

DOI: 10.19650/j.cnki.cjsi.J2209389

一种面向运动解码的 EEG-fNIRS 时频特征融合 与协同分类方法*

刘晋瑞^{1,2}, 宋 婷^{1,2}, 舒智林^{1,2}, 韩建达^{1,2,3}, 于宁波^{1,2,3}

(1. 南开大学人工智能学院 天津 300350; 2. 南开大学天津市智能机器人技术重点实验室 天津 300350;
3. 南开大学深圳研究院智能技术与机器人系统研究院 深圳 518083)

摘 要:脑功能成像技术可以反映人体运动时的大脑生理变化,进而解码运动状态,但单模态信号反映的大脑生理信息存在局限性。为此,本文提出了一种基于 EEG 和 fNIRS 信号的时频特征融合与协同分类方法,利用脑神经电活动和血氧信息的互补特性提高运动状态解码精度。首先,提取 EEG 的小波包能量熵特征,使用双向长短期记忆网络(Bi-LSTM)提取 fNIRS 的时域特征,将两类特征组合得到包含时频域信息的融合特征,实现 EEG 和 fNIRS 不同层次特征的信息互补。然后,利用 1DCNN 提取融合特征深层次信息。最后,采用全连接神经网络进行任务分类。将所提方法应用于公开数据集,本文所提的 EEG-fNIRS 信号协同分类方法准确率为 95.31%,较单模态分类高 7.81%~9.60%。结果表明,该方法充分融合了两互补信号的时频域信息,提高了对左右手握力运动的分类准确率。

关键词: EEG; fNIRS; 时频特征融合; 协同分类; 运动解码

中图分类号: TP391 TH776 **文献标识码:** A **国家标准学科分类代码:** 310.6110 520.2060

A time-frequency feature fusion and collaborative classification method for motion decoding with EEG-fNIRS signals

Liu Jinrui^{1,2}, Song Ting^{1,2}, Shu Zhilin^{1,2}, Han Jianda^{1,2,3}, Yu Ningbo^{1,2,3}

(1. College of Artificial Intelligence, Nankai University, Tianjin 300350, China; 2. Tianjin Key Laboratory of Intelligent Robotics, Nankai University, Tianjin 300350, China; 3. Institute of Intelligence Technology and Robotic Systems, Shenzhen Research Institute of Nankai University, Shenzhen 518083, China)

Abstract: Functional neural imaging technology can reflect the physiological change of the brain, and decode the movement state. However, the information by the single neural imaging modality is limited. In this article, a time-frequency feature fusion and collaborative classification method is proposed to achieve high precision motion state decoding with EEG and fNIRS signals, which takes the advantage of the complementation of electrical activity and hemoglobin changes. Firstly, the wavelet packet energy entropy feature of the EEG signal is extracted, the Bi-LSTM deep neural network is used to extract the time domain features of the fNIRS signal, and the achieved features are combined to obtain the fusion features containing the time-frequency domain information. The complementation of EEG and fNIRS features is achieved at multiple levels. Then, the 1DCNN is used to extract deep-level information from the fusion features. Finally, a fully connected neural network is used for classification. The proposed method has been tested with a public dataset. The EEG-fNIRS collaborative classification method achieves the accuracy of 95.31%, which is 7.81%~9.60% higher than those of single-modal signal classification methods. Experimental results show that this method fully integrates the time-frequency domain information of two physiologically complementary signals, and improves the classification accuracy of left and right hand grip tasks.

Keywords: EEG; fNIRS; time-frequency feature fusion; collaborative classification; motion decoding

0 引言

人类运动与大脑运动功能区之间存在密切联系^[1], 肢体运动受大脑控制的同时, 还会激活运动区域的神经元状态, 且激活程度受具体运动模式的影响^[2]。随着功能性成像技术的发展, 该技术可实时记录大脑区域的变化, 进而研究脑神经活动机制^[3]。通过研究运动与脑功能之间的机制, 发现大脑对运动的控制机理, 实现神经解码, 进而从大脑中得到运动信息, 在运动康复和脑机接口等领域得到广泛应用^[4-7]。因此, 基于脑功能成像技术研究运动与大脑功能信号之间的关系对促进脑科学研究有重要意义。

目前运动与脑神经功能存在的机制尚未完全明确, 采用脑功能成像技术对大脑运动区域进行信号采集, 可以研究运动与大脑相应功能区激活的联系。大脑信号记录方式分为两类, 一类是反映大脑神经活动的电生理信号 (EEG, MEG)^[8], 另一类是反映大脑血液中血红蛋白浓度变化的血液动力学信号 (fNIRS, fMRI, PET)^[9]。采集的大脑信号包含相关运动信息, 通过解码分析, 可实现对任务的分类。其中, 脑电图 (electroencephalogram, EEG) 可以记录大脑活动时的电位变化^[10]。功能性近红外 (functional near-infrared spectroscopy, fNIRS) 是利用 600~900 nm 近红外光对血液中主要成分测量, 并通过修正的比尔-朗伯定律计算得到血液中氧合血红蛋白 (oxygenated hemoglobin, HbO) 和脱氧血红蛋白 (deoxygenated hemoglobin, HbR) 的浓度变化, 从而反映大脑活动情况^[11]。而 fMRI 等虽然具有高空间分辨率, 但其采集设备具有局限性, 如设备体积较大, 要求受试者处于密闭空间中, 无法完成某些复杂运动任务, 适用人群也有限制。与 fMRI 等采集方式相比, EEG 和 fNIRS 信号采集设备具有可便携性, 允许受试者完成运动任务, 且 EEG 信号具有时间分辨率高, 频域特征突出等优点; fNIRS 信号具有空间分辨率高, 噪声小等优点。近年来, 许多学者开始使用 EEG 和 fNIRS 进行任务的分类^[11-14]。但由于利用单模态信号获得的信息有限, 难以保证分类任务的高精度。而同时采集 EEG 信号和 fNIRS 信号可以反映大脑的电生理和血液动力学这两类不同特性的信息。且 EEG 和 fNIRS 信号采集设备操作简单, 可进行联合采集, 不易相互干扰。因此使用 EEG 和 fNIRS 信号进行协同分类, 实现不同类别信息融合及特征互补^[15], 以提高分类准确率。

