



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于视角-规则的深度TSK模糊分类器及其在多元癫痫脑电信号识别中的应用

张雄涛, 李水苗, 翁江玮, 胡文军, 蒋云良

引用本文:

张雄涛, 李水苗, 翁江玮, 胡文军, 蒋云良. 基于视角-规则的深度TSK模糊分类器及其在多元癫痫脑电信号识别中的应用[J]. **控制与决策**, 2024, 39(4): 1315–1324.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1305>

您可能感兴趣的其他文章

Articles you may be interested in

[基于共享隐空间的多视角SVM](#)

Multi view SVM based on common hidden space

控制与决策. 2021, 36(3): 534–542 <https://doi.org/10.13195/j.kzyjc.2019.0829>

[融合稀疏编码与深度学习的草图特征表示](#)

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

[基于改进卷积神经网络的动力下肢假肢运动意图识别](#)

Intent recognition of power lower-limb prosthesis based on improved convolutional neural network

控制与决策. 2021, 36(12): 3031–3038 <https://doi.org/10.13195/j.kzyjc.2020.0326>

[结合注意力机制的循环神经网络复述识别模型](#)

Recurrent neural networks based paraphrase identification model combined with attention mechanism

控制与决策. 2021, 36(1): 152–158 <https://doi.org/10.13195/j.kzyjc.2019.0638>

[基于数据分布特性的代价敏感宽度学习系统](#)

Data distribution-based cost-sensitive broad learning system

控制与决策. 2021, 36(7): 1686–1692 <https://doi.org/10.13195/j.kzyjc.2019.1484>

基于视角-规则的深度 TSK 模糊分类器及其在多元癫痫脑电信号识别中的应用

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

(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. 浙江师范大学 计算机科学与技术学院, 浙江 金华 321004)

摘要: 在癫痫脑电信号分类检测中,传统机器学习方法分类效果不理想,深度学习模型虽然具有较好的特征学习优势,但其“黑盒”学习方式不具备可解释性,不能很好地应用于临床辅助诊断;并且,现有的多视角深度 TSK 模糊系统难以有效表征各视角特征之间的相关性.针对以上问题,提出一种基于视角-规则的深度 Takagi-Sugeno-Kang (TSK) 模糊分类器 (view-to-rule Takagi-Sugeno-Kang fuzzy classifier, VR-TSK-FC),并将其应用于多元癫痫脑电信号检测中.该算法在原始数据上构建前件规则以保证模型的可解释性,利用一维卷积神经网络 (1-dimensional convolutional neural network, 1D-CNN) 从多角度抓取多元脑电信号深度特征.每个模糊规则的后件部分分别采用一个视角的脑电信号深度特征作为其后件变量,视角-规则的学习方式提高了 VR-TSK-FC 表征能力.在 Bonn 和 CHB-MIT 数据集上,VR-TSK-FC 算法模糊逻辑推理过程保证可解释的基础上达到了较好分类效果.

关键词: TSK 模糊分类器; 多视角深度特征; 视角-规则; 癫痫脑电信号检测; 可解释性

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1305

引用格式: 张雄涛,李水苗,翁江玮,等.基于视角-规则的深度 TSK 模糊分类器及其在多元癫痫脑电信号识别中的应用[J].控制与决策,2024,39(4):1315-1324.

Recognition of multivariate epilepsy EEG signals based on view-to-rule deep TSK fuzzy classifier

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

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China; 2. Zhejiang Province Key Laboratory of Smart Management and Application of Modern Agricultural Resources, Huzhou 313000, China; 3. School of Computer Science and Technology, Zhejiang Normal University, Jinhua 321004, China)

Abstract: Traditional machine learning methods perform poorly in classification and detection epilepsy electroencephalogram (EEG) signals, while the state-of-the-art deep learning models show excellent predictive performance due to their powerful feature abstraction capabilities, but their behavior is black-box, leading to uninterpretable and not well suited for clinical diagnosis. Moreover, the existing multi-view deep TSK fuzzy system is difficult to effectively represent the correlation between the features of each view. To address the problems above, in this paper, we propose a view-to-rule deep TSK fuzzy classifier, i.e., VR-TSK-FC, and apply it to multivariate epilepsy EEG signal detection. The proposed classifier constructs antecedent-part of fuzzy rules on the original data to ensure interpretability, and the one-dimensional convolutional neural network (1D-CNN) learns deep features of multivariate EEG signals from multi-view. The consequent-part of each fuzzy rule adopts the EEG signal deep feature of each view as its consequent-part variable, and the fuzzy-deep view-to-rule learning method improves the representation ability of the proposed VR-TSK-FC. Experiments on the Bonn and CHB-MIT datasets demonstrate that, the fuzzy logic inference process of the proposed VR-TSK-FC achieves better classification results as well as concise interpretability.

Keywords: Takagi-Sugeno-Kang (TSK) fuzzy classifier; multi-view deep features; view-to-rule; epileptic EEG signal detection; interpretability

收稿日期: 2022-07-21; 录用日期: 2022-12-08.

基金项目: 国家自然科学基金区域创新发展联合基金项目 (U22A201856).

责任编辑: 侯忠生.

†通讯作者. E-mail: jyl@zjhu.edu.cn.

0 引言

随着多通道脑电信号采集系统的广泛临床应用,海量的脑电信号数据被用于疾病检测. 诸如癫痫发作期短, 发作间期长^[1], 多元脑电信号数据冗长且易受干扰, 需要医生具备丰富经验. 针对多元脑电信号的研究引起了广泛关注^[2], 例如支持向量机 (support vector machine, SVM)^[3]、决策树 (decision tree, DT)^[4]、朴素贝叶斯 (naive bayes, NB)^[5] 等一系列方法被应用于多元信号分析. 多元脑电信号数据处理步骤如文献 [6-7] 所述: 首先提取可以表征脑电信号的特征信息, 然后对提取的特征进行分类. 提取有效特征对于分类准确性有至关重要的影响^[8]. 但是, 在对多元脑电信号的研究中, 传统机器学习方法难以表征复杂的 EEG (electroencephalogram) 数据.

深度学习以显著的特征提取优势被广泛应用于各领域. 如文献 [9] 提出了基于深度卷积神经网络和深度残差学习的疲劳驾驶检测方法, 通过对驾驶员的脑电信号进行分析, 预测其驾驶状态. 有研究进一步探索了深度学习从多角度表征多元脑电信号^[10-13]. 文献 [14] 提出了堆叠一维卷积神经网络 (stacked 1D-CNN), 通过拼接两个不同结构 1D-CNN 提取的深度特征进行癫痫分类, 实验验证了堆叠 1D-CNN 可以提升模型特征提取性能. 同时, 文献 [15] 针对单视角学习易于忽视脑电信号的多元结构信息问题, 提出了基于多视角学习的深度多元表征方法用于癫痫发作检测. 深度神经网络基于强大学习能力所计算的结果可以与人类专家相媲美, 被广泛用于表征数据深度特征^[16-18]. 但是, 深度学习一直被模型结果的可解释性问题所困扰, “黑盒”式学习过程使医生患者难以理解其检测结果.

