

基于增强深度特征和TSK模糊分类器的癫痫脑电信号识别

蒋云良^{1,2}, 翁江玮^{1,2}, 申情^{2,3}, 胡文军^{1,2}, 张雄涛^{1,2†}

(1. 湖州师范学院信息工程学院, 浙江湖州 313000; 2. 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江湖州 313000; 3. 湖州学院理工学院, 浙江湖州 313000)

摘要: 识别癫痫脑电信号的关键在于获取有效的特征和构建可解释的分类器. 为此, 提出一种基于增强深度特征的TSK模糊分类器(ED-TSK-FC). 首先, ED-TSK-FC使用一维卷积神经网络(1D-CNN)自动获取癫痫脑电信号的深度特征与潜在类别信息, 并将深度特征和潜在类别信息合并为增强深度特征; 其次, 将增强深度特征作为ED-TSK-FC模糊规则前件与后件部分的训练变量, 保证原始输入的深度特征及其潜在意义都出现在模糊规则中, 进而对增强深度特征作出良好的解释; 然后, 采用岭回归极限学习算法对模糊规则的后件参数进行快速求解, 在不显著降低分类准确度的情况下, ED-TSK-FC的廉价训练方法可以缩短模型的训练时间; 最后, 在Bonn癫痫数据集上, 分别从分类性能、学习效率和可解释性3个方面, 验证ED-TSK-FC的优越性.

关键词: 脑电信号; 深度学习; 深度特征; 增强特征; TSK模糊分类器; 可解释性

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1031

引用格式: 蒋云良, 翁江玮, 申情, 等. 基于增强深度特征和TSK模糊分类器的癫痫脑电信号识别[J]. 控制与决策, 2023, 38(1): 171-180.

TSK fuzzy classifier based on enhanced deep feature for epilepsy EEG signal recognition

JIANG Yun-liang^{1,2}, WENG Jiang-wei^{1,2}, SHEN Qing^{2,3}, HU Wen-jun^{1,2}, ZHANG Xiong-tao^{1,2†}

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China; 2. Zhejiang Province Key Laboratory of Smart Management & Application of Modern Agricultural Resources, Huzhou 313000, China; 3. School of Science and Engineering, Huzhou College, Huzhou 313000, China)

Abstract: The key to recognize epileptic EEG signals is to obtain effective features and construct an interpretable classifier. In this paper, a Takagi-Sugeno-Kang (TSK) fuzzy classifier based on enhanced deep feature (ED-TSK-FC) for epilepsy EEG signal recognition is proposed. The ED-TSK-FC adopts an one-dimension convolution neural network (1D-CNN) to extract deep feature and label information, label information is expanded to the deep feature space to generate the enhanced deep feature. As the antecedent-consequent variable of the ED-TSK-FC, the enhanced deep feature can provide deep feature and label information for each fuzzy rule, hence fuzzy rules open the black box of the 1D-CNN in an interpretable manner. Finally, the ridge regression extreme learning algorithm is used to quickly solve the consequent parameters of fuzzy rules. In addition, the ED-TSK-FC also formulates a cheap strategy to decrease training time. Experiments show that this method provides an excellent performance on the Bonn epilepsy dataset in terms of classification performance, training time and interpretability.

Keywords: electroencephalogram (EEG); deep learning; deep feature; enhanced deep feature; Takagi-Sugeno-Kang (TSK) fuzzy classifier; interpretability

0 引言

癫痫是一种常见的神经系统疾病, 具有反复发作和难以治愈的特征, 需要患者进行长期的体征监测与药物治疗^[1]. 由于大多数癫痫患者通常会在没有明显症状的情况下突然发作, 往往会给患者造成意外的伤害. 因此, 提出一种智能的癫痫识别方法是有效提高

患者生命安全的重要手段.

脑电信号记录了大脑皮层不同部位的电压变化, 进而揭示了大脑神经元的生物电活动. 在过去几年中, 国内外采用脑电信号预处理、特征提取和分类的癫痫脑电信号识别技术取得了显著的进展^[2-4]. 由于脑电信号很容易受到心电信号、眼球运动和肌肉活

收稿日期: 2021-06-12; 录用日期: 2021-09-28.

基金项目: 国家自然科学基金面上项目(61771193, 61802123, 61772199).

†通讯作者. E-mail: 1047897965@qq.com.

动等噪声的污染^[5],可采用快速傅立叶变换^[6]、小波包分解^[7]与独立分量分析^[8]等方法提取脑电信号中的重要信息.但是,如何从原始脑电信号获得有效的特征并运用决策树^[9]、支持向量机^[10]等机器学习方法实现智能识别仍然是一项具有挑战性的工作.

深度学习作为一类新兴的多层神经网络模型,其逐层的神经表达方式可以从原始输入中提取抽象的深度特征,在图像识别、自然语言处理和医疗诊断等领域中得到快速发展^[11-13].在癫痫脑电信号识别任务中,卷积神经网络^[14]已经展示了良好的特征提取能力,且表现出超越临床医生的准确率.文献[15]首次将卷积神经网络应用于基于脑电信号的癫痫发作检测任务,不需要人工的特征提取和特征选择;文献[16]提出了一种基于卷积神经网络的癫痫脑电信号分类与分析的通用架构,并生成了相关的脑映射图像,供医学专家进一步研究使用.由于无法真正理解不同网络层内各个参数的含义,从而导致深度学习成为了一个黑盒模型,随着深度学习的架构变得更加复杂,人们很难解释深度学习究竟从原始输入中学到了哪些有用的知识,产生最终的识别结果.

TSK模糊分类器是一种具备可解释性的万能逼近器^[17-20],能够将学到的知识进行语义化解释,在自动化控制^[21]和医疗诊断^[22]等领域受到广泛关注.在TSK模糊分类器中,确定前件模糊规则和后件参数是两大关键步骤,通常可以借鉴专家经验进行人工赋值,也可以采用基于数据驱动(data-driven)的建模方法自动获取.近年来,融合深度学习和模糊分类器的深度模糊模型是进一步提高逼近精度和提供可解释性的可行方向,如文献[23]提出了一种基于可解释模糊深度信念网络(DBN)的室内用户运动预测分类器;文献[24]将稀疏自编码作为一种有效的模糊规则精简方法,从输入数据中获取深度特征,并在派生的深度特征空间中学习模糊规则参数;文献[25]提出一种融合多视角深度特征的TSK模糊系统对癫痫脑电信号进行检测.

深度卷积神经网络虽然在癫痫发作检测准确度上获得了巨大的成功,在可解释性方面还存在着较大提升空间.与之不同,模糊规则具备将学到的深度知识进行语义化解释的能力.鉴于此,本文构建一种基于增强深度特征的TSK模糊分类器(ED-TSK-FC),并将其应用于癫痫脑电识别任务,通过提取深度卷积神经网络中的深度特征和潜在类别信息构建可解释的模糊规则,派生一种可解释的模糊分类器,用来解决深度神经网络在癫痫识别过程中可解释性差的问

题.在ED-TSK-FC中,将原始脑电信号作为输入数据,通过一维卷积神经网络(1D-CNN)对癫痫脑电信号进行深度特征学习,通过逐层的神经表达可获得隐含层的深度特征与输出层潜在类别信息,并将深度特征和潜在类别信息合并为增强深度特征.此外,增强深度特征作为ED-TSK-FC模糊规则前件与后件部分的训练变量,在前件部分采用模糊聚类(FCM)算法^[26]对增强深度特征空间进行模糊划分并获得相应的前件参数,后件部分则引入岭回归极限学习算法^[27]对参数进行学习.