对于两信号融合, 目前常用的策略有 3 种: 将预处理后的两个信号直接融合, 融合从两个信号中提取的特征, 对两个信号单独分类的结果进行融合。随着人工智能的深入发展, 机器学习和深度学习方法也开始应用于各类

任务的大脑信号分类中^[16-17]。多项研究使用 EEG 和 fNIRS 信号融合策略, 并结合人工智能算法实现了两信号的协同分类。Chiarelli 等^[18]使用深度神经网络 DNN 分别对 EEG, fNIRS, EEG+fNIRS 信号进行左右手运动想象的分类, 将滑动时间窗内 EEG 的平均 ERD/ERS 特征和 fNIRS 的均值特征作为全连接前馈结构的 DNN 网络的输入。结果显示, 使用 EEG+fNIRS 达到 83.28% 的准确率, 较 EEG 高 9.89%, 较 fNIRS 高 11.36%。Hirsch 等^[19]使用 LDA 分别对 EEG 的共同空间模式 (common spatial pattern, CSP) 特征、fNIRS 中 HbO 和 HbR 的均值和斜率特征分别进行左右手握力解码, 然后设计了一个元分类器, 在决策层进行融合, 得到 79% 的准确率, 与仅使用单模态信号相比, 提高了模型鲁棒性。Ge 等^[20]设计了 EEG 和 fNIRS 的联合采集方法, 采集受试者握杯动作的 3 种状态的大脑活动信号, 同时基于脑网络和特征选择算法, 使用 SVM 分类器对 EEG-fNIRS 信号特征进行状态识别, 得到 EEG-fNIRS 识别准确率为 72.7%, 而 EEG 和 fNIRS 准确率为 68.6% 和 52.7%, 表明 EEG-fNIRS 双模态较单模态信号的表现好, 也揭示了复杂大脑网络对不同动作的激活状态。以上工作使用 EEG-fNIRS 联合分析方法实现了不同动作状态的解码, 但在提取特征和融合方法中仍有提升空间, 可以更好地利用 EEG 和 fNIRS 信号之间的互补性, 针对性地提取多维度特征, 以达到较高的准确率。

本文基于 EEG 和 fNIRS 在神经机理和信号时域频域方面的互补特性, 设计一种面向运动解码的 EEG-fNIRS 特征融合与协同分类方法。由于 EEG 和 fNIRS 的采样原理不同, 采样频率差异过大, 难以直接从原始信号层面进行融合, 因此本文采用特征层融合策略。通过利用两信号不同神经机理信息 (EEG 电生理, fNIRS 血液动力学) 的互补性, 提出了基于 EEG-fNIRS 信号时频域特征的协同分类方法, 实现了两种不同模态信号的特征融合。首先, 考虑到左右手运动任务下大脑区域激活程度不同, 提取 EEG 小波包分解能量熵特征, 更好地表征大脑区域间的激活程度差异。然后, 考虑到 fNIRS 受采集原理的限制, 采样频率较低, 主要是提取基于生理特点的时域特征, 并需要手动处理, 因此本文提出使用 Bi-LSTM 网络提取 fNIRS 信号的时域特征, 更好地表示任务中大脑血液动力学反映。进而, 融合 EEG 频域特征和 fNIRS 时域特征, 实现两类信号的特征互补。最后, 构建 EEG-fNIRS 协同分类方法, 设计 1DCNN+FC 网络, 提取深层信息。将所提方法在公开数据集中进行验证, 通过实现对左右手握力任务的分类, 验证本文提出的 EEG-fNIRS 信号协同分类方法可以大幅提高多模态信号融合分类的准确率。

1 方 法

本文提出了一种基于 EEG-fNIRS 信号时频特征融合与协同分类方法,流程如图 1 所示。首先,使用小波包分解提取 EEG 的频域能量熵特征,使用双向长短期记忆网络(bi-directional long short term memory, Bi-LSTM)自动

提取 fNIRS 时域特征,并将两信号特征进行拼接,得到融合特征。然后,使用一维卷积方法(1DCNN)对融合特征进行提取压缩。最后,输入到全连接神经网络(full connected neural network, FC)中实现左右手握力的协同分类。将本文所提方法应用在公开数据集中,验证多维度时频域特征融合方法的有效性,及多模态信号协同分类相较于单模态信号分类在运动任务中的高精度解码能力。

