

多尺度多粒度解耦蒸馏模糊分类器及其在癫痫脑电信号检测中的应用

蒋云良, 金森洋, 张雄涛, 刘凯宁, 申情

引用本文

蒋云良, 金森洋, 张雄涛, 刘凯宁, 申情. [多尺度多粒度解耦蒸馏模糊分类器及其在癫痫脑电信号检测中的应用](#)[J]. 计算机科学, 2025, 52(9): 37-46.

JIANG Yunliang, JIN Senyang, ZHANG Xiongtao, LIU Kaining, SHEN Qing. [Multi-scale Multi-granularity Decoupled Distillation Fuzzy Classifier and Its Application in Epileptic EEG Signal Detection](#) [J]. Computer Science, 2025, 52(9): 37-46.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多阶段行人特征挖掘的轨迹预测方法](#)

Trajectory Prediction Method Based on Multi-stage Pedestrian Feature Mining
计算机科学, 2025, 52(9): 241-248. <https://doi.org/10.11896/jsjcx.250700138>

[基于局部增强傅里叶神经算子的偏微分方程求解方法](#)

Partial Differential Equation Solving Method Based on Locally Enhanced Fourier Neural Operators
计算机科学, 2025, 52(9): 144-151. <https://doi.org/10.11896/jsjcx.240700122>

[解耦知识蒸馏在文档级关系抽取中的应用](#)

Application of Decoupled Knowledge Distillation Method in Document-level Relation Extraction
计算机科学, 2025, 52(8): 277-287. <https://doi.org/10.11896/jsjcx.240600050>

[一种基于CSO-LSTM的新能源发电功率预测方法](#)

CSO-LSTM Based Power Prediction Method for New Energy Generation
计算机科学, 2025, 52(6A): 240600053-11. <https://doi.org/10.11896/jsjcx.240600053>

[基于空间转换与多尺度特征融合的行人重识别方法](#)

Pedestrian Re-identification Based on Spatial Transformation and Multi-scale Feature Fusion
计算机科学, 2025, 52(6A): 240800156-7. <https://doi.org/10.11896/jsjcx.240800156>

多尺度多粒度解耦蒸馏模糊分类器及其在癫痫脑电信号检测中的应用

蒋云良^{1,2,3} 金森洋^{1,2} 张雄涛^{1,2} 刘凯宁^{1,2} 申情^{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 浙江师范大学计算机科学与技术学院 浙江 金华 321004

(02032@zjhu.edu.cn)

摘要 在癫痫脑电信号检测任务中,深度学习方法具有强大的深度表达能力,但可解释性较差,Takagi-Sugeno-Kang(TSK)模糊分类器虽具备良好的基于模糊规则的可解释性,但其建模能力有限。为了更好地兼顾癫痫检测模型的性能与可解释性,提出了一种多尺度多粒度解耦蒸馏模糊分类器(MMDD-TSK-FC)。首先,训练不同卷积核大小的一维卷积神经网络作为教师模型,目的是充分提取脑电信号在不同尺度上的特征信息;其次,将教师模型的输出结果软化成软标签,最小化其与对应不同规则粒度 TSK 模糊分类器输出软标签之间的 Kullback-Leibler 散度,以实现深度特征表示知识的有效迁移,同时最小化学生模型输出与真实标签的交叉熵损失;最后,通过投票法整合多个 TSK 模糊分类器的输出结果。同时,借由多粒度的 TSK 模糊分类器生成的多组由繁至简的 IF-THEN 规则,为模型检测依据提供可解释表达。在 Bonn 和新德里 HauzKhas 癫痫脑电数据集上的实验结果充分验证了 MMDD-TSK-FC 的优势,其相比经典 TSK 分类器提升了约 5% 的准确率,优于其他深度知识蒸馏模型约 3%。

关键词: TSK 模糊分类器;癫痫脑电信号检测;多尺度;多粒度;知识蒸馏;可解释性

中图分类号 TP391

Multi-scale Multi-granularity Decoupled Distillation Fuzzy Classifier and Its Application in Epileptic EEG Signal Detection

JIANG Yunliang^{1,2,3}, JIN Senyang^{1,2}, ZHANG Xiongtao^{1,2}, LIU Kaining^{1,2} and SHEN Qing^{1,2}

1 School of Information Engineering, Huzhou University, Huzhou, Zhejiang 313000, China

2 Zhejiang Province Key Laboratory of Smart Management and Application of Modern Agricultural Resources, Huzhou, Zhejiang 313000, China

3 School of Computer Science and Technology, Zhejiang Normal University, Jinhua, Zhejiang 321004, China

Abstract In the task of epileptic EEG signal detection, deep learning methods exhibit outstanding feature representation capabilities but suffer from poor interpretability. In contrast, the Takagi-Sugeno-Kang(TSK) fuzzy classifier is endowed with superior fuzzy-rule based interpretability, yet is hampered by its limited modeling ability. To well balance the performance and interpretability when deal with EEG signals, this paper proposes a Multi-scale Multi-granularity Decoupled Distillation TSK Fuzzy Classifier(MMDD-TSK-FC). Firstly, training one-dimensional Convolutional Neural Networks with different kernel sizes as teacher models enables comprehensive extraction of EEG features at multiple scales. Next, soft labels are generated by softening the outputs of the teacher models, and the Kullback-Leibler divergence between these soft labels and the outputs of TSK fuzzy classifiers with varying rule numbers is minimized to facilitate deep feature representation knowledge transfer. Meanwhile, the cross-entropy loss between the student model's output and the ground-truth labels is minimized. Finally, the outputs of multiple TSK fuzzy classifiers are integrated using a voting mechanism. Meanwhile, the multi-granularity TSK fuzzy classifiers generate multiple sets of IF-THEN rules with varying levels of complexity, providing interpretable reasoning to support the model's detection decisions. The experimental results on the Bonn and New Delhi HauzKhas epileptic EEG datasets thoroughly validate the superiority of the MMDD-TSK-FC, which improves accuracy by approximately 5% compared to the classical TSK classifier and outperforms other deep knowledge distillation models by around 3%.

到稿日期:2025-03-18 返修日期:2025-06-28

基金项目:国家自然科学基金(62376094, U22A20102);浙江省大学生科技创新活动计划项目(新苗人才计划)(2024R430B021)

This work was supported by the National Natural Science Foundation of China(62376094, U22A20102) and Zhejiang Provincial Undergraduate Science and Technology Innovation Program(Xinmiao Program)(2024R430B021).

通信作者:张雄涛(1047897965@qq.com)

Keywords Takagi-Sugeno-Kang fuzzy classifier, Epileptic EEG signal detection, Multi-scale, Multi-granularity, Knowledge distillation, Interpretability

1 引言

癫痫是一种常见的神经系统疾病,其主要特征为由大脑异常电活动引起的反复性发作,具有突发性和发作模式的不确定性,严重影响患者的日常生活。脑电图(Electroencephalogram, EEG)信号^[1]是检测癫痫的重要工具,通过对 EEG 信号分析可以及时识别癫痫发作的前兆。然而,在采集 EEG 信号时极易受噪声影响,如电磁干扰、患者肌肉运动和眨眼等,得到的信号往往具有非线性、时变性以及复杂的噪声干扰等,给癫痫检测带来了巨大的挑战。

为了提升癫痫检测的准确性和效率,越来越多的研究将机器学习方法引入 EEG 信号分析,Zheng 等^[2]研究了一种具有智能选择网络结构能力的自适应神经决策树,通过将原始的一维 EEG 矢量信号转换为添加了通道位置信息的二维矩阵信号,以克服矢量化输入 EEG 信号缺乏位置信息的问题。Tang 等^[3]提出了一种基于 K 近邻^[4]与自动编码器的半监督模型(KNN-based Smooth Auto-Encoder, K-SAE),通过自动编码器重建 K-SAE 得到新输入,以获得更优的特征表示。Abhishek 等^[5]引入了 Higuchi 和 Katz 分形维数、功率谱密度与谱熵等传统特征的癫痫发作自动检测方法,取得了较为先进的检测效果。EEG 信号分类精度依赖于有效的特征提取,而机器学习方法在处理复杂数据时往往难以高效提取关键特征,导致分类性能不理想。

