

面向脉搏波信号分类的可信增量集成学习

张成龙¹⁾ 张大鹏¹⁾ 戴世成¹⁾ 李锦兴²⁾ 丁世飞³⁾

¹⁾(香港中文大学(深圳)数据科学学院 广东 深圳 518172)

²⁾(哈尔滨工业大学(深圳)计算机科学与技术学院 广东 深圳 518055)

³⁾(中国矿业大学计算机科学与技术学院/人工智能学院 江苏 徐州 221116)

摘 要 中医数字化研究表明,脉搏波等医学生物特征与人体健康状态密切相关。然而,脉搏波信号采集过程中易产生噪声和异常值,提高数据不确定场景下的疾病诊断鲁棒性,对于人体健康计算具有重要应用价值。增量集成学习模型能够通过迭代拟合分类器残差,有效降低单模型偏差与方差,增强模型在决策边界区域的判别能力。因此,针对基于脉搏波信号的疾病诊断问题,本文提出一种基于随机配置网络的可信增量集成学习模型(Trustworthy Incremental Ensemble Classification Method With Stochastic Configuration Networks, TIEL-SCN)。首先, TIEL-SCN 以数据依赖的随机配置网络(Stochastic Configuration Networks, SCNs)为弱分类器,利用残差驱动的可信增量集成学习框架迭代拟合弱分类器残差,以提升预测性能。其次,可信增量集成学习框架通过将弱分类器输出概率分布映射为隶属度、非隶属度,利用直觉模糊理论计算综合置信度,进而生成基本概率分配(Basic Probability Assignment, BPA),借助证据理论(Dempster-Shafer Theory, DST)增量融合弱分类器输出,实现不确定性样本的鲁棒建模。最后,在真实脉搏波疾病数据集上的实验结果表明, TIEL-SCN 相比于 SOTA 随机学习模型以及集成学习模型具有更高的泛化性能和分类精度。

关键词 随机配置网络;集成学习;D-S 证据理论;增量学习;疾病诊断

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2026.02076

Trustworthy Incremental Ensemble Classification Method for Pulse Wave Signals

ZHANG Cheng-Long¹⁾ ZHANG David¹⁾ DAI Shi-Cheng¹⁾ LI Jin-Xing²⁾ DING Shi-Fei³⁾

¹⁾(School of Data Science, The Chinese University of Hong Kong, Shenzhen, Guangdong 518172)

²⁾(School of Computer Science and Technology, Harbin Institute of Technology (Shenzhen), Shenzhen, Guangdong 518055)

³⁾(School of Computer Science and Technology/School of Artificial Intelligence,
China University of Mining and Technology, Xuzhou, Jiangsu 221116)

Abstract With the widespread adoption of artificial intelligence (AI), its integration into the digitization of traditional Chinese medicine (TCM) has become an increasingly important research topic. Recent studies in digital TCM have shown that pulse wave signals are closely associated with multiple aspects of human health and can support the diagnosis of conditions such as diabetes, hypertension, hyperlipidemia, cardiovascular disorders, pulmonary diseases, and kidney diseases. Pulse diagnosis devices can acquire high-precision pulse wave signals rapidly, conveniently, and cost-effectively, without causing harm or discomfort, which makes large-scale screening and long-term monitoring feasible in clinical practice and community-level health management pro-

收稿日期:2025-11-19;在线发布日期:2026-03-25。本课题得到国家自然科学基金(62272133、62276265、62576344)资助。张成龙,博士,博士后,中国计算机学会(CCF)会员,主要研究领域为医学生物特征识别、粒计算、随机学习算法。E-mail: zhangchl1992@qq.com。张大鹏(通信作者),博士,教授,博士生导师,主要研究领域为图像处理、模式识别、机器学习、生物特征识别。E-mail: davidzhang@cuhk.edu.cn。戴世成,博士研究生,主要研究领域为多视图学习、图学习、生物特征识别。李锦兴(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)会员,主要研究领域为深度学习、生物特征识别。E-mail: lijinxing158@gmail.com。丁世飞,博士,教授,博士生导师,中国计算机学会(CCF)杰出会员,主要研究领域为粒计算、智能信息处理、模式识别、机器学习、数据挖掘。