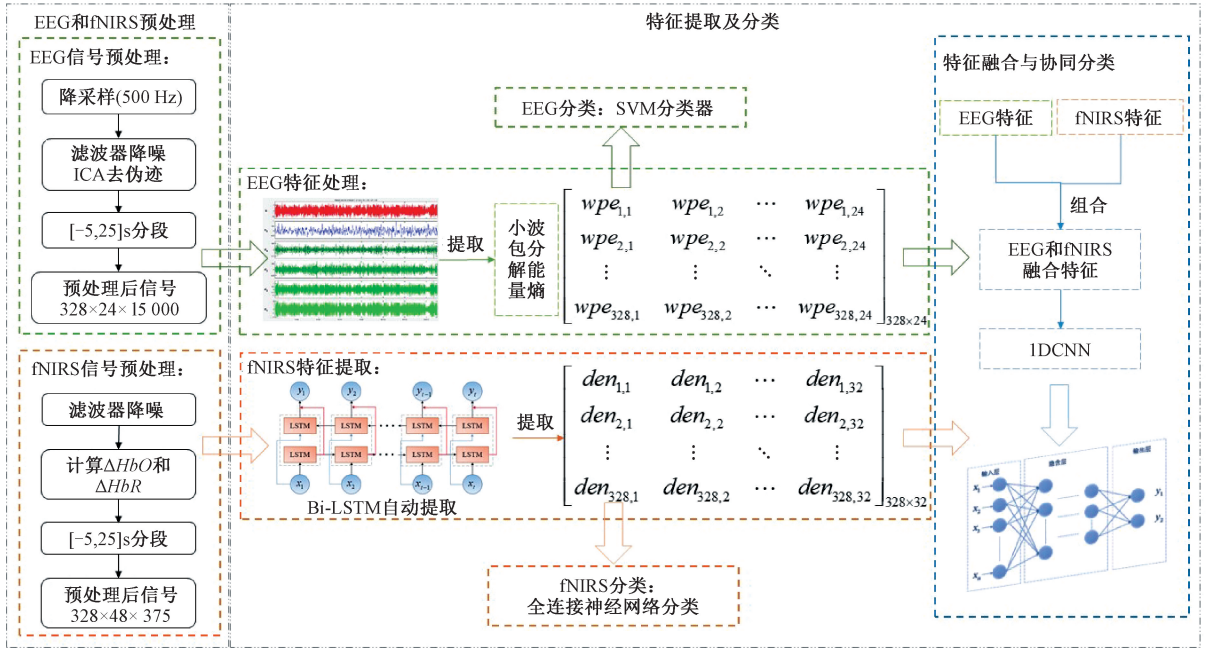


图 1 EEG-fNIRS 信号时频特征融合与协同分类处理流程

Fig. 1 EEG-fNIRS time-frequency feature fusion and collaborative classification pipeline

1.1 数据集

本文使用 Ortega 等发表的公开数据集 HYGRIP^[21] 进行 EEG 和 fNIRS 信号的协同分类方法研究。数据集包含根据计算机指令采集的 14 位右利手受试者进行左右手握握过程的 EEG、fNIRS 等信号,并且提供了各类信号可视化和预处理程序。该实验设计是通过计算机随机发送左手或右手的握力指令,受试者根据指令做出相应握

力动作并保证握力大小在最大握力的 25%~50%。每位受试者每只手需进行 10~13 组实验,每次实验持续时间为 21 s(包括 10 次连续握力 1.55 s/放松 0.55 s)两次实验之间休息 15~21 s,实验过程如图 2 所示。实验过程中,同步采集了位于大脑 C3 和 C4 运动区域共 24 个通道的实时 EEG 和 fNIRS 信号。其中,EEG 采样频率为 1 000 Hz, fNIRS 采样频率为 12.5 Hz。

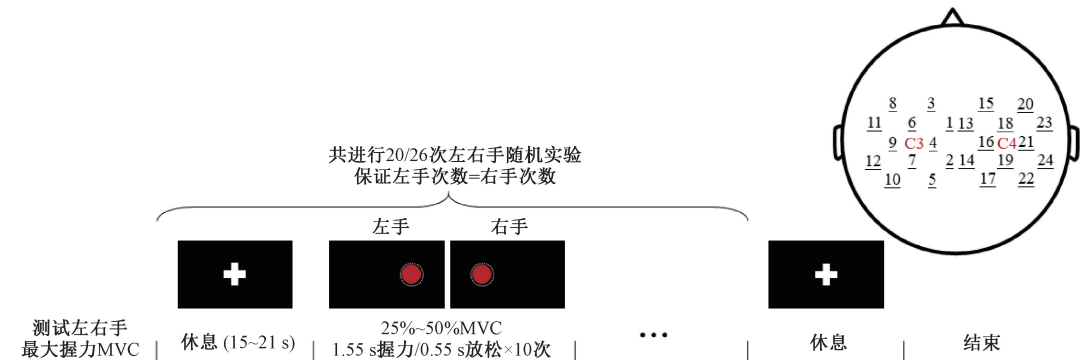


图 2 HYGRIP 数据集中左右手握力任务实验流程

Fig. 2 Experimental process of left/right grip task in HYGRIP dataset

1.2 EEG 频域特征提取及分类

由于 EEG 信号的频域特征明显,左右手握力运动在大脑左右脑区的表现不同^[22]。为表征左右手握力过程中大脑区域之间的能量差异^[23-24],本文提出提取 EEG 信号各通道的小波包能量熵特征,并使用支持向量机(support vector machine, SVM)对其进行分类。

对 EEG 信号进行 4 层小波包分解,计算各通道的能量熵作为其特征。下面是特征提取算法具体流程。

1) 初始化

初始化 14 位受试者数据,构建 $328 \times 24 \times 15\ 000$ 矩阵。使用‘db2’为母小波,进行 4 层小波包分解。

2) 提取 EEG 序列 $s_{i,j}$, i 为样本编号(1 ~ 328), j 为通道编号(1 ~ 24)。

3) 对每个 $s_{i,j}$ 进行小波包分解,获得分解后序列值: $w_{i,j,m,n}$ ($i = 1, \dots, 328, j = 1, \dots, 24, m = 0, \dots, 2^L - 1, n = 0, \dots, T_f^i$)