癫痫患者脑部神经元在异常放电时, 脑电图会呈现不同形态和不同时间的异常波形, 医生将根据一个区间模糊值判断是否为癫痫发作. TSK 模糊分类器正是由模糊值构建规则, 模糊逻辑推理学习使其具有天然可解释性以及强大非线性逼近能力^[9], 因而被广泛应用于医学领域^[20-22]. 有研究将模糊逻辑系统和深度学习相结合, 如文献 [23] 提出基于 TSK 的卷积递归模糊网络用于疲劳驾驶检测, 将模糊网络作为主干网络, 以局部反馈方式捕获时间依赖性. 文献 [24] 提出了基于 Hebbian 学习和二型 TSK 模糊逻辑构建的深度脑学习网络 (deep brain leaning Network, DBLN), 用于脑电信号特征中记忆退化的研究. 文献 [25] 提出将 1D-CNN 提取的深度特征和潜在类别信息相结合, 用于构建模糊规则前件和后件部

分, 使模型分类性能显著提升, 但基于深度特征构建规则而非原始数据, 在一定程度上削弱了模型的可解释性. 以上基于深度学习的 TSK 模糊分类器, 缓解了处理高维度复杂数据时面临的维度爆炸问题, 然而由单一视角学习具有非线性、非平稳且复杂的 EEG 信号时, 不能较好地多角度表征数据.

多角度学习有效地利用每个视角的特征信息, 相较于单视角深度 TSK 模型具有更好的建模效果. 文献 [26] 使用快速傅里叶变换和小波包分解分别提取频域和时频域浅层特征, 利用卷积神经网络学习其深度特征, 融合浅层和深度特征由 TSK 模糊系统进行癫痫发作检测. 文献 [27] 提出了多视角深度 TSK 模糊系统, 原始脑电信号由不同特征提取方法生成新的多视角深度特征数据集, 并将其作为输入数据通过 TSK 模糊算法实现分类. 文献 [28] 提出 EEG 脑电信号由不同的数据处理方法分别获得时域、频域、时频域数据, 经深度网络降维之后生成的多视角特征, 作为基于多视角学习的 TSK 模糊分类器 (MV-TSK-FS) 的输入, 以实现癫痫脑电信号分类. 以上基于视角和规则的深度模糊分类算法, 构建的模糊规则前件变量都是采用统一的视角特征, 未能充分利用同一数据不同视角间的相关性.

综上, 针对癫痫脑电信号深度学习模型 “黑盒” 检测问题, 以及现有多视角深度 TSK 模糊系统难以有效表征 EEG 数据各视角间的相关性, 本文提出一种新的基于视角-规则的深度 TSK 模糊算法 (VR-TSK-FC) 用于多元癫痫脑电信号分类. 该算法在原始数据上由模糊聚类算法 (fuzzy C-means, FCM) 构建模糊规则前件, 不同结构 1D-CNN 提取多角度互补特征, 每个规则的后件部分采用不同视角深度特征和岭回归极限学习优化算法求解后件参数.

本文的主要贡献如下:

1) 本文提出了一种新型 TSK 模糊分类器, 每个模糊规则的后件变量采用一个视角的深度特征. 基于视角-规则的深度 TSK 模糊分类器学习方式不同于传统 TSK 算法, 即 M 条模糊规则的后件变量采用 M 个视角的深度特征, 充分利用每个视角的独立性和不同视角间相关性, 有效表征了多元癫痫脑电信号. 该算法构建方式更具鲁棒性, 提升了分类性能.

2) 从多角度并行抓取多元脑电信号有效特征, 并将其分别作为模糊规则后件变量, 解决了传统 TSK 模糊分类器采用原始数据单一视角的特征局限问题, 可以更好地表征多元数据. 该算法在原始数据上构建模糊规则前件保证了分类结果的可解释性, 更小维

数的深度特征作为后件变量,降低了过拟合概率.

3) 在 Bonn 和 CHB-MIT 数据集进行了大量对比实验,验证了该算法在多元脑电信号分类检测中具有更好的性能. 本文对比了不同视角数对其分类效果的影响,实验表明增加视角数量可以提升准确率,但增加视角的数量存在一定阈值.

1 VR-TSK-FC

1.1 VR-TSK-FC模型结构

本文提出基于视角-规则的深度 TSK 模糊分类器,应用于癫痫多元脑电信号分类检测. 图 1 为 VR-TSK-FC 模型结构,其中 (a) 是多视角并行深度学习,由多个不同结构的 1D-CNN 提取癫痫脑电信号多视

角深度特征,即 $\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T$ 分别在第 τ_1 个视角下提取深度特征 $\mathbf{h}_i^{\tau_1} = (h_1^{\tau_1}, h_2^{\tau_1}, \dots, h_\alpha^{\tau_1})^T$, 第 τ_m 个视角下 $\mathbf{h}_i^{\tau_m} = (h_1^{\tau_m}, h_2^{\tau_m}, \dots, h_\beta^{\tau_m})^T$, 通过 τ_M 个视角获得深度特征 $\mathbf{H}_i = (\mathbf{h}_i^{\tau_1}, \dots, \mathbf{h}_i^{\tau_m}, \dots, \mathbf{h}_i^{\tau_M})$. (b) 是基于模糊规则的知识推理,首先对原始数据 $\{\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T\}_{i=1}^N$ 和标签 $\{z_i\}_{i=1}^N$ 构建可解性模糊表达,其中 d 为样本维度, N 为样本个数. 模糊规则层由 FCM 模糊聚类得到规则前件变量,将 τ_M 个 1D-CNN 的第 1 个全连接层的深度特征 \mathbf{H}_i 作为后件变量,每条模糊规则的后件变量采用一个视角的深度特征,使模糊规则与视角一一对应. 接下来将介绍 VR-TSK-FC 模型实现的具体过程.

