过五层分层时间细化策略和自适应平均池化（ADP）增强时空特征提取，从而提升驾驶员困倦和心理负荷评估的稳定性。此外，GAT-CNN [46] 将图注意力网络与卷积神经网络相结合，并利用由互信息驱动的邻接矩阵对通道间依赖进行建模，以实现端到端的驾驶员疲劳检测。

C. 实现细节与评估指标

所有实验均使用 PyTorch 2.9.0 框架。我们使用了 Google Colab 提供的一块 A100 GPU，并进行了交叉验证实验，以确保结果可复现。我们采用 AdamW 优化器，学习率设为 1e-4，训练 200 个周期。批量大小设为 32，交叉验证的折数设为 5。对于这五折数据，我们将 60% 用于训练，20% 用于验证，20% 用于测试。数据划分方法如图 4 所示。为确保实验结果可复现，我们将随机种子初始化为 2026年，从而确保每次实验的数据分布相同。我们使用的指标包括样本的准确率、精确率、召回率和 F1分数。

准确率衡量跨所有类别的预测总体正确性。精确率量化被标记为正类的项目中实际为正类的数量。召回率表示真正的正类项目中被正确识别的数量。F1分数表示精确率和召回率的调和平均值。

V. 实验结果

本节详细介绍对所提出模型 DeltaGateNet 的评估。我们通过五折被试内和被试间实验评估模型性能，并将其与三类基线方法进行比较：时间序列分类模型、基于深度学习的卷积神经网络/Transformer模型，以及成熟的脑电图专用模型。此外，我们还开展了消融研究，以量化各模型组件的贡献。

A. 与先前模型的比较

1）被试内实验：表I展示了所有对比模型在 SEED-VIG 和两个 SADT 数据集上的被试内分类性能，该性能通过五折交叉验证进行评估。所提出的 DeltaGateNet

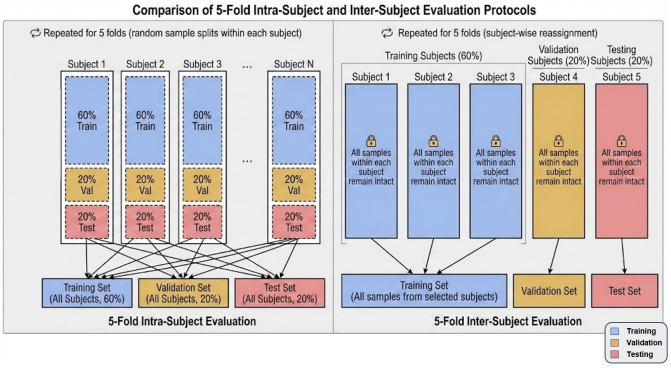


图4。 该图描述了我们的实验划分。我们通过进行5折交叉验证开展了全面的实验和评估，以验证结果的真实性。

在每个数据集的所有四项评估指标上均始终取得最高性能。

在 SEED-VIG 数据集上，DeltaGateNet 达到 $81.89 \pm 0.66\%$ 的准确率，比次优方法（TS-ception，$79.80 \pm 0.98\%$）高出近3个百分点。在精确率（84.37% 对比 81.26% ）、召回率（ 81.32% 对比 80.29% ）和 F1 分数（82.55% 对比 80.68%）方面，它同样表现出更优的提升。此外，DeltaGateNet 的准确率比 EEGNet 提高了8%。

在 SADT 2022 数据集和 SADT 2952 数据集上，DeltaGateNet 超越了所有最先进模型。令人惊讶的是，在多个数据集上，时间序列分类模型的表现优于基于脑电图的模型和基于Transformer的模型。

在基线模型中，时间序列分类方法通常表现良好，其中 InceptionTime 和 Resnet Wang 是实力强劲的竞争者。然而，DeltaGateNet 在几乎所有指标上都保持着明显且稳定的优势，验证了其在被试内疲劳识别中的有效性。相比之下，Transformer 和基于深度学习卷积的模型表现不如时间序列模型。这表明，用于测量驾驶疲劳的脑电数据，其表现并不直接取决于模型的规模或深度。

2）被试间实验：表II展示了更具挑战性的被试间分类结果，该结果通过五折跨受试者验证在 SEED-VIG 和 SADT 数据集上进行评估。在这一严格的跨被试范式下，我们提出的 DeltaGateNet 展现出卓越的泛化能力，在全部三个数据集上始终取得最高准确率。

在 SEED-VIG 上，DeltaGateNet 的准确率达到 55.55%，比表现最强的基线模型（FCN-Wang，48.91%）高出约 6.64 个百分点，展现出显著的性能提升。

在 SADT 2022 上，DeltaGateNet 的准确率达到 $83.21 \pm$ %，超过 InceptionTime（80.12%）3 个百分点以上，且方差更低。紧随 InceptionTime 模型之后的是 ViT 模型。DeltaGateNet 的准确率比 ViT 高 8 个百分点，这表明它相较于时间序列分类模型和基于 Transformer 的卷积神经网络模型具有更强的泛化能力。在 SADT 2952 上，DeltaGateNet 的准确率达到$84.49 \pm 7.3\%$，超过 FCN Wang（$82.99 \pm$