本文的主要贡献如下:

1) 提出一种基于增强深度特征的TSK模糊分类器(ED-TSK-FC).采用1D-CNN对癫痫脑电信号进行深度特征学习,其隐含层的深度特征往往具有更低的数据维度和更高的泛化能力,输出层也含有相应的潜在类别信息,能够有效表征原始输入的特征信息.

2) 在构造增强深度特征过程中,将潜在类别信息扩充到深度特征空间,进一步打开了特征空间的流形结构,提高了特征的可辨识性,并且采用可解释的模糊规则对增强深度特征作出良好的解释.

3) 考虑到1D-CNN的训练过程繁琐,本文给出了ED-TSK-FC的廉价训练方法.首先,在1D-CNN的损失函数未收敛之前终止学习,并提取训练样本的增强深度特征;然后,对ED-TSK-FC模糊规则参数进行快速求解.实验表明,这种廉价训练方法在不显著降低分类准确度的情况下,可缩短整个模型的训练时间.

1 ED-TSK-FC

1.1 ED-TSK-FC框架

图1描述了ED-TSK-FC的整体框架,将原始脑电信号 $\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T$ 作为输入,使用1D-CNN对癫痫脑电信号进行深度特征学习,通过逐层的神经表达获得隐含层的深度特征 $\mathbf{H}_\sigma = (h_1, h_2, \dots, h_r)^T$ 与输出层的潜在类别信息 $\mathbf{E}_\omega = (e_1, e_2, \dots, e_s)^T$.然后,将深度特征和潜在类别信息合并为增强深度特征 $\tilde{\mathbf{H}}_i = (h_1, h_2, \dots, h_r, h_{r+1}, h_{r+2}, \dots, h_{r+s})^T$,并作为ED-TSK-FC中模糊规则前件与后件部分的训练变量用于学习模糊规则参数.下面详述ED-TSK-FC的工作流程.

1.1.1 1D-CNN

如图1所示,1D-CNN由多个卷积层(C层)和最大池化层(MP层)逐层提取深度特征,然后通过若干个全连接层(FC层)和输出层进行分类.假设训练数据集为 $\{\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T\}_{i=1}^N$ 及标签集 $\{z_i\}_{i=1}^N$,其中 d 代表样本维度, N 代表样本的数量.

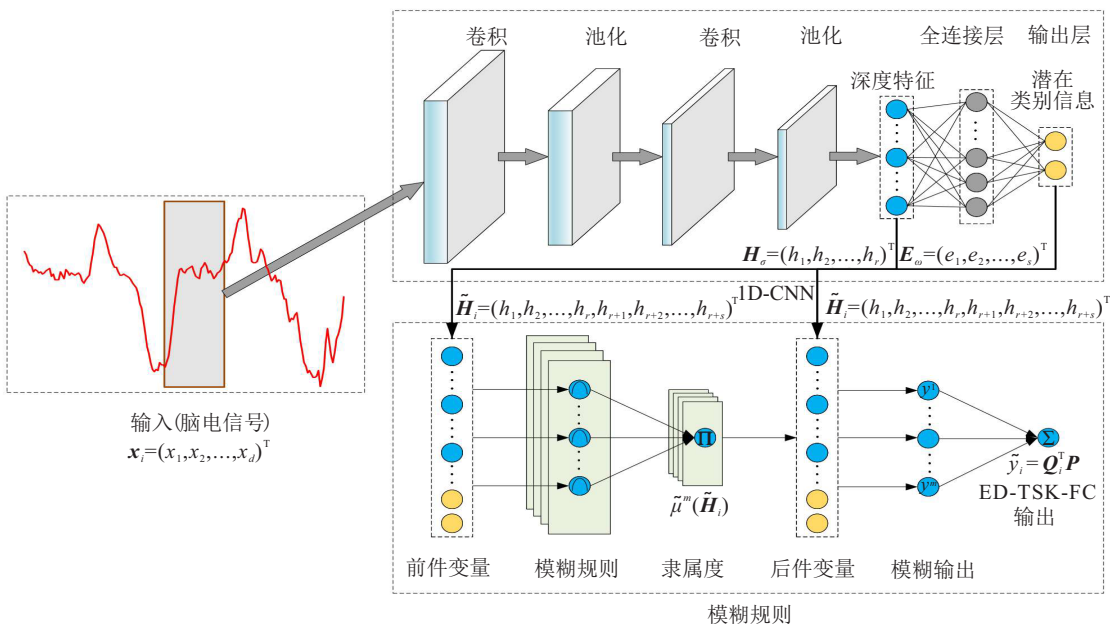


图1 ED-TSK-FC框架

在1D-CNN中,将第*l*层的输出结果(特征图)标记为 $H_l, l \in \{0, 1, \dots, L\}$,其中 H_0 代表原始输入 x_i .此外,第*l*层的权值和偏置分别是随机初始化的 W_l 和 b_l .

在C层中,采用局部连接方式(卷积核 W_l)执行卷积运算,并将偏置 b_l 添加到特征图中,然后采用激活函数 $f(\cdot)$ 进行非线性变换.计算过程如下所示:

$$H_l = f(W_l * H_{l-1} + b_l). \tag{1}$$

其中: $*$ 表示卷积运算, $f(\cdot)$ 选用PReLU激活函数^[28]提高1D-CNN的计算效率和拟合能力.PReLU激活函数表示如下:

$$f(a) = \begin{cases} a, & a > 0; \\ \varepsilon a, & a < 0. \end{cases} \tag{2}$$

其中: a 表示输入变量, ε 表示斜率的系数.

在MP层中,采用最大池化策略来选择每个特征图的局部显著特征,提高特征的鲁棒性.池化过程表示如下:

$$H_l = \text{Pool}(H_{l-1}), \tag{3}$$

其中 $\text{Pool}(\cdot)$ 表示最大池化操作.