4) 对每个 $w_{i,j,m,n}$ 计算每个频段的能量:

$$E_{i,j,m} = \sum_{n=0}^{T_s} |w_{i,j,m,n}|^2 \quad (1)$$

5) 对每个 $E_{i,j,m}$ 计算每个频段的能量占比:

$$e_{i,j,m} = \frac{E_{i,j,m}}{\sum_{m=0}^{L-1} E_{i,j,m}} \quad (2)$$

6) 对每个 $s_{i,j}$ 计算小波包分解能量熵:

$$wpe_{i,j} = - \sum_{m=0}^{2^L-1} [e_{i,j,m} \cdot \ln(e_{i,j,m})] \quad (3)$$

7) 输出结果: $wpe_{i,j}$, 对于每一个样本,得到 24×1 的特征向量。

在计算出 EEG 信号关于小波包分解能量熵的特征向量(24×1)后,使用 SVM 算法进行分类。由于 EEG 信号具有随机性及非平稳性等特点,且属于非线性信号,提取的特征向量显然也是非线性的,因此使用基于非线性高斯核函数的 SVM 算法将特征映射到高维空间中实现广义线性化,然后进行分类。分类决策函数和高斯径向基核函数如式(4)和(5)所示。

$$f(x) = \text{sign} \left(\sum_{i=1}^n \mathbf{w}^T \phi(x) + \mathbf{b}^* \right) \quad (4)$$

$$K(x_i, x_j) = \exp \left(- \frac{\|x_i - x_j\|}{2\delta^2} \right) \quad (5)$$

对于斜率 ω 和截距 \mathbf{b}^* , 使用求解有约束条件的最优化问题得到。另外,由于 EEG 信号 24 个通道之间存在相关性,提取特征之间必然存在冗余信息。因此使用主成分分析(principal component analysis, PCA)方法,将提取的特征映射到另一个空间中,使其方差最大化,实现特征选择,以去除冗余信息。

1.3 fNIRS 时域特征提取及分类

fNIRS 信号包括 24 通道的氧合血红蛋白(HbO)浓度序列和 24 通道的脱氧血红蛋白(HbR)浓度序列。这样,得到的 fNIRS 信号数据为 48×375 维矩阵。然后,分别使用 SVM 算法和 Bi-LSTM 深度神经网络对 fNIRS 信号进行分类。第 1 种方法是根据 fNIRS 信号生理性特点,提取 HbO、HbR 和 HbD(HbD 为 HbO 与 HbR 浓度之差)的均值、面积和斜率特征^[25-26],然后使用 SVM 对特征进行分类。第 2 种方法是使用 Bi-LSTM 网络对该信号进行时域特征提取及分类。

1) 生理性特征提取及分类

由 fNIRS 信号血液动力学反应^[27]可知,由运动等引起的大脑神经活动变化会增加代谢需求,从而使 HbO 浓度短暂降低后增加,HbR 浓度短暂增加后降低。为显示任务过程血红蛋白变化情况,绘制执行任务期间,大脑左右半球通道的平均血红蛋白浓度变化和幅度,如图 3 所示。根据该平均血红蛋白浓度变化图像,可以看出在 0~20 s 时间范围内的浓度变化情况符合血液动力学反应特点,HbO 浓度呈整体上升趋势,HbR 呈整体下降趋势。此外,通过对比不同侧握力任务下大脑左右半球的血红蛋白浓度变化可以看出,左手握力任务下,HbO 浓度变化在大脑右半球更显著;右手握力任务下,HbO 浓度变化在大脑左半球更显著。因此,为量化左右手握力运动对大脑血红蛋白浓度影响的差异,提取 24 通道 fNIRS 信号的生理性特征包括:HbO、HbR 和 HbD 在 0~20 s 的均值(SM)、面积(SA)和斜率(a)特征,计算式分别为:

$$SM = \frac{\sum_{n=1}^N x(n)}{N} \quad (6)$$

$$SA = \left| \sum_{n=1}^N x(n) \right| \quad (7)$$

$$\min R = \sum_{i=1}^N [y_i - (ax(n) + b)]^2 \quad (8)$$

其中, N 为信号序列的长度。随后,使用 SVM 对 3 种不同血红蛋白浓度的特征进行组合分类,以获得最优的特征组合方式,进而提高分类准确度。

2) Bi-LSTM 提取时域特征及分类

fNIRS 属于典型的多通道时序信号,对时序信号进行处理分类通常使用循环神经网络(recurrent neural network, RNN),该网络可以保留和利用时序信号的历史信息。但 RNN 网络存在梯度消失和爆炸问题,这对时序信号的长度有所限制。为解决以上问题,使用 LSTM 神经网络,使得在有效利用时间序列的先前信息的同时,添加遗忘机制丢弃先前的一些无用信息,以处理长时间依赖问题。fNIRS 信号的血红蛋白浓度变化与运动响应的的时间有密切关联,为了同时利用历史信息 and 未来信息,进




图 3 左右手握力任务下平均血红蛋白浓度变化曲线
Fig. 3 The average hemoglobin concentration change curve of the left/right grip task

一步提出使用 Bi-LSTM 网络,它是由两层 LSTM 组成,可以增加处理信息量,以获得更优性能,提高分类准确率。

Bi-LSTM 神经网络是由一个前向 LSTM 层和一个后向 LSTM 层组成,其中,每个 LSTM 单元结构如图 4 所示。LSTM 通过遗忘门、输入门和输出门对状态进行更新。

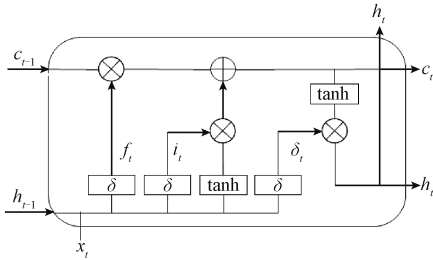


图 4 LSTM 单元结构
Fig. 4 LSTM unit structure

其中,遗忘门决定了要丢弃和保留的信息,计算公式为:

$$f_t = \delta(\mathbf{W}_f \cdot [h_{t-1}, x_t] + \mathbf{b}_f) \quad (9)$$

其中, δ 为 sigmoid 函数, h_{t-1} 为上一时刻的隐藏层输出, x_t 为当前时刻的输入。输入门负责将新的信息选择性地记录到细胞状态中,计算公式如下:

$$i_t = \delta(\mathbf{W}_i \cdot [h_{t-1}, x_t] + \mathbf{b}_i) \quad (10)$$

$$\tilde{c}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, x_t] + \mathbf{b}_c) \quad (11)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (12)$$

