arXiv:2304.01461v1 [cs.LG] 4 Apr 2023

面向三通道运动想象分类的时空频特征融合

Zhengqing Miao * **Meirong Zhao** *

摘要

低通道脑电设备对于便携式和娱乐应用至关重要。然而，脑电图的低空间分辨率给低通道运动想象解码带来了挑战。本研究提出了一种新型网络架构 TSFF-Net，该架构融合时空频特征，有效弥补了基于时间序列或时频模态的单模态特征提取网络的局限性。TSFF-Net 由四个主要部分组成：时频表示、时频特征提取、时空特征提取，以及特征融合与分类。时频表示和特征提取将原始脑电信号转换为时频谱图，并提取相关特征。时空网络以时间序列脑电试次为输入，并提取时空特征。特征融合采用最大均值差异损失，在再生核希尔伯特空间中约束时频特征与时空特征的分布，随后通过加权融合将这些特征结合起来，从而获得有效的时空频特征。此外，鲜有研究基于时频谱图探索三通道运动想象解码。本研究提出了一种基于时频谱图的浅层轻量级解码架构（TSFF-img），并使用两个公开数据集，将其低通道运动想象分类性能与其他方法进行比较。实验结果表明，TSFF-Net 不仅弥补了单模态特征提取网络在脑电解码方面的不足，而且优于其他最先进方法。总体而言，TSFF-Net 在低通道运动想象解码方面具有显著优势，并为通过算法提升低通道脑电解码能力提供了有价值的见解。

关键词 时频表示 · 脑机接口（BCI） · 脑电描记术（脑电图） · 特征融合 · 神经网络

1 引言

脑电描记术（脑电图）在运动康复、脑功能调节和娱乐等多个领域日益重要 [Park 等（2014）；Sterman（1996）；Olfers 和 Band（2018）]。作为一种非侵入性技术，脑电图通过检测和记录大脑神经元放电产生的电信号来测量脑活动 [Nunez 和 Srinivasan（2006）；Niedermeyer 和 da Silva（2005）]。脑电图的主要优势包括时间分辨率高、成本相对较低，并且适用于广泛的临床和研究应用[Lotte 等（2018）]。在便携式设备和娱乐应用中，低通道脑电采集系统发挥着关键作用，显著提升了脑电相关设备对用户的易用性和可及性 [Minguillon 等（2017）]。

运动想象是采集脑电数据的常见范式，广泛应用于脑机接口（BCI）中。在运动想象过程中，感觉运动皮层（包括初级运动皮层（M1）和初级躯体感觉皮层（S1））会产生可由脑电图记录的神经振荡 [Pfurtscheller 和 Neuper（2001年）]。这些振荡可分为不同的频段，例如 μ（8-12 Hz）和 β（13-30 Hz）节律。

通讯作者：Zhengqing Miao（mzq@tju.edu.cn）*中国天津市天津大学精密仪器与光电子工程学院，精密测量技术与仪器国家重点实验室，邮编 300072。

这些节律的功率会随着运动想象任务而变化，从而产生事件相关去同步化（ERD）或事件相关同步化（ERS）模式[Pfurtscheller 等人（2006年）]。
共空间模式（CSP）是一种广泛使用的空间滤波技术，可最大化两类运动想象信号之间的方差 [Lotte 和 Guan（2010）]。它能够提取用于分类的判别特征 [Ramoser 等人（2000）]。然而，CSP 相关方法的特征提取能力有限，且对脑电通道数量有较严格的要求。Baig 等人（2020年）指出，在基于 CSP 的运动想象分类研究中，通常会筛选 10–30 个脑电通道进行特征提取。Arvaneh 等人（2011年）还表明，在对左手和右手运动想象进行二分类时，仅使用三个通道（C3、C4 和 Cz）相比使用筛选出的 13 个脑电通道，分类准确率会显著下降。因此，基于 CSP 的特征提取方法在低通道数条件下用于运动想象特征提取时存在很大局限。

近年来，研究人员越来越多地探索人工神经网络强大的特征提取能力，以自动提取并分类运动想象信号的有效特征 [Al-Saegh 等人（2021年）；Craik 等人（2019年）]。这类方法主要分为两类：一类将时间序列脑电信号输入人工神经网络进行特征提取和分类；另一类先将原始脑电转换为图像，再输入人工神经网络进行特征提取和分类。

鉴于脑电图具有明显的时频特征，一些研究利用卷积神经网络（CNN）在自然图像特征提取方面的出色表现，从脑电图的频谱图中提取并分类有效特征 [Mammone 等人（2020年）]。例如，Khare和Bajaj（2020）首先使用平滑伪魏格纳-维尔分布（SPWVD）将带通滤波脑电信号转换为时频表示，然后使用预训练的 AlexNet 等经典 CNN 架构提取特征 [Krizhevsky 等人（2017年）],VGG[Simonyan 和 Zisserman（2014年）], 和 ResNet[He 等人（2016年）], ，在情绪识别方面取得了显著成果。Madhavan 等人（2019年）采用傅里叶同步压缩变换和小波同步压缩变换，将原始脑电转换为时频矩阵，然后使用深度卷积神经网络提取特征，在局灶性和非局灶性脑电信号分类中取得了良好效果。Xu 等人（2020年）首先将原始脑电转换为脑电地形图表示，然后使用卷积神经网络提取特征，在运动想象分类中表现良好。

与先将原始脑电转换为图像的方法不同，以时间序列脑电信号为输入的神经网络解码方法无需额外的转换步骤。Schirrmeister 等人（2017）提出了一项具有代表性的工作，直接将时间序列脑电信号输入人工神经网络进行特征提取。通过设置适当的时间卷积层和空间卷积层，他们证明端到端卷积神经网络能够实现与滤波器组共空间模式（FBCSP）相当的特征提取能力 [Ang 等人（2008年）]。EEGNet [Lawhern等人（2018年）]是另一种以时间序列脑电信号为输入的紧凑型 CNN 架构，在四种脑机接口范式中表现出优异的分类性能，分别为 P300视觉诱发电位、错误相关负电位、运动相关皮层电位和感觉运动节律。Miao 等人（2023年）提出了一种基于通道注意力和深度注意力的轻量级网络架构，在使用不同脑电通道进行运动想象和错误相关负电位的特征提取与分类方面表现良好。Borra 等人（2020年）提出了一种用于运动想象特征提取与分类的轻量级网络框架，通过时间 sinc 卷积层和空间深度卷积提取运动想象信号的有效特征。

然而，在现有的解码方法中，还没有专门针对低脑电通道场景设计的运动想象解码算法。一个可能的原因是脑电图的空间分辨率较低，因此许多研究尝试通过增加电极数量来提高运动想象分类的准确率 [Arvaneh 等人（2011）；Baig 等人（2020）]。不过，在便携式脑电设备和娱乐等领域，增加脑电通道数量会给使用带来不便，因此从算法角度提升低通道数脑电信号的分类性能具有重要意义。因此，本研究结合时间序列神经网络和基于图像的神经网络的优势，从算法角度提升低通道数运动想象的分类准确率，推动脑电图在便携式设备和娱乐领域的应用。

本研究提出一种时空频特征融合方法，通过所提出的时空频融合网络（TSFF-Net），在三通道场景下提取并分类运动想象特征。TSFF-Net由四个部分组成，即时频表示、基于频谱的时频特征提取层、基于时间序列的时空特征提取层，以及特征融合与分类。在两个运动想象公开数据集上的结果表明，TSFF-Net不仅优于最先进方法，而且仅使用三个脑电通道便超越了使用22个通道的方法。总之，TSFF-Net在低脑电通道解码方面具有巨大潜力。