经过若干次卷积和最大池化操作,将提取到的深度特征输入第1个FC层.在FC层中,通过权值 W_l 和偏置 b_l 进行计算,并利用激活函数 $f(\cdot)$ 进行非线性变换.计算过程如下:

$$H_l = f(W_l H_{l-1} + b_l), \tag{4}$$

其中 $f(\cdot)$ 仍选用PReLU激活函数.特别地,输出层为Softmax层,其输出 $H_l = (h_1, h_2, \dots, h_s)^T$ 被转换为

对应的概率结果, $E^i = (e_1, e_2, \dots, e_s)^T$,其中*s*代表类别的总数,计算如下:

$$e_{s'} = \frac{\exp(h_{s'})}{\sum_{s''=1}^s \exp(h_{s''})}, \quad s' = 1, 2, \dots, s. \tag{5}$$

在训练过程中,采用交叉熵损失函数度量1D-CNN的输出(潜在类别信息)与真实标签的差异,其计算公式如下:

$$\min - \frac{1}{N} \sum_{i=1}^N \sum_{s'=1}^s z_{i,s'} \log(e_{s'}^{E^i}). \tag{6}$$

1D-CNN的权值 W_l 和偏置 b_l 通过误差反向传播算法^[29]进行迭代和优化.具体来说,将式(6)的损失值从最后一层反向传播到第1层,并根据每1层的误差进行参数更新.假设 W_l 和 b_l 的导数为 ΔW_l 和 Δb_l ,参数更新公式为

$$W_l^\theta = W_l^{\theta-1} - \eta \Delta W_l^{\theta-1}, \tag{7}$$

$$b_l^\theta = b_l^{\theta-1} - \eta \Delta b_l^{\theta-1}. \tag{8}$$

其中: θ 表示训练迭代次数, η 表示学习率.在迭代过程中,采用Adam算法计算不同参数的自适应学习率.

一旦损失函数收敛,就可以确定 W_l 和 b_l 的最优参数.对于一个测试样本 x_{test} ,可以使用该网络提取任意隐含层的深度特征 H_l .在本文的研究中,将提取第1个FC层深度特征和输出层潜在类别信息作为ED-TSK-FC模糊规则的增强深度特征.为了便于区分,作出如下定义:第1个全连接层深度特征标记为 $H_\sigma = (h_1, h_2, \dots, h_r)^T$,输出层结果标记为 $E_\omega = (e_1, e_2, \dots, e_s)^T$,计算方法如下:

$$\mathbf{H}_l = \begin{cases} \text{Pool}(\mathbf{H}_{l-1}), l = 2, 4, \dots, \sigma; \\ f(\mathbf{W}_l * \mathbf{H}_{l-1} + \mathbf{b}_l), l = 1, 3, \dots, \sigma - 1. \end{cases} \quad (9)$$

$$\begin{cases} \mathbf{H}_l = f(\mathbf{W}_l \mathbf{H}_{l-1} + \mathbf{b}_l), l = \sigma + 1, \dots, \omega; \\ \mathbf{E}_\omega = \text{Softmax}(\mathbf{H}_\omega). \end{cases} \quad (10)$$

1.1.2 模糊规则

将输出层潜在类别信息 $\mathbf{E}_\omega = (e_1, e_2, \dots, e_s)^\top$ 扩充到深度特征空间 $\mathbf{H}_\sigma = (h_1, h_2, \dots, h_r)^\top$ 生成增强深度特征 $\tilde{\mathbf{H}}_i = (h_1, h_2, \dots, h_r, h_{r+1}, h_{r+2}, \dots, h_{r+s})^\top$. 因此, 所提出的 ED-TSK-FC 模糊规则可表述如下:

in rule m :

if h_1 is $\mathbf{A}_1^m \wedge h_2$ is $\mathbf{A}_2^m \wedge \dots \wedge h_{r+s}$ is \mathbf{A}_{r+s}^m ,

then $\mathbf{y}^m = p_0^m + p_1^m h_1 + p_2^m h_2 + \dots + p_{r+s}^m h_{r+s}$,

$$m = 1, 2, \dots, M. \quad (11)$$

其中: M 表示模糊规则总数, m 表示当前的模糊规则, \mathbf{A}_r^m 和 p_r^m 分别表示第 m 条规则中的第 r 个变量的模糊子集和后件参数, \mathbf{y}^m 表示第 m 条规则的模糊输出, \wedge 表示模糊取合算子.

根据文献 [30], 前件部分可采用 FCM 聚类算法进行模糊空间划分并估算每条规则的聚类中心 c_t^m 及核宽 k_t^m , 即

$$c_t^m = \frac{\sum_{i=1}^N \mu_i^m h_{it}}{\sum_{i=1}^N \mu_i^m}, \quad t = 1, 2, \dots, r + s; \quad (12)$$

$$k_t^m = \frac{\lambda \sum_{i=1}^N \mu_i^m (h_{it} - c_t^m)^2}{\sum_{i=1}^m \mu_i^m}. \quad (13)$$

其中: h_{it} 表示第 i 个样本的第 t 个分量, μ_i^m 表示在第 m 条规则下的隶属度, λ 是尺度因子. 此外, 利用高斯隶属度函数估计各规则的隶属度

$$\mu_{\mathbf{A}_t^m}(h_{it}) = \exp\left(\frac{-(h_{it} - c_t^m)^2}{2k_t^m}\right), \quad (14)$$

$$\mu^m(\tilde{\mathbf{H}}_i) = \prod_{t=1}^{r+s} \mu_{\mathbf{A}_t^m}(h_{it}). \quad (15)$$

将各规则的隶属度进行归一化处理, 有

$$\tilde{\mu}^m(\tilde{\mathbf{H}}_i) = \frac{\mu^m(\tilde{\mathbf{H}}_i)}{\sum_{m'=1}^M \mu^{m'}(\tilde{\mathbf{H}}_i)}. \quad (16)$$

因此, ED-TSK-FC 的输出 $\tilde{\mathbf{y}}_i$ 可以表示为

$$\tilde{\mathbf{y}}_i = \sum_{m=1}^M \tilde{\mu}^m(\tilde{\mathbf{H}}_i) \mathbf{y}^m. \quad (17)$$

令

$$\mathbf{p}^m = (p_0^m, p_1^m, \dots, p_{r+s}^m)^\top, \quad (18)$$

$$\mathbf{P} = ((\mathbf{p}^1)^\top, (\mathbf{p}^2)^\top, \dots, (\mathbf{p}^M)^\top)^\top, \quad (19)$$

$$\mathbf{q}_i^m = \tilde{\mu}^m(\tilde{\mathbf{H}}_i) (1, \tilde{\mathbf{H}}_i^\top)^\top, \quad (20)$$

$$\mathbf{Q}_i = ((\mathbf{q}_i^1)^\top, (\mathbf{q}_i^2)^\top, \dots, (\mathbf{q}_i^M)^\top)^\top. \quad (21)$$

式(17)可视为如下线性回归问题:

$$\tilde{\mathbf{y}}_i = \mathbf{Q}_i^\top \mathbf{P}. \quad (22)$$

在 ED-TSK-FC 中, 计算后件参数 \mathbf{P} 引入岭回归极限学习算法. 具体如下, 对于给定的训练数据集 $\{\mathbf{x}_i = (x_1, x_2, \dots, x_d)^\top\}_{i=1}^N$ 及标签集 $\{z_i\}_{i=1}^N$, 求解后件参数的目标公式可表示如下:

$$\min \frac{1}{2} \|\mathbf{Q}\mathbf{P} - \mathbf{Z}\|^2 + \frac{\alpha}{2} \|\mathbf{P}\|^2. \quad (23)$$

其中: 训练数据为 $\mathbf{Q} = (\mathbf{Q}_1, \mathbf{Q}_2, \dots, \mathbf{Q}_N)^\top$, $\mathbf{Z} = (z_1, z_2, \dots, z_N)^\top$, α 是正则化因子. 进而, 基于式(23)可以得出后件参数

$$\mathbf{P} = (\mathbf{Q}^\top \mathbf{Q} + \alpha \mathbf{I})^{-1} \mathbf{Q}^\top \mathbf{Z}. \quad (24)$$

至此, 整合 1.1.1 节中的 1D-CNN 的训练方法和 1.1.2 节模糊规则的前件及后件参数学习算法, 可得到 ED-TSK-FC 模型.