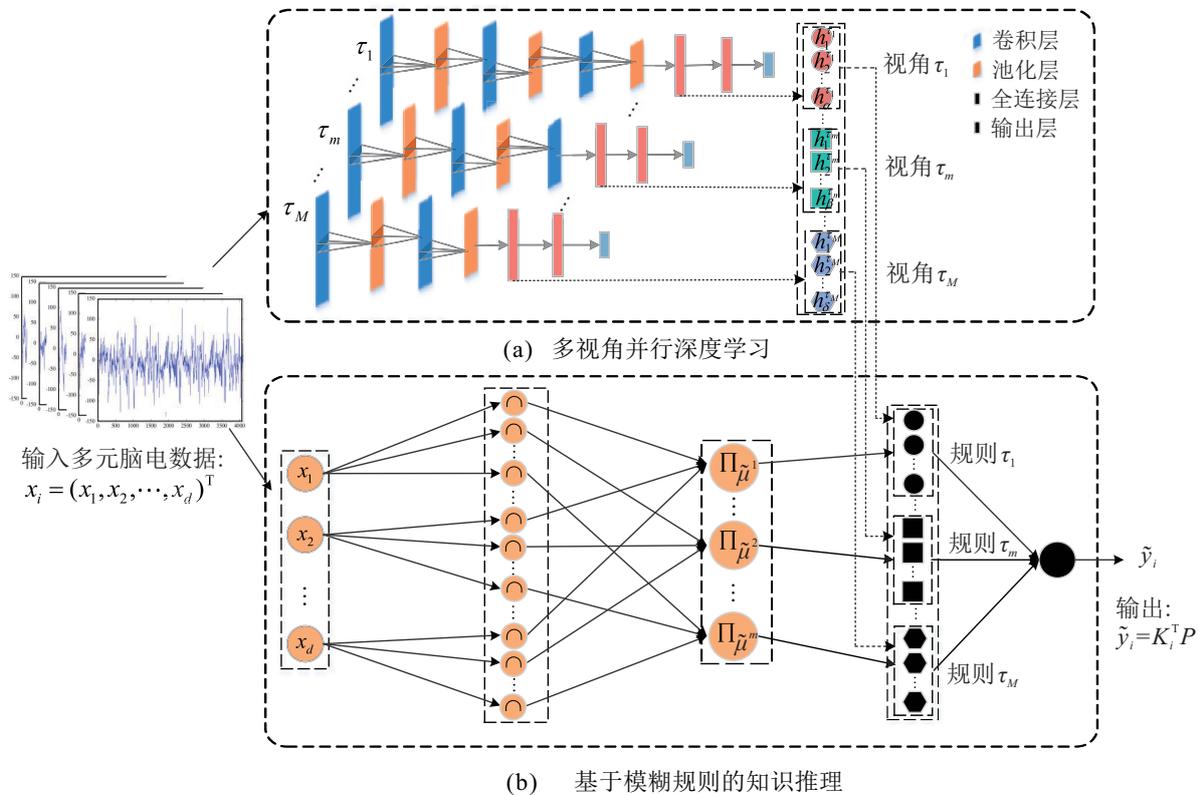


图 1 VR-TSK-FC 模型结构

1.1.1 VR-TSK-FC 多视角并行深度学习

VR-TSK-FC 通过 τ_M 个 1D-CNN 并行学习多角度提取深度特征,如图 1(a) 中每个 1D-CNN 的卷积层、池化层,其结构和参数不同. 根据文献 [29], 不同结构的 CNN 可以提取到不同深度特征表达,例如: 浅层 1D-CNN 提取简单特征, 深层 1D-CNN 提取高级语义特征. 接下来将以 VR-TSK-FC 中的一个视角为例介绍特征提取过程.

1D-CNN 在对数据 $\{\mathbf{x}_i\}_{i=1}^N$ 前向传播计算过程中, 随机初始化权重 \mathbf{W}_0 和偏置 \mathbf{b}_0 , 对输入数据 \mathbf{x}_i 做卷积计算. 通过 PReLU (parametric rectified linear unit)

激活函数计算第 l 层的特征图, \mathbf{H}_0 为原始输入数据 \mathbf{x} , 其计算过程为

$$\mathbf{H}_l = f(\mathbf{W}_l \mathbf{H}_{l-1} + \mathbf{b}_l). \quad (1)$$

VR-TSK-FC 的部分 1D-CNN 中加入批归一化 (batch normalization, BN) 以解决内部协同变量偏移问题 [30] (internal covariate shift, ICS), 减少对数据初始值的依赖, 加速 1D-CNN 收敛. 采用 PReLU 激活函数进行非线性计算, 相较于 ReLU (rectified linear unit) 函数, 在 PReLU 函数的左侧加入小的常量值, 从而保留了一部分神经元. 池化层采用最大池化, 选择感受野所覆盖区域特征最大值. 数据经过卷积层、池化层和

激活函数映射到隐层特征空间,由softmax函数转化为检测类别的概率值.

在第 γ 轮迭代中,由误差反向传播更新 \mathbf{W}_l 和 \mathbf{b}_l ,即

$$\mathbf{W}_l^\gamma = \mathbf{W}_l^{\gamma-1} - \kappa \Delta \mathbf{W}_l^{\gamma-1}, \quad (2)$$

$$\mathbf{b}_l^\gamma = \mathbf{b}_l^{\gamma-1} - \kappa \Delta \mathbf{b}_l^{\gamma-1}. \quad (3)$$

其中: κ 为学习率, $\Delta \mathbf{w}_l^{\gamma-1}$ 和 $\Delta \mathbf{b}_l^{\gamma-1}$ 分别代表 \mathbf{W}_l 和 \mathbf{b}_l 的偏导数.反向传播迭代训练拟合参数直至交叉熵损失函数收敛,多视角1D-CNN提取表征癫痫脑电信号的深度特征 $\mathbf{H}_i = \{(h_1^{\tau_1}, h_2^{\tau_1}, \dots, h_\alpha^{\tau_1})^T, \dots, (h_1^{\tau_m}, h_2^{\tau_m}, \dots, h_\beta^{\tau_m})^T, \dots, (h_1^{\tau_M}, h_2^{\tau_M}, \dots, h_\delta^{\tau_M})^T\}$.

1.1.2 VR-TSK-FC模糊规则构建

多元癫痫脑电信号经过滤波降噪等处理后作为输入数据,由模糊逻辑学习构建规则, τ_M 个1D-CNN提取的深度特征作为VR-TSK-FC后件变量,使一个模糊规则对应一个视角的深度特征.VR-TSK-FC的第1、第 m 、第 M 条规则如下:

In rule 1 :

If $(x_1 \text{ is } \mathbf{A}_{11}) \wedge (x_2 \text{ is } \mathbf{A}_{12}) \wedge \dots \wedge (x_d \text{ is } \mathbf{A}_{1d})$,

Then $y_1 = p_{10} + p_{11}h_1^{\tau_1} + p_{12}h_2^{\tau_1} + \dots + p_{1\alpha}h_\alpha^{\tau_1}$; (4)

In rule m :

If $(x_1 \text{ is } \mathbf{A}_{m1}) \wedge (x_2 \text{ is } \mathbf{A}_{m2}) \wedge \dots \wedge (x_d \text{ is } \mathbf{A}_{md})$,

Then

$y_m = p_{m0} + p_{m1}h_1^{\tau_m} + p_{m2}h_2^{\tau_m} + \dots + p_{m\beta}h_\beta^{\tau_m}$; (5)

