

基于Winger-Ville-CNN-LSTM的运动想象脑电信号识别

张欣悦, 王文波

武汉科技大学理学院, 湖北 武汉

收稿日期: 2026年5月9日; 录用日期: 2026年6月2日; 发布日期: 2026年6月8日

摘要

运动想象脑电信号(MI-EEG)识别是脑机接口系统研究的重要组成部分。为了更好地处理非平稳的脑电信号(EEG)并从中提取特征进行有效分类,本文提出了一种基于Winger-Ville分布(WVD)、二维卷积神经网络(CNN-2D)与长短时记忆网络(LSTM)的MI-EEG分类的模型(WVD-CNN-LSTM)。考虑到线性时频分析方法无法对EEG信号的瞬时功率谱密度进行准确描述,导致时频分析过程中EEG的部分重要非线性信息被丢失,本文使用WVD提取EEG数据的时频特征,构建具有高分辨率的信号时频表示结果。由于LSTM和CNN具有的强大特征提取能力以及对复杂数据的处理能力,为了能够利用两种网络的优势,本文采用将LSTM与二维CNN进行结合得到的CNN-2D + LSTM网络作为分类器。同时使用Softmax层进行分类决策与识别,最终输出MI-EEG的分类识别结果。本文采用来自于BCI竞赛IV公共数据集Data sets 2b进行实验分析,使用本文提出的方法对数据集中的左右手运动想象脑电数据集进行分类识别,并与现有方法进行了对比分析。实验结果表明,本文所提的方法具有较好的分类识别能力。与CSP方法、FBCSP-MIBIF方法和FBCSP-MIRSR方法相比,分类准确率分别提高了7.51%、5.07%和4.16%。

关键词

脑电信号, 运动想象, 时频分布, 卷积神经网络, 长短时记忆网络

Recognition of Motor Imagery EEG Signals Based on Wigner-Ville-CNN-LSTM

Xinyue Zhang, Wenbo Wang

College of Science, Wuhan University of Science and Technology, Wuhan Hubei

Received: May 9, 2026; accepted: June 2, 2026; published: June 8, 2026

Abstract

Motor imagery electroencephalogram (MI-EEG) recognition constitutes a crucial component of brain-computer interface (BCI) systems. To better process non-stationary EEG signals and extract features for effective classification, this paper proposes a MI-EEG classification model based on the Wigner-Ville Distribution (WVD), two-dimensional convolutional neural network (CNN-2D), and long short-term memory (LSTM) network, termed WVD-CNN-LSTM. Given that linear time-frequency analysis methods cannot accurately characterize the instantaneous power spectral density of EEG signals, leading to the loss of significant nonlinear information during time-frequency analysis, this study employs WVD to extract time-frequency features from EEG data and construct high-resolution time-frequency representations. Leveraging the powerful feature extraction capabilities and complex data processing abilities of LSTM and CNN, and to exploit the advantages of both networks, a hybrid CNN-2D + LSTM network is adopted as the classifier. The Softmax layer is subsequently utilized for classification decision-making and recognition, ultimately yielding the MI-EEG classification results. Experimental analysis was conducted using the BCI Competition IV public dataset Data sets 2b, where the proposed method was applied to classify left-hand and right-hand motor imagery EEG data, and comparative analysis with existing methods was performed. Experimental results demonstrate that the proposed method achieves superior classification performance. Compared with the CSP, FBCSP-MIBIF, and FBCSP-MIRSR methods, the classification accuracy is improved by 7.51%, 5.07%, and 4.16%, respectively.

Keywords

Electroencephalogram Signals, Motor Imagery, Time-Frequency Distribution, Convolutional Neural Network, Long Short-Term Memory Network

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

大脑是人体生命系统的“总司令”，在人体中有着极其重要的地位，它不仅有着控制人体运动、产生感觉的功能，同时也具有实现高级脑功能的高级中枢神经的功能，是支配人类生存活动的中枢神经系统[1]。大脑的不同区域各司其职，随着脑科学研究的不断深入与智能设备的现代化发展，通过解析人脑的脑电信号来操控外部设备研究逐渐成为研究热点[2]。

在当今社会中，患有破坏与外界进行交流的神经肌肉通路的疾病，如脊髓损伤、脑瘫、脑干中风、肌萎缩性侧索硬化症等闭锁综合征的患者逐渐增加[3]。对于这些患者来说，他们的大脑认知功能正常但神经肌肉通路功能丧失，因而他们能够清楚地感知到自己无法正常控制自身肌肉活动，这是一件极其煎熬的事情[4]。因此为了帮助这类患者改善运动功能，恢复一定的生活质量，将患者的大脑信号传输到外部并加以控制，用于解析脑电信号的脑机接口(BCI)技术也成为学者们研究的重点方向[5]。脑机接口系统是实现大脑与外部设备直接交互的一种系统。近年来，脑机接口技术迅速发展，安全度较高的非植入式BCI已广泛应用，其采集方式主要分为脑电信号(EEG)、脑磁图(MEG)、磁共振成像(MRI)、近红外光谱(NIRS)四类[6]。其中，EEG由于其出色的时间分辨率、便捷性、安全性等特点，成为了现今最常用的信号采集方式[7]。