表I受试者内评估结果（五折交叉验证）

模型	SEED-VIG				SADT 2022				SADT 2952			
	Acc	Pre	Rec	F1	Acc	Pre	Rec	F1	Acc	Pre	Rec	F1
EEGNet	73.10 ± 1.94	75.44 ± 1.23	73.94 ± 1.46	73.97 ± 1.88	76.78 ± 7.41	81.34 ± 4.24	76.99 ± 6.84	75.69 ± 8.46	88.35 ± 2.78	89.01 ± 2.57	87.01 ± 3.21	87.68 ± 3.07
FCN Wang	68.03 ± 1.19	70.07 ± 1.62	68.38 ± 0.75	68.50 ± 0.97	96.33 ± 1.65	96.32 ± 1.63	96.37 ± 1.61	96.32 ± 1.64	96.66 ± 2.06	96.39 ± 2.20	96.52 ± 2.29	96.45 ± 2.24
InceptionTime	77.41 ± 0.63	79.13 ± 0.61	77.85 ± 1.07	78.30 ± 0.79	94.35 ± 4.98	94.32 ± 4.95	94.39 ± 4.98	94.34 ± 4.97	95.37 ± 3.13	95.30 ± 3.32	95.17 ± 3.06	95.22 ± 3.18
Resnet Wang	77.64 ± 0.68	78.92 ± 0.79	78.44 ± 0.82	78.61 ± 0.62	93.32 ± 5.28	93.70 ± 4.74	93.39 ± 5.08	93.30 ± 5.31	94.07 ± 3.32	94.50 ± 3.14	93.28 ± 4.01	93.74 ± 3.72
XResnet	63.71 ± 2.42	67.33 ± 2.01	63.20 ± 3.14	63.54 ± 2.66	85.42 ± 8.05	86.20 ± 7.57	85.31 ± 8.12	85.24 ± 8.22	88.84 ± 7.24	88.60 ± 7.43	88.25 ± 7.61	88.37 ± 7.50
ViT	71.59 ± 0.50	73.85 ± 1.13	71.9 ± 1.11	72.41 ± 5.8	86.53 ± 4.92	86.85 ± 4.96	86.57 ± 4.89	86.50 ± 4.92	88.42 ± 5.30	88.57 ± 5.45	87.65 ± 5.41	87.95 ± 5.38
TSception	79.80 ± 0.98	81.26 ± 0.80	80.29 ± 1.11	80.68 ± 0.95	82.51 ± 2.99	85.77 ± 2.62	82.46 ± 3.24	82.04 ± 3.27	73.07 ± 5.13	79.60 ± 5.02	67.54 ± 5.16	67.01 ± 6.56
GAT-CNN	66.52 ± 1.07	68.32 ± 3.23	66.68 ± 1.48	66.58 ± 1.29	71.30 ± 1.95	79.63 ± 1.99	57.31 ± 5.03	66.49 ± 3.31	71.61 ± 1.78	78.05 ± 2.96	44.01 ± 4.26	56.06 ± 2.75
DeltaGateNet	**81.89 ± 0.66**	**84.37 ± 0.52**	**81.32 ± 0.64**	**82.55 ± 0.58**	**96.81 ± 2.58**	**96.98 ± 2.34**	**96.80 ± 2.60**	**96.81 ± 2.59**	**96.84 ± 1.43**	**96.73 ± 1.41**	**96.81 ± 1.53**	**96.77 ± 1.47**

表II受试者间评估结果（五折跨受试者验证）

模型	SEED-VIG				SADT 2022年				SADT 2952			
	Acc	Pre	Rec	F1	Acc	Pre	Rec	F1	Acc	Pre	Rec	F1
EEGNet	44.64 ± 5.99	46.56 ± 8.93	43.21 ± 4.96	39.52 ± 4.73	68.99 ± 4.84	74.77 ± 6.49	68.99 ± 4.84	67.13 ± 5.10	77.01 ± 11.27	79.96 ± 11.07	76.00 ± 10.34	75.22 ± 12.49
FCN Wang	48.91 ± 8.05	50.10 ± 10.98	48.66 ± 9.10	46.16 ± 8.63	73.93 ± 10.29	75.33 ± 10.04	73.93 ± 10.29	73.48 ± 10.52	82.99 ± 11.61	82.46 ± 9.80	83.21 ± 12.18	81.14 ± 12.70
InceptionTime	47.05 ± 5.38	48.27 ± 5.26	45.98 ± 8.42	43.96 ± 8.73	80.12 ± 9.11	81.37 ± 8.28	80.12 ± 9.11	79.70 ± 9.71	76.03 ± 4.12	77.32 ± 2.30	75.90 ± 3.46	74.28 ± 3.55
Resnet Wang	45.61 ± 5.66	42.53 ± 9.46	44.66 ± 6.32	41.35 ± 8.49	72.67 ± 7.74	74.90 ± 6.82	72.67 ± 7.74	71.72 ± 8.61	72.47 ± 12.81	74.04 ± 12.42	71.65 ± 12.10	71.00 ± 13.66
XResnet	45.76 ± 4.28	48.32 ± 5.42	44.07 ± 4.78	42.09 ± 7.00	64.07 ± 9.99	72.52 ± 7.67	64.07 ± 9.99	58.91 ± 13.75	66.11 ± 6.25	68.18 ± 7.37	61.33 ± 6.34	58.74 ± 8.86
ViT	46.06 ± 4.62	47.75 ± 8.24	43.00 ± 4.90	40.40 ± 4.27	75.54 ± 6.38	77.03 ± 6.25	75.54 ± 6.38	75.13 ± 6.65	78.58 ± 4.60	77.46 ± 4.64	79.37 ± 6.28	77.37 ± 5.04
TSception	42.19 ± 3.90	42.98 ± 7.89	41.91 ± 5.61	38.64 ± 7.80	73.71 ± 4.68	76.89 ± 3.68	73.71 ± 4.68	72.79 ± 5.47	58.25 ± 7.80	66.38 ± 2.37	62.30 ± 2.66	55.56 ± 6.15
GAT-CNN	41.26 ± 5.99	37.96 ± 6.30	41.74 ± 3.84	36.22 ± 6.17	64.10 ± 6.80	79.42 ± 12.05	36.92 ± 10.17	50.15 ± 11.99	60.54 ± 12.75	57.80 ± 19.06	21.57 ± 17.43	29.06 ± 21.81
DeltaGateNet	**55.55 ± 3.96**	**54.20 ± 12.81**	**48.32 ± 7.60**	**47.32 ± 8.21**	**83.21 ± 6.25**	**84.18 ± 5.50**	**83.21 ± 6.25**	**83.03 ± 6.41**	**84.49 ± 7.36**	**85.66 ± 6.83**	**83.90 ± 5.85**	**83.92 ± 6.93**