In rule M :

If $(x_1 \text{ is } \mathbf{A}_{M1}) \wedge (x_2 \text{ is } \mathbf{A}_{M2}) \wedge \dots \wedge (x_d \text{ is } \mathbf{A}_{Md})$,

Then

$y_M = p_{M0} + p_{M1}h_1^{\tau_M} + p_{M2}h_2^{\tau_M} + \dots + p_{M\delta}h_\delta^{\tau_M}$. (6)

其中: $m \geq 2$; M 为模糊规则总数; \mathbf{A}_{md} 表示在第 m 条模糊规则下,输入癫痫脑电信号数据 $\mathbf{x}_i = (x_1, x_2, \dots, x_d)^T$ 的第 d 维特征所对应的模糊子集; $p_{m\beta}$ 表示第 m 条模糊规则中第 β 个后件参数; y_m 是第 m 条模糊规则的输出; \wedge 表示模糊合取操作.模糊规则隶属度计算如下:

$$\mu_{\mathbf{A}_{mj}}(x_{ij}) = \exp\left(-\frac{(x_{ij} - c_j^m)^2}{2\sigma_j^m}\right). \quad (7)$$

其中: x_{ij} 为输入样本 \mathbf{x}_i 的第 j 个特征; c_j^m 为FCM聚类中心点;核宽 σ_j^m 计算如下:

$$\sigma_j^m = \frac{\varepsilon \sum_{i=1}^N u_i^m (x_{ij} - c_j^m)}{\sum_{i=1}^N u_i^m}, \quad (8)$$

ε 为尺度参数, u_i^m 属于第 m 个中心点的模糊隶属度.

通过以上计算得到VR-TSK-FC的前件变量,多视角深度特征作为后件变量,对输入癫痫脑电信号数据VR-TSK-FC模糊系统的输出为

$$\tilde{y}_i = \sum_{m=1}^M \tilde{\mu}^m(\mathbf{x}_i) y_m. \quad (9)$$

其中: $\tilde{\mu}^m(\mathbf{x}_i)$ 为隶属度归一化结果, y_m 为式(5)中一阶线性函数.

VR-TSK-FC参数表达成矩阵形式为

$$\mathbf{p}_m = (p_{m0}, p_{m1}, p_{m2}, \dots, p_{m\beta})^T, \quad (10)$$

$$\mathbf{P} = ((\mathbf{p}_1)^T, \dots, (\mathbf{p}_m)^T, \dots, (\mathbf{p}_M)^T)^T, \quad (11)$$

$$\mathbf{h}_i^{\tau_m} = (h_1^{\tau_m}, h_2^{\tau_m}, \dots, h_\beta^{\tau_m})^T, \quad (12)$$

$$\mathbf{H}_i = (\mathbf{h}_i^{\tau_1}, \dots, \mathbf{h}_i^{\tau_m}, \dots, \mathbf{h}_i^{\tau_M}), \quad (13)$$

$$\mathbf{k}_i^m = \tilde{\mu}^m(\mathbf{x}_i) (1, (\mathbf{h}_i^{\tau_m})^T)^T, \quad (14)$$

$$\mathbf{K}_i = ((\mathbf{k}_i^1})^T, \dots, (\mathbf{k}_i^m)^T, \dots, (\mathbf{k}_i^M)^T)^T. \quad (15)$$

式(10)中,第 m 条规则后件参数表示为 \mathbf{p}_m , M 个规则后件参数表示为 \mathbf{P} .式(12)中 $\mathbf{h}_i^{\tau_m}$ 是第 i 个样本通过第 τ_m 个1D-CNN提取得到的深度特征,将其作为VR-TSK-FC第 m 条模糊规则的后件变量, M 个视角提取的深度特征表示为 \mathbf{H}_i .VR-TSK-FC已知参数表示为 \mathbf{K}_i .综上,将VR-TSK-FC输出转化为如下线性回归问题:

$$\tilde{y}_i = \mathbf{K}_i^T \mathbf{P}. \quad (16)$$

后件参数使用岭回归极限学习算法^[31]求解,对训练数据集 $\{\mathbf{x}_i, z_i\}_{i=1}^N$, $\mathbf{x}_i \in R^d$, $z_i \in R$,构建VR-TSK-FC优化目标函数

$$\min_{\mathbf{P}} \frac{1}{2} \|\mathbf{K}\mathbf{P} - \mathbf{Z}\|^2 + \frac{\lambda}{2} \|\mathbf{P}\|^2. \quad (17)$$

其中: λ 为岭回归参数, $\mathbf{K} = (\mathbf{K}_1, \mathbf{K}_2, \dots, \mathbf{K}_N)^T$, $\mathbf{Z} = (z_1, z_2, \dots, z_N)^T$.后件参数 \mathbf{P} 求解为

$$\mathbf{P} = (\mathbf{K}^T \mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{K}^T \mathbf{Z}. \quad (18)$$

至此,VR-TSK-FC模糊深度学习求解过程结束.

1.2 VR-TSK-FC深度学习算法

VR-TSK-FC算法包括训练过程和测试过程,其中 τ_M 个1D-CNN并行学习,不同视角独立更新参数.VR-TSK-FC算法首先由不同1D-CNN迭代学习多角度深度特征;然后原始数据通过FCM算法构建模糊前件规则,由高斯函数计算隶属度,将多视角深度特

征作为后件变量;最后对目标函数通过岭回归极限学习优化算法求解后件参数. VR-TSK-FC算法具体实现步骤如下.

step 1: VR-TSK-FC多视角并行深度学习.

step 1.1: 将数据 $\{\mathbf{x}_i\}_{i=1}^N$ 以及标签 $\{z_i\}_{i=1}^N$ 划分为训练集、测试集, 设置1D-CNN最大迭代次数 γ_1 ;

step 1.2: τ_M 个1D-CNN并行学习根据式(1)执行卷积操作, 由最大池化选择显著特征;

step 1.3: 计算全连接层并采用 PReLU 激活函数;

step 1.4: 由 softmax 函数计算所属类别概率;

step 1.5: 每个视角1D-CNN损失变量不同, 由交叉熵函数计算各视角预测输出 \tilde{y}_i 与标签 z_i 误差;

step 1.6: 误差反向传播计算由式(2)和(3)更新各视角权重 \mathbf{W}_l 和偏置 \mathbf{b}_l ;

step 1.7: 提取多视角1D-CNN在第1层全连接层的深度特征 $\mathbf{H}_i = (\mathbf{h}_i^{\tau_1}, \dots, \mathbf{h}_i^{\tau_m}, \dots, \mathbf{h}_i^{\tau_M})$;

step 1.8: 直至不符合 $\gamma < \gamma_1$ 迭代条件循环结束.

step 2: VR-TSK-FC模糊规则构建.