本文的主要贡献可概括如下:

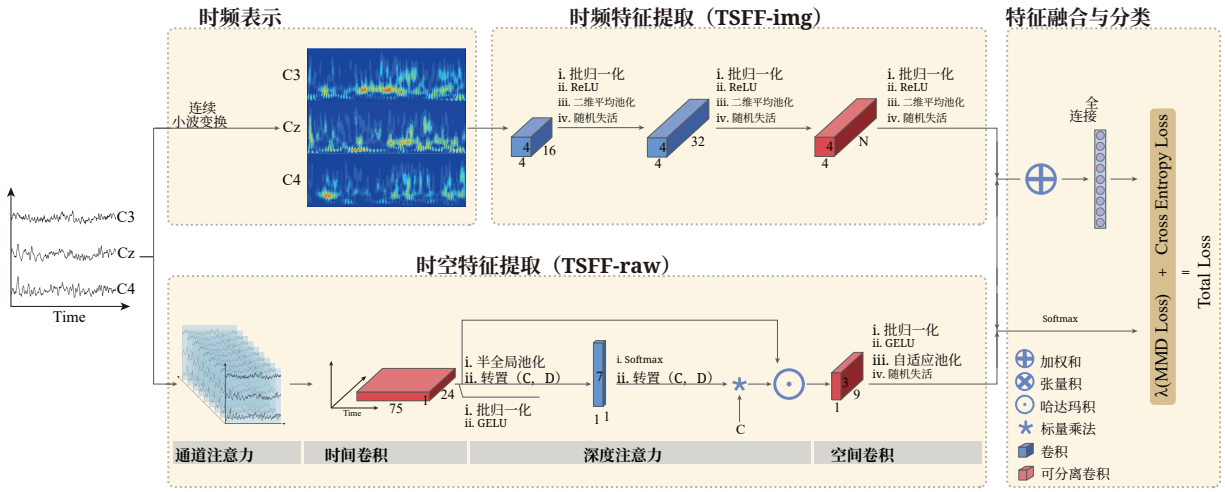


图1：时空频特征融合网络架构（TSFF-Net）。TSFF-Net 包含四个组成部分，即时频表示、时频特征提取、时空特征提取以及特征融合与分类。

1. 从多模态融合的角度提出了一种用于三通道运动想象脑电解码的网络架构，有效融合时空频特征，以弥补单模态网络在三通道运动想象脑电特征提取方面的不足。2. 提出了一种用于三通道运动想象脑电的频谱特征提取网络架构 TSFF-Img；与 AlexNet、VGG 和 ResNet 等自然图像网络架构相比，该架构在三通道运动想象脑电解码方面更具优势。3. 在两个公开的运动想象数据集上进行的全面实验验证了所提方法的有效性，为未来低通道脑电解码研究提供了有价值的参考。

本文其余部分安排如下：第2节详细介绍所提出的时空频特征融合网络（TSFF-Net）。第3节介绍数据集、实验设置和预处理方法。第4节讨论本研究的结果与主要发现。最后，第5节总结全文。

2 方法

TSFF-Net 以预处理后的分段脑电试次作为输入，包含四个部分：时频表示、时频特征提取、时空特征提取以及特征融合与分类（如图1所示）。设分段脑电试次为 $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^{N}$、$\mathbf{x}_i \in \mathbb{R}^{C\times T}$，其中 N 表示训练样本总数，C 表示脑电通道数，T 表示每个试次包含的样本数。下面将详细介绍 TSFF-Net 的以下四个组成部分。

2.1 时频表示

对于$\mathbf{x}_i$中的每个通道，使用连续小波变换（CWT）[Rioul 和 Duhamel（1992年）]将时域数据转换为相应的频谱。令$\mathbf{x}_{i,j}$表示$\mathbf{x}_i$中第 j个通道的时域脑电数据，简写为 $s(t)$。连续小波变换按以下公式进行：

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int s(t)\psi\left(\frac{t-b}{a}\right) dt \tag{1}$$

其中，ψ 表示小波母函数，ψ 是 ψ的复共轭，a 和 b 分别表示伸缩变量和平移变量。本研究选用 Morlet 小波 [Lin 和 Qu（2000年）] 作为小波母函数，其定义如下：

$$\psi(t) = \exp\left(-\frac{\beta^2 t^2}{2}\right)\cos(\pi t) \tag{2}$$

表1：TSFF-img网络架构及可学习参数数量

层(l)	层类型	#滤波器	滤波器尺寸	步幅	填充	组	Bias	# 参数
c1	卷积	16	4×4	1	2	1	16	784
r1	ReLU	-	-	-	-	-	-	-
r1	平均池化	16	8×8	-	-	-	-	-
r1	随机失活	-	P=0.25	-	-	-	-	-
c2	卷积	32	4×4	1	2	1	32	8224
r2	ReLU	-	-	-	-	-	-	-
r2	平均池化	32	3×3	-	-	-	-	-
r2	随机失活	-	P=0.25	-	-	-	-	-
c3	卷积	64	1×1	1	0	1	0	2048
r3	批归一化	64	-	-	-	-	-	128
c3	卷积	64	4×4	1	2	64	0	1024
r3	批归一化	64	-	-	-	-	-	128
r3	ReLU	-	-	-	-	-	-	-
r3	平均池化	32	3×3	-	-	-	-	0
r3	随机失活	-	P=0.25	-	-	-	-	0
fc	全连接	-	-	-	-	-	2	1154
总计								13490

其中 β 是一个用于平衡 Morlet 小波的时间分辨率和频率分辨率的参数 .
连续小波变换（CWT）的输出是一个复值矩阵，其中每个元素代表特定时间和频率下的小波系数。小波系数的幅值表示该时间和频率下脑电活动的强度。脑电频谱图的频率范围与原始脑电带通滤波器的通带一致，以减小噪声对频谱图的影响。为生成时频图，将小波系数的幅值平方后，绘制为时间和频率的函数。对每个脑电片段进行连续小波变换，可得到一幅 800 x 600 的时频谱图像。在 TSFF-Net 中，将 C3、Cz 和 C4 通道对应的频谱图像沿宽度方向拼接，再将拼接后的图像下采样至 224 x 224，然后输入 TSFF-Net 的频谱特征提取部分进行特征提取。

2.2 时频特征提取

如表1所示，所提出的 TSFF-img 网络包含三个特征提取层，每层之后均接有一系列正则化操作。这些正则化操作与原始脑电特征提取网络中使用的操作一致。与自然图像特征提取网络架构中常用的最大池化操作不同，鉴于脑电信号的信噪比较低且容易受到噪声污染，TSFF-img 网络中的池化层采用平均池化。频谱网络前两层特征提取层的参数固定，卷积核分别为 (16, 4, 4) 和 (32, 4, 4)，其中 16 和 32 表示卷积核的数量，(4, 4) 表示卷积核的尺寸。为减少 TSFF-img 中的参数数量，最后一个卷积层采用可分离卷积。表1列出了输入分段脑电试次长度为 1000 时 TSFF-img 中的参数数量。最后一个卷积层所用卷积核的数量根据时空特征提取层（TSFF-raw）的输出确定，以确保 TSFF-img 网络输出特征的维度与 TSFF-raw 输出特征的维度一致，从而进行后续特征融合。

如表1所示，当输入分段脑电试次的时间长度为1000时，TSFF-img在二分类任务中仅包含13,490个可学习参数。这一数量显著少于经典自然图像识别网络，例如 AlexNet [Krizhevsky 等人（2017年）], VGG[Simonyan 和 Zisserman（2014年）], 以及 ResNet[He 等人（2016年）], , 后者拥有数百万甚至数十亿个参数。TSFF-img能够利用少量参数和有限的数据集有效提取特征。此外，TSFF-img网络仅由三层组成，旨在学习脑电图时频谱中的轮廓等浅层信息，同时忽略时频谱中的详细信息，以减少噪声干扰。