表III消融评估结果（五折交叉验证）

模型	SEED-VIG				SADT 2022				SADT 2952			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
受试者内评估												
MLP	43.72±0.74	30.87±2.20	33.35±0.03	20.46±0.26	72.53±11.83	72.53±11.98	72.52±11.97	72.44±11.97	74.30±8.73	74.71±10.33	71.36±9.14	71.68±10.09
双向增量 + 多层感知机	54.03±1.69	64.69±2.99	45.59±1.37	43.13±1.01	87.71±13.04	87.72±13.07	87.66±13.15	87.64±13.17	87.07±10.12	86.17±11.08	86.18±11.26	86.14±11.17
门控时间卷积 + 多层感知机	71.01±1.12	71.87±0.96	71.81±1.26	71.67±0.96	92.17±2.94	92.28±3.01	92.17±2.99	92.15±2.95	93.30±3.35	93.43±2.95	92.86±3.80	92.99±3.52
DeltaGateNet	**81.89±0.66**	**84.37±0.52**	**81.32±0.64**	**82.55±0.58**	**96.81±2.58**	**96.98±2.34**	**96.80±2.60**	**96.81±2.59**	**96.84±1.43**	**96.73±1.41**	**96.81±1.53**	**96.77±1.47**
主体间评估												
MLP	43.86±7.98	24.96±8.41	33.37±0.87	22.09±3.47	69.73±10.06	71.61±7.16	69.73±10.06	66.62±15.90	70.28±12.88	69.98±14.39	65.25±10.71	65.87±12.16
双向增量 + 多层感知机	45.83±1.77	34.38±4.08	37.32±1.39	31.62±4.46	75.03±13.83	71.63±19.22	70.74±18.89	70.35±19.10	81.05±14.05	80.10±14.06	78.16±13.20	78.78±13.45
门控时间卷积 + 多层感知机	43.37±4.13	43.54±5.69	40.98±3.15	47.32±8.21	79.51±1.76	80.53±1.60	79.51±1.76	79.34±1.85	77.54±8.46	78.93±3.65	78.94±5.89	76.55±8.13
DeltaGateNet	**55.55±3.96**	**54.20±12.81**	**48.32±7.60**	**47.32±8.21**	**83.21±6.25**	**84.18±5.50**	**83.21±6.25**	**83.03±6.41**	**84.49±7.36**	**85.66±6.83**	**83.90±5.85**	**83.92±6.93**

11.61%），且方差更小，表现出更高的稳定性。

正如观察到的，在 SEED-VIG 数据集上，第一名与第二名之间的差距始终大于 SADT。这源于任务难度的根本差异：SADT 是一个二分类问题，而 SEED-VIG 则是未经筛选的三分类问题。这种更具挑战性的范式更能展现 DeltaGateNet 的先进学习能力。

这些结果证实，DeltaGateNet 不仅在受试者内评估中表现出色，还能稳健地泛化至未见过的受试者，其表现优于专用脑电图模型和通用时间序列分类器。这些主体间设置与现实生活中的检测场景更加接近。由于 DeltaGateNet 在多个数据集上优于不同领域的最先进模型，这表明 DeltaGateNet 已准备好部署以解决现实世界的问题。

B. 消融实验

1） 各个模块的影响：本节对各模块的学习能力进行了全面研究，并对模型开展了严格的实验与分析。结果汇总于表 III 中。此外，我们在更具挑战性的被试间分类实验中评估模型，以检验其在不同受试者之间的泛化能力。如表中所示，在所有模型和数据集上，被试间表现始终低于被试内表现，体现了跨被试泛化的难度。尽管如此，我们的最终模型在所有被试间设置下均取得最佳表现，展现出强大的泛化能力。