其中, i_t 为输入门的门控状态, \tilde{c}_t 为产生的新的候选细胞状态, c_t 为保留到最终的细胞状态。输出门决定细胞的输出,计算公式如下:

$$o_t = \delta(\mathbf{W}_o \cdot [h_{t-1}, x_t] + \mathbf{b}_o) \quad (13)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (14)$$

其中, o_t 为输出门的门控状态, h_t 为当前时刻 LSTM 单元的输出。在得到每个 LSTM 单元的输出后,将两个由前向后向计算的 LSTM 单元组合,即可得到 Bi-LSTM 单元结构。每个单元的输出由式 (15) ~ (17) 计算得到。

$$h_{ft} = LSTM(x_t, h_{ft-1}) \quad (15)$$

$$h_{bt} = LSTM(x_t, h_{bt-1}) \quad (16)$$

$$y_t = g(\mathbf{W}_{ft} \cdot h_{ft} + \mathbf{W}_{bt} \cdot h_{bt} + \mathbf{b}_y) \quad (17)$$

其中, h_{ft} 和 h_{bt} 分别为前向和后向 LSTM 单元的输出。 y_t 为 Bi-LSTM 单元输出。本文使用 Tensorflow 库来创建 Bi-LSTM 网络,具体网络结构如图 5 所示。




图 5 Bi-LSTM 网络结构
Fig. 5 Bi-LSTM neural network structure

在网络模型搭建中,为减小过拟合现象,提高准确率,使用标准化、正则化方法并添加随机丢弃神经元机制。在对预处理后数据进行标准化处理后,输入到 Bi-LSTM 层。激活函数使用 'tanh' 函数,如式 (18) 所示,并添加参数为 0.1 的 L2 正则化项。之后,将 Bi-LSTM 层的输出数据做扁平化处理,输入全连接层,并在每层全连接层后,添加 Dropout 层以防止过拟合。激活函数均使用 'elu' 函数,如式 (19) 所示,可缓解梯度消失问题,同时提高模型鲁棒性。对于输出层,使用 'softmax' 激活函数来获得分类结果。最后,使用交叉熵损失函数和 Adam 优化器进行训练的迭代计算。

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (18)$$

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (19)$$

1.4 EEG-fNIRS 时频特征融合与协同分类

到目前为止,已经建立了用于对 EEG 小波包分解能量熵分类的 SVM 模型,用于对 fNIRS 生理性特征分类的 SVM 模型和 Bi-LSTM 自动提取特征及分类模型。在本节中,将对两信号进行时频特征融合与协同分类方法的研究,充分利用两信号带来的不同信息来提高任务的分类精度。

在机理层面,EEG 信号记录的是大脑神经元产生的电信号,是脑神经电生理活动的总体反映,fNIRS 信号是活动中血氧水平变化的反映。两者从采样原理层面有着本质的区别,包含的反映相应运动状态的信息具有差异性。因此,分别从频域和时域角度提取两信号特征并融合,同时进一步提取融合特征的深层信息,可得到两信号的互补信息,实现多维度的特征融合。

EEG-fNIRS 时频特征融合与协同分类流程如图 6 所示。对于 EEG 信号,由于该信号具有频域信息突出的特点,因此使用提取的小波包能量熵作为其频域特征。对于 fNIRS 信号,其记录了任务期间血氧浓度随时间的变化情况,因此使用 Bi-LSTM 网络模型,经过 Bi-LSTM 处理后,将下一全连接层的输出作为其时域特征,即 32×1 的特征向量。然后,将提取的 EEG 小波包能量熵特征与 Bi-LSTM 深度神经网络自动提取的 fNIRS 特征进行拼接,得到融合特征。提出使用 1DCNN 对融合特征进行处理的方法,以进一步提取有用特征,提高分类准确率。1DCNN 方法即利用一维的卷积核对融合特征进行卷积操作,计算公式如式(20)所示。1DCNN 方法在一方面可以进行特征的压缩,另一方面可以提取深层特征。通过对 EEG 和 fNIRS 信号进行多维度特征提取和融合,可得到相较于单模态信号更多的有效信息,以提高分类性能。最后,使用全连接神经网络对选择后融合特征进行分类。

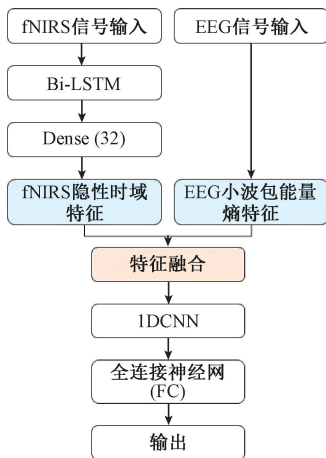


图 6 EEG-fNIRS 时频特征融合与协同分类流程

Fig. 6 EEG-fNIRS time-frequency feature fusion and collaborative classification pipeline

$$S(n) = (f * g)[n] = \sum_{m=0}^{N-1} f(m)g(n-m) \quad (20)$$

其中,设置 1DCNN 中过滤器个数为 3,卷积核大小为 3,步长为 1。使输入的 56×1 的融合特征经过 1DCNN 后得到 54×3 维输出,然后利用两层全连接神经网络进行左右手的分类。