1.2 ED-TSK-FC 学习算法及其廉价学习算法

本节将 ED-TSK-FC 的整个学习算法描述为算法 1, 其主要包含两个阶段:

1) 训练阶段. 首先通过迭代更新 1D-CNN 中的参数 \mathbf{W}_l 和 \mathbf{b}_l , 迭代完成后, 对增强深度特征 $\tilde{\mathbf{H}}_i$ 进行提取. 在模糊规则中利用 FCM 算法对增强深度特征进行模糊划分, 并利用岭回归极限学习机对后件参数 \mathbf{P} 进行求解.

2) 测试阶段. 使用已经训练好的 ED-TSK-FC 对测试样本 \mathbf{x}_{test} 进行预测. 具体来说, 通过 1D-CNN 提取测试样本的增强深度特征, 并计算其在不同规则下的隶属度, 最后得到模糊规则后件输出.

算法 1 ED-TSK-FC 学习算法.

输入: 训练数据集 $\{\mathbf{x}_i = (x_1, x_2, \dots, x_d)^\top\}_{i=1}^N$ 及标签集 $\{z_i\}_{i=1}^N$, 1D-CNN 的最大迭代次数 $\tilde{\theta}$, 初始学习率 η , 规则数 M , 尺度因子 λ 和正则化因子 α ; 测试样本 \mathbf{x}_{test} .

输出: 训练完成的 ED-TSK-FC; 测试样本的输出

$\tilde{\mathbf{y}}_{\text{test}}$.

训练阶段.

初始化: 随机初始化 \mathbf{W}_l 和 \mathbf{b}_l ;

For $\theta < \tilde{\theta}$

step 1: 输入训练样本 $\{\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T\}_{i=1}^N$, 根据式(1)~(3), 训练样本通过C层和MP层进行卷积和池化操作.

step 2: 在FC层, 利用式(4)和(5), 计算样本属于每个标签的概率.

step 3: 根据交叉熵损失函数(6)对1D-CNN进行误差反向传播, 参数更新公式如下:

$$\begin{aligned} \mathbf{W}_l^\theta &= \mathbf{W}_l^{\theta-1} - \eta \Delta \mathbf{W}_l^{\theta-1}, \\ \mathbf{b}_l^\theta &= \mathbf{b}_l^{\theta-1} - \eta \Delta \mathbf{b}_l^{\theta-1}. \end{aligned}$$

End

step 4: 根据式(9)和(10), 分别提取第1个全连接层深度特征 $\mathbf{H}_\sigma = (h_1, h_2, \dots, h_r)^T$ 和输出层结果 $\mathbf{E}_\omega = (e_1, e_2, \dots, e_s)^T$.

step 5: 将输出层结果 \mathbf{E}_ω 扩充到深度特征空间 \mathbf{H}_σ 生成增强深度特征 $\tilde{\mathbf{H}}_i = (h_1, h_2, \dots, h_r, h_{r+1}, h_{r+2}, \dots, h_{r+s})^T$.

step 6: 运行FCM算法生成模糊隶属度矩阵.

step 7: 根据式(12)和(13), 估计模糊规则的聚类中心 c_i^m 及核宽 k_i^m .

step 8: 根据式(14)~(16), 计算样本在不同规则中的隶属度 $\tilde{\mu}^m(\tilde{\mathbf{H}}_i)$.

step 9: 根据式(20)和(21), 计算并生成 \mathbf{Q}_i , ED-TSK-FC的输出可以表示为 $\tilde{\mathbf{y}}_i = \mathbf{Q}_i^T \mathbf{P}$.

step 10: 利用岭回归极限学习算法, 后件参数 \mathbf{P} 的计算公式如下:

$$\mathbf{P} = (\mathbf{Q}^T \mathbf{Q} + \alpha \mathbf{I})^{-1} \mathbf{Q}^T \mathbf{Z}.$$

测试阶段.

step 1: 输入测试样本 \mathbf{x}_{test} .

step 2: 根据式(9)和(10), 分别提取第1个全连接层深度特征 $\mathbf{H}_\sigma = (h_1, h_2, \dots, h_r)^T$ 和输出层结果 $\mathbf{E}_\omega = (e_1, e_2, \dots, e_s)^T$.

step 3: 将输出层结果 \mathbf{E}_ω 扩充到深度特征空间 \mathbf{H}_σ 生成增强深度特征 $\tilde{\mathbf{H}}_{\text{test}} = (h_1, h_2, \dots, h_r, h_{r+1}, h_{r+2}, \dots, h_{r+s})^T$.

step 4: 根据式(14)~(16), 计算测试样本在不同规则中的隶属度 $\tilde{\mu}^m(\tilde{\mathbf{H}}_{\text{test}})$.

step 5: 根据式(20)和(21), 计算并生成 \mathbf{Q}_{test} .

step 6: 根据式(22), 计算测试样本的输出 $\tilde{\mathbf{y}}_{\text{test}}$.

接下来分析ED-TSK-FC算法的时间复杂度. ED-TSK-FC中1D-CNN的运算复杂度约为

$$O\left(\tilde{\theta} \left(\sum_{l=1}^L C_{l-1} w_l C_l \chi_l \right)\right).$$

其中: $\tilde{\theta}$ 表示1D-CNN的最大迭代次数, C_l 表示第 l 层的特征图数量, w_l 表示卷积核尺寸, χ_l 表示特征图的维度. 在模糊规则中, FCM算法的复杂度为 $O(\theta_2 N M^2 (r + s))$, 其中 θ_2 表示FCM的最大迭代次数. 岭回归极限学习算法的时间复杂度为 $O(N(r + s)^2 + (r + s)^3)$. 因此, ED-TSK-FC总时间复杂度为

$$O\left(\tilde{\theta} \left(\sum_{l=1}^L C_{l-1} w_l C_l \chi_l \right) + \theta_2 N M^2 (r + s) + N(r + s)^2 + (r + s)^3\right).$$

考虑到ED-TSK-FC中1D-CNN的训练过程复杂度较高, 进一步提出一种廉价的训练方法. 根据文献[31-32], 神经网络的批量学习过程实际上所表达的是一种核学习机. 在准确度要求不高的情况下, 网络的学习仅需在最后一层实施即可, 而在隐含层的参数可任意赋值. 基于此, 提出如下廉价训练方法:

1) 在1D-CNN的损失函数未收敛之前, 提前终止学习, 即 $\tilde{\theta}_{\text{cheap}} \ll \tilde{\theta}$.