2.3 时间-空间特征提取

本研究所采用的时空特征提取层与 LMDA-Net [Miao 等人（2023年）]采用的特征提取相同。LMDA-Net 的特征提取层分为四个组成部分：通道注意力

模型、时间卷积层、深度注意力模型和空间卷积层（如图1所示）。LMDA-Net 也是一种轻量级网络架构，在时间卷积层和空间卷积层中均采用可分离卷积。

在 LMDA-Net 中，通道注意力模块通过张量积运算将脑电信号的空间信息扩展至深度维度，从而缓解采集过程中容积传导导致脑电信号空间分辨率较低的问题。设 $\mathbf{X}$ 为时间序列脑电的输入样本，$\mathbf{C}$、$\mathbf{C}$ $\in \mathbb{R}^{D\times 1\times C}$ 为服从正态分布的张量。通道注意力模块的公式如下：

$$\mathbf{X}'_{hct} = \sum_{d} \mathbf{X}_{dct}\mathbf{C}_{hdc} \tag{3}$$

方程中的下标 （3）中的下标表示相应的维度。字母下标相同表示这两个张量在该维度上形状有相同的

LMDA-Net 在时间卷积层与空间卷积层之间设有深度注意力模块（如图1所示）。该深度注意力模块增强了时间序列脑电信号的时域特征与空域特征之间的联系，从而充分利用这些信号的时间特征和空间特征。

2.4 特征融合与分类

TSFF-Net 的特征融合包括两个组成部分：对时空特征提取层和时频特征提取层的输出特征进行加权融合，以及通过最大均值差异损失 [Gretton等人（2012）]在高维空间中对这些输出特征进行对齐。由于时空特征和时频特征源自同一类脑电信号的不同表示，因此它们在某些高维空间中应具有相似的特征分布。特征加权融合和最大均值差异损失均可确保不同模态的神经网络所提取的特征得到有效结合，从而克服单模态特征提取网络的局限性。

设 TSFF-raw 的展平输出特征为$\mathbf{S}$，TSFF-img 的展平输出特征为$\mathbf{F}$，其中（$\mathbf{F}$，$\mathbf{S}$ $\in \mathbb{R}^{N\times D}$）。由于时频特征与时空特征之间存在幅值不匹配，在应用最大均值差异损失之前，使用 softmax函数对$\mathbf{S}$ 和$\mathbf{F}$ 进行归一化。例如，对于$\mathbf{S}$，softmax函数表示为：

$$\mathbf{S}(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^{N}\exp(x_j)} \tag{4}$$

其中，x_i 表示$\mathbf{S}$中第 i个样本的展平特征。

随后将归一化后的$\mathbf{S}$和$\mathbf{F}$ 输入最大均值差异损失，其定义如下：

$$d_k^2(p,q) \triangleq \left\|\mathbf{E}_p\left[\phi(\mathbf{S})\right] - \mathbf{E}_q\left[\phi(\mathbf{F})\right]\right\|_{\mathcal{H}_k}^2 \tag{5}$$

其中，p 和 q 分别表示$\mathbf{S}$ 和$\mathbf{F}$的概率分布。$\mathbf{E}_p$ 和$\mathbf{E}_q$ 表示概率分布 p 和 q的均值嵌入。 $\phi(\cdot)$表示特征映射的核函数，而下标 $\mathcal{H}_k$ 表示两个特征分布的均值差异应被限制在再生核希尔伯特空间（RKHS）中的单位球内 [Rosipal 和 Trejo（2001年）]。

TSFF-Net 中全连接层的输入是$\mathbf{S}$ 和$\mathbf{F}$的加权平均。令 η表示特征权重，其中 $0 \le \eta \le 1$，则时频与时空网络输出特征的加权融合可表示为：

$$\mathbf{G} = \eta\cdot\mathbf{S} + (1-\eta)\cdot\mathbf{F} \tag{6}$$

融合后的特征$\mathbf{G}$ 随后输入全连接网络，并使用交叉熵损失进行分类 [香农（2001年）]。设 TSFF-Net 的预测结果为 P，Y 表示预测样本的真实标签。交叉熵损失可表示为：

$$L_c(Y,P) = -\frac{1}{N}\sum_{i=1}^{N}\sum_{m=1}^{M} y_{i,m}\log(p_{i,m}) \tag{7}$$

其中，N 表示训练样本的数量，M 表示运动想象类别的数量，m对应一个特定的运动想象类别。$y_{i,\ m}$ 表示真实标签 Y的第 m个元素，而$p_{i,\ m}$表示 TSFF-Net 将对应样本预测为类别 m 的概率值。

在 TSFF-Net 的训练过程中，总损失函数表示为：

$$L = L_c + \lambda L_{MMD} \tag{8}$$

其中，λ 表示最大均值差异损失的权重。

3 实验设置

3.1 数据集

3.1.1 BCI竞赛IV数据集IIA（BCI4-2A）

BCI4-2A 数据集* 由九名健康参与者（ID A01-A09）在两个不同实验阶段采集的脑电图数据组成。数据使用10-20系统采集，包含22个脑电通道，采样率为250 Hz。每位参与者完成四项运动想象任务，包括想象左手、右手、双脚和舌头的运动。每个实验阶段包含288个脑电数据试次。第一阶段采集的所有数据均用于训练，第二阶段的数据用于测试。在我们的实验中，截取运动想象提示后 [2, 6]秒的时间分段，作为一个脑电数据试次。除四分类任务外，我们还单独研究了左手和右手运动想象的二分类任务，每个实验阶段包含144个试次。该数据集包含22个通道；然而，在后续实验中，我们仅选取C3、Cz和C4通道对应的数据进行分析。

3.1.2 BCI竞赛IV数据集IIB（BCI4-2B）

BCI4-2B数据集† 包含从九名健康参与者（ID B01-B09）采集的脑电数据，使用 3 个脑电电极通道（C3、Cz 和 C4），采样率为 250 Hz，采集分五个独立阶段进行。每位参与者完成两项运动想象任务，即想象左手和右手的运动。前两个阶段每个阶段包含 120 个试次，且不提供反馈；后三个阶段每个阶段包含 160 个试次，并在屏幕上显示笑脸作为反馈。前三个阶段的全部数据用于训练，最后两个阶段的数据用于测试。在我们的实验中，提取运动想象提示后 [3, 7] 秒的时间分段，作为一个脑电数据试次。

3.2 预处理

采用 200 阶布莱克曼窗带通滤波器对原始脑电数据进行滤波。滤波器的通带选定为 [4, 38] Hz。随后，根据各数据集中的任务时长对滤波后的原始脑电数据进行分段。经过以下两个预处理步骤后，分段脑电试次依次输入图1所示的网络框架进行训练。

采用 200 阶布莱克曼窗带通滤波器对原始脑电数据进行预处理。滤波器的通带选定为 [4, 38] Hz 范围，以有效捕捉与运动想象任务相关的主要目标频段，例如 μ（8-12 Hz）和 β（13-30 Hz）节律。随后，根据各数据集对应的具体任务时长对滤波后的原始脑电数据进行分段，提取单个试次以供进一步分析。分段后的脑电试次依次经过以下两个预处理步骤，然后输入 TSFF-Net。