运动想象脑电信号(MI-EEG) [8]是如今最常用的脑电信号之一, 对于其的分类研究与应用已是当下脑机接口系统研究的重要组成部分。目前, 基于 MI-EEG 的脑机接口系统已在医学康复治疗领域有了一定研究与应用。例如, 利用 MI-EEG 促进脑卒中患者运动功能的康复[9] [10]、检测患有意识障碍患者的意识以便及时诊断与治疗[11]。除生物医学领域外, MI-EEG 在智能家居与体能训练等领域也有着十分广阔的应用前景。在智能家居领域, 可以利用 MI-EEG 辅助人们更加便捷地通过意念控制智能家居的开关与使用[12]。对于运动员来说, 运动想象训练法可以改善运动员心理状态并加速身体机能的恢复。综上所述, 对于 MI-EEG 的研究不论是在科研领域还是生活中都有着十分重要的意义与应用前景。

随着深度学习方法的快速发展, EEG 信号的分类研究已大量应用深度学习方法来提高分类准确率。CNN 可以直接从 EEG 中学习 ERD/ERS 脑电模式并提取层次结构[13] [14]。例如, Lawhern 与 Solon 等人提出的 EEGNet 浅层 CNN 模型, 将多个卷积滤波器以并行、串行的形式相结合, 对输入的 EEG 原始信号提取其空间与时间特征, 结果显示该模型相比起传统机器学习方法有着更优越的分类性能[15]。对 MI-EEG 的分类研究, CNN 结构的优越特征也已在多项研究中得到证明。Echtioui 等[16]利用 CSP 提取的空间特征与小波包分解提取的时频特征, 对 CNN、CNN + LSTM、CNN-SVM 与 CNN + LSTM-SVM 四种分类模型进行了对比, 结果表明 CNN-SVM 具有最好的分类效果。Xie 等[17]提出了一种两分支的并行卷积神经网络的深度学习算法, 结果表明该方法在分类准确率上相对于其他先进方法有明显优势。对于 MI-EEG 分类问题, 特征提取与分类器的选择至关重要, 如何获取时频图是 MI-EEG 分类的关键。

传统的脑电信号特征提取方法, 大致包括时域、频域、时频域与空域这几大方面。时域特征主要包含均值、方差、峰度、偏度、Hjorth 参数[18]、去趋势波动分析(DFA) [19] [20]、分行维数[21]。Lee 等[22]采取了三种特征提取方法分别提取了空域、时域、频域特征, 并对三种特征与分类器的分类结果进行了比较, 结果表明时域特征与收缩正则化线性判别分析组合得到的分类准确率最高。频域特征主要包括带通功率[23]与功率谱密度(PSD) [24] [25]。Herman 等[26]对光谱信号表示的不同方法进行了比较, 结果表明功率谱密度在 MI-EEG 分类上拥有更好的鲁棒性与有效性。空域特征方面的研究主要集中于对共空间模式(CSP)的优化与改进。Ali 等[27]提出基于对角加载的正则化 CSP (DL-CSP)和皮尔逊相关系数(PCC)的特征选择方法, 并在三个数据集上均验证了该方法能有效提高分类准确率。

时频分布作为常见的信号的二维表示, 常被用作 CNN 网络的输入来进行 EEG 的分类任务, 例如频谱特征[28] [29]及其二维图像[30] [31]等。时频特征可以揭示信号在不同时间与频率上的特性, 现今常用的时频分析方法有短时傅里叶变换(STFT) [32] [33]、小波变换(WT) [34]、S 变换[35]、希尔伯特黄变换等。郭玉雪等[36]提出了一种离散小波变换(DWT)与卷积自编码(CAE)相结合的 MI-EEG 分类算法, 研究结果表明该算法在左右手 MI-EEG 分类应用中相比其他方法具有更优的性能。Mahmud 等人[37]提出了一种基于连续小波变换(CWT)的多通道脑电数据特征表示, 并与 CNN 相结合用于情绪识别, 同时基于 CWT 域能量熵比提出了有效信道与 CWT 尺度选择方案, 以降低计算复杂度, 结果表明该方法在 2 类与 3 类问题上, 效价与唤醒分类准确率均有所提升。Liyangedera 等人[38]将 CSP、STFT 与常见的神经网络相结合用于冥想与非冥想脑电信号的分类识别, 实验结果显示不论是使用 CSP、STFT 还是二者结合的算法, 均可以有效实现脑电图冥想与非冥想数据的分类。Liu 等[35]使用 S 变换提取了脑电图信号的相位与功率谱, 并设计了一个双流卷积神经网络模型作为分类器, 成功证明了相位输入特征在 EEG 检测中的有用性。尽管以上这些国内外研究都证明了常用的时频方法与神经网络的结合在 EEG 分类研究上的可行性, 但由于在对 EEG 频谱和能量密度与时间之间的关系进行描述时, STFT、WT 等时频分析方法都是采用的线性时频联合函数来进行的, 而能量是非线性的, 采用这些线性的时频分析方法会忽略掉信号的部分非线性信息, 难以完整准确地对 EEG 信号进行描述分析。