在 SEED VIG III 的被试内设置中，仅使用多层感知机的表现较差，为 43.72%。加入双向增量模块后，准确率提升至 54.03%。门控时间卷积 +多层感知机的准确率为 71.01%，而完整的 DeltaGateNet 达到 81.89%，这体现了两个模块的协同效应。这证明我们的模块能够从不同的潜在空间中提取特征。双向增量模块能够将模型的准确率提高 11%，展现出该模块强大的能力。它不仅能提升多层感知机等简单模型的性能，而且不包含任何可学习参数，从而使设计更加高效。在被试间设置中，我们的模型比次优基线（双向增量 +多层感知机）的准确率高 9.72%，展现出与被试内设置相似的学习能力。

在 SADT 2022 III 的被试内设置下，完整模型的准确率达到 96.81%，而门控时间卷积 +多层感知机为 92.17%，双向增量 +多层感知机为 87.71%。在被试间设置下，完整模型的准确率达到 83.21%

表IVSEED-VIG、SADT 2022和SADT 2952上的卷积核大小调优结果（五折交叉验证）

卷积核大小	SEED-VIG				SADT 2022				SADT 2952			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
受试者内评估												
K = 1	71.08±3.86	74.39±2.37	68.30±5.48	69.58±4.83	94.92±2.07	94.97±2.02	94.95±2.09	94.90±2.07	95.69±1.76	95.66±1.79	95.50±1.70	95.55±1.75
K = 3	73.04±3.81	77.27±3.57	70.43±5.01	72.12±4.77	96.56±2.08	96.97±2.03	96.95±2.14	96.81±2.59	95.75±1.85	95.65±1.99	95.62±1.84	95.62±1.91
K = 5	74.14±3.74	78.26±3.29	71.87±5.01	73.52±4.68	96.16±2.24	96.18±2.34	96.16±2.23	96.15±2.24	96.70±1.73	96.59±1.87	96.67±1.67	96.61±1.78
K = 7	**81.89±0.66**	**84.37±0.52**	**81.32±0.64**	**82.55±0.58**	**96.81±2.58**	**96.98±2.34**	**96.80±2.60**	**96.81±2.59**	**96.84±1.43**	**96.73±1.41**	**96.81±1.53**	**96.77±1.47**
主体间评估												
K = 1	48.73±4.03	49.30±9.92	42.36±5.44	37.72±5.58	65.72±17.05	67.64±20.15	63.34±21.36	62.87±20.17	78.74±6.78	79.76±7.22	78.01±7.99	77.25±8.22
K = 3	48.12±4.27	49.08±11.38	41.00±4.58	37.10±5.30	74.45±8.41	79.30±5.73	74.45±8.41	72.84±9.81	63.88±21.13	64.88±19.83	65.45±20.71	62.13±22.21
K = 5	43.37±4.13	43.54±5.69	40.98±3.15	47.32±8.21	82.25±11.86	88.26±6.88	85.25±11.86	84.10±14.05	77.75±8.82	79.56±6.16	78.51±7.90	76.91±9.02
K = 7	**55.55±3.96**	**54.20±12.81**	**48.32±7.60**	**47.32±8.21**	**83.21±6.25**	**84.18±5.50**	**83.21±6.25**	**83.03±6.41**	**84.49±7.36**	**85.66±6.83**	**83.90±5.85**	**83.92±6.93**

表五SEED-VIG、SADT 2022和SADT 2952上的步长调优结果（五折交叉验证）

步长	SEED-VIG				SADT 2022				SADT 2952			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
受试者内评估												
S = 1	**81.89±0.66**	**84.37±0.52**	**81.32±0.64**	**82.55±0.58**	**96.81±2.58**	**96.98±2.34**	**96.80±2.60**	**96.81±2.59**	**96.84±1.43**	**96.73±1.41**	**96.81±1.53**	**96.77±1.47**
S = 2	78.11±2.89	80.82±1.81	77.47±3.57	78.62±3.14	95.60±2.63	95.67±2.53	95.61±2.65	95.60±2.63	95.93±1.76	95.77±1.83	95.92±1.78	95.84±1.81
S = 3	78.10±2.41	80.55±1.69	77.67±2.98	78.69±2.61	95.12±2.79	95.13±2.81	95.16±2.80	95.12±2.80	95.90±0.84	95.89±0.75	95.66±1.05	95.74±0.87
主体间评估												
S = 1	**55.55±3.96**	**54.20±12.81**	**48.32±7.60**	**47.32±8.21**	**83.21±6.25**	**84.18±5.50**	**83.21±6.25**	**83.03±6.41**	**84.49±7.36**	**85.66±6.83**	**83.90±5.85**	**83.92±6.93**
S = 2	49.16±7.14	53.21±10.90	44.43±8.11	41.30±6.49	75.422±8.95	78.00±7.02	75.42±8.95	74.42±10.05	81.66±10.16	82.23±10.38	81.62±10.00	81.22±10.11
S = 3	47.51±8.76	50.25±11.32	43.16±7.15	39.33±7.19	81.28±12.27	82.60±12.04	81.28±12.27	81.03±12.38	81.70±12.25	83.53±9.42	81.90±10.49	79.69±12.39