3.2.1 归一化

为消除数据尺度对神经网络训练的影响并提高网络的收敛速度，我们首先对每个试次获得的幅值进行归一化。通过以下公式将每个试次的脑电数据归一化至 [-1, 1] 。

考虑到本研究仅关注数量有限的通道，具体为三个通道，通道 C3 和 C4 可能比通道 Cz 更重要，因此需要采用有别于 [Miao 等人（2022）]所使用的通道归一化方法的定制归一化方案。我们采用基于试次的归一化策略对脑电数据进行预处理。该方法确保每个试次获得的幅值均经过一致的归一化，从而减轻由通道特异性特征可能引起的偏差。通过以下公式将每个试次的脑电数据缩放至 [-1, 1]范围：

$$\mathbf{x}_i = \frac{\mathbf{x}_i}{\max\left(|\mathbf{x}_i|\right)} \tag{9}$$

其中，i 表示 x 的第 i个试次， $|\cdot|$ 表示对矩阵取绝对值。

*www.bbci.de/competition/iv/#数据集2a
†www.bbci.de/competition/iv/#数据集2b

3.2.2 欧几里得对齐

为了确保特征提取过程的鲁棒性和泛化能力，我们采用了 [Miao等人（2022）] 提出的域对齐方法，为训练数据和测试数据构建域不变表示。该方法旨在为所有 n 个对齐试次建立一致且统一的平均协方差矩阵，从而有效缩小训练数据集与测试数据集之间的分布差异。此过程得到一个单位矩阵 [He 和 Wu（2019）]，最终有助于实现更准确、可靠的特征提取。
该欧几里得对齐方法的具体实现如下：

$$\bar{\mathbf{R}} = \frac{1}{N}\sum_{i=1}^{N}\mathbf{x}_i\mathbf{x}_i^T$$
$$\tilde{\mathbf{x}}_i = \bar{\mathbf{R}}^{-1/2}\mathbf{x}_i \tag{10}$$

通过将域对齐技术纳入本研究，我们有效地解决了训练数据和测试数据因各自分布存在固有差异而可能产生的差异。

3.3 实验环境和参数设置

所有实验均使用PyTorch（版本1.10.1）框架，在配备Intel(R) Xeon(R) Gold 5117 CPU（运行频率为2.00 GHz）和Nvidia Tesla V100 GPU的高性能工作站上进行。为确保最佳性能，我们采用AdamW优化器对所有模型进行训练，并使用Loshchilov和Hutter（2018）所述的默认参数。训练过程采用批大小为32的小批次进行。所有网络的训练轮数均不超过350个epoch。
需要指出的是，Schirrmeister等人（2017）提出的ConvNet架构包含用于脑电解码的浅层和深层两个版本。然而，包括Lawhern等人（2018）以及Schirrmeister等人（2017）本人在内的先前研究表明，在脑电解码中，浅层ConvNet相比深层ConvNet更具优势。因此，我们在实验中采用了浅层ConvNet架构（下文简称ConvNet）。

4 结果

在第4.1节中，我们评估了多种方法在BCI4-2A二分类和四分类任务，以及BCI4-2B二分类任务中的最佳分类性能。在第4.2节中，我们比较了若干神经网络模型在BCI4-2A数据集二分类任务上的预测性能。具体而言，我们评估了EEGNet、ConvNet、LMDA-Net、TSff-img和TSFF-Net在每个脑电时间段上的所有参与者平均准确率，并将其表现与基于CSP的模型进行了比较。在第4.3节中，我们比较了所提出的TSFF-img与预训练的AlexNet、VGG和ResNet在脑电频谱图上的分类性能。在第4.4节中，我们进行了消融实验，以展示各个模块对TSFF-Net的影响。

4.1 实验结果分析

4.1.1 BCI4-2A 二分类

我们首先分析了在 BCI4-2A 中，不同模型针对左手与右手二分类任务的分类性能。由于 BCI4-2A 是一个四分类数据集，神经网络相关研究通常展示的是多分类任务中的性能。为此，我们依据 EEGNet [Lawhern等人（2018）], ConvNet[Schirrmeister等人（2017），以及 LMDA-Net [Miao 等人（2023）]的开源代码，复现了这三种网络模型仅使用 C3、Cz 和 C4 通道时的分类性能。EA-CSP[He 和 Wu（2019）]以及 SCSP[Arvaneh 等人（2011）] 用于评估所提出方法在 BCI4-2A 左手与右手二分类任务中的分类性能。其中，SCSP 还探究了仅使用 C3、Cz 和 C4 通道时所提出方法的分类性能。此外，在 BCI4-2A 二分类任务中，SCSP 仅用三个通道便取得了与 Zanini 等人（2017）相同的平均准确率，而后者使用了 22 个通道。因此，SCSP 的分类性能可作为 CSP 相关方法的代表。神经网络的一些预处理方法部分借鉴了 He 和 Wu（2019）在欧几里得空间中对齐参与者平均协方差矩阵的思路，因此我们也比较了神经网络相关方法与 EA-CSP 在二分类任务中的分类性能。TSFF-img 是本文提出的一种轻量级谱分析方法，我们还测试了在相同场景下，它与基于时间序列的神经网络特征提取方法之间的分类性能差

表2：不同算法在 BCI4-2A 上的二分类性能

方法	A01	A02	A03	A04	A05	A06	A07	A08	A09	Mean	Std	P值
EA-CSP(C=22)	87.5	56.3	98.6	73.6	50.0	64.6	68.8	89.6	72.9	73.5	16.0	0.039
SCSP(C=22)	**91.0**	56.3	96.5	72.9	63.9	63.9	79.9	**97.2**	91.7	79.2	15.6	0.12
SCSP	75.7	53.5	93.1	68.1	53.5	61.1	57.6	86.8	88.9	70.9	15.7	0.011
LMDA-Net	80.6	69.4	97.9	69.4	76.4	66.7	**95.8**	84.7	91.0	81.3	11.8	0.011
ConvNet	86.8	67.4	96.5	68.1	**79.9**	61.1	**95.8**	83.3	**92.4**	81.2	13.1	0.062
EEGNet	82.6	63.9	97.2	68.1	73.6	65.3	82.6	84.7	91.0	78.8	11.7	0.0039
TSFF-img	79.9	63.9	93.1	61.8	73.6	57.6	81.3	79.2	91.0	75.7	12.5	0.0039
TSFF-Net	86.8	**75.7**	**100.0**	**75.0**	79.2	**75.0**	**95.8**	86.8	91.7	**85.1**	9.5	-

P值表示TSFF-Net与其他结果之间的Wilcoxon符号秩检验结果。符号C=22 表示该方法使用22个通道，而Others方法仅使用三个通道（即C3、C4和Cz）。EEGNet、ConvNet和LMDA-Net的结果采用其开源网络架构获得，实验设置与TSFF-Net相同。

在相同场景下，它与基于时间序列的神经网络特征提取方法在分类性能方面存在差异。

从表2可以看出，仅使用3个通道时，SCSP的平均准确率为70.9%；使用22个通道后，这一数值提升至79.2%。相比之下，EA-CSP使用22个通道时的平均分类准确率为73.5%。将表2中的神经网络方法与SCSP（3个通道）的分类性能进行比较，可以发现，神经网络方法在均值和标准差方面均占优势。这在一定程度上表明，在通道数较少时，神经网络方法在运动想象二分类任务中的性能优于CSP相关方法。然而，仅使用3个通道时，LMDA-Net、ConvNet和TSFF-Net在平均准确率和标准差方面均优于SCSP（22个通道）。在所测试的方法中，基于时间序列的模型（即LMDA-Net、ConvNet和EEGNet）的性能优于以TSFF-img为代表的基于时频谱的方法。然而，所提出的TSFF-Net能够有效提升TSFF-img和TSFF-raw（即LMDA-Net）的分类性能，这表明所提出的融合方法在低通道数的运动想象二分类场景中是有效的。