深度学习由于其深层结构而具有强大的特征提取能力,被广泛应用于脑电信号分析。Khare 等^[6]使用时频分析和卷积神经网络(Convolutional Neural Network, CNN)替代机器学习方法涉及的手动特征处理步骤,获得了一定的性能提升。Anita 等^[7]提出使用多尺度深度空洞卷积神经网络捕获 EEG 的局部与全局特征,并使用长短期记忆递归神经网络处理,解决了 CNN 只能提取局部时间特征的问题。但深度学习方法的中间节点产生的深度特征难以被解释,研究者提出了许多方法^[8],试图提高深度学习模型的可解释性,但如何解释深度学习中间层的“黑箱”结构仍是一个挑战。

Takagi-Sugeno-Kang(TSK)模糊系统因具有处理模糊信息和非线性问题的能力,同时 IF-THEN 规则有着天然的可解释性,故被广泛应用于模式识别领域。TSK 模糊分类器通过模糊规则将输入信号转化为准确的输出,使得它在癫痫发作检测中表现出良好的性能,尤其是在处理不确定和模糊信息时。Jiang 等^[9]将 TSK 模糊系统引入癫痫病电识别,提出了一种可解释的基于多视图学习框架和模糊系统建模的癫痫病电识别方法,对每个视图使用不同的特征提取方法,并根据每个视图的权重来评估其重要性,即每种特征提取方法的重要性。Deng 等^[10]考虑到训练数据和测试数据之间的分布差异,引入两种新的迁移学习机制并提出了增强的转换迁移学习 TSK 模糊系统构建方法。但两者在特征信息提取方面仍然逊色于深度学习模型,如卷积神经网络。

知识蒸馏^[11]作为一种模型压缩技术,能够将深度学习强

大的特征提取能力与表征能力迁移至 TSK 模糊分类器,在保证模型分类结果准确性的同时减少计算资源的消耗,这对癫痫实时检测具有重要意义。目前已有研究将知识蒸馏与 TSK 模糊分类器进行结合,兼顾分类精度与模型可解释性。Gu 等^[12]将卷积神经网络作为教师模型,迁移隐藏知识到 TSK 模糊分类器中,有效提升了模型性能。Jiang 等^[13]将卷积神经网络获取的深度特征与具有信号原始信息的浅层特征融合,并提出使用基于最小学习机的知识蒸馏算法快速求解模型后件参数,进一步提升了蒸馏效果与模型泛化性能。前者在蒸馏时简单使用了全局软标签,未能充分挖掘癫痫信号在不同尺度下的变化特征;后者在模糊规则推理过程中使用了卷积神经网络产生的深度特征,在一定程度上削弱了 TSK 模糊分类器的可解释性。

多尺度学习^[14]作为一种有效的数据处理方法,近年来受到广泛关注。其核心思想是结合不同尺度的信息采样,以提供更加全面、精细且准确的特征表示,从而增强模型的表达能力和适应性。多粒度学习^[15]是多尺度学习的进一步拓展,它不仅关注不同尺度的数据特征,还强调在不同粒度上对数据进行分解和表达,以适应复杂任务的需求。细粒度的特征表示能够展示更多的细节信息,粗粒度的特征表示更易体现出趋势上的变化信息。两者结合有助于挖掘 EEG 信号中潜在的时间信息,增强模型对癫痫发作的识别能力。多尺度卷积神经网络能够提取不同尺度的特征信息,而多粒度 TSK 模糊分类器通过多层次的 IF-THEN 规则对信息进行表达。借助知识蒸馏,可将前者提取的复杂特征有效映射到后者的规则体系,构建更具准确性与可靠性的辅助诊断工具,从而为临床决策提供支持。

综上,针对癫痫病脑信号特征提取难度大,可用的深度学习模型产生的深度特征难以解释的问题,本文提出了一种新颖的多尺度多粒度解耦蒸馏 TSK 模糊分类器(Multi-scale Multi-granularity Decoupled Distillation TSK Fuzzy Classifier, MMDD-TSK-FC),用于脑电信号检测。该方法利用多尺度的一维卷积神经网络(1D-CNN)作为教师模型,将隐藏知识通过知识蒸馏转移至多粒度的 TSK 模糊分类器,同时设计多个蒸馏通道解耦不同尺度对不同粒度知识的转移过程,最终通过投票机制融合多个不同粒度 TSK 模糊分类器的输出,以生成最终分类结果。

本文的主要贡献总结如下:

1)提出了一种融合多尺度与多粒度解耦蒸馏的 TSK 模糊分类器 MMDD-TSK-FC,充分考虑癫痫信号在不同尺度下的信息特征,并通过解耦知识蒸馏,将隐藏知识迁移至多粒度的 TSK 模糊分类器。在提高分类精度的同时,提出的方法兼顾了效率与可解释性,为脑电信号分类问题提供了具有实用价值的解决路径。

2)训练得到的 TSK 模糊分类器在推理时完全基于原始数据计算前件参数而非深度特征,从而保证了对原始数据的可解释性。此外,不同粒度的模糊规则提供了由繁至简的多

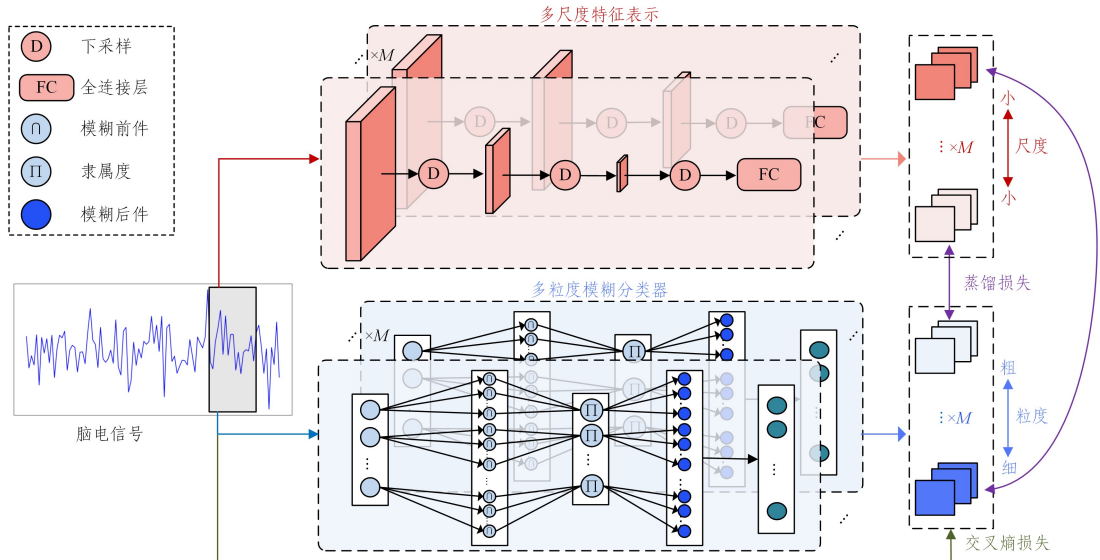
组规则表达,进一步增强了模型的解释性和鲁棒性。

3)在 Bonn 和新德里 HanzKhas 癫痫脑电数据集上进行了全面的性能评估,实验结果表明,与深度学习教师模型和最新的模糊分类器相比,提出的 MMDD-TSK-FC 在多个评估指标上均取得了优异的性能,验证了多尺度多粒度解耦蒸馏模糊分类器的有效性。

2 多尺度多粒度解耦蒸馏模糊分类器

2.1 MMDD-TSK-FC 模型结构设计

图 1 展示了 MMDD-TSK-FC 的整体框架,其中 M 为尺



注:红色部分为多尺度特征表示学习模块,蓝色部分为多粒度模糊分类器。

图 1 MMDD-TSK-FC 整体框架图

Fig. 1 Overall framework of MMDD-TSK-FC

2.1.1 多尺度特征表示学习

为了赋予 MMDD-TSK-FC 可与深度学习方法相媲美的特征表示能力,构建以 1D-CNN 为教师模型的蒸馏框架。同时,为了使学生模型更有效地学习全局和局部特征信息,将整体特征表示知识解耦为多个不同尺度的知识,以便在不同尺度下提取更加细致和全面的特征表示。其中每一尺度的模型结构如图 1 所示,1D-CNN 通过多次下采样(卷积层和池化层)减小数据维度,最后通过全连接层进行分类。记训练数据集的输入为 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times D}$, 对应的标签集记为 $\mathbf{Y}=[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T \in \{0, 1\}^{N \times C}$ 。其中 N 表示样本数量, D 表示样本维度, C 表示分类类别的个数。将 1D-CNN 中第 l 层的输出记为 $\mathbf{H}_l, l \in \{0, 1, \dots, L-1\}$, 其中 $\mathbf{H}_0 = \mathbf{x}_i, i \in \{0, 1, \dots, N\}$, 即某一样例输入。在每一层的下采样操作中,首先执行卷积操作,运算结果使用激活函数 $f(\cdot)$ 进行非线性变换,具体过程如下:

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

其中, $\text{Pool}(\cdot)$ 表示最大池化操作, $f(\cdot)$ 表示激活函数, \mathbf{W}_l 为第 l 层的卷积核, $*$ 表示卷积运算, \mathbf{b}_l 是偏置。选择 Leaky ReLU 作为激活函数^[16], 激活函数表示如下:

$$f(a) = \begin{cases} a, & a > 0 \\ \delta a, & a \leq 0 \end{cases} \quad (2)$$

其中, a 表示输入变量, δ 是一个小于 1 的常数。

度与粒度的个数。输入脑电信号经过多尺度的一维卷积神经网络和多粒度的 TSK-FC 获得预测概率输出。总损失由两部分组成:一是多尺度 1D-CNN 生成的软标签与相应多粒度 TSK-FC 输出之间的知识蒸馏损失;二是由多粒度 TSK-FC 输出与真实标签计算的交叉熵损失总和。此外,多尺度的 1D-CNN 与多粒度的 TSK-FC (Takagi-Sugeno-Kang-Fuzzy Classifier) 根据其卷积核大小与规则数目一一对应(大卷积核对应较少的规则数,小卷积核对应较多的规则数),最终采用投票机制结合多个 TSK-FC 的预测结果,生成最终分类决策。接下来详细介绍 MMDD-TSK-FC 的具体实现。

最后,通过全连接层 FC 与 Softmax 函数计算得到概率输出结果,其计算过程可表示为:

$$\mathbf{E} = \phi(\mathbf{W}_L \mathbf{H}_{L-1} + \mathbf{b}_L) \quad (3)$$

其中, \mathbf{E} 为最终的概率输出结果, $\phi(\cdot)$ 是 Softmax 函数, $\mathbf{E} = [e_1, e_2, \dots, e_C]$, C 代表类别的个数, Softmax 计算式如下:

$$e_c = \frac{\exp(h_c)}{\sum_{c'=1}^C \exp(h_{c'})}, c = 1, 2, \dots, C \quad (4)$$

其中, e_c 是模型对 c 类的概率输出, h_c 是模型全连接层对 c 类的概率输出。

通过交叉熵损失函数衡量每一尺度 1D-CNN 输出与真实标签之间的差异,并使用 Adam 优化算法^[17]与反向传播算法最小化损失函数,更新公式如下:

$$\boldsymbol{\theta} = (\mathbf{W}_0, \mathbf{W}_1, \dots, \mathbf{W}_L, \mathbf{b}_0, \mathbf{b}_1, \dots, \mathbf{b}_L) \quad (5)$$

$$\boldsymbol{\theta}_t = \boldsymbol{\theta}_t - \eta \Delta \boldsymbol{\theta}_{t-1} \quad (6)$$

其中, $\boldsymbol{\theta}$ 表示所有需要优化的参数, $\boldsymbol{\theta}_t$ 表示第 t 轮更新后的参数值, η 表示学习率, $\Delta \boldsymbol{\theta}_{t-1}$ 表示 $\boldsymbol{\theta}_{t-1}$ 的梯度。

研究^[18]表明,大卷积核具有更大的有效感受野和更强的偏差容忍能力,在某些场景下能够显著提升模型性能,而小卷积核对细节信息的捕获更加稳定。因此,本文为解耦后的多条并行 1D-CNN 训练通道配置不同大小的卷积核,以同时增强其对大时间跨度脑电信号变化以及短时间信号细微波动的

感知能力。具体来讲,本文设计了 M 组具有相同结构的 1D-CNN 并分别设置卷积核大小为 $K_m, m=1, 2, \dots, M$, 每一尺度通道均根据式(5)和式(6)进行独立训练,避免不同感受野信息之间互相干扰。

2.1.2 多粒度 TSK 模糊分类器

单一规则数的 TSK-FC 难以充分学习多尺度教师模型的特征表示知识。对于大卷积核提取的全局知识,过多的规则可能导致“过度解读”;而对于小卷积核提取的局部知识,规则数过少则可能导致“表达不清”。因此,本文采用具有不同规则数目的 TSK-FC 作为学生模型,通过不同粒度的规则表达更精确地学习与解析多尺度教师模型的知识。

TSK 模糊分类器通过 IF-THEN 规则进行表述,一阶模糊 IF-THEN 规则结构如下:

$$\begin{aligned} &\text{IF } x_{i,1} \text{ is } A_{1,r} \wedge x_{i,2} \text{ is } A_{2,r} \wedge \dots \wedge x_{i,D} \text{ is } A_{D,r} \\ &\text{THEN } f_r(x_i) = p_0^r + p_1^r x_{i,1} + \dots + p_D^r x_{i,D} \\ &r=1, 2, \dots, R \end{aligned} \quad (7)$$

其中, $x_{i,d}$ 表示输入向量 \mathbf{x}_i 的第 d 个特征值, $A_{d,r}$ 表示与第 r 条规则中的第 d 个特征相关的模糊集, D 表示特征空间的维度, $f_r(\mathbf{x}_i)$ 是 TSK-FC 第 r 条规则的输出, p_d^r 表示与第 d 个特征相关的第 r 条规则中的后件参数, R 表示模糊规则数。

在 TSK-FC 中,一般使用高斯函数作为隶属度函数来描述模糊集 $A_{d,r}$, 定义为:

$$\mu_{A_{d,r}}(x_{i,d}) = \exp\left(-\frac{(x_{i,d} - v_{d,r})^2}{2\sigma_{d,r}^2}\right) \quad (8)$$

其中, $\mu_{A_{d,r}}(x_{i,d})$ 表示实例 \mathbf{x}_i 的第 d 个特征在模糊集 $A_{d,r}$ 下的高斯隶属度值, 两个参数 $v_{d,r}$ 和 $\sigma_{d,r}$, 分别表示高斯函数的中心和高斯核宽度, 本文采用 Fuzzy c -means(FCM) 聚类算法^[19-20] 获得聚类中心 $v_{d,r}$, 核宽度 $\sigma_{d,r}$ 的计算式如下:

$$\sigma_{d,r} = \left[\frac{\sum_{i=1}^N u_{i,r}^m (x_{i,d} - v_{d,r})^2}{\sum_{i=1}^N u_{i,r}^m} \right]^{\frac{1}{2}} \quad (9)$$

其中, $u_{i,r}^m$ 是 FCM 聚类算法中第 i 个样本对第 r 个聚类中心的模糊隶属度, m 是模糊指数。

对于第 r 个模糊集 $A_{d,r}$, 若第 d 个特征 $x_{i,d}$ 的隶属度为 $\mu_{A_{d,r}}(x_{i,d})$, 则实例 \mathbf{x}_i 对第 r 条规则的激活强度 $\mu_r(\mathbf{x}_i)$ 定义为:

$$\mu_r(\mathbf{x}_i) = \prod_{d=1}^D \mu_{A_{d,r}}(x_{i,d}) \quad (10)$$

$$\tilde{\mu}_r(\mathbf{x}_i) = \frac{\mu_r(\mathbf{x}_i)}{\sum_{r'=1}^R \mu_{r'}(\mathbf{x}_i)} \quad (11)$$

其中, $\tilde{\mu}_r(\mathbf{x}_i)$ 表示归一化后的规则激活强度, TSK-FC 的输出 $f_{\text{TSK-FC}}(\mathbf{x}_i)$ 表示为:

$$f_{\text{TSK-FC}}(\mathbf{x}_i) = \sum_{r=1}^R \tilde{\mu}_r(\mathbf{x}_i) f_r(\mathbf{x}_i) \quad (12)$$