2) 在提前终止学习的1D-CNN中提取增强深度特征并作为模糊规则前件与后件部分的训练变量.

该廉价训练方法将1D-CNN的参数进行快速学习, 并在ED-TSK-FC模糊规则的后件学习中引入岭回归极限学习算法, 保证了ED-TSK-FC的收敛性.

2 实验研究

本节基于癫痫脑电信号的分类任务对所提出的ED-TSK-FC进行验证与评估. 本实验运行的硬件环境为: AMD Ryzen 5 3600 3.6 GHz and 32 G RAM, GeForce RTX 2070 SUPER with 8 G RAM, the 64-bit Microsoft Windows 10; 编程环境为: Python 3.5.2 with torch 1.2.0.

2.1 数据集描述

本实验所采用的癫痫数据来自德国 Bonn 大学^[33], 经预处理后公开发布在UCI数据库. 表1给出了该数据集的详细信息, 包括脑电信号的类型, 每个类对应的测试状态和样本数量, 每个样本的维度是178.

表1 Bonn癫痫数据集

类型	具体描述	数量	分组
癫痫发作	癫痫患者癫痫发作期间	2300	A
	癫痫患者癫痫发作间歇期	2300	B
正常	癫痫患者癫痫未发作期间	2300	C
	健康志愿者闭眼	2300	D
	健康志愿者睁眼	2300	E

进一步将 Bonn 数据集划分成4个实验数据集,

如表2所示,以验证ED-TSK-FC在不同实验条件下的稳定性.其中:dataset 1~dataset 3包含了癫痫患者在不同状态下的脑电信号,dataset 4则按照健康志愿者与癫痫患者发作期的脑电信号进行划分.

表2 实验数据集

数据集	癫痫	正常
dataset 1	A	B
dataset 2	A	C
dataset 3	A	B/C
dataset 4	A	D/E

2.2 实验设置和性能指标

本文通过试错法确定1D-CNN的隐含层结构、核尺寸、步长等参数,表3报告了1D-CNN的具体结构.

表3 1D-CNN的结构

网络层	维度	特征图	核尺寸(步长)
输入层	1×178	—	—
卷积层	1×89	32	1×3(2)
池化层	1×44	32	1×2(2)
卷积层	1×22	16	1×3(2)
池化层	1×11	16	1×2(2)
卷积层	1×6	1	1×3(2)
全连接层	6	—	—
全连接层	5	—	—
输出层	2	—	—

此外,最大迭代次数 $\tilde{\theta}$ 设置为100,初始学习率 η 设置为0.001,其余参数均设定为默认值.为保证模糊系统的可解释性,ED-TSK-FC的模糊规则寻优范围设定为 $M = \{5, 8, \dots, 32\}$,式(13)中尺度因子的寻优范围为 $\lambda = \{2^{-6}, 2^{-5}, \dots, 2^2\}$,式(24)中惩罚因子的寻优范围为 $\alpha = \{0.001, 0.01, \dots, 100\}$.

为了评价该模型的有效性,将本文提出的ED-TSK-FC分别与3种一阶TSK模糊分类器、2种基于深度特征的分类器以及1D-CNN进行了比较.具体来说,3种TSK模糊分类器分别是基于原始数据的TSK模糊分类器(Shallow-TSK-FC),基于PCA算法的TSK模糊分类器(PCA-TSK-FC)和基于1D-CNN深度特征

的TSK模糊分类器(Deep-TSK-FC),模糊规则寻优范围均设定为 $M = \{5, 8, \dots, 32\}$,尺度因子的寻优范围为 $\lambda = \{2^{-6}, 2^{-5}, \dots, 2^2\}$,惩罚因子的寻优范围为 $\alpha = \{0.001, 0.01, \dots, 100\}$.2种基于1D-CNN深度特征的分类器分别是支持向量机(Deep-SVM)和决策树(Deep-DT),Deep-SVM的惩罚因子寻优范围为 $\{0.01, 0.1, \dots, 100\}$,Deep-DT的最大深度的寻优范围为 $\{4, 5, \dots, 10\}$,其余参数均设定为默认值.

为对本文的实验结果进行合理地评价与分析,选用了评价指标accuracy和F-measure^[34],具体公式如下:

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}}, \quad (25)$$

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (26)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (27)$$

$$F\text{-measure} = \frac{2PR}{P + R}. \quad (28)$$

其中:TP(真阳性)表示被正确识别为癫痫样本的数量,TN(即真阴性)表示被正确识别为正常样本的数量,FP(即假阳性)表示被错误识别为癫痫样本的数量,FN(即假阴性)表示被错误识别为正常样本的数量.

在本实验中,采用五折交叉验证的方式确定每个模型的最优参数.具体来说,将数据集等分为5个子集,逐次将其中4个子集用于训练,剩下的子集用于验证分类性能,程序重复运行5次,评价指标的均值和标准差在所有相关表中的结果用均值±标准差表示.

2.3 实验结果与分析

表4和表5给出了ED-TSK-FC及6种比较分类器在4个数据集上的实验结果,实验比较了平均测试accuracy和F-measure及其标准方差,其中最好的结果用粗体表示.结果归纳如下:

表4 ED-TSK-FC及6种比较分类器在4个数据集的accuracy对比结果

	Shallow-TSK-FC	PCA-TSK-FC	1D-CNN	Deep-SVM	Deep-DT	Deep-TSK-FC	ED-TSK-FC
dataset 1	91.50 ± 0.79	92.91 ± 0.54	96.43 ± 0.66	97.19 ± 0.45	96.35 ± 0.33	96.87 ± 0.64	97.52 ± 0.53
dataset 2	93.04 ± 1.25	94.54 ± 0.69	98.54 ± 0.24	99.09 ± 0.21	97.93 ± 0.37	98.50 ± 0.71	99.15 ± 0.43
dataset 3	92.09 ± 0.60	94.57 ± 0.68	97.07 ± 0.47	97.00 ± 0.39	95.83 ± 0.31	96.62 ± 0.24	97.14 ± 0.27
dataset 4	96.49 ± 0.56	96.93 ± 0.30	97.81 ± 1.38	99.32 ± 0.23	98.40 ± 0.30	98.99 ± 0.18	99.58 ± 0.15

表5 ED-TSK-FC及6种比较分类器在4个数据集的F-measure对比结果

	Shallow-TSK-FC	PCA-TSK-FC	1D-CNN	Deep-SVM	Deep-DT	Deep-TSK-FC	ED-TSK-FC
dataset 1	92.08 ± 0.68	92.90 ± 0.70	96.43 ± 0.59	97.18 ± 0.39	96.33 ± 0.23	96.90 ± 0.56	97.52 ± 0.49
dataset 2	92.87 ± 1.40	94.29 ± 0.78	98.54 ± 0.24	99.08 ± 0.22	97.79 ± 0.68	98.51 ± 0.66	99.16 ± 0.40
dataset 3	87.62 ± 0.93	91.64 ± 0.97	95.56 ± 0.81	95.46 ± 0.50	93.69 ± 0.50	94.88 ± 0.31	95.70 ± 0.43
dataset 4	94.84 ± 0.79	95.20 ± 0.58	96.69 ± 2.07	98.98 ± 0.32	97.60 ± 0.43	98.48 ± 0.26	99.37 ± 0.22

1) 由表4的实验结果可以看出,在分类准确度上,基于1D-CNN深度特征的分类器Deep-SVM、Deep-DT和Deep-TSK-FC均优于Shallow-TSK-FC和PCA-TSK-FC,且在大多数情况下高于1D-CNN,这说明1D-CNN所提取到的深度特征具备了更可靠的分类能力.此外,ED-TSK-FC在4个数据集中的表现均优于6个比较分类器.其原因在于,增强深度特征采用将输出层潜在类别信息扩充到深度特征空间的方式,进一步打开原始输入的特征空间流形结构,实现更鲁棒的癫痫脑电信号分类.