4.1.2 BCI4-2B 二分类

我们进一步验证了不同方法在 BCI4-2B 上的分类性能。FBCSP [Ang 等人（2008）] 是一种具有代表性的手工特征提取方法，通过设置滤波器组增强 CSP 在多个频段上的特征提取能力。WasF-ConvNet [Zhao 等人（2019）]是一种用于运动想象脑电解码的时空频特征提取神经网络。上述神经网络方法均未采用数据增强，也未借助其他参与者的数据进行训练。

如表 3 所示，在 BCI4-2B 上，基于时间序列的方法的平均准确率高于与 CSP 相关的方法，但 ConvNet 除外。就准确率而言，TSFF-img 与表 3 中的其他神经网络方法相比并无优势。这可能是因为与时频谱相比，时间序列包含更多信息。然而，本研究提出的 TSFF-Net 在一定程度上通过融合时间序列特征与时频特征，弥补了这一不足。

值得一提的是，WasF-ConvNet [Zhao 等人（2019）] 是一种结合时空特征与频率特征的方法，通过依次实现时频卷积和空间卷积，达到时空频特征联合学习的目的。从实验结果来看，在 BCI4-2B 数据集中，对于大多数参与者，所提出的方法均优于 WasF-ConvNet，且平均准确率领先 WasF-ConvNet 3.8%。这证明了特征融合的可行性。

4.1.3 BCI4-2A 四分类

据我们所知，目前尚无研究探讨低通道场景下的运动想象多分类问题，这可能是因为在此类场景中难以覆盖与相关神经活动对应的脑区。然而，由于容积传导效应，单个脑电电极测得的电信号是多种神经活动叠加的结果。这会降低脑电图的空间分辨率，但也为低通道场景下的运动想象多分类任务提供了可能性。

表 3：不同算法在 BCI4-2B 上的二分类性能

方法	B01	B02	B03	B04	B05	B06	B07	B08	B09	Mean	Std	P值
CSP	66.6	57.8	61.3	94.1	80.6	75.0	72.5	89.4	85.6	75.9	12.6	0.0039
FBCSP	70.0	60.4	60.9	97.5	93.1	80.6	78.1	92.5	88.9	80.2	14.0	0.0039
WaSF-ConvNet	74.0	64.0	**86.0**	98.0	86.0	73.0	**89.0**	93.0	81.0	82.7	10.7	0.25
EEGNet	77.5	61.1	63.1	**98.4**	**96.6**	83.8	84.4	92.8	88.4	82.9	13.5	0.02
ConvNet	74.4	56.1	57.5	97.5	95.3	82.2	79.7	87.5	86.6	79.6	14.8	0.0039
LMDA-Net	81.2	62.1	71.8	**98.4**	95.6	89.3	85.0	**94.6**	91.8	85.5	12.0	0.25
TSFF-img	76.6	60.7	55.9	96.9	84.1	76.6	78.4	93.4	84.4	78.5	13.5	0.0039
TSFF-Net	**83.8**	**66.8**	67.8	**98.4**	95.6	**90.0**	86.2	93.8	**95.0**	**86.4**	11.8	-

P值表示 TSFF-Net 与其他结果之间的 Wilcoxon符号秩检验。该数据集中的 CSP、ConvNet 和 EEGNet 结果分别来自 Tang 等人（2020年）、Zhao 等人（2020年）和 Miao等人（2022）。

表4：不同算法在 BCI4-2A 上的四分类性能

方法	A01	A02	A03	A04	A05	A06	A07	A08	A09	Mean	Std	P值
LMDA-Net	69.8	52.8	74.0	50.7	48.3	43.8	86.1	54.2	72.9	61.4	14.6	0.011
EEGNet	68.4	50.4	77.8	47.2	43.4	45.8	**86.8**	55.9	69.8	60.6	15.6	0.007
ConvNet	67.7	**58.7**	72.9	**52.1**	**59.4**	43.1	86.8	56.6	73.3	63.4	13.1	0.49
TSFF-img	66.7	58.3	74.3	45.1	47.6	39.9	75.0	48.3	69.8	58.3	13.5	0.007
TSFF-Net	**74.3**	56.3	**78.8**	51.7	52.1	**50.3**	86.1	**61.5**	**75.7**	**65.2**	13.6	-

P值表示 TSFF-Net 与其他结果之间的 Wilcoxon符号秩检验结果。EEGNet、ConvNet 和 LMDA-Net 的结果采用其开源网络架构，并使用与 TSFF-Net 相同的实验设置获得。

为探究这一问题，我们基于 EEGNet [Lawhern等人（2018）], ConvNet [Schirrmeister等人（2017）], 和 LMDA-Net [Miao 等人（2023）]提供的源代码，使用 C3、Cz 和 C4 通道验证了模型在四分类运动想象任务上的表现。实验结果表明，就分类性能而言，基于时间序列的模型仍优于基于时频谱的模型。在各种场景下，ConvNet 的分类性能均优于 LMDA-Net 和 TSFF-img。然而，通过融合时空特征提取网络与时频特征提取网络学习到的特征，TSFF-Net 在大多数参与者的表现以及平均准确率方面均优于 ConvNet。这进一步支持了本文提出的时空频融合框架的有效性，表明该框架在低通道运动想象场景中更具优势。

4.2 人工神经网络与 CSP 相关方法的比较

神经网络模型需要经过一定数量的训练轮次才能收敛。因此，我们在 BCI4-2A 二分类任务中比较了 EEGNet、ConvNet、LMDA、TSFF-img 和 TSFF-Net 在 350 个训练轮次内的表现，并以 SCSP（3 通道）、SCSP（22 通道）和 EA-CSP（22 通道）作为基准。需要注意的是，图 2 展示了所有参与者的神经网络模型在每个训练轮次的平均准确率。由于不同参与者的收敛速度可能略有差异，对每个轮次所有参与者的准确率取平均值，可能会导致神经网络模型的平均准确率降低。因此，图 2 中所示神经网络的平均准确率低于表2中列出的所有参与者的平均准确率。相比之下，CSP 相关方法会先计算每位参与者的最佳分类结果，再对这些结果取平均值，以得到最终结果。

如图 2 所示，所有神经网络模型在训练轮次少于 150 轮时均已收敛。收敛后，所有基于时间序列的模型的准确率均高于 SCSP（3 通道）。经过约 260 个训练轮次后，EEGNet、ConvNet 和 LMDA-Net（TSFF-raw）的分类性能均超过 EA-CSP（22）。这表明基于时间序列的模型在低通道运动想象场景中具有优势。

从图 2 可以看出，在仅使用三个通道的情况下，所提出的 TSFF-Net 的分类性能优于 SCSP（22 个通道）。这表明，所提出的 TSFF-Net 能够有效解决低通道场景下特征提取的局限性，从而为低通道运动想象脑电的使用提供更多便利。