2 实验及结果分析

2.1 数据处理

本文直接使用 HYGRIP 数据集的 EEG 和 fNIRS 信号($[-5,25]$ s 的分段处理)。为使分类结果更准确,对 14 位受试者所有数据进行标准化处理,将所有数据转化到 $[-1,1]$ 区间,如式(21)所示。

$$y(n) = 2 \frac{x(n) - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (21)$$

其中, $x(n)$ 为原始数据; x_{\max} 和 x_{\min} 分别为原始数据中的最大值和最小值; $y(n)$ 为归一化后的数据值。

在整个实验中,为保证结果的可靠性,将数据集中共 328 组数据按照 4:1 的比例划分为训练集和测试集。其中,测试集数据全程不参与训练,属于完全陌生数据。另外,针对训练集数据采用 8 折交叉验证方法,将训练集数据分为 8 份,取其中 7 份用作训练,另 1 份用作验证,计算 8 次结果平均值作为训练和验证的结果,以充分利用数据。最后,将测试集输入到训练好的模型中,得到最终的分类结果。

2.2 结果分析

根据上述所提方法,使用 SVM 对提取的 EEG 小波包能量熵特征进行分类,使用 SVM 方法及 Bi-LSTM 方法对 fNIRS 信号进行特征提取及分类。随后,融合 EEG 和 fNIRS 两信号多维度特征并分类实现了基于 EEG-fNIRS 时频特征融合与协同分类。下面对所得结果进行分析。

对于 EEG 信号,将基于高斯核函数+PCA 的 SVM 分类算法与使用其它常见核函数、是否使用 PCA 方法的 SVM 算法进行对比,验证本文所使用方法的有效性,结果如表 1 所示。对 EEG 信号提取的非线性、复杂性特征,为使 SVM 广义线性分类器得到更好的分类效果,需要通过空间映射方式增加两类样本特征之间的可分性。从表中可以看出,使用非线性核函数的结果明显优于线性核函数,可见将数据非线性映射到高维空间中可提高对 EEG 特征的分类准确率。最终得到使用高斯 SVM+PCA 方法,可获得最高 87.5% 的分类准确率。

对于 fNIRS 信号,分别使用 SVM 方法和 Bi-LSTM 深度神经网络方法对任务进行分类。在使用 SVM 对提取的 fNIRS 信号生理性特征进行组合分类中,使用 HbD (HbD = HbO-HbR) 的均值、面积和斜率特征达到最

表1 使用不同核函数的 SVM 算法对 EEG 分类的准确率
Table 1 The accuracy of EEG classification using SVM with different kernel functions %

核函数	不使用 PCA 准确率	使用 PCA 准确率
线性	62.5	61.0
二次	80.8	79.6
三次	81.7	81.4
高斯	82.8	87.5

高 71.70% 的分类准确率。而直接将预处理后的数据输入到 Bi-LSTM 神经网络中提取时域特征并分类,得到了 85.71% 的分类准确率。同时,采用 FC 神经网络、卷积神经网络(convolutional neural network, CNN)、LSTM 神经网络对 fNIRS 信号进行分类,结果如表 2 所示,可以看出使用 Bi-LSTM 神经网络的准确率最高。

表2 使用不同方法对 fNIRS 信号分类的准确率
Table 2 The accuracy of fNIRS classification by different methods

分类方法	分类准确率/%
fNIRS-SVM	71.70
fNIRS-FC	78.57
fNIRS-CNN	81.25
fNIRS-LSTM	82.86
fNIRS-BiLSTM	85.71

对于 EEG-fNIRS 信号协同分类,使用提出的分类方法对 EEG-fNIRS 信号进行分类,并与已有的基于 SVM 和 DNN 神经网络的协同分类方法进行比较。表 3 对比了各方法对 EEG 和 fNIRS 两信号单独分类及协同分类的结果,可以明显得到使用本文所提的基于 EEG-fNIRS 时频特征融合与协同分类方法实现了 95.31% 的分类准确率,且较单模态信号分类准确率分别提升了 7.81% 和 9.60%。同时,本文方法较已有方法的准确率高,证明本

表3 使用不同协同分类方法对 EEG-fNIRS 分类的准确率
Table 3 The accuracy of EEG-fNIRS classification using different collaborative classification methods

方法	准确率/%	
单模态信号	EEG-高斯 SVM+PCA	87.50
	fNIRS-BiLSTM	85.71
	EEG-fNIRS-SVM	89.10
多模态信号	EEG-fNIRS-DNN	90.00
	EEG-fNIRS-1DCNN+FC(本文)	95.31

文提出方法可以有效融合多模态特征,进而提高分类准确率。

3 讨论

本文提出了一种基于 EEG-fNIRS 信号时频特征融合与协同分类方法。融合特征充分利用了不同模态的 EEG 和 fNIRS 两信号在采样机理层面的互补特性,以及两信号在时频域反映的不同信息。另外,使用 1DCNN 方法对融合特征进行了深层特征提取,提取了多维度的信息,提高了协同分类的准确率。将所提方法在公开数据集 HYGRIP 中进行验证,从结果可以看出,将 EEG 小波包能量熵特征和 Bi-LSTM 提取的 fNIRS 时域特征进行融合与协同分类的准确率明显高于分别对两种信号进行分类的准确率。对于 EEG 信号,使用高斯 SVM+PCA 方法对提取的小波包能量熵特征进行分类,实现了 87.5% 的准确率。对于 fNIRS 信号,使用 Bi-LSTM 方法自动提取时域特征并分类实现了 85.71% 的准确率。对于 EEG-fNIRS,得到时频域融合特征,再使用 1DCNN 方法进行进一步的特征提取,然后使用 FC 网络进行分类,得到准确率为 95.31%。可以看到,使用 EEG-fNIRS 协同分类的精度分别比使用 EEG 或 fNIRS 信号高 7.81% 和 9.60%。本文方法所提取的 EEG 频域特征和 fNIRS 时域特征更能反映任务中大脑活动的差异,且使用 1DCNN 和 FC 网络对融合特征进行了进一步的信息提取和分类。相较于 Chiarelli 等^[18]使用的特征提取方法和仅使用全连接前馈 DNN 网络的分类方法,本文方法可以更深入地获取两信号时频域的互补信息,取得了更高的分类准确率。