2) 由表5的实验结果可以看出,ED-TSK-FC表现出高于其他6个分类器的F-measure指标,尤其在dataset 4中,ED-TSK-FC的F-measure相对于其他分类器的优势更加明显.这表明ED-TSK-FC能够在多种脑电信号混合的数据集中有效捕捉癫痫脑电信号的特征并完成癫痫识别.

图2充分比较了所提出ED-TSK-FC的廉价训练方法与1D-CNN在4个数据集不同迭代次数下的性能差异.具体来说,每次1D-CNN迭代完成后均提取其增强深度特征并训练ED-TSK-FC中模糊规则的参数,其中第0次迭代表示1D-CNN仅初始化.由图2可以看出,当1D-CNN的训练迭代次数较低时,1D-CNN不具备良好的分类性能,而派生的ED-TSK-FC能够达到较高的分类性能.随着迭代次数的增加,1D-CNN的分类能力不断提高,ED-TSK-FC的分类性能也得到了相应的提升.这说明,1D-CNN的损失函数未收敛之前,无法获得良好的分类性能,在ED-TSK-FC的后件学习中引入岭回归极限学习算法可以保证ED-TSK-FC具备良好的收敛性.

此外,表6进一步展示了图2中典型的5个ED-TSK-FC廉价版本(即ED-TSK-FC-*,*代表1D-CNN的迭代次数)的总训练时间与准确度.以dataset 1为例,当1D-CNN完成初始化后,派生的ED-TSK-FC-0的准确度为91.11%,具备了良好的分类能力,训练时间为0.3907s.随着1D-CNN迭代次数的提高,派生的

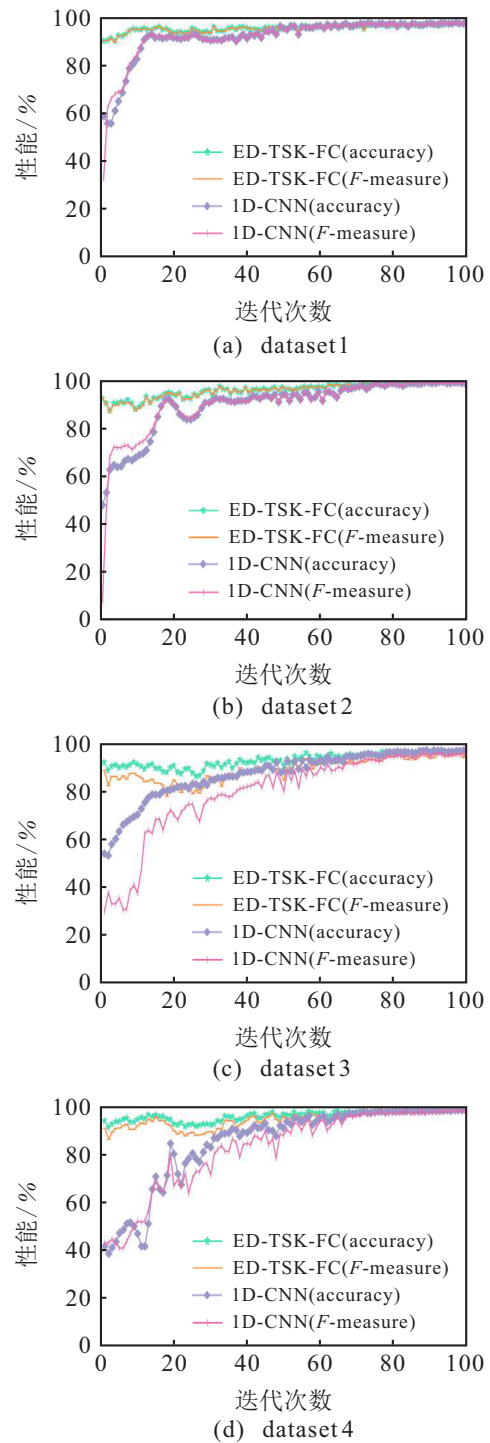


图2 ED-TSK-FC的廉价训练方法与1D-CNN在4个数据集与不同迭代次数下的性能差异

表6 ED-TSK-FC及其廉价版本与1D-CNN在4个数据集的总训练时间以及准确度

model	dataset 1		dataset 2		dataset 3		dataset 4	
	training time	accuracy	training time	accuracy	training time	accuracy	training time	accuracy
ED-TSK-FC-0	0.3907	91.11±0.35	0.2343	91.17±1.24	1.0453	92.11±1.22	1.0539	94.97±1.89
ED-TSK-FC-20	2.8983	93.19±0.24	2.8116	93.13±1.84	4.8305	88.04±1.26	4.8870	94.04±1.48
ED-TSK-FC-40	5.4900	94.69±0.11	5.3542	95.39±0.99	8.5905	92.43±0.16	8.6920	97.42±0.86
ED-TSK-FC-60	8.1144	95.52±0.40	7.9920	96.87±0.31	12.3645	94.30±1.71	12.4845	98.30±0.25
ED-TSK-FC-80	10.7008	96.63±0.50	10.4589	98.72±0.19	16.1732	96.32±1.05	16.2735	99.16±0.07
ED-TSK-FC	13.3273	97.52±0.53	13.0223	99.15±0.43	20.0499	97.14±0.27	20.0424	99.58±0.15
1D-CNN	13.0028	96.43±0.66	12.8459	98.54±0.24	19.1491	97.07±0.47	19.1411	97.81±1.38