其可进一步表示为模糊规则映射的高维特征空间的线性模型, 即:

$$f_{\text{TSK-FC}}(\mathbf{x}_i) = \mathbf{x}_i^T \mathbf{p}_g \quad (13)$$

$$\mathbf{x}_{i,e} = [1, \mathbf{x}_i^T]^T \in \mathbb{R}^{(D+1) \times 1} \quad (14)$$

$$\tilde{\mathbf{x}}_i^e = \tilde{\mu}_r(\mathbf{x}_i) \mathbf{x}_{i,e} \in \mathbb{R}^{(D+1) \times 1} \quad (15)$$

$$\mathbf{x}_{i,g} = [(\tilde{\mathbf{x}}_i^e)^T, (\tilde{\mathbf{x}}_i^e)^T, \dots, (\tilde{\mathbf{x}}_i^e)^T]^T \in \mathbb{R}^{R(D+1) \times 1} \quad (16)$$

$$\mathbf{p}^r = [p_0^r, p_1^r, \dots, p_D^r]^T \in \mathbb{R}^{(D+1) \times 1} \quad (17)$$

$$\mathbf{p}_g = [(\mathbf{p}^1)^T, (\mathbf{p}^2)^T, \dots, (\mathbf{p}^R)^T]^T \in \mathbb{R}^{R(D+1) \times 1} \quad (18)$$

其中, $\mathbf{x}_{i,g}$ 表示通过模糊规则映射实例 \mathbf{x}_i 得到的向量, \mathbf{p}_g 表示包含 TSK-FC 所有后件参数的向量, $\mathbf{x}_{i,e}, \tilde{\mathbf{x}}_i^e, \mathbf{p}^r$ 均为线性模型表示的中间变量, 不具有实际意义。对 TSK-FC 的直接输出结果 $f_{\text{TSK-FC}}(\mathbf{x}_i)$ 使用式(4)计算得到模型的概率输出结果, 记为 \mathbf{z}_i^s , 即学生模型 S 的概率输出。为每一粒度通道设置不同的规则数 $R_m, m=1, 2, \dots, M$, 具体训练过程将在 2.1.3 节中详细介绍。

2.1.3 多尺度多粒度解耦蒸馏模糊分类器

本研究分别使用 T 和 S 来表示教师模型和学生模型, 各自的详细结构设计已在上文中介绍。首先介绍标准知识蒸馏的过程。对教师模型概率输出 $\mathbf{E} = \mathbf{z}_i^T = [z_{i,1}^T, z_{i,2}^T, \dots, z_{i,c}^T, \dots, z_{i,C}^T] \in \mathbb{R}^{1 \times C}$ 使用带温度参数 τ 的 softmax 函数进行软化得到软标签, 计算方式如下:

$$\tilde{z}_{i,c}^T = \frac{\exp\left(\frac{z_{i,c}^T}{\tau}\right)}{\sum_{c'=1}^C \exp\left(\frac{z_{i,c'}^T}{\tau}\right)}, c=1, 2, \dots, C \quad (19)$$

其中, $\tilde{z}_{i,c}^T$ 和 $z_{i,c}^T$ 分别为教师模型 T 对第 i 个样例 c 类别的预测软标签和预测概率值, $\tilde{\mathbf{z}}_i^T = [\tilde{z}_{i,1}^T, \tilde{z}_{i,2}^T, \dots, \tilde{z}_{i,c}^T, \dots, \tilde{z}_{i,C}^T] \in \mathbb{R}^{1 \times C}$ 为教师模型概率输出 \mathbf{z}_i^T 所对应的软标签, 学生模型的软标签 $\tilde{\mathbf{z}}_i^s$ 通过相同方式得到。

使用 Kullback-Leible(KL) 散度计算蒸馏损失 \mathcal{L}_{KL} , 计算式如下:

$$\mathcal{L}_{\text{KL}}(\tilde{\mathbf{z}}_i^T | \tilde{\mathbf{z}}_i^s) = \sum_{c=1}^C \tilde{z}_{i,c}^T \log\left(\frac{\tilde{z}_{i,c}^T}{\tilde{z}_{i,c}^s}\right) \quad (20)$$

MMDD-TSK-FC 为每个尺度的概率输出建立知识蒸馏通道, 引导学生模型更加全面地对不同精细程度的特征表示进行学习。具体来说, MMDD-TSK-FC 通过如下多尺度多粒度解耦蒸馏损失 $\mathcal{L}_{\text{MMDDK}}$ 进行训练:

$$\mathcal{L}_{\text{MMDDK}} = \frac{1}{|S|} \sum_{i=1}^N \sum_{(K,R) \in S} \mathcal{L}_{\text{KL}}(\tilde{\mathbf{z}}_i^{T^K} | \tilde{\mathbf{z}}_i^{S^R}) \quad (21)$$

其中, S 是尺度粒度集合, 包含多组核大小与规则数组合 (K, R) ; $|S|$ 是集合大小; $\tilde{\mathbf{z}}_i^{T^K}$ 是卷积核大小为 K 的教师模型 T^K 的软标签; $\tilde{\mathbf{z}}_i^{S^R}$ 是规则数为 R 的学生模型 S^R 的软标签。

使用交叉熵(Cross-Entropy, CE) 损失函数作为学生输出与真实标签的损失函数:

$$\mathcal{L}_{\text{CE}} = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(z_{i,c}^s) \quad (22)$$

其中, $y_{i,c}$ 表示第 i 个样本的真实标签类别 c 的值。综上, MMDD-TSK-FC 的总损失函数表示如下:

$$\mathcal{L}_{\text{MMDD-TSK-FC}} = \alpha \mathcal{L}_{\text{MMDDK}} + (1-\alpha) \mathcal{L}_{\text{CE}} \quad (23)$$

其中, α 是蒸馏损失的比重参数。

使用 Adam 算法与反向传播算法优化多个后件参数 \mathbf{p}_g 以最小化损失函数, 通过投票法结合所有粒度学生模型的输出, 最终输出如下:

$$\hat{y}_{i,c} = \mathbb{I}\left(\sum_{m=1}^M \mathbb{I}(z_{i,m,c}^s \geq 0.5) \geq \frac{M}{2}\right), c=1, 2, \dots, C \quad (24)$$

其中, $\hat{y}_{i,c}$ 是 MMDD-TSK-FC 对第 i 个样本类别 c 的预测结果; $\mathbb{I}(\cdot)$ 是指示函数, 用于确定每个粒度模型的结果以及投票结果; M 是蒸馏通道的个数, 结果由 M 个 TSK-FC 的

分类结果 $z_{i,m,c}^S$ 投票决定; C 表示分类类别的个数。

2.2 MMDD-TSK-FC 学习算法

MMDD-TSK-FC 学习算法包含教师模型预训练和学生模型蒸馏训练,具体训练过程的伪代码如算法 1 和算法 2 所示。

算法 1 多尺度 1D-CNN 模型训练

输入:训练数据集 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times D}$ 及其标签集 $\mathbf{Y}=[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T \in \{0,1\}^{N \times C}$, 最大迭代次数 β , 初始学习率 η , 尺度粒度集合 $S=[(K_1, R_1), (K_2, R_2), \dots, (K_M, R_M)]$

输出:训练完成的 M 个 1D-CNN 模型

1. for $m \leftarrow 1$ to M do
2. 设置卷积核大小为 K_m , 初始化 \mathbf{W}_1 和 \mathbf{b}_1 ;
3. for $t \leftarrow 1$ to β do
4. 输入样本 X 根据式(1)–式(4)计算得到样本属于每个标签的概率;
5. 计算概率输出与真实标签 Y 的交叉熵损失;
6. 根据式(5)和式(6)对 1D-CNN 进行反向传播更新 \mathbf{W}_1 和 \mathbf{b}_1 ;
7. end
8. 保存当前尺度的 1D-CNN 模型 \mathbb{T}^{K_m} ;
9. end

算法 2 MMDD-TSK-FC 学习算法

输入:训练数据集 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times D}$ 及其标签集 $\mathbf{Y}=[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T \in \{0,1\}^{N \times C}$, 最大迭代次数 Υ , 初始学习率 η , 尺度粒度集合 $S=[(K_1, R_1), (K_2, R_2), \dots, (K_M, R_M)]$, 正则化因子 α , 温度参数 τ , 测试样本 X_{test} , 训练完成的 M 个教师模型 $[\mathbb{T}^{K_1}, \mathbb{T}^{K_2}, \dots, \mathbb{T}^{K_M}]$