因此, 本文采用基于非线性变换的 Wigner-Ville 分布(WVD)提取运动想象脑电信号的时频信息, 并

将其与二维卷积神经网络(CNN-2D)、长短时记忆网络(LSTM)相结合, 构建基于 WVD-CNN-LSTM 的分类识别模型。首先, 采用 WVD 模型将 EEG 信号投射到时频域, 得到了蕴含更多的时频信息的时频图。然后, 将 LSTM 与二维 CNN 进行结合得到的 CNN-2D+LSTM 网络作为分类器, 采用 Softmax 层对 MI-EEG 信号进行分类识别与结果输出。实验结果表明, 本文提出 WVD-CNN-LSTM 方法在 MI-EEG 的分类上获得了较高精度的分类结果, 与经典的 EEG 分类模型相比具有更高的分类精度和鲁棒性。

2. 数据集与数据预处理

2.1. BCI 数据集

本研究中使用的数据集是来自于 BCI 竞赛 IV 公共数据集 Data sets 2b, 该数据集是基于视觉诱发的左右手运动想象脑电数据集, 包括了 9 名实验者的 EEG 数据, 这 9 名实验者均为右利手且视力正常或经矫正后达到正常视力, 以确保排除了由于视力原因对实验结果造成的影响。EEG 电极放置如图 1 所示, 脑电信号数据来自于 Cz、C3、C4 这 3 个电极记录的运动想象, 采样频率为 250 Hz, 所有信号数据都经过了 0.5~100 Hz 的带通滤波与 50 Hz 的陷波滤波处理。同时为了排除眼电的干扰, 还采集了眼电数据, 眼电电极分布如图 2 所示。每位受试者的实验数据分别包含五个阶段, 分别是前两个无反馈的训练数据阶段与后三个带反馈的记录数据阶段, 而每个实验阶段的具体流程见图 3。

在数据采集过程中, 实验者被要求坐在距离显示屏 1 米的位置进行实验。前两个无反馈实验阶段中, 每次运动想象测试开始时屏幕上显示一个十字光标并伴随一个 70 ms 的短音提示, 1 s 后屏幕中的十字光标根据要进行的左右手运动想象任务变成相应的朝左或右的箭头, 图案大约持续 1.25 s 后, 实验者需在 3~7 s 的时间段内进行运动想象并得到相应的 EEG 数据, 在此之后实验者可以休息至少 1.5 s。后三个有反馈实验阶段中, 每次运动想象测试开始时屏幕上显示一个灰色笑脸, 2 s 后播放一个 70 ms 的短音提示, 第 3 s 开始呈现视觉提示信号, 实验者根据提示想象左右手运动并将笑脸移向对应侧, 若笑脸移动方向正确则变为绿色笑脸, 反之变为红色沮丧脸, 第 7.5 s 时显示屏变空白, 在此之后实验者可以获得随机 1~2 s 不等的休息时间。




Figure 1. Placement of EEG electrode
图 1. EEG 电极的放置




Figure 2. Placement of EOG electrode
图 2. EOG 电极的放置




Figure 3. The process of a single test stage
图 3. 单个实验阶段的流程

2.2. 数据预处理

本研究采用的数据预处理过程主要包括三部分：带通滤波、Z 分数归一化、基于振幅的伪影去除。首先采用 8~30 Hz 的 Butterworth 带通滤波器来消除原始信号中不需要的低频漂移与高频噪声，保留了多位研究人员所认为的是心理活动良好指标的 α 波段与 β 波段。接下来对于因电极放置差异、个人生理差异或其他记录条件的差异而可能产生的变异性，选择对过滤后的数据集执行 Z 分数归一化，使不同受试者与不同实验阶段之间的振幅标准化。将每个通道过滤后的数据减去平均值后除以标准差，以确保所有通道的均值为 0，方差为 1，实现所有数据的均匀缩放。最后由于实验中实验者的眼球运动或肌肉活动可能产生一些干扰信号，为了解决这一问题，对归一化后的数据进行了基于振幅的伪影去除，将归一化数据集中超过设定阈值 3 的数据点都替换为 NaN，并应用 255 阶中值滤波器得到的值替换数据中的所有 NaN 值，同时采用公共平均参考(CAR)方法对信号进行参考。

3. 基于 Wigner-Ville-CNN-2D-LSTM 的 EEG 识别

3.1. 识别模型整体框架

本文所使用的分类模型结构如图 4 所示。首先对经过 8~30 Hz 带通滤波、Z 分数归一化和伪影去除预处理的 EEG 数据进行时频分析，采用 WVD 提取其时频特征，构造能得到 EEG 数据高分辨率的时频表示，接下来将构造的时频表示输入 CNN-2D 与 LSTM 相结合的分类器进行进一步的特征提取与分类。在本研究所用的 CNN-2D + LSTM 分类器中，首先利用带有 ReLU 激活函数的卷积层来自动提取特征，进行填充后输入 2×2 最大池化层，该过程被重复两遍。在经过两个卷积层后，最后使用 LSTM 与全连接层(FC)结合来对网络训练提取到的深度抽象特征进行分类。