step 2.1: 设置规模数 M , 尺度参数 ε , 岭回归参数 λ ;

step 2.2: 训练数据 \mathbf{x}_i 由 FCM 算法计算中心点 c_j^m , 并由式(8)计算核宽 σ_j^m ;

step 2.3: 根据式(7)计算各个模糊规则隶属度, 对其归一化得到 $\tilde{\mu}^m(\mathbf{x}_i)$;

step 2.4: 将 $\mathbf{H}_i = (\mathbf{h}_i^{\tau_1}, \dots, \mathbf{h}_i^{\tau_m}, \dots, \mathbf{h}_i^{\tau_M})$ 作为后件变量, 根据式(14)计算 \mathbf{k}_i^m , 由式(15)构建 \mathbf{K}_i ;

step 2.5: 给定标签 $\mathbf{Z} = (z_1, z_2, \dots, z_N)^T$, 由岭回归极限学习算法求解式(18)中后件参数 \mathbf{P} ;

step 2.6: 测试数据由 FCM 算法计算中心点, 式(7)和(8)计算测试数据的核宽和各个规则隶属度;

step 2.7: 测试数据由式(14)和(15)构建 \mathbf{K} ;

step 2.8: 由式(16)得到预测输出 \tilde{y} .

VR-TSK-FC算法时间复杂度包括两部分. 多视角并行深度学习部分(如图1(a))由 τ_M 个1D-CNN并行训练, 因此其时间复杂度由最复杂1D-CNN网络决定, 即 $O\left(\gamma_1 \left(\sum_{l=1}^L C_{l-1} \times w_l \times C_l \times D_l\right)\right)$, 其中 L 为 τ_M 个1D-CNN网络最大深度, γ_1 为1D-CNN的迭代次数, C_l 为第 l 卷积层的卷积核个数, w_l 为卷积核尺寸, D_l 为特征图的维度. 基于模糊规则的知识推理部分(如图1(b))包括FCM算法模糊聚类构建规则, 以及岭回归极限学习算法求解后件参数. FCM的时间复杂度为 $O(\gamma_2 NdM^2 + NdM)$. 其中: γ_2 为FCM最大迭代次数, N 为样本数, M 为模糊聚类个数, d 为样本维度. VR-TSK-FC算法的后件变量由不同维度的多视

角深度特征构成. 为方便计算岭回归极限学习求解的时间复杂度, 取多视角深度特征的最大维度 $\phi = \max\{\alpha, \dots, \beta, \dots, \delta\}$. 岭回归极限学习求解的时间复杂度为 $O(N\phi^2 + \phi^3)$, 因此VR-TSK-FC总时间复杂度为 $O\left(\gamma_1 \left(\sum_{l=1}^L C_{l-1} \times w_l \times C_l \times D_l\right) + NdM(\gamma_2 M + 1) + N\phi^2 + \phi^3\right)$.

2 实验研究

为验证VR-TSK-FC模型的有效性, 选用波士顿儿童医院-麻省理工学院的CHB-MIT数据集和波恩大学在UCI公布的Bonn数据集进行实验. 平台为AMD Ryzen 5 3400 3.7GHz 32G RAM 64-bit Microsoft Windows 10, 编程环境为Python 3.8 with Torch 1.6.0 + CPU.

2.1 数据集介绍

Bonn数据集^[32]是德国波恩大学公开可用的基准数据集, 是癫痫病脑电图信号分类领域应用最为广泛的数据集之一. Bonn数据集包含5个脑电信号子集: A、B、C、D和E. 该数据采用标准的10-20电极放置系统进行采集, 采样频率为173.61 Hz. 在该数据集中, 每个子集包含100个23.6s的信号, 2300条数据, 每条数据有178个特征维度. 其中数据集A和数据集B由正常脑电信号组成, 数据集C和数据集D是发作间期脑电信号, 数据集E为癫痫患者疾病发作期间收集的脑电信号, 如表1所示.

表1 Bonn数据集

子集	数据表述	电极类型
Set A	健康志愿者睁眼EEG	头皮表面
Set B	健康志愿者闭眼EEG	头皮表面
Set C	相反半球海马体EEG	颅内
Set D	致痫区发作间期EEG	颅内
Set E	癫痫发作EEG	颅内

表2中对Bonn数据进行划分, 列出了4种在临床研究中具有重要意义和价值的分类任务, 用于测试VR-TSK-FC算法在癫痫疾病检测中的分类性能.

表2 Bonn数据集划分

数据集	EEG子集	临床任务
Dataset 1	D vs E	发作间期 vs 发作期
Dataset 2	C vs E	发作间期 vs 发作期
Dataset 3	C, D vs E	发作间期 vs 发作期
Dataset 4	A, B vs E	正常 vs 发作期

CHB-MIT数据集^[33]有23位患者, 共24个子集, 分别记为CHB 01~CHB 24(其中记为CHB 01的患者间隔1.5年记录了第2次癫痫检测数据CHB 21). 数

据由256 Hz采样频率的10-20电极放置法捕获,有23个通道的916h头皮脑电信号记录,共198次癫痫发作.从CHB-MIT数据集中选用了CHB 01~CHB 05作为此次实验数据,每个子集的样本数不同,每条数据有 23×53 个特征维度.

1D-CNN的结构参数设置和视角个数通过试错的方式确定.根据文献[34]的研究结果,即在对脑电信号处理中,由4个卷积层构建的CNN模型分类效

果优于ResNet 50等深层网络,因此本文所构建的1D-CNN卷积层数均不大于4.为了保证VR-TSK-FC的多视角1D-CNN深度学习模块能够提取到多元癫痫脑电信号的不同特征信息,每个1D-CNN的步长值、卷积核、填充值以及全连接层的神经元个数均不同,限于篇幅,表3中以Bonn数据集为例列出了部分1D-CNN模型每层参数的设置.其中Conv为卷积层,BN为批归一化层,MP为最大池化层,Dense为全连接层.