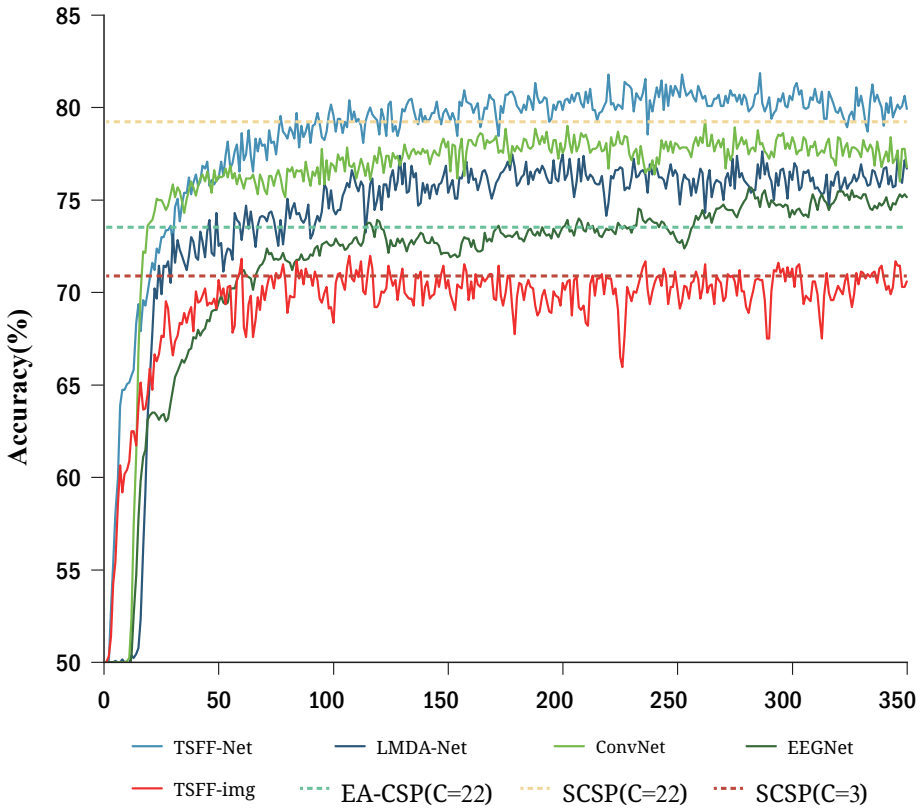


图 2：BCI4-2A 上人工神经网络与基于共同空间模式的方法在二分类中的性能比较。每个训练轮次中，人工神经网络计算所有参与者的准确率平均值，而基于共同空间模式的方法则先求出每位参与者的最佳准确率，再计算平均值。

4.3 基于时频谱图的模型比较

在本小节中，我们详细评估了不同模型在低通道场景下对时频谱图的特征提取能力。具体而言，我们比较了 TSFF-img 方法与经典自然图像卷积网络的分类性能，并探讨了不同拼接方法和下采样尺寸对 TSFF-img 网络性能的影响。

4.3.1 TSFF-img 与经典卷积神经网络的比较

Khare 和 Bajaj（2020）采用预训练的 AlexNet、VGG 和 ResNet 网络识别时频谱图，进而识别脑电信号中蕴含的情绪相关信息。据我们所知，目前尚无研究针对低通道脑电场景，基于时频谱图进行运动想象分类。因此，我们将 TSFF-img 与预训练的 AlexNet、VGG16 和 ResNet18 在运动想象分类方面的性能进行了比较。

为详细展示各模型在不同数据集上的表现，我们使用箱线图呈现各模型的分类性能。如图3所示，预训练的 AlexNet 和 VGG16 在二分类和四分类任务中均未表现出优势。在相同的训练条件下，预训练的 AlexNet 和 VGG16 的表现均接近随机猜测。相比之下，采用浅层轻量级网络架构的 TSFF-img 优于 AlexNet 和 VGG16。与 ResNet18 相比，在上述运动想象任务中，TSFF-img 的均值和中位数指标均高于 ResNet18。这些结果表明，与预训练的 ResNet18、AlexNet 和 VGG16 相比，TSFF-img 在运动想象时频谱图分类性能方面具有明显优势。

我们还研究了拼接方式和下采样尺寸对 BCI4-2B数据集中不同通道时频谱图分类准确率的影响。时频谱图的尺寸为

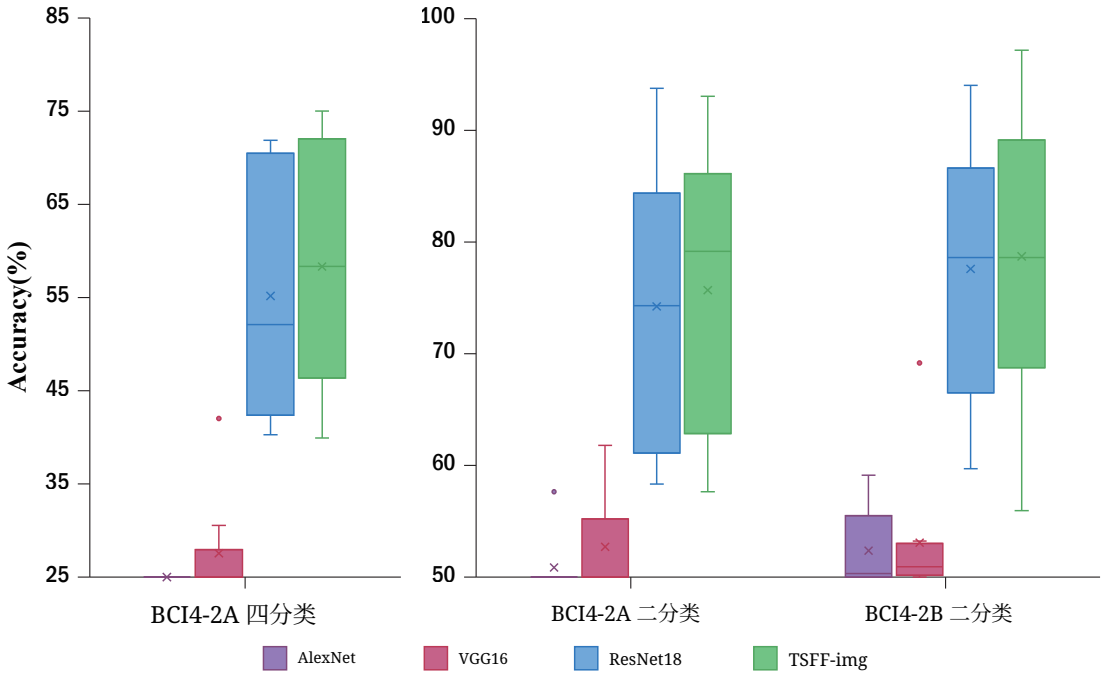


图3：TSFF-img 与预训练卷积神经网络在低通道脑电运动想象分类中的性能比较

表5：TSFF-img 的不同拼接方法和下采样尺寸对 BCI4-2B 分类结果的影响

方法	B01	B02	B03	B04	B05	B06	B07	B08	B09	AVE	STD	P值
TSFF-img(L224)	74.7	60.0	**56.3**	95.9	82.8	73.8	79.4	92.5	81.6	77.4	13.2	0.054
TSFF-img(D224)	75.0	56.1	55.6	95.6	82.5	75.3	**80.9**	91.3	81.3	77.1	13.8	0.07
TSFF-img(W72)	70.3	58.2	57.2	95.6	71.3	70.6	70.3	91.3	78.4	73.7	13.1	0.01
TSFF-img(W128)	74.1	54.6	57.8	95.6	80.0	74.7	78.4	92.2	81.3	76.5	13.6	0.049
TSFF-img(W512)	73.8	57.5	55.9	95.3	**86.6**	**78.1**	77.8	92.8	81.3	77.7	13.8	0.18
TSFF-img(W224)	**76.6**	**60.7**	55.9	**96.9**	84.1	76.6	78.4	**93.4**	**84.4**	**78.5**	13.5	-

P值表示对SEPCONWIDCAT224与其他结果进行的Wilcoxon符号秩检验。符号（L224）表示对时频谱图进行长度方向拼接，然后下采样至 [3, 224, 224]。同样，符号W和D分别表示宽度方向拼接和深度方向拼接操作。