准确率为 79.51%，而门控时间卷积 +多层感知机为 75.03%，双向增量 + 多层感知机则为 75.03%，展现了其在二分类数据集上的跨域能力，以及其应用于真实驾驶场景的可行性。

在 SADT 2952 III 上，完整模型再次展现出最佳性能，证实双向时间建模和逐通道编码对于捕捉疲劳相关动态都至关重要。DeltaGateNet 在被试间设置下达到 84.49% 的准确率，优于 GatedTemporal Conv + MLP 的 77.54% 和 Bidirectional Delta + MLP 的 81.05%。在被试内设置下，其性能更加突出，准确率达到惊人的 96.84%。

这些消融结果一致表明，双向增量模块和门控时间卷积模块都对模型性能有显著贡献，二者的完整集成在被试内和被试间评估中均实现了最高的准确率和鲁棒性。此外，二者的结合优于最先进模型，凸显了其从不同潜在空间中学习更丰富表示的能力。

2) 参数分析消融研究：除了将我们的模型与最先进模型进行全面比较外，我们还开展了研究，以考察模型的功能。我们进行了实验，测试门控时间卷积模块的卷积核大小和双向增量模块的步长，从而深入了解模型有效运行的原因。这些实验为理解模型的运行机制及其各组成部分之间的协同关系提供了关键洞见。

我们对卷积核尺寸 $K \in \{1,3,5,7\}$ 进行了实验，其中 K 表示一维卷积核的大小。我们还对步长 $S \in \{1,2,3\}$ 进行了实验，其中 S 表示双向模块的步长。

查看 SEED-VIG 数据集的表 IV 可以看到，当卷积核大小从 $K = 1$ 增加到 $K = 7$ 时，受试者内评估中的参数增加了 10%。类似的影响也体现在跨被试评估范式中。至于步长，我们发现步长越大，准确率越低。我们认为，这是因为随着步长增大，对微分的近似变得不够稳健。

表 IV 展示了我们针对 SADT 2022 数据集进行的参数分析。可以看出，随着参数逐渐接近我们的最优参数，准确率逐渐提高，方差也随之降低，表明模型具有更高的稳定性。表五中对 SADT 2952 数据集的参数分析也证实了我们的参数是最优的。

结果证实，配置 $S = 1$ 和$K = 7$ 在主体内和主体间评估范式下均能取得更好的性能。时间卷积$K = 7$ 能够捕获广泛的文本模式，而细粒度增量模块 $S = 1$ 则提取关键的短期双向变化。二者的融合表示为警觉性估计提供了稳健且全面的特征空间。

3）双向差分特征的频带分析：在经过严格预处理（带通滤波 0.5–30Hz、50 Hz 陷波滤波、伪迹剔除）后，我们评估了各典型脑电图频带中 BidirectionalDelta 能量与 PERCLOS 之间的关联。θ 频带（ 4–8 Hz ）的 BidirectionalDelta 能量与 PERCLOS 呈现出最强的正相关（皮尔逊 $r = +0.279$, $p < 0.001$, $R^2 = 7.79\%$, $N = 15{,}612$ 个样本），这与既有神经生理学研究结果一致，即困倦状态下 θ振荡会增强。θ振荡（4–8 Hz）是公认的困倦和入睡起始电生理标志物 [47], [48]。α频带特征表现相近（r =+0.271），β频带特征则呈现预期的负相关（$r = -0.111$），这证实 BidirectionalDelta 模块捕捉到的是真实的觉醒相关脑电动态，而非伪迹。详情可见图5。这种 θ 频带特异性的相关模式完全吻合