分析 EEG-fNIRS 协同分类优于单一信号分类的原因:

1) 信息量的增加。与单模态信号相比,两个信号同时使用的信息增加,可用特征也相应增加。此外,EEG 和 fNIRS 采集的脑功能区信号类型不同。前者收集神经电信号,后者收集脑血流中血红蛋白浓度的变化。这样,同时使用两种不同类型的互补信息自然可以提高分类的准确率。

2) 融合策略的选择。由于 EEG 和 fNIRS 信号采样率分别为 1 000 Hz 和 12.5 Hz,相差近 10^2 数量级,对两信号进行降采样和上采样易造成信息的缺失,因此难以从原始信号进行融合。另外,在决策层融合两信号单独分类的结果可以提高分类的鲁棒性,但精度没有得到明显提高^[19]。因此,本文选择在特征层进行融合,避免了信息的丢失问题,提高了分类准确度。

3) 模型建立的合理性和有效性。使用 Bi-LSTM 神经网络提取 fNIRS 时域特征,使网络能够学习时间序列信号的历史与未来信息。同时,提出 1DCNN+FC 方法对

融合特征进一步提取分类,使得 EEG-fNIRS 信号的融合特征包括多方面信息。最后,依靠神经网络结构对非线性的逼近能力,使模型更为真实地反映左右手进行握力动作与 EEG-fNIRS 之间的内在联系。

基于多模态的脑功能信号的融合与协同分类方法仍存在巨大挑战,以本文研究的 EEG 和 fNIRS 信号融合为例,两信号的采集原理等有较大差异,目前已有的信号融合方法存在一定局限性。如何在保证信息不丢失的前提下,更好的实现两信号的融合是未来的研究重点。本文的研究方法主要关注于对两信号特征融合方法的研究,今后的工作将针对 EEG 和 fNIRS 原始信号频率差异大,难以直接由原始信号进行融合的问题展开研究,同时关注两信号与指定任务之间的特定联系,实现更好的互补信息融合。

4 结 论

本文提出了一种基于 EEG-fNIRS 时频域特征融合与协同分类方法,将提取的 EEG 小波包能量熵特征与 Bi-LSTM 自动提取的 fNIRS 时域特征进行组合,然后进行协同分类。将该方法运用在公开数据集中,实现了 95.31% 的准确率,较单模态信号分类准确率分别提升了 7.81% 和 9.60%。实验结果表明,本文所提方法融合了 EEG 电生理和 fNIRS 血氧浓度变化的多角度信息,再结合深度学习方法,提高了运动任务分类性能,证明了两种不同模态信号融合可以提高运动解码能力,为多模态信息融合方法的研究提供了参考。

参考文献

[1] EICKHOFF S B, CONSTABLE R T, YEO B T T. Topographic organization of the cerebral cortex and brain cartography[J]. *Neuroimage*, 2018, 170: 332-347.

[2] PAPAIE A E, HOOKS B M. Circuit changes in motor cortex during motor skill learning [J]. *Neuroscience*, 2018, 368: 283-297.

[3] LEBRETON M, BAVARD S, DAUNIZEAU J, et al. Assessing inter-individual differences with task-related functional neuroimaging[J]. *Nature Human Behaviour*, 2019, 3(9): 897-905.

[4] MIN B K, MARZELLI M J, YOO S S. Neuroimaging-based approaches in the brain-computer interface [J]. *Trends in Biotechnology*, 2010, 28(11): 552-560.

[5] BHATTACHARYYA S, KHASNOBISH A, GHOSH P, et al. A review on brain imaging techniques for BCI applications [M]. *Medical Imaging: Concepts, Methodologies, Tools, and Applications*, IGI Global, 2017: 300-330.

[6] GAO Y, CAVUOTO L, SCHWARTZBERG S, et al. The effects of transcranial electrical stimulation on human motor functions: A comprehensive review of functional neuroimaging studies [J]. *Frontiers in Neuroscience*, 2020, 14:744.

[7] BUMA F E, LINDEMAN E, RAMSEY N F, et al. Functional neuroimaging studies of early upper limb recovery after stroke: A systematic review of the literature[J]. *Neurorehabilitation and Neural Repair*, 2010, 24(7): 589-608.

[8] HE B, YANG L, WILKE C, et al. Electrophysiological imaging of brain activity and connectivity—Challenges and opportunities[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(7): 1918-1931.

[9] VILLRINGER A, DIRNAGL U. Coupling of brain activity and cerebral blood flow: Basis of functional neuroimaging[J]. *Cerebrovascular and Brain Metabolism Reviews*, 1995, 7(3): 240-276.

[10] JACKSON A F, BOLGER D J. The neurophysiological bases of EEG and EEG measurement: A review for the rest of us [J]. *Psychophysiology*, 2014, 51 (11): 1061-1071.

[11] NASEER N, HONG K S. fNIRS-based brain-computer interfaces: A review [J]. *Frontiers in Human Neuroscience*, 2015, 9: 3.

[12] 柳长源,李文强,毕晓君. 基于 RCNN-LSTM 的脑电情感识别研究[J]. *自动化学报*, 2022, 48(3): 917-925.