每个通道的尺寸为 [3, W、L]。我们尝试在不同维度拼接时频谱图，例如，长度方向拼接为 [3, W、3L] ，宽度方向拼接为 [3, 3W、L] ，深度方向拼接为 [9, W、L]。随后，我们遵循 Khare等人 Khare 和 Bajaj（2020）的方法，将拼接后的时频图下采样至 [3, 224,224]。

表5显示，对不同通道的时频谱图进行宽度方向拼接，比长度方向拼接和深度方向拼接能取得更好的分类表现。因此，我们在实验中为TSFF-img选择了宽度方向拼接。此外，我们评估了宽度方向拼接中不同下采样尺寸对分类结果的影响。表5表明，下采样至224时的平均分类准确率高于下采样至72、128和512时的结果。因此，我们选择下采样尺寸224，用于后续时频谱图分析。

考虑到表5所示的结果，我们选择将不同通道的时频谱图沿宽度方向拼接，然后下采样至 [3, 224, 224] ，再输入 TSFF-img 进行训练（如图1所示）。

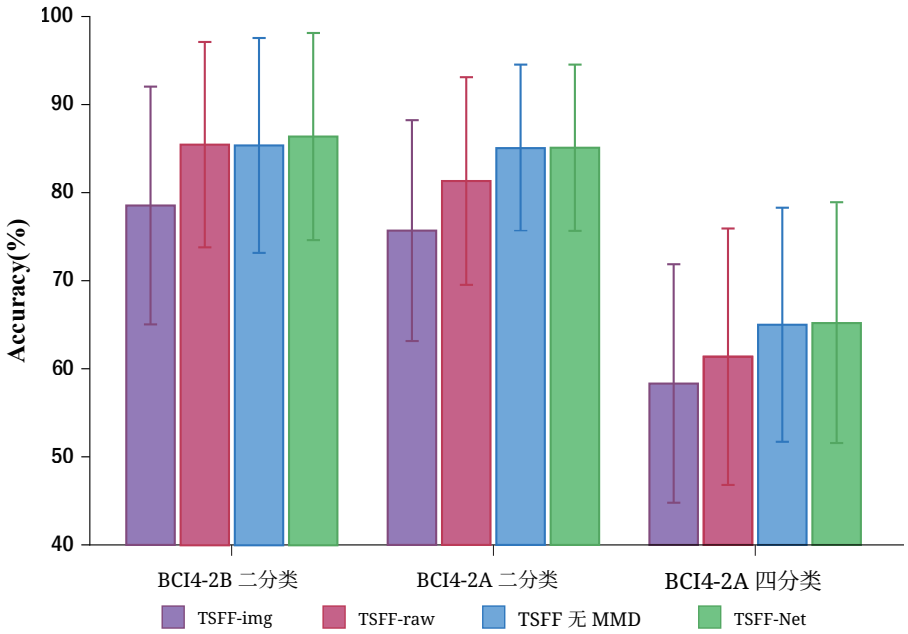


图 4：TSFF-Net 在低通道场景下对分类性能的消融研究

4.4 消融研究

所提出的融合方法由时空特征提取网络（TSFF-raw）、时频特征提取网络（TSFF-img）以及特征融合与分类组件组成。消融实验结果如图 4 所示，展示了在不同场景下，仅使用 TSFF-raw 网络、仅使用 TSFF-img 网络、不使用最大均值差异损失的特征融合，以及完整的所提出融合框架（TSFF-Net）时的 MI 分类性能。图 4 中的直方图显示了所有参与者的平均准确率，误差线则表示不同参与者分类结果的标准差。

从图 4 可以看出，在相同测试场景下，基于时间序列的方法（TSFF-raw）的分类性能优于基于时频谱图的方法。因此，所提出的融合方法通过 TSFF-img 网络，在特征提取过程中弥补了 TSFF-raw 网络忽略的时频特征。在特征融合阶段，BCI4-2A 数据集上的分类结果表明，对时空特征和时频特征进行加权融合可显著提高分类准确率。当时频特征集的权重调整为 0.001 时（考虑到时频谱图与时间序列脑电数据输入神经网络时数量级不同），BCI4-2A 在左手和右手任务的二分类中取得最高平均准确率 85.1%，在四分类任务中取得 65.0%。

然而，对于 BCI4-2A 二分类任务，采用最大均值差异损失并不能提高平均准确率。加入最大均值差异损失，并将其权重设为 0.1（相应的时频特征权重为 0.01）后，BCI4-2A 四分类任务的平均准确率达到 65.2%。对于 BCI4-2B，仅对时空特征和时频特征进行加权融合不足以提高平均准确率。将最大均值差异损失的权重（即上文的 λ）设为 1，同时将时频特征的权重设为 0.001 后，BCI4-2B数据集的平均准确率达到 86.4%。据我们所知，这也是在相同测试条件下，BCI4-2B上取得的最高平均准确率。

通过比较上述实验结果可以看出，所提出的 TSFF-Net 能够有效融合时空特征与时频特征，弥补低通道运动想象分类中单模态特征的不足。该方法为低通道场景下采集的运动想象脑电数据提供了一种强有力的分类算法，从而推动此类设备在各种应用中的广泛使用。

5 结论

本文提出了一种新型网络架构 TSFF-Net，通过融合时空频特征，有效应对低通道运动想象脑电解码中的挑战。TSFF-Net 弥补了基于时间序列或时频模态的单模态特征提取网络的局限性。通过融合时空频特征，TSFF-Net 在 BCI4-2A 和 BCI4-2B 数据集上的分类准确率均优于其他最先进方法。具体而言，在 BCI4-2A 数据集上，TSFF-Net 仅使用三个通道便取得了优异表现，超过了部分基于 22 个通道设计的经典算法。此外，鉴于鲜有研究探索基于三通道时频谱图的运动想象分类，我们提出了一种轻量级、浅层的解码架构 TSFF-img，用于特征提取。实验结果表明，在从脑电图时频谱图中提取特征方面，TSFF-img 优于 AlexNet、VGG 和 ResNet 等常见自然图像网络架构。这表明，轻量级浅层神经网络架构同样适用于时频谱图的特征提取。此外，我们设计了全面的实验来验证所提出的方法，并对实验结果进行了统计分析。总体而言，TSFF-Net 在低通道运动想象解码方面具有显著潜力，可为通过算法改进低通道脑电解码提供有价值的见解。TSFF-Net 的成功为进一步研究与应用开辟了新途径，尤其是在低通道脑电设备至关重要的便携式和娱乐应用场景中。

统计与可重复性

所有实验均采用留出测试集法，并固定所有初始化随机种子，以确保神经网络模型所得结果具有可重复性。本研究所用的超参数并非针对每位参与者单独优化，而是根据所有参与者的平均准确率设定。具体而言，在每种分类情境下，所有参与者均采用相同的初始化参数。鉴于本研究观察到较大的个体差异，我们计算了每位参与者的平均准确率和方差。此外，我们进行了Wilcoxon符号秩检验，以确定所提方法与其他方法相比的统计显著性（即P值）。

数据与代码可用性声明

支持本研究结论的原始脑电数据分别可从www.bbci.de/competition/iv/ #dataset2a和 www.bbci.de/competition/iv/#dataset2b获取。
EEGNet、ConvNet 和 LMDA-Net 的源代码分别可在以下网页公开获取：https: //github.com/vlawhern/arl-eegmodels、https://github.com/TNTLFreiburg/braindecode 和 https: //github.com/MiaoZhengQing/LMDA-Code。我们很高兴公开提供 TSFF-Net 的源代码，网址为 https://github.com/MiaoZhengQing/TSFF。