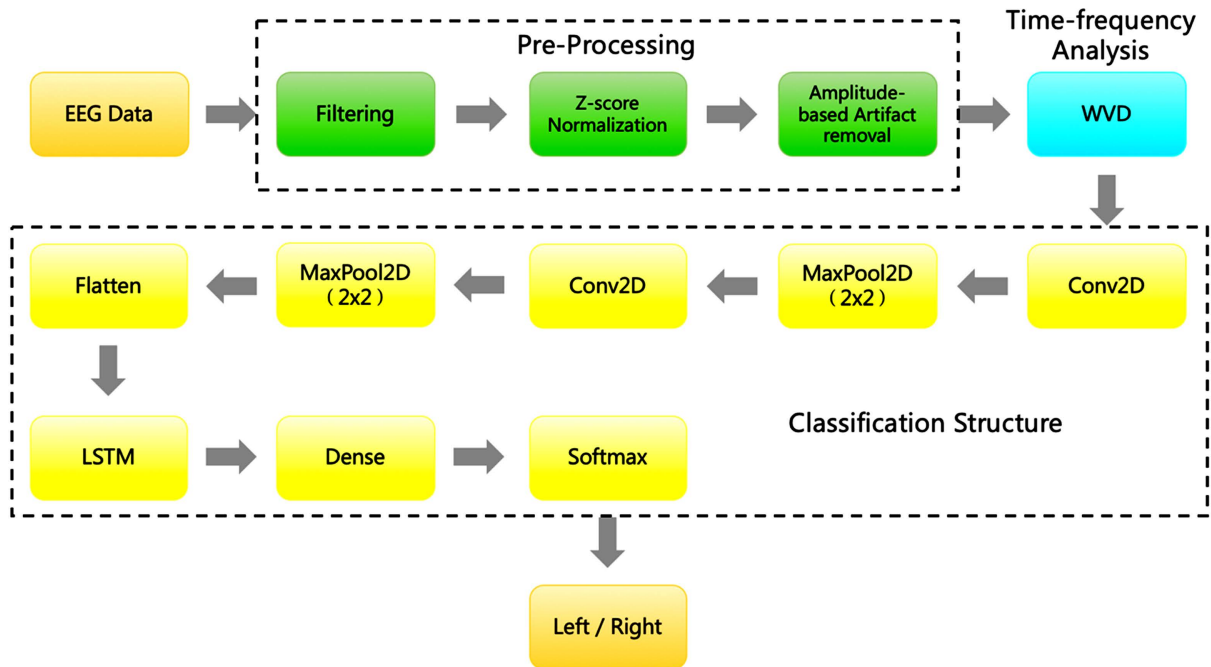


Figure 4. Classification model structure
图 4. 分类模型结构

3.2. Wigner-Ville 分布

对于现实当中信号往往是非平稳的情况, 仅了解信号在时域与频域的全局统计特性是远远不够的, 因此为了捕捉信号频谱随时间变化的情况, 需要从时频域出发对信号进行分析, 即时频分析。时频分析方法按照视频联合函数可分为线性时频分析与双线性时频分析, 又称二次型时频分析。常见的线型时频分析主要有 STFT、Gabor 展开、WT 等, 但他们无法对信号的瞬时功率谱密度进行描述, 会导致信号的部分非线性信息在时频分析中被忽略, 此时二次型时频分析就是一种更为直观合理的时频分析方法。

二次型时频分析是信号从时域投影到时频域的二次变换, 其不再满足线性时频分析所具有的线性叠加性但满足二次叠加性。Wigner-Ville 分布(WVD)是二次型时频分析中最常用的一种, 其重要的特点之一就是具有明确的物理意义, 可被看作信号能量在时域和频域中的分布, 相对于其他二次型时频分析具有更多对信号分析有利的数学性质, 能够在一定程度上提高信号时频表示的分辨率[39]。因此本研究选择 WVD 作为时频分析方法对预处理后的 EEG 数据提取时频特征。

由于二次型变换在处理多分量信号时会出现交叉项干扰, 这极大影响了时频分析的结果[31]。因此为了解决 WVD 存在的交叉项问题, 首先需要将时域信号 $x(t)$ 转换为解析形式 $a_x(t)$ [40]:

$$a_x(t) = x(t) + jHT\{x(t)\} \quad (1)$$

其中 $HT\{\}$ 为 Hilbert 变换[41]。由于解析信号 $a_x(t)$ 的 WVD 不存在交叉项, 因此不会造成信号信息的损失。利用下式得到瞬时频率 $f_i(t)$, 以获得最高的时频分辨率:

$$f_i(t) = \frac{1}{2\pi i} \frac{d\theta(t)}{dt} \quad (2)$$

其中, $\theta(t)$ 为解析信号 $a_x(t)$ 的相位。得到解析信号与瞬时频率后, 通过下式构造 WVD:

$$W_{a_x}(t, f) = \int_{-\infty}^{\infty} a_x\left(t + \frac{\tau}{2}\right) a_x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi r f} \partial \tau \quad (3)$$

由此通过 WVD 得到了 EEG 信号的时频特征, 可用于输入后续的网络中进行进一步的特征提取与分类。

3.3. CNN-2D + LSTM 模型

卷积神经网络(CNN)可以使用其内核从数据中提取空间特征, 相较于人工神经网络(ANN)参数数量有了明显的减少, 有效降低了模型的计算量, 这一特点促使了越来越多的研究选择使用 CNN 来解决传统 ANN 无法完成的复杂任务。近年来, CNN 已凭借其强大的特征提取能力与对复杂数据的处理能力, 在图像识别、目标检测等领域得到了广泛的应用。本研究中选择二维卷积神经网络(CNN-2D)来进行运动想象脑电信号的分类, 并且为了合理表征 EEG 信号中所蕴含的时间信息, 引入了长短时记忆网络(LSTM)与 CNN-2D 相结合, 共同组成了 CNN-2D + LSTM 分类器。该分类器结构如下图 5 所示:

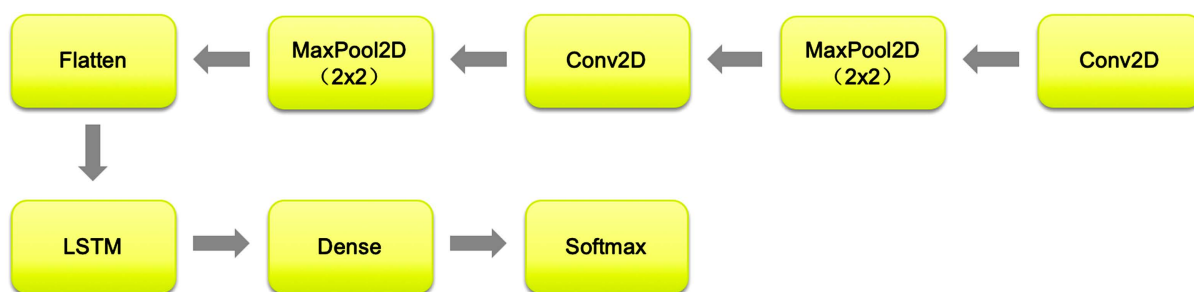


Figure 5. CNN-2D + LSTM structure

图 5. CNN-2D + LSTM 结构

对于 CNN-2D 包含两个卷积层与两个 2×2 最大池化层, 卷积层中使用 ReLU 函数作为激活函数。ReLU 函数可以在保持所有正值不变的情况下将所有的负值置为 0, 为模型引入了非线性特征的表示, 函数公式如下式所示:

$$\text{ReLU}(x) = \max(0, x) \quad (4)$$

输入数据首先经过 CNN-2D 的卷积层结构中进行特征提取, 接下来在经过展平层后, 输出的特征被输入到 LSTM 层与全连接层进行分类。LSTM 层采用 tanh 函数作为激活函数, 单元数为 4, 并且为防止过拟合, 将 dropout 设置为 0.5。最后采用 Softmax 层完成分类与结果的输出, 全连接层与 Softmax 层的神经元数量分别为 32 和 2, 其中 Softmax 层的神经元数量与二分类任务相对应因此是 2。网络中采用分类交叉熵作为损失函数, 使用 Adam 优化器, 并将学习率设置为 10^{-4} 。CNN-2D + LSTM 网络分类模型的详细相关参数设置见下表 1。

3.4. 评价指标

本研究采用两种广泛应用于分类模型性能评估的评价指标: 准确率(Acc)与 Kappa 系数。Acc 是分类模型正确分类的样本数占总样本数的比例, 而 Kappa 系数常被用于分类任务的一致性检验, 以衡量分类精度, 又被称为假设性的随机一致性概率。Acc 与 Kappa 系数的数学表达式如下(5)式与(6)式:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \quad (5)$$

$$K = \frac{\text{Acc} - p_e}{1 - p_e} \quad (6)$$

式(5)中, TP (True Positives)为将正类预测为正类的样本数, TN (True Negatives)为将负类预测为负类的样本数, FP (False Positives)为将负类预测正类的样本数, FN (False Negatives)为将正类预测为负类的样本数。式(6)中, p_e 为随机预测的 Acc, 具体解释为: 假设每一类的实际样本数分别为 $a_1, a_2, a_3, \dots, a_C$, 而实际预测出的每一类所含样本数为 $b_1, b_2, b_3, \dots, b_C$, 总样本数为 n , 则 p_e 可以表示为:

$$p_e = \frac{a_1 \times b_1 + a_2 \times b_2 + \dots + a_C \times b_C}{n \times n} \quad (7)$$

Table 1. Parameter settings of CNN-2D + LSTM network

表 1. CNN-2D + LSTM 网络的参数设置

网络层	卷积核数	卷积核尺寸	池化窗口	填充方式	步长	激活函数	参数量
卷积层	4	3 × 3	-	same	(1, 1)	ReLU	40
池化层	-	-	2 × 2	valid	(2, 2)	-	0
卷积层	4	3 × 3	-	same	(1, 1)	ReLU	148
池化层	-	-	2 × 2	valid	(2, 2)	-	0
Flatten 层	-	-	-	-	-	-	0
LSTM	-	-	-	-	-	tanh	14,864
全连接层	-	-	-	-	-	ReLU	160
Softmax 层	-	-	-	-	-	Softmax	66

4. 结果与讨论

4.1. 实验结果

为了确定本文所提出的方法架构的可行性, 本文将数据集中的原始数据经过带通滤波、Z 分数归一化、基于振幅的伪影去除等预处理后得到的数据, 使用 Wigner-Ville 分布(WVD)得到其时频特征后, 输入本文选用的 CNN-2D 与 LSTM 相结合的分类器中进行分类, 并将得到的分类实验结果与采用 Ang 等人[42]所提出的共空间模式算法(CSP)与分别结合了基于互信息的最佳个体特征算法(MIBIF)和基于互信息的粗糙集约简算法(MIRSR)的滤波器组共空间模式算法(FBCSP)所得到的分类实验结果进行了对比, 两种分类实验均采用了 10 折交叉检验。表 2 展示了数据集中不同被试在本文所提出的方法架构与文献[42]中采用方法的 Acc 与 Kappa 值结果。