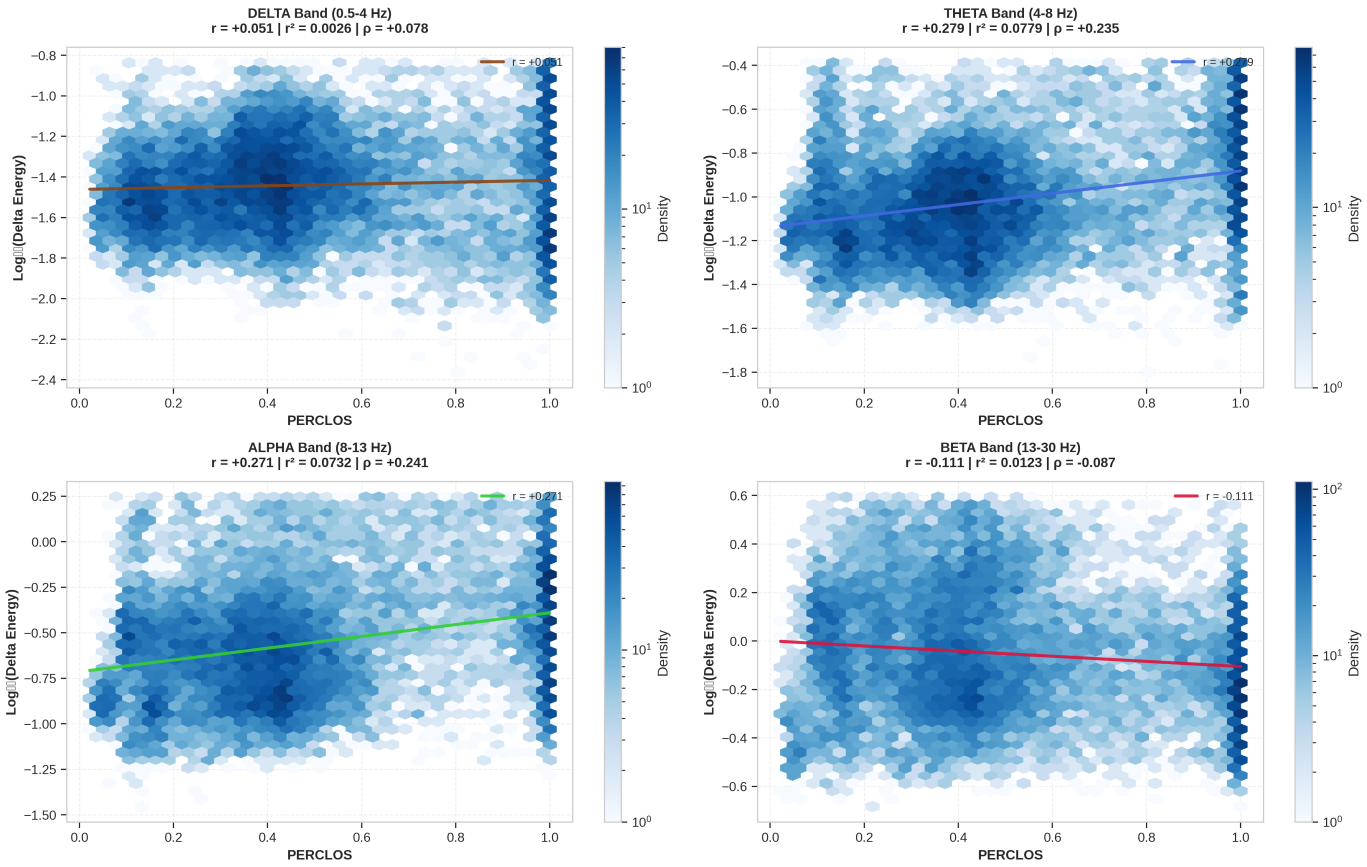


图5。BidirectionalDelta 能量与 PERCLOS 的频带特异性相关性。（**a–d**）六边形分箱散点图展示了**对数**10变换后的 BidirectionalDelta 能量与 PERCLOS 的关系，涵盖 delta（**0.5–4** Hz）、theta（**4–8** Hz）、alpha（**8–13** Hz）和 beta（**13–30**Hz）频带。图中叠加了回归线（彩色）以及皮尔逊/斯皮尔曼相关系数。

警觉性下降的已知神经生理学特征，并进一步验证了 BidirectionalDelta 捕捉到的是真实的困倦相关脑电动态，而非伪迹。因此，该模块能够以较高的计算效率提取 θ频带时间特征，用于实时疲劳监测。

六、结论

本文提出了一种具有门控时间编码的双向时序动态建模框架，用于基于脑电图的驾驶疲劳识别。首先，我们引入双向增量模块，将一阶时间微分分解为正向和负向分量，从而显式建模与警觉度下降相关的不对称神经激活与抑制模式。其次，我们设计了门控时间卷积模块，利用逐深度时间卷积和残差学习，为每个脑电通道学习长期时间依赖关系，在增强有限通道配置下时间表征鲁棒性的同时，保留空间特异性。第三，我们提出了一个完整框架，有效融合双向时间动态与通道级时间编码，从而提升跨主体（主体间）场景下的可解释性和泛化能力。在主体内和主体间评估设置下于 SADT 和 SEED-VIG 数据集上开展的大量实验表明，我们提出的方法始终优于现有方法。未来，我们将考虑以多模态生理信号数据作为输入，构建更加通用的驾驶疲劳识别模型。我们还将致力于融合环境信息与生理数据，以更全面地评估疲劳状态。

致谢

我们谨向 Xiaomin Ouyang教授、Zhihong Li教授和 Nevin L. Zhang教授致以诚挚谢意，感谢他们为我们的研究论文提供了宝贵指导。

参考文献

[1] M.E. Shaik，“驾驶员困倦检测与预测的系统综述”，《运输研究跨学科视角》，第21卷，文章编号100864，2023年。[2] M. Sprajcer 等，“开车时疲倦到什么程度才算过度疲倦？一项评估使用既往睡眠时长检测驾驶能力受损情况的系统综述”，《自然科学与睡眠》，第15卷，第2期，第175–206页，2023年。[3] M.S. Al-Quraishi、S.S.A. Ali、A. Muhammad、T.B. Tang 和 S. Elferik，“驾驶员状态检测与监测技术：系统综述”，《*Heliyon*》，第10卷，第20期，2024年。[4] O.O. Ajayi、A.M. Kurien、K. Djouani 和 L. Dieng，“驾驶员疲劳检测方法、数据集与模型的多模态系统综述”，《*IEEE Access*》，2025年。