输出:训练完成的 MMDD-TSK-FC 模型, 测试样本的分类结果 \mathbf{Y}_{test}

训练阶段:

1. for $m \leftarrow 1$ to M do
2. 设置模糊规则数为 R_m ;
3. for $t \leftarrow 1$ to Υ do
4. 根据式(8)和式(9)以及 FCM 算法得到 R_m 条模糊规则的前件参数;
5. 根据式(10)和式(11)计算不同规则的激活强度;
6. 根据式(13)计算得到模型 S^{R_m} 的概率输出;
7. 根据式(1)–式(4)计算得到模型 \mathbb{T}^{K_m} 的概率输出;
8. 根据式(19)计算 \mathbb{T}^{K_m} 与 S^{R_m} 的软标签;
9. 根据式(20)–式(23)计算模型的目标损失;
10. 通过式(5)和式(6)进行反向传播更新 S^{R_m} 的后件参数矩阵 $\mathbf{P}_{g,m}$;
11. end

12. 保存当前粒度的 TSK-FC 模型 S^{R_m} ;

13. end

测试阶段:

1. 输入测试样本 \mathbf{X}_{test} ;
2. for $m \leftarrow 1$ to M do
3. 设置模糊规则数为 R_m ;
4. 根据式(13)计算 S^{R_m} 的概率输出 \mathbf{z}_m^S ;
5. end
6. 根据式(24)计算得到预测结果 \mathbf{Y}_{test} ;

接下来对 MMDD-TSK-FC 进行复杂度分析。教师模型

1D-CNN 训练时间复杂度为 $O(\sum_{m=1}^M \beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K_m)$ 。其中 M 是尺度的个数, β 是教师训练的最大迭代次数, L 为 1D-CNN 的总层数, \mathcal{H}_l 是第 l 层特征图的特征维度, C_l 是第 l 层输出的通道数, K_m 为第 m 个尺度的核大小。在 IF-THEN 规则中, 前件参数计算过程的复杂度为 $O(\epsilon NR_m^2 D)$, 其中 ϵ 表示 FCM 算法的最大迭代次数, N 是样本的个数, R_m 是第 m 个尺度下的模糊规则数, D 是样本数据的特征维度。计算后件参数矩阵的时间复杂度为 $O(\gamma NR_m D(D+1))$, 其中 γ 是学生训练的最大迭代次数。蒸馏训练多个粒度的 TSK-FC 时间复杂度为 $O(\sum_{m=1}^M (\epsilon NR_m^2 D + \gamma NR_m D^2))$ 。因此, MMDD-TSK-FC 算法的时间复杂度为 $O(\sum_{m=1}^M \beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K_m + \sum_{m=1}^M (\epsilon NR_m^2 D + \gamma NR_m D^2))$ 。

表 1 列出了教师模型 1D-CNN 以及不同基于 TSK 的方法在训练与测试阶段的时间复杂度分析, 为方便比较, 本文统一表示所有算法中的近似参数的符号。其中 K 表示卷积核大小, R 表示规则数, V 表示视角个数, 其余参数含义均与本文中保持一致。从训练时间复杂度来看, 教师模型 1D-CNN 受卷积层堆叠深度与通道数影响较大; 而基于模糊系统的 TSK-FC 系列方法复杂度大多为 $O(\epsilon NR^2 D + \gamma NR D^2)$, 其中 MV-TSK-FC 由于融合多视角的学习策略还额外引入了系数 V , 增加了整体计算负担。相比之下, 本文提出的 MMDD-TSK-FC 引入了多个尺度与粒度建模, 虽然在训练阶段复杂度略有增加, 但整体仅为线性增长, 而非指数级增长。在测试阶段, MMDD-TSK-FC 的复杂度与典型 TSK-FC 方法基本一致, 且显著优于包含多层卷积结构的 1D-CNN, ED-TSK-FC 和 MV-TSK-FC 方法。因此, 尽管本文方法在训练复杂度上略有增加, 但在测试复杂度上并未带来显著的额外计算开销。

表 1 不同方法在训练与测试阶段的时间复杂度比较

Table 1 Time complexity comparison of different methods in terms of training and testing stages

方法	训练时间复杂度 $O(*)$	测试时间复杂度 $O(*)$
1D-CNN ^[21]	$\beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K$	$\sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K$
FCM-TSK-FC ^[22]	$\epsilon NR^2 D + \gamma NR D^2$	$NR^2 D + NR D^2$
PCA-TSK-FC ^[23]	$\epsilon NR^2 D + \gamma NR D^2$	$NR^2 D + NR D^2$
MV-TSK-FC ^[24]	$\beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K + V(\epsilon NR^2 D + \gamma NR D^2)$	$\sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K + V(NR^2 D + NR D^2)$
STSK-LLM-KD ^[25]	$\epsilon NR^2 D + \gamma NR D^3$	$NR^2 D + NR D^3$
ED-TSK-FC ^[26]	$\beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K + \epsilon NR^2 D + \gamma NR D^2$	$\sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K + NR^2 D + NR D^2$
MMDD-TSK-FC	$\sum_{m=1}^M \beta \sum_{l=1}^L \mathcal{H}_l C_l C_{l-1} K_m + \sum_{m=1}^M (\epsilon NR_m^2 D + \gamma NR_m D^2)$	$\sum_{m=1}^M (NR_m^2 D + NR_m D^2)$

3 实验研究

本章将在癫痫脑电信号检测任务上对所提出的 MMDD-TSK-FC 进行评估。实验运行硬件环境为 AMD Ryzen 5 3400G with 32GB RAM, 64-bit Microsoft Windows 11, 软件环境为 Python 3.11。本文所有实验过程都采用五折交叉方式, 每次随机取一折交叉的样本作为测试集, 其余的样本作为训练集, 结果取 5 次实验的平均值。

3.1 数据集

Bonn EEG 数据集^[27]是德国波恩大学提供的癫痫检测公开数据集, 广泛用于脑电信号分析与模式识别研究。数据集包含 5 个子集 (A-E), 分别来自健康人和癫痫患者的头皮 EEG 或颅内 EEG 信号, 每个子集包含 100 个时长 23.6 s 的片段, 采样率为 173.61 Hz, 经过预处理后得到 2300 条特征维度为 178 的样本, 如表 2 所列。

表 2 Bonn 数据集介绍
Table 2 Details of Bonn dataset

子集	状态	电极位置
A	健康人睁眼	头皮
B	健康人闭眼	头皮
C	患者发作间期	颅内海马体
D	患者发作间期	颅内病社区
E	患者发作期	颅内病社区

新德里 HauzKhas 癫痫脑电数据集^[28]采集了 10 名癫痫患者的 EEG 信号, 采用 10~20 电极放置系统记录数据, 用于癫痫发作的检测。该数据集分为 3 类: 癫痫发作前 (Preictal)、癫痫发作间歇期 (Interictal) 和癫痫发作中 (Ictal)。每个类别均包含 256 条数据, 采样频率为 200 Hz。经过预处理后得到 768 条特征维度为 14 的样本。

在癫痫检测的临床应用中, 区分发作期与非发作期是核心目标^[29]。Bonn 数据集包含 5 个子集, 其中 A 类至 D 类电极位置差异较大且对其分类与临床实际需求不符, 故不设置 A 类至 D 类间的分类任务。同时, 受限于采集设备和采集操作方式的差异, Bonn 与新德里 HauzKhas 癫痫脑电数据集不适合直接混合使用。基于以上原因, 本文对表 1 中的数据以及新德里 HauzKhas 癫痫脑电数据集中的 3 类数据进行任务划分, 如表 3 所列, 得到 6 种在临床研究中具有重要意义的分类任务, 用于验证 MMDD-TSK-FC 的在癫痫脑电信号分类上的性能表现。

表 3 实验数据集任务划分

Table 3 Division of tasks in experimental datasets

任务编号	数据集	正类子集	负类子集
Task 1	Bonn	A, B	E
Task 2	Bonn	C, D	E
Task 3	Bonn	C	E
Task 4	Bonn	D	E
Task 5	HauzKhas	Interictal	Ictal
Task 6	HauzKhas	Preictal	Ictal