表7 ED-TSK-FC前3条规则的聚类中心及核宽

规则	模糊规则参数
规则1	前件 $\mathbf{c}_1 = (57.5348, 98.2213, 98.8597, 99.5494, 102.6806, 67.4723, 0.0196, 0.9804)^T$ $\mathbf{k}_1 = (27.8546, 53.9427, 57.2677, 56.5404, 54.5038, 38.189, 0.0003, 0.0003)^T$
	后件 $\mathbf{p}^1 = (2.1900 \times 10^{-6}, 9.1670 \times 10^{-5}, 1.4805 \times 10^{-4}, 2.8400 \times 10^{-6}, -3.0844 \times 10^{-3}, 1.3000 \times 10^{-7}, 2.0980 \times 10^{-5}, 1.4663 \times 10^{-2}, 1.2900 \times 10^{-6})^T$
规则2	前件 $\mathbf{c}_2 = (24.6585, 39.2501, 38.8708, 39.2044, 39.4693, 24.9107, 0.0577, 0.9423)^T$ $\mathbf{k}_2 = (9.933, 20.744, 20.7389, 20.2864, 21.2539, 13.9379, 0.0008, 0.0008)^T$
	后件 $\mathbf{p}^2 = (3.5200 \times 10^{-5}, 6.7452 \times 10^{-4}, 2.6600 \times 10^{-6}, 7.4145 \times 10^{-4}, 1.5000 \times 10^{-7}, 4.9700 \times 10^{-6}, 8.2575 \times 10^{-3}, 1.8100 \times 10^{-6}, 4.7400 \times 10^{-5})^T$
规则3	前件 $\mathbf{c}_3 = (31.394, 51.4788, 50.3541, 50.7417, 52.2498, 33.5645, 0.0385, 0.9615)^T$ $\mathbf{k}_3 = (12.3962, 25.4989, 25.7078, 25.1569, 26.2772, 17.4965, 0.0005, 0.0005)^T$
	后件 $\mathbf{p}^3 = (1.5140 \times 10^{-3}, 3.2800 \times 10^{-6}, 4.9636 \times 10^{-4}, 2.0000 \times 10^{-7}, -8.4300 \times 10^{-6}, 6.3067 \times 10^{-3}, 1.4600 \times 10^{-6}, -1.9200 \times 10^{-6}, 1.3056 \times 10^{-3})^T$

ED-TSK-FC-80的准确度达到96.64%，超过了1D-CNN的准确度，训练时间缩短了2.3020s；ED-TSK-FC的廉价版本与ED-TSK-FC相比，虽然在准确度方面存在一定的差距，但是ED-TSK-FC的廉价训练方法可以显著缩短模型的训练时间，快速实现分类能力。同时，在高准确度的分类场景中，可以增加1D-CNN的迭代次数，即实现完整的ED-TSK-FC训练过程，从而提高分类能力。在未来的工作中，将进一步完善这种方法的理论依据。

在ED-TSK-FC中模糊规则通过高斯隶属度计算样本在不同规则下的隶属度，每条模糊规则的前件部分与相应的后件输出对1D-CNN的增强深度特征提供了可解释性。为了更加详细地阐述ED-TSK-FC如何解释增强深度特征，下面以Dataset 1为例进行说明。首先，图3展示了ED-TSK-FC在 $\lambda = 2^{-6}, \alpha = 0.01$ 的情况下，随着模糊规则总数的增加，ED-TSK-FC的分类性能的变化。可以看出，增加模糊规则并没有显著提高ED-TSK-FC的分类性能，且在8条和20条模糊规则时，ED-TSK-FC达到了较高的平均分类性能。




图3 模糊规则对ED-TSK-FC的性能影响

综合考虑ED-TSK-FC的可解释性与分类性能，采用8条模糊规则对增强深度特征进行解释，表7给

出了前3条规则的聚类中心及核宽。

对于测试样本 \mathbf{x}_{test} ，其增强深度特征为

$$\tilde{\mathbf{H}}_{test} = (h_1, h_2, \dots, h_8)^T,$$

其中： h_1, h_2, \dots, h_6 表示深度特征； h_7 和 h_8 表示潜在类别信息。这里说明与第1行相对应的第1个模糊规则：

in rule 1 :

$$\begin{aligned} &\text{if } h_1 \text{ is } \exp\left(\frac{-(h_1 - 57.5348)^2}{2 \times 27.8546}\right) \wedge \\ &h_2 \text{ is } \exp\left(\frac{-(h_2 - 98.2213)^2}{2 \times 53.9427}\right) \wedge \\ &h_3 \text{ is } \exp\left(\frac{-(h_3 - 98.8597)^2}{2 \times 57.2677}\right) \wedge \\ &h_4 \text{ is } \exp\left(\frac{-(h_4 - 99.5494)^2}{2 \times 56.5404}\right) \wedge \\ &h_5 \text{ is } \exp\left(\frac{-(h_5 - 102.6806)^2}{2 \times 54.5038}\right) \wedge \\ &h_6 \text{ is } \exp\left(\frac{-(h_6 - 67.4723)^2}{2 \times 38.1890}\right) \wedge \\ &h_7 \text{ is } \exp\left(\frac{-(h_7 - 0.0196)^2}{2 \times 0.0003}\right) \wedge \\ &h_8 \text{ is } \exp\left(\frac{-(h_8 - 0.9804)^2}{2 \times 0.0003}\right), \end{aligned}$$

then

$$\begin{aligned} \mathbf{y}^1 = &2.1900 \times 10^{-6} + 9.1670 \times 10^{-5} h_1 + \\ &1.4805 \times 10^{-4} h_2 + 2.8400 \times 10^{-6} h_3 - \\ &3.0844 \times 10^{-3} h_4 + 1.3000 \times 10^{-7} h_5 + \\ &2.098010^{-5} h_6 + 1.4663 \times 10^{-2} h_7 + \\ &1.2900 \times 10^{-6} h_8. \end{aligned}$$

3 结论

本文提出了一种基于增强深度特征的TSK模糊分类器ED-TSK-FC并应用于癫痫脑电信号识别。增

强深度特征更加充分利用了1D-CNN的有用信息,提高了ED-TSK-FC的分类性能. 基于模糊规则的高可解释性,ED-TSK-FC对增强深度特征作出了良好的解释. 此外,给出了ED-TSK-FC的廉价训练方法,实验表明该方法在不显著降低分类准确度的情况下,可以缩短整个模型的训练时间.

未来的工作将主要集中在理论和应用方面. 虽然从实验上验证了增强深度特征在分类性能上优于原始数据及深度特征,但是应该设法从理论上加以证明. 此外,该廉价训练方法虽然能够提高模型的学习效率,但是其理论依据并不完整,值得进一步深入探究. 最后,在实际应用中,可以将ED-TSK-FC部署在医疗诊断或交通流预测等实际应用场景中.

参考文献(References)