[5] Z. Tian、N.S. Albakry 和 Y. Du，“照明智能适应与分析框架：提升夜间驾驶疲劳监测的综合解决方案”，*PLoS ONE*，第19卷，第8期，文章编号 e0308201，2024年。[6] D. Yu、W. Wang、T. Ding、Z. Niu、J. Zhi、X. Xie、Z. Zhang、X. Tang 和 D. Yu，“基于 DynGraph-TF 的脑电识别框架在列车驾驶员精神疲劳预测中的应用研究”，《先进工程信息学》，第68卷，文章编号103675，2025年。[7] Y. Cao、T. Chen、K. Han、H. Chung、Z. Huang 和 H. Ding，“SET-DGCN：一种面向年轻驾驶员的端到端脑电图疲劳检测方法”，《事故分析与预防》，第225卷，文章编号108311，2026年。[8] J. Hu、M.M.U. Rahman 和 T.-M. Laleg-Kirati，“利用 Mamba 和动态图库学习对脑电图与心电图进行自适应长程建模”，《科学报告》，第15卷，第1期，文章编号38762，2025年。[9] J. Wang、S. Zhao、Z. Luo、Y. Zhou、S. Li 和 G. Pan，“Eegmamba：基于 Mamba 的脑电基础模型”，《神经网络》，文章编号107816，2025年。[10] B. Gao、Y. Yan、C. Huangfu、J. Cai 和 H. Wang，“IDSRN：用于驾驶员疲劳评估的可解释动态系统循环网络”，《应用科学》，第15卷，第21期，文章编号11384，2025年。[11] O.E. Krigolson、H. Howse、M.R. Hammerstrom、A. Walzak、B. Wright 和 K.G. Hecker，“利用脑电图实时评估认知疲劳：一项医学模拟研究”，《医学科学教育者》，第1–9页，2025年。[12] I. Babu Henry Samuel、C. Wang、S.E. Burke、B. Kluger 和 M. Ding，“年轻人与老年人应对认知疲劳的代偿性神经反应”，《神经回路前沿》，第13卷，文章编号12，2019年。[13] T. Liu、Y. Wu、A. Ye、L. Cao 和 Y. Cao，“用于脑机接口通道选择优化的两阶段稀疏多目标进化算法”，《人类神经科学前沿》，第18卷，文章编号1400077，2024年。[14] W.M. Shalash，“利用单脑电通道进行驾驶员疲劳检测的深度学习卷积神经网络模型”，《理论与应用信息技术杂志》，第99卷，第2期，第462–477页，2021年。[15] A.V. Parekkattil、S.K. Varun 和 T.K.R. Bollu，“利用协方差增强型二维卷积神经网络进行基于脑电图的反应时间预测”，载于 *国际模式识别会议*，第296–310页，2024年。[16] J. Cui、Z. Lan、Y. Liu、R. Li、F. Li、O. Sourina 和 W. M¨uller-Wittig，“一种用于从单通道脑电图中跨受试者检测驾驶员困倦的紧凑且可解释的卷积神经网络”，《方法》，第202卷，第173–184页，2022年。[17] Y. Sun、M. Ke 和 L. Wang，“一种利用可穿戴设备进行基于多模态生理信号的心理状态识别的新型 InceptionTime 框架”，载于 *2025年第五届生物信息学与智能计算会议论文集*，第563–570页，2025年。[18] J. Tang、W. Zhou、W. Zheng、Z. Zeng、J. Li、R. Su、T. Adili、W. Chen、C. Chen 和 J. Luo，“用于驾驶疲劳检测的注意力引导多尺度卷积神经网络”，《*IEEE*传感器杂志》，第24卷，第14期，第23280–23290页，2024年。[19] Z. Wang、X. Du、C. Jiang 和 J. Sun，“基于脑电信号的驾驶员疲劳程度预测研究”，《传感器》，第25卷，第23期，文章编号7316，2025年。[20] W. Yang、X. Wang、W. Qi 和 W. Wang，“LGFormer：融合局部与全局表征的脑电解码模型”，《神经工程杂志》，第22卷，第2期，文章编号026042，2025年。[21] E. Modesitt、H. Yin、W. Huang Wang 和 B. Lu，“将预训练 ViT 与 TCNet 融合以增强脑电回归”，载于 *国际人机交互会议*，第47–59页，2024年。[22] V.J. Lawhern、A.J. Solon、N.R. Waytowich、S.M. Gordon、C.P. Hung 和 B.J. Lance，“EEGNet：一种用于基于脑电图的脑机接口的紧凑型卷积神经网络”，《神经工程杂志》，第15卷，第5期，文章编号056013，2018年。[23] S. Hana、R. Hassan、A.R. Faizabadi、A. Gubbi、M.Z. Bellary 和 V. Manjula，“利用轻量级深度神经网络优化 EEGNet，从原始脑电信号数据集中检测人体压力水平”，载于*2025*年第三届集成电路与通信系统国际会议 *(ICICACS)*，第1–6页，2025年。[24] G. Kim 和 S. Choi，“深度神经网络中利用导数特征进行声音事件检测”，《应用科学》，第10卷，第14期，第4911页，2020年7月。[25] A. J. Anderson、C. Davis 和 E. C. Lalor，“深度学习模型揭示语境与听者注意力如何影响语音到语言转换的电生理相关指标”，《PLOS计算生物学》，第20卷，第11期，第 e1012537 页，2024年11月。[26] Y. N. Dauphin、A. Fan、M. Auli 和 D. Grangier，《使用门控卷积网络进行语言建模》，arXiv，预印本 arXiv:1612.08083，2016年12月。