3.2 实验设置和性能指标

教师模型的结构设计除卷积核大小外均与文献^[26]保持

一致, LeakyReLU 中的常数 δ 基于经验设置为 0.01, 教师与学生模型最大迭代次数 β 和 γ 均设置为 100, 以保证模型充分拟合, 初始学习率 η 均设置为 0.001, 避免过大或过小的学习率影响训练效果, 蒸馏正则化因子寻优范围 $\alpha = \{0.001, 0.01, \dots, 100\}$, 蒸馏温度寻优范围 $\tau = \{1, 3, 5, 8, 10, 20\}$, 尺度粒度集合 S 按表 4 设置。

表 4 尺度粒度集合 S 定义

Table 4 Definition of scale-granularity set S

组别 m	核大小	模糊规则数
1	1×3	11
2	1×5	9
3	1×7	7
4	1×9	5
5	1×11	3

将本文提出的 MMDD-TSK-FC 与深度信念网络 DBN、固定尺度的教师模型 1D-CNN、基于局部二元模式平均绝对偏差与熵优化的方法 LBPMAD^[30]、3 种新颖的一阶 TSK-FC、基于知识蒸馏的 TSK-FC STSK-LLM-KD 和性能突出的 ED-TSK-FC 共 8 种方法进行比较, 以充分评价模型的有效性, LBPMAD 直接与论文中的结果进行对比, 其余对比方法及各自的参数寻优范围如表 5 所列。其中, l 表示 DBN 隐含层单元个数, K 和 P 分别表示 1D-CNN 中的核大小和填充大小。在 FCM-TSK-FC, PCA-TSK-FC 以及 ED-TSK-FC 中, M , λ 和 α 分别表示规则数、模糊聚类尺度因子和岭回归求解正则参数; 在 MV-TSK-FC 中, K 表示规则数, λ_1 , λ_2 和 ϵ 分别表示约束后件参数的正则化因子、多视角协同学习的正则化因子以及算法收敛阈值; 在 STSK-LLM-KD 中, K 表示规则数, τ 表示蒸馏温度, α 表示蒸馏参数。

表 5 参数的搜索范围

Table 5 Search ranges of parameters

方法	参数寻优范围
Deep Belief Network (DBN) ^[31]	$l \in \{100, 200, 500, 1000\}$
1D-CNN	$K \in \{3, 5, \dots, 13\}$ $P \in \{1, 2, 3\}$
FCM-TSK-FC	$M \in \{5, 8, \dots, 32\}$ $\lambda \in \{0.001, 0.01, \dots, 100\}$ $\alpha \in \{0.0, 0.01, \dots, 100\}$
PCA-TSK-FC	$M \in \{5, 8, \dots, 32\}$ $\lambda \in \{0.001, 0.01, \dots, 100\}$ $\alpha \in \{0.0, 0.01, \dots, 100\}$
MV-TSK-FC	$K \in \{1, 2, \dots, 10\}$ $\lambda_1 \in \{0.001, 0.01, \dots, 100\}$ $\lambda_2 \in \{0.001, 0.01, \dots, 100\}$ $\epsilon \in \{10^{-6}, 10^{-5}, \dots, 10^{-2}\}$
STSK-LLM-KD	$K \in \{1, 2, \dots, 20\}$ $\tau \in \{1.5, 10, 20, 100\}$ $\alpha \in \{0.0, 0.25, 0.50, 0.75, 1\}$
ED-TSK-FC	$M \in \{5, 8, \dots, 32\}$ $\lambda \in \{2^{-6}, 2^{-5}, \dots, 2^2\}$ $\alpha \in \{0.001, 0.01, \dots, 100\}$

为了对结果进行全面合理地分析, 选用评价指标 Accuracy 与 F-measure (F_1), 计算式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (25)$$

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

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

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (28)$$

其中, TP (真阳性)为模型正确预测为癫痫发作的样本数, TN (真阴性)为模型正确预测为非癫痫的样本数, FP (假阳性)为模型错误地将非癫痫样本预测为癫痫的样本数, FN (假阴性)为模型错误地将癫痫样本预测为非癫痫的样本数, P 表示精确率, R 表示召回率。更高的 $Accuracy$ 和 F_1 值,表明模型在分类任务中的性能更优。

3.3 结果与分析

表 6 和表 7 列出了 MMDD-TSK-FC 与 8 种对比方法在 2 个数据集的 6 项分类任务上的实验结果,取 $Accuracy$ 和 F_1 值在最优参数下的平均结果,每项任务中的最好结果用粗

体标出。其中,由于模型 LBPMD 并未给出 HanzKhas 数据集上的结果,因此表中并未列出并用“—”表示。可以明显看出,MMDD-TSK-FC 方法在各项任务中表现出色,在绝大多数任务上,其平均准确率和 F_1 值均超过 96%,整体性能显著优于 8 种对比方法。特别是在任务 2 和任务 4 上,MMDD-TSK-FC 的准确率和 F_1 值接近或超过 99%,表明模型能够更准确地建模输入特征与输出标签之间的关系,具有出色的泛化能力。值得注意的是,在所有对比方法均表现较弱的任务 6 中,MMDD-TSK-FC 展现出了较大的性能优势,仅在 Bonn 数据集的任务 2 上,MMDD-TSK-FC 的表现略低于 ED-TSK-FC。这一现象可归因于 ED-TSK-FC 的深度特征提取方法,其充分利用了深层语义信息,进而优化了分类性能。相比之下,MMDD-TSK-FC 在特征解释性方面具有明显优势,其能够在原始特征空间直接构建多组由简至繁的 IF-THEN 模糊规则,为实际应用场景,尤其是临床决策等领域,提供了更高的可解释性。

表 6 MMDD-TSK-FC 与 8 种对比方法在 2 个数据集的 6 个任务上的平均 Accuracy

Table 6 Average Accuracy of MMDD-TSK-FC and eight benchmark methods on six tasks in two datasets

任务	DBN	1D-CNN	LBPMD	FCM-TSK-FC	PCA-TSK-FC	MV-TSK-FC	STSK-LLM-KD	ED-TSK-FC	MMDD-TSK-FC
Task 1	92.95	96.43	97.00	91.47	91.19	95.65	93.48	97.52	97.99
Task 2	95.56	98.54	97.00	92.95	95.54	97.39	94.52	99.15	98.84
Task 3	92.98	97.07	95.00	94.26	95.5	95.58	95.98	97.14	97.62
Task 4	97.04	97.81	99.00	96.57	96.23	97.89	97.74	99.58	99.62
Task 5	91.28	97.27	—	90.77	91.14	95.37	98.20	97.42	98.86
Task 6	82.74	93.36	—	92.25	92.74	93.85	94.30	93.94	96.43

表 7 MMDD-TSK-FC 与 8 种对比方法在 2 个数据集的 6 个任务上的平均 F_1

Table 7 Average F_1 of MMDD-TSK-FC and eight benchmark methods on six tasks in two datasets

任务	DBN	1D-CNN	LBPMD	FCM-TSK-FC	PCA-TSK-FC	MV-TSK-FC	STSK-LLM-KD	ED-TSK-FC	MMDD-TSK-FC
Task 1	92.83	96.43	97.00	95.3	91.39	95.76	93.32	97.52	97.92
Task 2	95.58	98.54	97.00	92.11	95.66	97.37	94.17	99.16	98.83
Task 3	88.72	95.56	93.22	91.47	92.79	93.13	95.41	95.70	97.42
Task 4	95.45	96.69	98.49	94.86	94.31	96.57	97.38	99.37	99.39
Task 5	90.88	96.89	—	89.58	90.32	95.63	98.05	97.28	98.42
Task 6	88.71	93.02	—	91.47	89.63	94.52	94.22	93.69	96.49

此外,本文提出的 MSD-TSK-FC 在各项实验中均优于单一尺度学习的 1D-CNN 教师模型。具体而言,1D-CNN 在卷积核尺寸较大时,能够有效缓解原始信号中的异常波动,而在卷积核尺寸较小时,能够捕捉细粒度特征变化,从而在不同尺度上实现对关键信息的全面建模。其次,如表 7 所列,在任务 4 和任务 6 上,多尺度特征融合策略显著提升了模型的 F_1 值,表明本文方法能够有效平衡全局趋势建模与局部细节捕捉之间的关系。