表3 Bonn数据在部分1D-CNN的参数设置

网络层	CNN 1			网络层	CNN 2			网络层	CNN 3		
	维度	特征图	卷积核(步长)		维度	特征图	卷积核(步长)		维度	特征图	卷积核(步长)
输入层	1×178	—	—	输入层	1×178	—	—	输入层	1×178	—	—
Conv	1×89	32	$1 \times 3(2)$	Conv	1×86	16	$1 \times 4(1)$	Conv	1×178	64	$1 \times 3(1)$
BN+MP	1×44	32	$1 \times 2(2)$	BN+MP	1×83	16	$1 \times 2(2)$	MP	1×89	64	$1 \times 2(2)$
Conv	1×22	16	$1 \times 3(2)$	Conv	1×42	8	$1 \times 4(1)$	Conv	1×89	32	$1 \times 3(1)$
MP	1×11	16	$1 \times 2(2)$	MP	1×20	8	$1 \times 2(2)$	MP	1×44	32	$1 \times 2(2)$
Conv	1×6	1	$1 \times 3(2)$	Conv	1×11	1	$1 \times 4(2)$	Conv	1×44	16	$1 \times 3(2)$
Dense	6	—	—	MP	1×6	1	$1 \times 2(2)$	MP	1×22	16	$1 \times 2(2)$
Dense	5	—	—	Dense	10	—	—	Conv	1×22	1	$1 \times 3(1)$
输出层	2	—	—	Dense	10	—	—	MP	1×11	1	$1 \times 2(2)$
				输出层	2	—	—	Dense	11	—	—
								Dense	11	—	—
								输出层	2	—	—

2.2 性能评价指标

为评估VR-TSK-FC模型性能,通过Accuracy(ACC)和F-Measure(F_1)对实验结果有效性进行衡量分析,其公式如下所示:

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \times 100\%, \quad (19)$$

$$P = \frac{TP}{TP + FP}, \quad (20)$$

$$R = \frac{TP}{TP + FN}, \quad (21)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \times 100\%. \quad (22)$$

其中:数据分类结果有4种可能,分别为真阳性(true positive, TP),即癫痫样本被正确检测;真阴性(true negative, TN),即健康样本被正确检测;假阳性(false positive, FP),即被误检为癫痫的样本;假阴性(false negative, FN),即被误检为健康的样本; P (Precision)为精确率, R (Recall)为召回率.

2.3 实验设置

为验证VR-TSK-FC模型分类性能,将其与传统分类算法和深度学习模型进行对比实验,包括:

1)3种机器学习算法:决策树(DT)算法^[4],贝叶斯(NB)算法^[5], K 近邻(K -nearest neighbor, KNN)算

法^[35];

2)两种深度学习模型:一维卷积神经网络(1D-CNN)^[9],深度信念网络(deep belief network, DBN)^[20];

3)两种传统TSK模糊分类算法:基于原始数据的TSK算法^[27],由主成分分析(PCA)降维的PAC-TSK算法;

4)两种后件变量采用1D-CNN深度特征的TSK算法:由1个1D-CNN提取的深度特征作为TSK后件变量的SDF-TSK(single deep feature TSK)算法,由多视角深度特征拼接共同作为TSK后件变量的MDFC-TSK(multiple deep feature connection TSK)算法.

对比实验中,DT算法最大深度寻优范围 $t = \{4, 5, \dots, 8\}$,KNN算法邻居数寻优范围 $k = \{3, 5, 7\}$.NB算法采用默认参数,DBN中原始数据实施归一化处理.1D-CNN对比实验结果选自VR-TSK-FC的一个视角.PCA-TSK、TSK、SDF-TSK、MDFC-TSK算法均为1阶TSK,可调参数均同VR-TSK-FC.PCA-TSK算法降维维度寻优范围 $n = \{60, 70, \dots, 120\}$,VR-TSK-FC中视角数量寻优范围 $\tau_M = \{2, 3, \dots, 7\}$,模糊规则数寻优范围 $M = \{2, 3, \dots, 10\}$.FCM聚类的尺度参数寻优范围 $\varepsilon = \{2^{-6}, 2^{-5}, \dots, 2^2\}$.岭回归极

限学习优化算法求解时参数寻优范围 $\lambda = \{10^{-3}, 10^{-2}, \dots, 10^2\}$. Bonn 与 CHB-MIT 数据集对比实验可调参数寻优设置相同.

2.4 实验结果与分析

在癫痫脑电信号数据集 Bonn 和 CHB-MIT 上, 通过 ACC 和 F_1 值评估 VR-TSK-FC 算法性能. 实验得出: 联合 5 个视角提取的多元脑电信号深度特征使 VR-TSK-FC 算法分类效果最优. 表 4 和表 5 的实验结果表明: VR-TSK-FC 癫痫发作检测分类效果优于 DT、

KNN、NB、PCA-TSK、TSK、SDF-TSK. VR-TSK-FC 算法在 Bonn 的 4 个子集上 ACC 值分别达到 95.65%、97.39%、95.58%、97.89%, VR-TSK-FC 在 Dataset 2 和 Dataset 4 表现最佳. 在表 6 和表 7 中, VR-TSK-FC 算法在 CHB-MIT 的 5 个子集上 ACC 值分别达到 99.07%、98.09%、98.13%、94.05%、98.98%, 在 CHB 04 数据集上分类性能略差于 DBN, 在 CHB 05 数据集上与 1D-CNN F_1 值持平, VR-TSK-FC 相较于其他算法在个体癫痫发作检测中有明显优势.

表 4 Bonn 数据集上各方法 Accuracy 值

数据集	DT	KNN	NB	DBN	CNN	PCA-TSK	TSK	SDF-TSK	MDFC-TSK	VR-TSK-FC
Dataset 1	84.95	90.65	88.08	92.95	95.21	91.19	91.47	93.15	94.56	95.65
Dataset 2	87.21	91.85	95.39	95.56	96.08	95.54	92.95	95.97	96.84	97.39
Dataset 3	87.88	94.78	93.15	92.98	95.32	95.5	94.26	92.83	94.46	95.58
Dataset 4	88.41	90.43	96.34	97.04	96.73	96.23	96.57	96.52	97.02	97.89

表 5 Bonn 数据集上各方法 F_1 -Measure 值

数据集	DT	KNN	NB	DBN	CNN	PCA-TSK	TSK	SDF-TSK	MDFC-TSK	VR-TSK-FC
Dataset 1	84.64	90.16	87.26	92.83	95.47	91.39	93.3	93.31	94.74	95.76
Dataset 2	86.27	91.64	95.82	95.58	96.12	95.66	92.11	96.11	96.83	97.37
Dataset 3	80.66	91.51	90.79	88.72	93.67	92.79	91.47	89.97	94.67	93.13
Dataset 4	81.48	83.33	94.35	95.45	95.57	94.31	94.86	94.59	95.43	96.57

表 6 CHB-MIT 数据集上各方法 Accuracy 值

数据集	DT	KNN	NB	DBN	CNN	PCA-TSK	TSK	SDF-TSK	MDFC-TSK	VR-TSK-FC
CHB 01	95.72	98.51	95.72	97.39	98.14	97.58	97.02	97.58	98.32	99.07
CHB 02	97.13	94.26	94.26	97.21	95.69	95.69	96.17	96.65	97.61	98.09
CHB 03	95.84	97.30	95.43	96.46	97.51	96.26	96.47	94.80	97.92	98.13
CHB 04	91.50	91.08	91.65	95.11	93.84	91.51	90.45	90.23	92.36	94.05
CHB 05	97.37	97.07	97.80	98.38	98.10	97.80	97.22	97.51	97.66	98.98