[12] LIU CH Y, LI W Q, BI X J. Research on EEG emotion recognition based on RCNN-LSTM[J]. *Acta Automatica Sinica*, 2022, 48(3): 917-925.

[13] AL-SAEIGH A, DAWWD S A, ABDUL-JABBAR J M. Deep learning for motor imagery EEG-based classification: A review [J]. *Biomedical Signal Processing and Control*, 2021, 63: 102172.

[14] CRAIK A, HE Y, CONTRERAS-VIDAL J L. Deep learning for electroencephalogram (EEG) classification tasks: A review [J]. *Journal of Neural Engineering*, 2019, 16(3): 031001.

[15] 周伊婕,宋西姊,何峰,等. 基于脑电的多模态神经功能成像新技术研究进展[J]. *中国生物医学工程学报*, 2020, 39(5): 595-602.

[15] ZHOU Y J, SONG X Z, HE F, et al. Research progress of multimodal functional neural imaging technology based on EEG[J]. *Chinese Journal of Biomedical Engineering*, 2020, 39(5): 595-602.

[16] HONG K S, KHAN M J, HONG M J. Feature extraction and classification methods for hybrid fNIRS-EEG brain-computer interfaces [J]. *Frontiers in Human*

- Neuroscience, 2018, 12: 246.
- [17] LIU Z, SHORE J, WANG M, et al. A systematic review on hybrid EEG/fNIRS in brain-computer interface [J]. Biomedical Signal Processing and Control, 2021, 68: 102595.
- [18] CHIARELLI A M, CROCE P, MERLA A, et al. Deep learning for hybrid EEG-fNIRS brain-computer interface: Application to motor imagery classification [J]. Journal of Neural Engineering, 2018, 15(3): 036028.
- [19] HIRSCH G, DIRODI M, XU R, et al. Online classification of motor imagery using EEG and fNIRS: A hybrid approach with real time human-computer interaction [C]. International Conference on Human-Computer Interaction, Springer, Cham, 2020: 231-238.
- [20] GE S, WANG P, LIU H, et al. Neural activity and decoding of action observation using combined EEG and fNIRS measurement [J]. Frontiers in Human Neuroscience, 2019, 13: 357.
- [21] ORTEGA P, ZHAO T, FAISAL A A. HYGRIP: Full-stack characterization of neurobehavioral signals (fNIRS, EEG, EMG, force and breathing) during a bimanual grip force control task [J]. Frontiers in Neuroscience, 2020: 14.
- [22] DECETY J, GREZES J, COSTES N, et al. Brain activity during observation of actions. Influence of action content and subject's strategy [J]. Brain: A Journal of Neurology, 1997, 120(10): 1763-1777.
- [23] MISHRA A, SHARMA S, KUMAR S, et al. Effect of hand grip actions on object recognition process: A machine learning-based approach for improved motor rehabilitation [J]. Neural Computing and Applications, 2021, 33(7): 2339-2350.
- [24] RAGHU S, SRIRAAM N, KUMAR G P. Effect of wavelet packet log energy entropy on electroencephalogram (EEG) signals [J]. International Journal of Biomedical and Clinical Engineering (IJBCE), 2015, 4(1): 32-43.
- [25] NASEER N, NOORI F M, QURESHI N K, et al. Determining optimal feature-combination for LDA classification of functional near-infrared spectroscopy signals in brain-computer interface application [J]. Frontiers in Human Neuroscience, 2016, 10: 237.
- [26] HONG K S, NASEER N, KIM Y H. Classification of prefrontal and motor cortex signals for three-class fNIRS-BCI [J]. Neuroscience Letters, 2015, 587: 87-92.

- [27] SCOTT N A. Cortical specificity in neurovascular coupling [J]. Journal of Neurophysiology, 2015, 114(6): 3031-3032.

作者简介



刘晋瑞, 2021年于北京科技大学获得学士学位, 现为南开大学人工智能学院硕士研究生, 主要研究方向为神经康复机器人和人工智能技术。

E-mail: liu_jinrui06@mail.nankai.edu.cn

Liu Jinrui received her B. Sc. degree from University of Science and Technology Beijing in 2021. She is currently a master student in the College of Artificial Intelligence at Nankai University. Her main research interests include AI and robotics for neurorehabilitation.



韩建达, 1990年于西安交通大学获得学士学位, 1994年于中国科学院沈阳自动化研究所硕士研究生毕业(直博), 1998年于哈尔滨工业大学获得博士学位, 现为南开大学杰出教授, 主要研究方向为机器人自主行为与人机协作/共融方法, 医疗康复机器人、地面移动及飞行机器人技术与系统。

E-mail: hanjianda@nankai.edu.cn

Han Jianda received his B. Sc. degree from Xi'an Jiaotong University in 1990, M. Sc. degree from Shenyang Institute of Automation, Chinese Academy of Sciences in 1994, and Ph. D. degree from Harbin Institute of Technology in 1998. He is currently an outstanding professor at Nankai University. His main research interests include robot autonomy and human-robot coordination, medical and rehabilitation robots, mobile and flying robots.



于宁波(通信作者), 2003年于天津大学获得学士学位, 2005年于香港科技大学获得硕士学位, 2011年于瑞士苏黎世联邦理工学院获得博士学位, 现为南开大学人工智能学院教授, 主要研究方向为医疗人工智能、医疗康复机器人。

E-mail: nyu@nankai.edu.cn

Yu Ningbo (Corresponding author) received his B. Sc. degree from Tianjin University in 2003, M. Sc. degree from the Hong Kong University of Science and Technology in 2005, and Ph. D. degree from ETH Zurich in 2011. He is currently a professor in the College of Artificial Intelligence at Nankai University. His main research interests include AI and robotics in medicine.