4.2. 分类性能与对比讨论

根据表 1 的对比结果显示, 相较于文献[42]提出的分类算法, 本文所提出的方法取得了最高的平均分类准确率 77.1%与平均 Kappa 值 0.541, 并且在除了被试 4 与被试 6 以外的被试者上均取得了最高的分类准确率与 Kappa 值。这一结果充分证明了本文所选取的方法具有不错的分类性能。

文献[42]所提出的共空间模式算法(CSP)与结合了基于互信息的最佳个体特征算法(MIBIF)和基于互信息的粗糙集约简算法(MIRSR)的滤波器组共空间模式算法(FBCSP)分别获得了 71.7%、73.4%、74%的分类准确率与 0.438、0.475、0.502 的 Kappa 值, 这一结果表明, 相比于 MIBIF 特征选择算法, MISRS 特

征选择算法产生了更高的平均 Kappa 值。同时也表明, 在 S1、S5、S6 三名被试者中 MIRSR 特征选择算法表现最佳; 在 S4、S7、S8 三名被试中 MIBIF 特征选择算法表现最佳; 在 S2、S3、S9 三名被试中 CSP 算法表现最佳, 其中被试者 8 在 MIBIF 特征选择算法与 CSP 算法下的分类准确率无明显差异但 CSP 算法下的 Kappa 值较高。而与这三个算法进行对比, 本文方法在平均分类准确率上分别提高了 7.51%、5.07%、4.16%, 在 S1、S5 两名被试者中相对于 MIRSR 特征选择算法分类准确率分别提高了 8.95%、1.39%, 在 S7、S8 两名被试者中相对于 MIBIF 特征选择算法分类准确率提高了 1.46%、7.61%, 在 S2、S3、S9 三名被试中 CSP 算法分类准确率分别提高了 9.33%、4.04% 与 6.84%。

综上所述, 相比于传统的特征选择与机器学习算法, 本文所提出的采用 WVD 提取 MI-EEG 数据的时频特征并引入 CNN-2D + LSTM 模型分类器进行分类的方法, 能够较为明显地提高 MI-EEG 的分类准确率, 具有较为良好的分类性能与可行性。

Table 2. The method used in this article and the method used in the literature [42] compare the classification accuracy and Kappa value on the BCIIV-2b dataset

表 2. 本文方法与文献[42]所用方法在 BCIIV-2b 数据集上分类准确率与 Kappa 值对比

被试者	CSP		FBCSP- MIRSR		FBCSP-MIBIF		本文方法	
	Acc	Kappa	Acc	Kappa	Acc	Kappa	Acc	Kappa
S1	0.607	0.274	0.631	0.372	0.622	0.336	0.688	0.393
S2	0.538	0.059	0.517	0.028	0.503	0.022	0.588	0.174
S3	0.574	0.157	0.553	0.112	0.562	0.139	0.597	0.194
S4	0.925	0.845	0.950	0.929	0.963	0.933	0.932	0.865
S5	0.776	0.559	0.865	0.719	0.850	0.703	0.877	0.733
S6	0.527	0.036	0.637	0.375	0.594	0.189	0.597	0.194
S7	0.817	0.582	0.829	0.603	0.835	0.625	0.847	0.694
S8	0.856	0.761	0.850	0.758	0.856	0.738	0.921	0.842
S9	0.832	0.673	0.827	0.618	0.817	0.593	0.889	0.778
Mean	0.717	0.438	0.740	0.502	0.734	0.475	0.771	0.541

5. 结论

本文提出了一种基于 WVD-CNN-2D-LSTM 的运动想象脑电信号分类方法, 首先使用 WVD 提取 EEG 数据的时频特征, 实现非平稳脑电信号的高分辨率时频分析, 为后续 EEG 识别步骤提供高质量输入。然后, 采用 CNN-2D 与 LSTM 融合架构的分类模型, CNN-2D + LSTM 的分类框架同时利用 CNN 网络与 LSTM 网络的优势, 可以更有效的提取 EEG 信号的时频特征。最后, 基于所提取的特征采用 Softmax 层进行分类决策, 并输出 EEG 的识别结果。基于 BCI-IV-Data sets 2b 数据集的实验结果表明, 与已有算法相比, 本文方法在 Data sets 2b 数据集上能够获得更好的分类结果, Acc 和 Kappa 值分别达到了 0.771 和 0.541。实验结果验证了本文方法在 MI-EEG 分类任务中的可行性与有效性, 并且由于本文的网络仅包含两个卷积层, 本文模型在训练时间上也具有一定程度的优势。

参考文献

- [1] Son, J. and Ku, J. (2019) Development of Brain Computer Interface Based Action Observation Program with Functional