表 7 CHB-MIT 数据集上各方法 F_1 -Measure 值

数据集	DT	KNN	NB	DBN	CNN	PCA-TSK	TSK	SDF-TSK	MDFC-TSK	VR-TSK-FC
CHB 01	93.48	97.62	93.59	96.02	97.14	96.07	95.29	96.23	97.35	98.54
CHB 02	95.52	90.47	91.43	95.95	93.43	93.71	93.75	94.49	96.40	96.92
CHB 03	93.67	95.90	93.33	94.89	96.48	94.23	94.60	92.58	96.89	99.38
CHB 04	86.76	84.44	85.29	91.57	89.22	85.61	84.10	84.46	88.39	89.63
CHB 05	96.09	95.41	96.77	97.56	98.53	96.63	95.91	96.26	96.58	98.89

表 4~表 7 中的实验数据表明, VR-TSK-FC 算法中每个模糊规则后件部分采用不同视角深度特征, 其模糊逻辑推理学习方式是有效的. 在原始数据上构建规则保证了可解释性, 并取得可接受分类准确度. 具有重要临床研究意义的 Dataset 1 由癫痫发作期和发作间歇期组成, 各对比算法受发作间歇期异常波动信号影响, 分类效果不佳, 而 1D-CNN 捕获了可以区分二者的深度特征, 达到较好的分类效果. VR-

TSK-FC 算法利用不同结构的 1D-CNN 提取不同视角深度特征, 将其作为每条数据的不同规则后件变量, 充分利用了同一数据的不同视角间相关性. 从各对比算法的 F_1 值可以看出, VR-TSK-FC 相较其他算法分类性能更稳定, 应用于医学诊断更具优势.

同样, 基于 “If-Then” 规则的 DT 算法分类效果差, 虽然二者前件规则推理相似, 但是 VR-TSK-FC 算法的 “Then” 是一种精确函数, 由模糊推理前件部分的

线性局部方程构建,使得对含有不确定性的脑电信号数据有更好的分类效果.对于区分癫痫发作期和发作间歇期的特征,KNN和NB算法不能较好地区分从而影响了分类效果,NB算法在不同数据集分类性能不稳定.

传统TSK算法癫痫发作检测准确度不佳,VR-TSK-FC算法优于传统TSK算法的主要原因有:1)癫痫脑电信号具有个体特异性,而VR-TSK-FC利用多视角1D-CNN从多角度提取互补信息能够更好地表征EEG数据,各规则的后件部分采用不同视角特征,使得VR-TSK-FC算法更具泛化性能;2)采用视角-规则的学习方式更好地利用了同一数据不同视角间的相关性,同时深度特征维度远小于原始数据维度,降低了岭回归极限学习参数的数量,减轻了一阶线性函数过拟合的概率.

为了进一步验证VR-TSK-FC算法后件部分构建方式的有效性,在前件模糊规则同等参数学习情况下设立SDF-TSK和MDFC-TSK算法.在Bonn和CHB-MIT所有数据子集的实验中,SDF-TSK算法采用同一个视角获取其深度特征作为后件变量,即SDF-TSK算法基于原始数据构建模糊前件规则,后件变量

采用1D-CNN提取深度特征.对于 x_i 的每条规则的后件变量均对应同样的 h_i .MDFC-TSK算法的 x_i 的每条规则后件变量为 $h_i^{T_1}, \dots, h_i^{T_m}, \dots, h_i^{T_M}$,而非一个规则对应一个视角深度特征的模糊学习方式.实验结果表明,VR-TSK-FC算法总体上优于SDF-TSK和MDFC-TSK算法,仅在Bonn数据子集Dataset 3上 F_1 值略差于MDFC-TSK算法.VR-TSK-FC算法明显优于SDF-TSK算法,多视角学习比单一视角更利于表征复杂的癫痫脑电信号数据.VR-TSK-FC算法基于视角-规则的学习方式,相较于MDFC-TSK算法更具鲁棒性.

表8为CHB 01子集上不同视角数量的VR-TSK-FC实验结果.其中:1-View表示一个1D-CNN视角的VR-TSK-FC,2-View表示两个1D-CNN视角,以此类推.当采用5个视角提取特征时VR-TSK-FC的分类检测准确度达到99.07%.1D-CNN数量从1到5时,VR-TSK-FC的分类准确率不断提升;当1D-CNN数量从5到7时,VR-TSK-FC分类精确率受到影响出现下降趋势.这表明VR-TSK-FC的分类精确度不随视角数量的增加而逐渐提高,前件规则匹配适当数量的多视角深度特征可以使VR-TSK-FC精度最佳.

表8 不同视角数量的VR-TSK-FC在CHB-MIT数据集上Accuracy和F-Measure值

metrics	1-View	2-View	3-View	4-View	5-View	6-View	7-View
ACC	96.65	97.58	98.51	98.70	99.07	98.51	98.51
F1	94.49	96.10	97.65	97.94	98.54	97.63	97.63

对Bonn数据集的Accuracy实验结果计算了Friedman Ranking值,从Ranking值中进一步观察VR-TSK-FC与对比算法的平均分类准确度差异.由图2的排序结果可以看出,VR-TSK-FC取得最优等级,表明VR-TSK-FC与其他对比算法存在显著性差异.相对于深度网络“黑盒”式学习过程,基于原始数据构建模糊规则的方式,使VR-TSK-FC继承了TSK模糊系统的高可解释性,应用于癫痫脑电信号医学辅助诊断时更易于医生理解其分类结果.

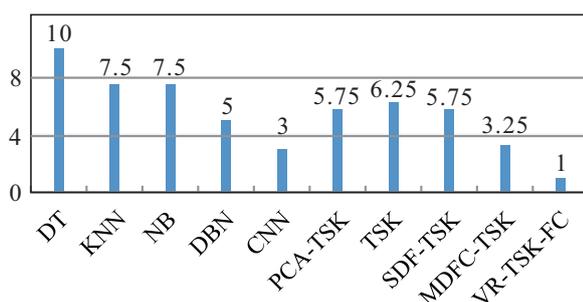


图2 Bonn数据集各算法Ranking值

3 结论

本文提出了基于视角-规则的深度TSK模糊分类算法,并应用于癫痫脑电信号分类检测任务.基于原始数据构建规则使其可解释性更具说服力,不同结构的一维卷积神经网络从多角度抓取癫痫脑电信号深度特征,每个模糊规则的后件部分分别采用一个视角的深度特征作为其后件变量.模糊规则能够更好地表征各视角之间的相关性,从而提升模型泛化性能.视角-规则的学习方式提高了VR-TSK-FC分类性能,实验结果验证了VR-TSK-FC算法的有效性,但是VR-TSK-FC算法还需要更多的临床数据去证实,以期早日应用于癫痫的临床诊断中.