作者贡献声明

ZhengqingMiao：概念构思、方法设计、正式分析、调查、可视化、撰写初稿 **Meirong Zhao**监督、经费获取。

利益冲突声明

作者声明不存在任何利益冲突。

致谢

我们衷心感谢杨一伟对图表的润色。我们也要向匿名审稿人致以诚挚的谢意，感谢他们提出的建设性反馈和宝贵建议，这些意见对提升本文质量起到了重要作用。

参考文献

Al-Saegh, A., Dawwd, S.A., Abdul-Jabbar, J.M., 2021年。用于运动想象脑电图分类的深度学习：综述。Biomedical Signal Processing and Control 63, 102172。Ang, K.K., Chin, Z.Y., Zhang, H., Guan, C., 2008年。脑机接口中的滤波器组共空间模式（FBCSP），载于：2008年 IEEE国际神经网络联合会议（IEEE计算智能世界大会），IEEE。第2390–2397页。Arvaneh, M., Guan, C., Ang, K.K., Quek, C., 2011年。优化基于脑电图的脑机接口中的通道选择与分类准确率。IEEE生物医学工程汇刊 58, 1865–1873。Baig, M.Z., Aslam, N., Shum, H.P., 2020年。运动想象脑电图应用中的通道选择滤波技术：综述。Artificial Intelligence Review 53, 1207–1232。Borra, D., Fantozzi, S., Magosso, E., 2020年。用于脑电解码的可解释轻量级卷积神经网络：动作执行与运动想象的应用。Neural Networks 129, 55–74。Craik, A., He, Y., Contreras-Vidal, J.L., 2019年。用于脑电图分类任务的深度学习：综述。Journal of Neural Engineering 16, 031001。Gretton, A., Borgwardt, K.M., Rasch, M.J., Sch¨olkopf, B., Smola, A., 2012年。核双样本检验。The Journal of Machine Learning Research 13, 723–773。He, H., Wu, D., 2019年。脑机接口的迁移学习：一种基于欧几里得空间的数据对齐方法。IEEE生物医学工程汇刊 67, 399–410。He, K., Zhang, X., Ren, S., Sun, J., 2016年。用于图像识别的深度残差学习，载于：IEEE计算机视觉与模式识别会议论文集，第770–778页。Khare, S.K., Bajaj, V., 2020年。基于时频表示和卷积神经网络的情绪识别。IEEE神经网络与学习系统汇刊 32, 2901–2909。Krizhevsky, A., Sutskever, I., Hinton, G.E., 2017年。使用深度卷积神经网络进行ImageNet分类。Communications of the ACM 60, 84–90。Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P., Lance, B.J., 2018年。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。Journal of Neural Engineering 15, 056013。Lin, J., Qu, L., 2000年。基于Morlet 小波的特征提取及其在机械故障诊断中的应用。Journal of Sound and Vibration 234, 135–148。Loshchilov, I., Hutter, F., 2018年。修正Adam中的权重衰减正则化。网址：https://openreview.net/ forum?id=rk6qdGgCZ。Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., Yger, F., 2018年。基于脑电图的脑机接口分类算法综述：十年更新。Journal of Neural Engineering 15, 031005。Lotte, F., Guan, C., 2010年。通过正则化共空间模式改进脑机接口设计：统一理论与新算法。IEEE生物医学工程汇刊 58, 355–362。Madhavan, S., Tripathy, R.K., Pachori, R.B., 2019年。用于局灶性与非局灶性脑电信号分类的时频域深度卷积神经网络。IEEE Sensors Journal 20, 3078–3086。Mammone, N., Ieracitano, C., Morabito, F.C., 2020年。一种深度卷积神经网络方法：从源级脑电信号的时频图中解码上肢运动准备。Neural Networks 124, 357–372。Miao, Z., Zhang, X., Menon, C., Zheng, Y., Zhao, M., Ming, D., 2022年。利用通用深度领域自适应框架为跨会话运动想象分类进行预训练。arXiv预印本 arXiv:2202.09559。Miao, Z., Zhang, X., Zhao, M., Ming, D., 2023年。LMDA-Net：用于通用基于脑电图的脑机接口范式及可解释性的轻量级多维注意力网络。arXiv预印本 arXiv:2303.16407。Minguillon, J., Lopez-Gordo, M.A., Pelayo, F., 2017年。日常生活中的脑电图脑机接口发展趋势：伪迹去除的要求。Biomedical Signal Processing and Control 31, 407–418。Niedermeyer, E., da Silva, F.L., 2005年。脑电描记术：基本原理、临床应用及相关领域。Lippincott Williams & Wilkins。Nunez, P.L., Srinivasan, R., 2006年。脑电场：脑电图的神经物理学。牛津大学出版社，美国。Olfers, K.J., Band, G.P., 2018年。游戏化训练提升灵活性与注意力，改善任务切换表现：脑电图研究中的认知训练近迁移与远迁移。Psychological Research 82, 186–202。

Park, W.、Kwon, G.H.、Kim, D.H.、Kim, Y.H.、Kim, S.P.、Kim, L.，2014年。运动康复期间基于单试次脑电图评估中风患者的认知投入。IEEE神经系统与康复工程汇刊 23，351–362。Pfurtscheller, G.、Brunner, C.、Schl¨ogl, A.、Da Silva, F.L.，2006年。不同运动想象任务中 μ节律的（去）同步化与脑电图单试次分类。NeuroImage 31，153–159。Pfurtscheller, G.、Neuper, C.，2001年。运动想象与直接脑机通信。IEEE论文集 89，1123–1134。Ramoser, H.、Muller-Gerking, J.、Pfurtscheller, G.，2000年。想象手部运动期间单试次脑电图的最优空间滤波。IEEE康复工程汇刊 8，441–446。Rioul, O.、Duhamel, P.，1992年。离散小波变换和连续小波变换的快速算法。IEEE信息论汇刊 38，569–586。Rosipal, R.、Trejo, L.J.，2001年。再生核希尔伯特空间中的核偏最小二乘回归。机器学习研究杂志 2，97–123。Schirrmeister, R.T.、Springenberg, J.T.、Fiederer, L.D.J.、Glasstetter, M.、Eggensperger, K.、Tangermann, M.、Hutter, F.、Burgard, W.、Ball, T.，2017年。利用卷积神经网络进行脑电解码与可视化的深度学习。人脑图谱 38，5391–5420。Shannon, C.E.，2001年。通信的数学理论。ACM SIGMOBILE移动计算与通信评论 5，3–55。Simonyan, K.、Zisserman, A.，2014年。用于大规模图像识别的超深度卷积网络。arXiv预印本 arXiv:1409.1556。Sterman, M.B.，1996年。脑电节律活动的生理起源及功能相关性：对自我调节的启示。生物反馈与自我调节 21，3–33。Tang, X.、Li, W.、Li, X.、Ma, W.、Dang, X.，2020年。基于条件优化经验模态分解和多尺度卷积神经网络的运动想象脑电识别。专家系统与应用 149，113285。Xu, M.、Yao, J.、Zhang, Z.、Li, R.、Yang, B.、Li, C.、Li, J.、Zhang, J.，2020年。通过卷积神经网络学习用于分类的脑电地形表示。模式识别 105，107390。Zanini, P.、Congedo, M.、Jutten, C.、Said, S.、Berthoumieu, Y.，2017年。迁移学习：黎曼几何框架及其在脑机接口中的应用。IEEE生物医学工程汇刊 65，1107–1116。Zhao, D.、Tang, F.、Si, B.、Feng, X.，2019年。学习用于小规模标注数据脑电解码的联合时空频特征。Neural Networks 114，67–77。Zhao, H.、Zheng, Q.、Ma, K.、Li, H.、Zheng, Y.，2020年。面向非平稳脑电分类的基于深度表示的领域自适应。IEEE神经网络与学习系统汇刊 32，535–545。