- Electrical Stimulation Device (FES). 2019 7th International Winter Conference on Brain-Computer Interface (BCI), Gangwon, 18-20 February 2019, 1-2. <https://doi.org/10.1109/iww-bci.2019.8737253>
- [2] 李鹏. 让脑电波为人类造福[J]. 发明与创新, 2003(6): 37.
- [3] 高上凯. 脑机接口的现状与未来[J]. 机器人产业, 2019(5): 40-44.
- [4] Branco, M.P., Pels, E.G.M., Sars, R.H., Aarnoutse, E.J., Ramsey, N.F., Vansteensel, M.J., et al. (2021) Brain-Computer Interfaces for Communication: Preferences of Individuals with Locked-In Syndrome. *Neurorehabilitation and Neural Repair*, **35**, 267-279. <https://doi.org/10.1177/1545968321989331>
- [5] 蒲慕明, 徐波, 谭铁牛. 脑科学与类脑研究概述[J]. 中国科学院院刊, 2016, 31(7): 725-736, 714.
- [6] Colucci, A., Vermehren, M., Cavallo, A., Angerhöfer, C., Peekhaus, N., Zollo, L., et al. (2022) Brain-Computer Interface-Controlled Exoskeletons in Clinical Neurorehabilitation: Ready or Not? *Neurorehabilitation and Neural Repair*, **36**, 747-756. <https://doi.org/10.1177/15459683221138751>
- [7] Mridha, M.F., Das, S.C., Kabir, M.M., Lima, A.A., Islam, M.R. and Watanobe, Y. (2021) Brain-Computer Interface: Advancement and Challenges. *Sensors*, **21**, Article No. 5746. <https://doi.org/10.3390/s21175746>
- [8] 蒲慕明. 脑科学研究的三大发展方向[J]. 中国科学院院刊, 2019, 34(7): 807-813.
- [9] 王麒深, 时昌润, 吴晋, 等. 脑机接口训练促进脑卒中患者运动功能改善的研究进展[J]. 临床神经病学杂志, 2025, 38(2): 135-138.
- [10] Shen, S., Chu, T., Wang, J., Zhao, H., Tang, J., Xu, L., et al. (2025) Progress in the Application of Motor Imagery Therapy in Upper Limb Motor Function Rehabilitation of Stroke Patients with Hemiplegia. *Frontiers in Neurology*, **16**, Article ID: 1454499. <https://doi.org/10.3389/fneur.2025.1454499>
- [11] Fló, E., Fraiman, D. and Sitt, J.D. (2025) Assessing Brain-Muscle Networks during Motor Imagery to Detect Covert Command-Following. *BMC Medicine*, **23**, Article No. 68. <https://doi.org/10.1186/s12916-025-03846-0>
- [12] Cyranoski, D. (2014) Marmosets Are Stars of Japan's Ambitious Brain Project. *Nature*, **514**, 151-152. <https://doi.org/10.1038/514151a>
- [13] Zhao, X., Zhang, H., Zhu, G., You, F., Kuang, S. and Sun, L. (2019) A Multi-Branch 3D Convolutional Neural Network for EEG-Based Motor Imagery Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **27**, 2164-2177. <https://doi.org/10.1109/tnsre.2019.2938295>
- [14] Schirrmester, R.T., Springenberg, J.T., Fiederer, L.D.J., Glasstetter, M., Eggenberger, K., Tangermann, M., et al. (2017) Deep Learning with Convolutional Neural Networks for EEG Decoding and Visualization. *Human Brain Mapping*, **38**, 5391-5420. <https://doi.org/10.1002/hbm.23730>
- [15] Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P. and Lance, B.J. (2018) EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain-Computer Interfaces. *Journal of Neural Engineering*, **15**, Article ID: 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- [16] Echioui, A., Zouch, W., Ghorbel, M. and Mhiri, C. (2023) Convolutional Neural Network with Support Vector Machine for Motor Imagery EEG Signal Classification. *Multimedia Tools and Applications*, **82**, 45891-45911. <https://doi.org/10.1007/s11042-023-15468-w>
- [17] Xie, Y. and Oniga, S. (2024) Enhancing Motor Imagery Classification in Brain-Computer Interfaces Using Deep Learning and Continuous Wavelet Transform. *Applied Sciences*, **14**, Article No. 8828. <https://doi.org/10.3390/app14198828>
- [18] 夏理健, 刘小平, 王新, 等. 基于 CEEMD 散布熵和 Hjorth 参数的混合特征滚动轴承故障诊断研究[J]. 机电工程, 2021, 38(12): 1564-1571.
- [19] Kozhamkulova, F. and Akhtar, M.T. (2024) A Hybrid Approach to Enhanced Signal Denoising Using Data-Driven Multiresolution Analysis with Detrended-Fluctuation-Analysis-Based Thresholding and Stationary Wavelet Transform. *Applied Sciences*, **14**, Article No. 10866. <https://doi.org/10.3390/app142310866>
- [20] López, J.L. and Vásquez-Coronel, J.A. (2024) Analyzing Monofractal Short and Very Short Time Series: A Comparison of Detrended Fluctuation Analysis and Convolutional Neural Networks as Classifiers. *Fractal and Fractional*, **8**, Article No. 460. <https://doi.org/10.3390/fractalfract8080460>
- [21] 赵似兰, 彭伟, 段鲲. 睡眠脑电的分形维数分析[J]. 生物物理学报, 1995(2): 226-232.
- [22] Lee, S., Kim, H., Kim, H., Jeong, J., Lee, S. and Kim, D. (2019) Comparative Analysis of Features Extracted from EEG Spatial, Spectral and Temporal Domains for Binary and Multiclass Motor Imagery Classification. *Information Sciences*, **502**, 190-200. <https://doi.org/10.1016/j.ins.2019.06.008>
- [23] 莫云. 基于 CSP 变换和滤波器组的对数带通功率特征提取方法[J]. 电子测量技术, 2021, 44(10): 33-38.
- [24] 赵德春, 沈利豪, 蒋宇皓, 等. 基于共空间模式和功率谱密度的脑电信号分类[J]. 科学技术与工程, 2023, 23(10): 4272-4278.