参考文献(References)

- [1] Acharya U R, Vinitha Sree S, Swapna G, et al. Automated EEG analysis of epilepsy: A review[J]. Knowledge-Based Systems, 2013, 45: 147-165.
- [2] 晁浩, 刘永利, 连卫芳. EEG情感识别中基于集成深度

- 学习模型的多分析域特征融合[J]. 控制与决策, 2020, 35(7): 1674-1680.
(Chao H, Liu Y L, Lian W F. Multi-analysis domain feature fusion of EEG emotion recognition based on integrated deep learning model[J]. Control and Decision, 2020, 35(7): 1674-1680.)
- [3] Omidvar M, Zahedi A, Bakhshi H. EEG signal processing for epilepsy seizure detection using 5-level Db4 discrete wavelet transform, GA-based feature selection and ANN/SVM classifiers[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(11): 10395-10403.
- [4] Albaqami H, Hassan G M, Subasi A, et al. Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree[J]. Biomedical Signal Processing and Control, 2021, 70: 102957.
- [5] Yager R R. An extension of the naive Bayesian classifier[J]. Information Sciences, 2006, 176(5): 577-588.
- [6] Cao J W, Zhu J H, Hu W B, et al. Epileptic signal classification with deep EEG features by stacked CNNs[J]. IEEE Transactions on Cognitive and Developmental Systems, 2020, 12(4): 709-722.
- [7] 高云园, 高博, 罗志增, 等. 基于脑电多特征融合的癫痫发作预测方法[J]. 控制与决策, 2023, 38(1): 161-170.
(Gao Y Y, Gao B, Luo Z Z, et al. A seizure prediction method based on EEG multi-feature fusion[J]. Control and Decision, 2023, 38(1): 161-170.)
- [8] Swami P, Gandhi T K, Panigrahi B K, et al. A novel robust diagnostic model to detect seizures in electroencephalography[J]. Expert Systems with Applications, 2016, 56: 116-130.
- [9] Zeng H, Yang C, Dai G J, et al. EEG classification of driver mental states by deep learning[J]. Cognitive Neurodynamics, 2018, 12(6): 597-606.
- [10] Yang Y X, Gao Z K, Li Y L, et al. A CNN identified by reinforcement learning-based optimization framework for EEG-based state evaluation[J]. Journal of Neural Engineering, 2021, 18(4): 046059.
- [11] Zheng W L, Lu B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Transactions on Autonomous Mental Development, 2015, 7(3): 162-175.
- [12] Zhao J, Xie X J, Xu X, et al. Multi-view learning overview: Recent progress and new challenges[J]. Information Fusion, 2017, 38: 43-54.
- [13] Valliani A A A, Ranti D, Oermann E K. Deep learning and neurology: A systematic review[J]. Neurology and Therapy, 2019, 8(2): 351-365.
- [14] Wang X S, Wang X L, Liu W Y, et al. One dimensional convolutional neural networks for seizure onset detection using long-term scalp and intracranial EEG[J]. Neurocomputing, 2021, 459: 212-222.
- [15] Yuan Y, Xun G X, Jia K B, et al. A multi-view deep learning framework for EEG seizure detection[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(1): 83-94.
- [16] Ullah I, Hussain M, Qazi E U H, et al. An automated system for epilepsy detection using EEG brain signals based on deep learning approach[J]. Expert Systems with Applications, 2018, 107: 61-71.
- [17] Liu X L, Lv L Y, Shen Y L, et al. Multiscale space-time-frequency feature-guided multitask learning CNN for motor imagery EEG classification[J]. Journal of Neural Engineering, 2021, 18(2): 026003.
- [18] Schirrmester R T, Springenberg J T, Fiederer L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. Human Brain Mapping, 2017, 38(11): 5391-5420.
- [19] Jiang Y Z, Zhang Y P, Lin C, et al. EEG-based driver drowsiness estimation using an online multi-view and transfer TSK fuzzy system[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(3): 1752-1764.
- [20] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [21] Capizzi G, Sciuto G L, Napoli C, et al. Small lung nodules detection based on fuzzy-logic and probabilistic neural network with bioinspired reinforcement learning[J]. IEEE Transactions on Fuzzy Systems, 2020, 28(6): 1178-1189.
- [22] Hu Z Y, Wang J, Zhang C X, et al. Uncertainty modeling for multicenter autism spectrum disorder classification using Takagi-Sugeno-Kang fuzzy systems[J]. IEEE Transactions on Cognitive and Developmental Systems, 2022, 14(2): 730-739.
- [23] Du G L, Wang Z Y, Li C Q, et al. A TSK-type convolutional recurrent fuzzy network for predicting driving fatigue[J]. IEEE Transactions on Fuzzy Systems, 2021, 29(8): 2100-2111.
- [24] Ghosh L, Konar A, Rakshit P, et al. Mimicking short-term memory in shape-reconstruction task using an EEG-induced type-2 fuzzy deep brain learning network[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2020, 4(4): 571-588.
- [25] 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.
(Jiang Y L, Weng J W, Shen Q, et al. TSK fuzzy

- classifier based on enhanced deep feature for epilepsy EEG signal recognition[J]. *Control and Decision*, 2023, 38(1): 171-180.)
- [26] Soni M, Nayak N R, Selvakumar V, et al. Recurrent neural network model for identifying epilepsy based neurological auditory disorder[C]. *Artificial Intelligence for Neurological Disorders*. Amsterdam: Elsevier, 2023: 91-105.
- [27] 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.
- [28] 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.
- [29] Kim K, Lin H L, Choi J Y, et al. A design framework for hierarchical ensemble of multiple feature extractors and multiple classifiers[J]. *Pattern Recognition*, 2016, 52: 1-16.
- [30] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. *Proceedings of the 32nd International Conference on International Conference on Machine Learning*. New York, 2015: 448-456.
- [31] Deng Z H, Choi K S, Jiang Y Z, et al. Generalized hidden-mapping ridge regression, knowledge-leveraged inductive transfer learning for neural networks, fuzzy systems and kernel methods[J]. *IEEE Transactions on Cybernetics*, 2014, 44(12): 2585-2599.
- [32] 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.
- [33] Goldberger A L, Amaral L A, Glass L, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): E215-E220.
- [34] Khare S K, Bajaj V, Acharya U R. SPWVD-CNN for automated detection of schizophrenia patients using EEG signals[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-9.
- [35] Aha D W, Kibler D, Albert M K. Instance-based learning algorithms[J]. *Machine Learning*, 1991, 6(1): 37-66.

作者简介

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

李水苗(1997—), 女, 硕士生, 从事深度模糊系统、机器学习等研究, E-mail: 1535625841@qq.com;

翁江玮(1997—), 男, 硕士生, 从事人工智能与模式识别、机器学习等研究, E-mail: 347314873@qq.com;

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;

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: jyl@zjhu.edu.cn.