- [1] Yao J, Wang H, Xiao Z. Correlation between EEG during AED withdrawal and epilepsy recurrence: A meta-analysis[J]. *Neurological Sciences*, 2019, 40(8): 1637-1644.
- [2] Craik A, He Y T, Contreras-Vidal J L. Deep learning for electroencephalogram (EEG) classification tasks: A review[J]. *Journal of Neural Engineering*, 2019, 16(3): 031001.
- [3] Vidyaratne L S, Iftekharruddin K M. Real-time epileptic seizure detection using EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 2017, 25(11): 2146-2156.
- [4] Bhattacharyya A, Pachori R B. A multivariate approach for patient-specific EEG seizure detection using empirical wavelet transform[J]. *IEEE Transactions on Bio-Medical Engineering*, 2017, 64(9): 2003-2015.
- [5] 张进, 李伟, 俞建成, 等. 基于组合分类器的不同状态下脑电信号分类[J]. *控制与决策*, 2019, 34(5): 897-907.
(Zhang J, Li W, Yu J C, et al. Classification of EEG signals in different states based on combined classifier[J]. *Control and Decision*, 2019, 34(5): 897-907.)
- [6] Jiang Y Z, Deng Z H, Chung F L, et al. Recognition of epileptic EEG signals using a novel multiview TSK fuzzy system[J]. *IEEE Transactions on Fuzzy Systems*, 2017, 25(1): 3-20.
- [7] Zhang Y, Liu B, Ji X M, et al. Classification of EEG signals based on autoregressive model and wavelet packet decomposition[J]. *Neural Processing Letters*, 2017, 45(2): 365-378.
- [8] Maddirala A K, Shaik R A. Separation of sources from single-channel EEG signals using independent component analysis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(2): 382-393.
- [9] Siddiqui M K, Islam M Z, Kabir M A. A novel quick seizure detection and localization through brain data mining on ECoG dataset[J]. *Neural Computing and Applications*, 2019, 31(9): 5595-5608.
- [10] Al-Hadeethi H, Abdulla S, Diykh M, et al. Adaptive boost LS-SVM classification approach for time-series signal classification in epileptic seizure diagnosis applications[J]. *Expert Systems with Applications*, 2020, 161: 113676.
- [11] Wu Z F, Shen C H, van den Hengel A. Wider or deeper: Revisiting the ResNet model for visual recognition[J]. *Pattern Recognition*, 2019, 90: 119-133.
- [12] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Honolulu, 2017: 1132-1140.
- [13] Amodei D, Anubhai R, Battenberg E, et al. Deep speech 2: End-to-end speech recognition in English and mandarin[J]. *Proceedings of the 33rd International Conference on International Conference on Machine Learning*, 2016, 48: 173-182.
- [14] Ozcan A R, Erturk S. Seizure prediction in scalp EEG using 3D convolutional neural networks with an image-based approach[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(11): 2284-2293.
- [15] Acharya U R, Oh S L, Hagiwara Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals[J]. *Computers in Biology and Medicine*, 2018, 100: 270-278.
- [16] Hossain M S, Amin S U, Alsulaiman M, et al. Applying deep learning for epilepsy seizure detection and brain mapping visualization[J]. *ACM Transactions on Multimedia Computing, Communications, and Applications: TOMM*, 2019, 15(1s): 1-17.
- [17] 张雄涛, 蒋云良, 胡文军, 等. 并行集成具有高可解释的TSK模糊分类器[J]. *控制与决策*, 2020, 35(10): 2535-2542.
(Zhang X T, Jiang Y L, Hu W J, et al. Ensemble TSK fuzzy classifiers with parallel learning and high interpretability[J]. *Control and Decision*, 2020, 35(10): 2535-2542.)
- [18] Zhang X T, Nojima Y, Ishibuchi H, et al. Prediction by fuzzy clustering and KNN on validation data with parallel ensemble of interpretable TSK fuzzy classifiers[J]. *IEEE Transactions on Systems, Man, and Cybernetics:*

- Systems, 2022, 52(1): 400-414.
- [19] Zhou T, Chung F L, Wang S T. Deep TSK fuzzy classifier with stacked generalization and triplely concise interpretability guarantee for large data[J]. IEEE Transactions on Fuzzy Systems, 2017, 25(5): 1207-1221.
- [20] Zhang Y P, Ishibuchi H, Wang S T. Deep Takagi-sugeno-Kang fuzzy classifier with shared linguistic fuzzy rules[J]. IEEE Transactions on Fuzzy Systems, 2018, 26(3): 1535-1549.
- [21] Jiang B P, Karimi H R, Yang S C, et al. Observer-based adaptive sliding mode control for nonlinear stochastic Markov jump systems via T-S fuzzy modeling: Applications to robot arm model[J]. IEEE Transactions on Industrial Electronics, 2021, 68(1): 466-477.
- [22] Xu P, Deng Z H, Cui C, et al. Concise fuzzy system modeling integrating soft subspace clustering and sparse learning[J]. IEEE Transactions on Fuzzy Systems, 2019, 27(11): 2176-2189.
- [23] Zhang X T, Chung F L, Wang S T. An interpretable fuzzy DBN-based classifier for indoor user movement prediction in ambient assisted living applications[J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 42-53.
- [24] Sevakula R K, Verma N K. Fuzzy rule reduction using sparse auto-encoders[C]. 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). IEEE, 2015: 1-7.
- [25] Tian X B, Deng Z H, Ying W H, et al. Deep multi-view feature learning for EEG-based epileptic seizure detection[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(10): 1962-1972.
- [26] Bezdek J C, Ehrlich R, Full W. FCM: The fuzzy c -means clustering algorithm[J]. Computers & Geosciences, 1984, 10(2/3): 191-203.
- [27] 邓赵红, 张江滨, 蒋亦樟, 等. 基于模糊子空间聚类的0阶岭回归TSK模糊系统[J]. 控制与决策, 2016, 31(5): 882-888.
(Deng Z H, Zhang J B, Jiang Y Z, et al. Fuzzy subspace clustering based 0-order ridge regression TSK fuzzy system[J]. Control and Decision, 2016, 31(5): 882-888.)
- [28] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification[C]. 2015 IEEE International Conference on Computer Vision. Santiago, 2015: 1026-1034.
- [29] Le Cun Y, Touresky D, Hinton G, et al. A theoretical framework for back-propagation[C]. Proceedings of the 1988 Connectionist Models Summer School. Pittsburgh, 1988, 1: 21-28.
- [30] Deng Z H, Choi K S, Chung F L, et al. Scalable TSK fuzzy modeling for very large datasets using minimal-enclosing-ball approximation[J]. IEEE Transactions on Fuzzy Systems, 2011, 19(2): 210-226.
- [31] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [32] 王士同, 钟富礼, 蒋亦樟. 我们还需要前馈神经网络技术吗[J]. 江南大学学报: 自然科学版, 2013, 12(6): 631-636.
(Wang S T, Zhong F L, Jiang Y Z. Feedforward neural networks: Useful or not?[J]. Journal of Jiangnan University: Natural Science Edition, 2013, 12(6): 631-636.)
- [33] Andrzejak R G, Lehnertz K, Mormann F, et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. Physical Review E, Statistical, Nonlinear, and Soft Matter Physics, 2001, 64(6): 061907.
- [34] Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks[J]. Information Processing & Management, 2009, 45(4): 427-437.

作者简介

蒋云良(1967—), 男, 教授, 博士生导师, 从事智能信息处理、GIS等研究, E-mail: jy1@zjhu.edu.cn;

翁江玮(1997—), 男, 硕士生, 从事人工智能与模式识别的研究, E-mail: 347314873@qq.com;

申情(1982—), 女, 副教授, 硕士, 从事软件测试、人工智能等研究, E-mail: sq@zjhu.edu.cn;

胡文军(1977—), 男, 教授, 博士, 从事机器学习、模式识别等研究, E-mail: huwenjun@zjhu.edu.cn;

张雄涛(1984—), 男, 副教授, 博士, 从事人工智能与模式识别、机器学习的研究, E-mail: 1047897965@qq.com.

(责任编辑: 孙艺红)