[27] A. van den Oord、S. Dieleman、H. Zen、K. Simonyan、O. Vinyals、A. Graves、N. Kalchbrenner、A. Senior 和 K. Kavukcuoglu，《WaveNet：一种原始音频生成模型》，arXiv，预印本 arXiv:1609.03499，2016年9月。[28] Z. Wu、S. Pan、G. Long、J. Jiang 和 C. Zhang，《用于深度时空图建模的 Graph WaveNet》，arXiv，预印本 arXiv: 1906 00121, 2019 。May [29] D. Hendrycks 和 K. Gimpel，《高斯误差线性单元（GELU）》，arXiv，预印本 arXiv:1606.08415，2016年6月。[30] K. He、X. Zhang、S. Ren 和 J. Sun，《用于图像识别的深度残差学习》，发表于 IEEE 计算机视觉与模式识别会议（CVPR）论文集，2016年6月。[31] S. Balduzzi、M. Frean、L. Leary、J. Lewis、K. W.-D. Ma 和 B. McWilliams，《梯度破碎问题：如果残差网络是答案，那么问题是什么？》，发表于国际机器学习会议（ICML）论文集，2017年7月。[32] C. Liu 等，《一种用于基于脑电图的运动想象分类的紧凑型多分支一维卷积神经网络》，《生物医学信号处理与控制》，第80卷，第1部分，104270页，2023年3月。[33] O. B. Guney 等，《GDNet-EEG：一种基于分组深度卷积、具备注意力感知能力的深度神经网络，用于稳态视觉诱发电位刺激频率识别》，《神经科学前沿》，第17卷，1160040页，2023年4月。[34] D. Gao 等，《基于对数梅尔频谱图和卷积循环神经网络的脑电驾驶疲劳检测》，《神经科学前沿》，第17卷，1136609页，2023年3月。[35] W. Zheng 和 B. Lu，《一种利用脑电图和额部眼电图估计警觉度的多模态方法》，《神经工程杂志》，第14卷，第2期，2017年2月，文章编号：026017。[36] D. Dinges 和 R. Grace，《PERCLOS：一种经精神运动警觉评估的有效警觉性心理生理指标》，美国交通部联邦公路管理局，技术报告 FHWA-MCRT-98 006，1998 - 。[37] Z. Gao、C. Chuang、J. King 和 C. Lin，《持续注意驾驶任务期间的多通道脑电图记录》，《科学数据》，第19卷，第6期，第1–10页，2019年4月。[38] Cui, Jian（ 2021）。脑电驾驶员困倦数据集（不平衡）。figshare。数据集。https://doi.org/ 10 6084 9 16586957 1 。/m .figshare. .v [39] Cui, Jian（）。2021 脑电驾驶员困倦数据集。figshare。数据集。https://doi.org/ 10 6084 9 14273687 3 。/m .figshare. .v [40] Z. Wang、W. Yan 和 T. Oates，《从头开始使用深度神经网络进行时间序列分类》，发表于国际联合神经网络会议（*IJCNN*）论文集，2017年，第1578–1585页。[41] H. Ismail Fawaz 等，《InceptionTime：为时间序列分类寻找 AlexNet》，《数据挖掘与知识发现》，第34卷，第6期，第1936–1962页，2020年。[42] T. He、Z. Zhang、H. Zhang、Z. Zhang、J. Xie 和 M. Li，《使用卷积神经网络进行图像分类的实用技巧集》，发表于*IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）论文集，2019年6月，第558–567页。[43] A. Dosovitskiy、L. Beyer、A. Kolesnikov、D. Weissenborn、X. Zhai、T. Unterthiner、M. Dehghani、M. Minderer、G. Heigold、S. Gelly、J. Uszkoreit 和 N. Houlsby，《一张图像胜过 16×16 个词：用于大规模图像识别的 Transformer》，发表于国际学习表征会议（ICLR）论文集，2021年4月。[44] V. J. Lawhern 等，《EEGNet：一种用于基于脑电图的脑机接口的紧凑型卷积神经网络》，《神经工程杂志》，第15卷，第5期，文章编号：056013，2018年。[45] G. Siddhad、A. Singh、R. Saini 和 P. P. Roy，《改进的 TSception：基于脑电图分析驾驶员困倦和心理负荷》，*arXiv* 预印本 *arXiv:2512.21747 [cs.HC]*, 2026。 [https://doi.org/10. 48550 2512 21747] /arXiv. . J. Chen、Y. Cui、C. Wei、K. [46] Polat 和 F. Alenezi，《基于脑电图图注意力卷积神经网络的驾驶疲劳检测：一种由互信息驱动连接性的端到端学习方法》，《应用软计算》，第186卷，A部分，文章编号：114097，2026 [10 1016 2025 114097] 年1月。[47] https://doi.org/ . /j.asoc. . S. Makeig 和 T.-P. Jung，《警觉性下降：表现波动与脑电图波动的相关性》，《临床神经生理学电图》，第98卷，第1期，第18–29页，1996年。[48] C. Cajochen、S. B. S. Khalsa、J. K. Wyatt、C. A. Czeisler 和 D.-J. Dijk，《持续觉醒40小时期间脑电图和眼电图的变化》，《美国生理学杂志：调节、综合与比较生理学》，第276卷，第5期，第R1450–R1458页，1999年。