3.4 解耦蒸馏效果分析与消融实验

在本研究中,尺度粒度是指对特征空间划分与模糊规则表达的细化程度,不同尺度对应不同卷积核大小,不同粒度对应不同数量与复杂度的模糊规则。本文在模型设计中依据“多层次表达”的原则设定粒度:粗粒度强调全局模式表达,适用于捕捉样本间的整体趋势;细粒度则强化对局部特征差异的刻画,提升模型对异质样本的辨别能力。粒度的选择对实验结果具有显著影响:粒度过粗可能导致规则表达不细致,无

法覆盖复杂分布下的语义结构;细粒度虽提升了表达能力,但可能引入冗余规则,影响模型的可解释性。

为了进一步研究多尺度多粒度解耦蒸馏的有效性,对尺度粒度集合 S 进行了更加详细的设置,以探究不同解耦程度对模型性能的影响。将原先的 5 个蒸馏通道扩充到 1,3,5,9,11 个,具体的卷积核大小以及规则数设置如表 8 所列。蒸馏温度取 $\tau=3$,正则化因子取 $\alpha=0.01$,结果取五折交叉认证下准确率和 F_1 值的平均结果。

表 8 多种尺度粒度集合 S 的定义

Table 8 Definition of the different scale-granularity set S

通道个数	核大小	模糊规则数
1	7	7
3	3,5,7	7,5,3
5	3,5,7,9,11	11,9,7,5,3
9	3~11	11~3
11	2~12	12~2

图 2 和图 3 展示了各种尺度的 MMDD-TSK-FC 在 Bonn

数据集的任务 1—任务 4 上的实验结果。从结果可以看出,在准确率以及 F_1 指标上,所有的多尺度多粒度解耦蒸馏(通道个数 $M > 1$) 结果均优于单一通道蒸馏的结果,验证了引入多尺度与多粒度机制能够有效提升模型性能。同时,随着尺度与粒度解耦程度的增加(即 M 值的增大),MMDD-TSK-FC 的准确率和 F_1 值整体呈现上升趋势,仅在任务 1 中 F_1 指标出现轻微的下降趋势,表明更高层次的解耦在大多数情况下能够带来更显著的性能提升。为验证多尺度(MS)与多粒度(MG)机制在癫痫检测任务中的有效性,本文设计了消融实验,具体如下:1) w/o MS, 即移除 MS 机制;2) w/o MG, 即移除 MG 机制;3) w/o MS & MG, 即同时移除 MS 与 MG 机制。在任务 1 中将上述模型与完整模型 MMDD-TSK-FC(同时使用 MS 与 MG 机制)进行对比,以系统地评估各机制对模型性能的贡献。为确保实验结果的公平性与代表性,所有设置中的参数均按网格搜索的最优结果设定。在 w/o MS 中,将代表尺度的卷积核大小固定为 7;在 w/o MG 中,表征粒度层次的规则数设为 7。




图 2 不同通道个数的 MMDD-TSK-FC 在 Bonn 数据集 4 种任务中的平均 Accuracy

Fig. 2 Average Accuracy of MMDD-TSK-FC with different numbers of channels across four tasks on Bonn dataset




图 3 不同通道个数的 MMDD-TSK-FC 在 Bonn 数据集 4 种任务中的平均 F_1

Fig. 3 Average F_1 of MMDD-TSK-FC with different numbers of channels across four tasks on Bonn dataset

实验结果如图 4 所示,无论是去除 MS 机制还是 MG 机制,模型的 Accuracy 和 F_1 两个指标值均低于完整的 MMDD-TSK-FC,分别达到 97.73%/97.69% (w/o MS) 与 97.71%/97.70% (w/o MG),且明显优于同时移除 MS 与 MG 机制的模型(w/o MS & MG),表明两种机制均有助于提升模型对癫痫信号关键特征的提取与表示能力。在解耦蒸馏框架的引导下,MS 与 MG 机制能够实现有效协同,从不同维度建模癫痫信号中的时间与标签结构,进而显著增强检测性能。




图 4 MS 和 MG 对准确率和 F_1 的消融实验结果

Fig. 4 Ablation study results of MS and MG on Accuracy and F_1

3.5 参数敏感性分析

图 5 给出了 MMDD-TSK-FC 在选取不同蒸馏参数和蒸馏温度时对 Accuracy 以及 F_1 产生的影响。可以明显看到,随着蒸馏参数和蒸馏温度的增大,分类性能均出现先轻微提高后下降的现象。同时根据实验结果可知,蒸馏参数范围在 $[0.01, 0.1]$ 时效果较好,这表明适当的教师知识可以提高检测性能。当教师知识占比过高时,学生模型可能受到错误的引导;当教师知识过少时,学生模型无法有效受到教师模型指导。蒸馏温度在 $[5, 8]$ 范围内是一个较好的选择,这说明较低的温度不能有效地蒸馏出类别之间的相似信息,而较高的温度则会破坏模型对不同类别的预测,适中的蒸馏温度才能够有效促进知识传递。




图 5 蒸馏参数 α 和蒸馏温度 τ 对 Accuracy 和 F_1 的影响

Fig. 5 Effectiveness of distillation parameter α and distillation temperature τ on Accuracy and F_1

3.6 可解释性分析

多粒度 TSK 模糊分类器的可解释性体现在其所生成的 IF-THEN 规则中的模糊语言描述。为验证所提出分类器在可解释性方面的有效性,本文选取 Bonn 数据集中第一个患者的样本数据,针对所构建的多粒度 IF-THEN 规则进行分析。考虑篇幅限制与展示效果,仅展示 7 条模糊规则,并将特征值归一化至区间 $[0, 1]$,以更直观地展示规则与特征之间的关系。具体数据如表 9 所列。

表9 多粒度模糊规则描述

Table 9 Description of multi-granularity fuzzy rules

规则 r	前件参数 $v_r = (v_{1,r}, v_{2,r}, \dots, v_{D,r})^T, \sigma_r = (\sigma_{1,r}, \sigma_{2,r}, \dots, \sigma_{D,r})^T$	规则激活强度 $\tilde{\mu}_r(\mathbf{x}_0)$	后件参数输出 $f_r(\mathbf{x}_0)$
1	$v_1 = [0.501, 0.456, 0.365, 0.543, 0.492],$ $\sigma_1 = [1.071, 1.031, 1.004, 1.052, 0.926]$	$\tilde{\mu}_1(\mathbf{x}_0) = 1.84 \times 10^{-5}$	$f_1(\mathbf{x}_0) = 1.2837$
2	$v_2 = [0.590, 0.401, 0.269, 0.170, 0.334],$ $\sigma_2 = [1.005, 0.948, 1.091, 0.998, 0.903]$	$\tilde{\mu}_2(\mathbf{x}_0) = 8.74 \times 10^{-3}$	$f_2(\mathbf{x}_0) = -0.9472$
3	$v_3 = [0.548, 0.806, 0.700, 0.894, 0.649],$ $\sigma_3 = [1.029, 0.929, 1.113, 1.029, 1.004]$	$\tilde{\mu}_3(\mathbf{x}_0) = 1.10 \times 10^{-2}$	$f_3(\mathbf{x}_0) = 0.5631$
4	$v_4 = [0.431, 0.403, 0.651, 0.401, 0.308],$ $\sigma_4 = [1.023, 0.998, 0.931, 0.981, 0.986]$	$\tilde{\mu}_4(\mathbf{x}_0) = 1.53 \times 10^{-2}$	$f_4(\mathbf{x}_0) = -1.2048$
5	$v_5 = [0.776, 0.371, 0.676, 0.225, 0.598],$ $\sigma_5 = [1.111, 0.940, 0.929, 0.891, 1.076]$	$\tilde{\mu}_5(\mathbf{x}_0) = 9.57 \times 10^{-1}$	$f_5(\mathbf{x}_0) = 1.0417$
6	$v_6 = [0.410, 0.479, 0.465, 0.132, 0.783],$ $\sigma_6 = [0.903, 1.103, 0.955, 1.076, 1.038]$	$\tilde{\mu}_6(\mathbf{x}_0) = 2.70 \times 10^{-3}$	$f_6(\mathbf{x}_0) = -0.7183$
7	$v_7 = [0.376, 0.464, 0.514, 0.502, 0.291],$ $\sigma_7 = [0.966, 1.013, 1.014, 0.922, 1.068]$	$\tilde{\mu}_7(\mathbf{x}_0) = 4.81 \times 10^{-3}$	$f_7(\mathbf{x}_0) = 0.3359$