- [25] Kim, C., Sun, J., Liu, D., Wang, Q. and Paek, S. (2018) An Effective Feature Extraction Method by Power Spectral Density of EEG Signal for 2-Class Motor Imagery-Based BCI. *Medical & Biological Engineering & Computing*, **56**, 1645-1658. <https://doi.org/10.1007/s11517-017-1761-4>
- [26] Herman, P., Prasad, G., McGinnity, T.M. and Coyle, D. (2008) Comparative Analysis of Spectral Approaches to Feature Extraction for EEG-Based Motor Imagery Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **16**, 317-326. <https://doi.org/10.1109/tnsre.2008.926694>
- [27] Ali, H.S., Ismail, A.I., El-Rabaie, E.M. and Abd El-Samie, F.E. (2025) Diagonal Loading Common Spatial Patterns with Pearson Correlation Coefficient Based Feature Selection for Efficient Motor Imagery Classification. *Computer Methods in Biomechanics and Biomedical Engineering*, 1-15. <https://doi.org/10.1080/10255842.2025.2457122>
- [28] Zhang, X. and Wu, D. (2019) On the Vulnerability of CNN Classifiers in EEG-Based BCIs. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **27**, 814-825. <https://doi.org/10.1109/tnsre.2019.2908955>
- [29] Jin, J., Liu, C., Daly, I., Miao, Y., Li, S., Wang, X., et al. (2020) Bispectrum-Based Channel Selection for Motor Imagery Based Brain-Computer Interfacing. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **28**, 2153-2163. <https://doi.org/10.1109/tnsre.2020.3020975>
- [30] Wei, Z., Zou, J., Zhang, J. and Xu, J. (2019) Automatic Epileptic EEG Detection Using Convolutional Neural Network with Improvements in Time-Domain. *Biomedical Signal Processing and Control*, **53**, Article ID: 101551. <https://doi.org/10.1016/j.bspc.2019.04.028>
- [31] Zeng, M., Zhang, X., Zhao, C., Lu, X. and Meng, Q. (2021) GRP-DNet: A Gray Recurrence Plot-Based Densely Connected Convolutional Network for Classification of Epileptiform EEG. *Journal of Neuroscience Methods*, **347**, Article ID: 108953. <https://doi.org/10.1016/j.jneumeth.2020.108953>
- [32] 袁新杰, 孙飞越. 基于短时傅立叶变换和改进 Vision Transformer 的滚动轴承故障诊断方法[J]. 起重运输机械, 2024(16): 70-75.
- [33] 胡华强. 基于短时傅立叶变换的有源干扰信号识别分析[J]. 电子技术, 2024, 53(6): 18-19.
- [34] 肖健, 等. 多域特征融合的脑电信号肢体运动特征提取与动作识别[J]. 电子测量技术, 2024, 47(18): 23-30.
- [35] Liu, Y., Liu, G., Wu, S. and Tin, C. (2025) Phase Spectrogram of EEG from S-Transform Enhances Epileptic Seizure Detection. *Expert Systems with Applications*, **262**, Article ID: 125621. <https://doi.org/10.1016/j.eswa.2024.125621>
- [36] 郭玉雪, 于洪丽, 么航, 等. 基于离散小波变换的卷积自编码运动想象脑电信号的分类[J]. 电子测量技术, 2023, 46(19): 188-196.
- [37] Mahmud, M.S., Fattah, S.A., Saquib, M. and Saha, O. (2024) Emotion Recognition with Reduced Channels Using CWT Based EEG Feature Representation and a CNN Classifier. *Biomedical Physics & Engineering Express*, **10**, Article ID: 045003. <https://doi.org/10.1088/2057-1976/ad31f9>
- [38] Liyanagedera, N.D., Bareham, C.A., Kempton, H. and Guesgen, H.W. (2025) Novel Machine Learning-Driven Comparative Analysis of CSP, STFT, and CSP-STFT Fusion for EEG Data Classification across Multiple Meditation and Non-Meditation Sessions in BCI Pipeline. *Brain Informatics*, **12**, Article No. 4. <https://doi.org/10.1186/s40708-025-00251-4>
- [39] O'Toole, J.M. and Boashash, B. (2013) Fast and Memory-Efficient Algorithms for Computing Quadratic Time-frequency Distributions. *Applied and Computational Harmonic Analysis*, **35**, 350-358. <https://doi.org/10.1016/j.acha.2013.01.003>
- [40] O'Toole, J.M., Mesbah, M. and Boashash, B. (2008) A New Discrete Analytic Signal for Reducing Aliasing in the Discrete Wigner-Ville Distribution. *IEEE Transactions on Signal Processing*, **56**, 5427-5434. <https://doi.org/10.1109/tsp.2008.929325>
- [41] Emara, H.M., Elwekeil, M., Taha, T.E., El-Fishawy, A.S., El-Rabaie, E.M., Alotaiby, T., et al. (2021) Hilbert Transform and Statistical Analysis for Channel Selection and Epileptic Seizure Prediction. *Wireless Personal Communications*, **116**, 3371-3395. <https://doi.org/10.1007/s11277-020-07857-3>
- [42] Ang, K.K., Chin, Z.Y., Wang, C., Guan, C. and Zhang, H. (2012) Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. *Frontiers in Neuroscience*, **6**, Article No. 39. <https://doi.org/10.3389/fnins.2012.00039>