表中数据可借助模糊语言转换为人类易于理解的语义形式。例如,第五条规则所对应的5个中心点[0.776, 0.371, 0.676, 0.225, 0.598]可以描述为[很高、低、高、很低、中],规则5的激活强度较大,说明此时患者样本 \mathbf{x}_0 与该语义规则的匹配度较高,若使用F1表示特征1的值,F2表示特征2的值,此时的规则5可以表示为式(29)中易于理解的形式。规则激活强度与后件参数输出的加权和为TSK模糊分类器的预测值,只考虑当前5个特征时输出结果约为1.001,即该患者样本 \mathbf{x}_0 检测为癫痫发作。显然,前件参数的向量形式反映了各特征的重要性,模糊规则的语义描述则将其转化为可读的自然语言形式。规则的激活强度衡量了样本与规则语义之间的匹配程度,从而揭示了规则层面的语义可解释性,而后件参数表征了各条规则在最终决策中所起的相对作用,体现出各条规则的重要性。

IF(F1 is very high)And(F2 is low)And(F3 is high)And(F4 is very low)And(F5 is medium), THEN $f_5(\mathbf{x}_0) = 1.0417$ (29)

结束语 本文提出了一种基于多尺度多粒度解耦蒸馏的TSK模糊分类器MMDD-TSK-FC,并将其应用于癫痫脑电信号识别。MMDD-TSK-FC通过将不同尺度的1D-CNN教师模型的特征表示能力进行解耦蒸馏,并迁移至具有多粒度结构的TSK-FC学生模型,实现了对输入数据局部与全局特征的有效提取。最终,模型以由繁至简的IF-THEN模糊规则形式表达,较传统深度模型提供了更强的可解释性。同时,借助高效的知识迁移机制,MMDD-TSK-FC在同类模型中展现出领先的泛化性能。尽管本文提出的MMDD-TSK-FC模型在癫痫脑电信号检测任务中展现出良好的性能和可解释性,但由于脑电信号采集设备型号差异以及脑电数据的稀缺,当前检测模型对数据一致性依赖较大,可能在处理非平稳信号或分布不均的特征时表现出适应性不足的问题,面临一定的推广难度。

未来的研究工作将从以下两个方向展开:探索可学习的隶属函数结构,使模型能根据数据规模动态调整模糊划分,提高对复杂特征分布的适应能力;其次,将模型扩展应用于跨模态任务或小样本学习等更具挑战性的实际应用场景,以进一

步验证其通用性与实用价值,以促进其在临床上的广泛运用。


参考文献

- [1] SHARMA R, MEENA H K. Emerging trends in EEG signal processing: A systematic review[J]. SN Computer Science, 2024, 5(4): 415.
- [2] ZHENG Y, DING J, LIU F, et al. Adaptive neural decision tree for EEG based emotion recognition[J]. Information Sciences, 2023, 643: 119160.
- [3] TANG X, WANG T, DU Y, et al. Motor imagery EEG recognition with KNN-based smooth auto-encoder[J]. Artificial Intelligence in Medicine, 2019, 101: 101747.
- [4] ZHANG C Y, LI Z X, CAO J D. Network intrusion detection based on random k-nearest neighbor ensemble algorithm[J]. Journal of Nantong University(Natural Science Edition), 2023, 22(3): 26-32.
- [5] ABHISHEK S, KUMAR S, MOHAN N, et al. EEG based automated detection of seizure using machine learning approach and traditional features[J]. Expert Systems with Applications, 2024, 251: 123991.
- [6] 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.
- [7] ANITA M, KOWSHALYA A M. Automatic epileptic seizure detection using MSA-DCNN and LSTM techniques with EEG signals[J]. Expert Systems with Applications, 2024, 238: 121727.
- [8] XU B, YANG G. Interpretability research of deep learning: A literature survey[J]. Information Fusion, 2025, 115: 102721.
- [9] JIANG Y, DENG Z, CHUNG F L, et al. Recognition of epileptic EEG signals using a novel multiview TSK fuzzy system[J]. IEEE Transactions on Fuzzy Systems, 2016, 25(1): 3-20.
- [10] DENG Z, XU P, XIE L, et al. Transductive joint-knowledge-transfer TSK-FC for recognition of epileptic EEG signals[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(8): 1481-1494.

- [11] SUN S, REN W, LI J, et al. Logit standardization in knowledge distillation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2024;15731-15740.
- [12] GU X, CHENG X. Distilling a deep neural network into a Takagi-Sugeno-Kang fuzzy inference system[J]. arXiv;2010. 04974, 2020.
- [13] JIANG Y, WENG J, ZHANG X, et al. A CNN-based born-again TSK fuzzy classifier integrating soft label information and knowledge distillation [J]. IEEE Transactions on Fuzzy Systems, 2022, 31(6):1843-1854.
- [14] YAN Z, LOW W F, CHEN Y, et al. Multi-scale 3d gaussian splatting for anti-aliased rendering [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2024;20923-20931.
- [15] XIE J, XIANG X, XIA S, et al. MGNR: A multi-granularity neighbor relationship and its application in KNN classification and clustering methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12):7956-7972.
- [16] XU J, LI Z, DU B, et al. Reluplex made more practical: Leaky ReLU[C]// 2020 IEEE Symposium on Computers and communications (ISCC). IEEE, 2020;1-7.
- [17] BIAN K, PRIYADARSHI R. Machine learning optimization techniques: a Survey, classification, challenges, and Future Research Issues[J]. Archives of Computational Methods in Engineering, 2024, 31(7):4209-4233.
- [18] DING X, ZHANG X, HAN J, et al. Scaling up your kernels to 31×31 : Revisiting large kernel design in cnns[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022;11963-11975.
- [19] XU A L, ZHU Y M, SUN Q, et al. Deep Learning Air Quality Forecast with Divided Area Based on K-means[J]. Journal of Nantong University(Natural Science Edition), 2021, 20(3):49-56.
- [20] PEDRYCZ W. Federated FCM: Clustering under privacy requirements[J]. IEEE Transactions on Fuzzy Systems, 2021, 30(8):3384-3388.
- [21] XU H, TIAN Y, REN H, et al. A lightweight channel and time attention enhanced 1D CNN model for environmental sound classification[J]. Expert Systems with Applications, 2024, 249:123768.
- [22] SHI Z, WU D, GUO C, et al. FCM-RDpA: TSK fuzzy regression model construction using fuzzy C-means clustering, regularization, Droprule, and Powerball Adabelief [J]. Information Sciences, 2021, 574:490-504.
- [23] XU P, DENG Z, WANG J, et al. Transfer representation learning with TSK fuzzy system[J]. IEEE Transactions on Fuzzy Systems, 2019, 29(3):649-663.
- [24] TIAN X B, DENG Z H, WANG S T. Multi-view Epilepsy Detection Algorithm Combining Deep and Shallow Features[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(10):1712-1726.
- [25] ZHANG X, YIN Z, JIANG Y, et al. Fuzzy knowledge distillation from high-order TSK to low-order TSK[J]. arXiv;2302.08038, 2023.
- [26] 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.
- [27] 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, 2001, 64(6):061907.
- [28] SAMEER M, GUPTA B. Detection of epileptical seizures based on alpha band statistical features[J]. Wireless Personal Communications, 2020, 115(2):909-925.
- [29] RAHMAN R, VARNOSFADERANI S M, MAKKE O, et al. Comprehensive analysis of EEG datasets for epileptic seizure prediction[C]// 2021 IEEE International Symposium on Circuits and Systems (ISCAS). IEEE, 2021;1-5.
- [30] SHYU K K, HUANG S C, LEE L H, et al. A low complexity estimation method of entropy for real-time seizure detection[J]. IEEE Access, 2023, 11:5990-5999.
- [31] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7):1527-1554.



JIANG Yunliang, born in 1967, Ph.D., professor, Ph.D supervisor. His main research interests include deep learning, intelligent transportation, intelligent healthcare and smart education.



ZHANG Xiongtao, born in 1984, Ph.D., associate professor. His main research interests include artificial intelligence, pattern recognize and machine learning.

(责任编辑:何杨)