grams for diverse populations. When combined with reliable diagnostic indicators from Western medicine, pulse-based analysis can significantly contribute to computational health assessment. However, pulse wave acquisition is susceptible to noise and outliers. In practice, signal quality can be affected by inter-subject variability, sensor placement and contact pressure, motion artifacts, and device/environmental differences. These factors may distort waveform morphology and can also introduce uncertain or incorrect labels, making learning-based diagnosis unstable in real-world deployment. Enhancing the robustness of pulse wave modeling under uncertainty is therefore crucial for practical health computing applications. Incremental ensemble learning can iteratively fit classifier residuals, thereby reducing the bias and variance of individual models and improving discrimination near decision boundaries. Nevertheless, conventional residual-driven ensembles may repeatedly emphasize samples with large residuals without distinguishing informative hard samples from noisy or conflicting ones, which can lead to error accumulation. Moreover, many ensemble fusion strategies do not explicitly model the credibility of each weak learner at the sample level; consequently, low-confidence outputs may still dominate residual updates and degrade stability. To address these issues in pulse wave - based disease diagnosis, we propose a Trustworthy Incremental Ensemble Learning method based on Stochastic Configuration Networks (TIEL-SCN). First, TIEL-SCN employs data-dependent stochastic configuration networks (SCNs) as weak classifiers within a residual-driven incremental learning framework to progressively fit residuals and improve predictive performance. Second, to explicitly represent uncertainty, the proposed framework transforms each weak classifier's probabilistic outputs into membership and non-membership degrees, reflecting both support for a target class and the strength of the most competitive incorrect class. Based on intuitionistic fuzzy set theory, a comprehensive confidence score is computed to quantify the reliability of each prediction. Using this confidence, TIEL-SCN constructs basic probability assignments (BPAs) that allocate belief to specific classes as well as to an uncertainty set, enabling the model to express hesitation rather than forcing ambiguous samples into a single class. The BPAs are then incrementally fused via Dempster - Shafer theory (DST), which alleviates conflicts among weak learners and reduces the influence of unreliable evidence. Finally, the fused evidence guides residual updates in subsequent iterations, improving robustness to noise and outliers throughout the learning process. Experiments on real pulse wave datasets covering diabetes, hypertension, hyperlipidemia, cardiovascular disorders, pulmonary disease, and kidney diseases, as well as a multi-disease classification setting, demonstrate that TIEL-SCN achieves better generalization and higher classification accuracy than existing randomized learning methods and ensemble baselines, particularly under different levels of label noise.

Keywords stochastic configuration network; ensemble learning; Dempster-Shafer theory; incremental learning; disease diagnosis

1 引言

近年来“人工智能+医疗卫生”应用发展背景下,新一代人工智能深度赋能传统中医诊疗设备,提升了脉诊仪等智能中医设备的信号感知能力,使其能够快速便捷、低成本、无损伤、无疼痛地获取高精

度脉搏波信号,结合精准的西医诊断标记,能够为疾病低成本无创筛查与风险预警提供便利,为促进中西医融合、破解医疗资源区域分配不均问题,开展居家养老安全风险预警和防范服务,实现人工智能在健康管理、健康监测、健康照护等方面应用创造了可能^[1-3]。

随机向量函数链接神经网络(Random Vector

Functional Link Neural Network, RVFL)^[4-5]、宽度学习系统(Broad Learning System, BLS)^[6]以及随机配置网络(Stochastic Configuration Networks, SCNs)^[7-8]等基于随机权重的轻量化神经网络具有良好的学习效率和泛化性能,易于与卷积神经网络^[9]、图神经网络(Graph Neural Networks, GNNs)^[10]等网络架构结合,得到了广泛的应用与发展^[11-12]。其中,随机配置网络能够在较少人为干预下,通过不等式约束自适应地选择随机参数,增量构造神经网络架构,易于部署在可穿戴医疗设备^[13]。为提升 SCN 性能,Yan 等分析了 SCN 在收敛性、全局逼近能力等方面的局限,结合增量训练与正交投影,提出了贪心 SCN 及其变体^[14]。Qiu 等利用动态粒化机制自适应处理不确定性回归数据,提出了粒度 SCN 模型^[15]。Ding 等面向含有噪声的标签缺失场景,提出了鲁棒半监督 SCN 模型^[16]。Guo 等针对不确定性分类任务,设计了基于直觉模糊的监督机制,提出了直觉模糊 SCN 模型,提升了二分类任务的鲁棒性^[17]。

在医疗数据分析场景,Banik 等针对结直肠癌息肉分割任务设计了一种深度分层 BLS 模型^[18]。Guo 等针对医疗数据类不平衡以及概念漂移场景,提出了一种基于集成自训练的鲁棒半监督 BLS 模型^[19]。Fan 等针对心电图波形形态差异及类不平衡问题,提出了基于领域自适应的类特定加权 BLS 模型^[20]。Dai 等针对多视角脉搏波数据融合,提出了一种基于模糊 SCN 的深度典型相关分析模型^[21]。其中,脉搏波信号感知易受个体差异、测量噪声以及姿态变化等人为因素影响,呈现非线性、非平稳特性^[21]。神经网络集成能够有效结合多个神经网络模型个体的能力,降低单个模型过拟合的风险^[22-23],基于随机权重的神经网络集成有利于进一步提升集成模型的学习效率^[24]。

现阶段,随机神经网络集成可根据集成学习策略划分如下:鉴于 Bootstrap 采样能够从原始训练集反复抽取不同的训练子集,训练子集的差异可以减少基模型的方差,从而提升集成模型泛化性。Lu 等基于 Bootstrap 采样策略,构建了面向区间预测(Prediction Intervals, PI)任务集成鲁棒随机配置网络架构^[25-27]。Guo 和 Chen 面向不完备标注场景,并行训练多个 BLS 模型投票生成伪标签,提升了半监督学习的性能^[28]。Miao 等提出了基于 Shapley 值特征选择的集成宽度学习系统,利用近似 Shapley 值评估特征贡献进行特征筛选,通过对弱分类器加权投票构建集成模型^[29]。鉴于集成深度学习

能够充分利用深度神经网络高阶表征信息,提升深度模型判别性能,Shi 等提出了基于随机权重的集成深度学习模型,根据各级隐含层输出分别构建基模型,结合 Voting 等集成学习策略进行决策^[30]。随后,Hu 等结合 Boosting 和模糊学习系统,设计了面向回归任务的集成深度随机向量函数链接神经网络^[31]。Sajid 等通过引入模糊学习系统,提升了集成深度随机向量函数链接神经网络的鲁棒性^[32]。Zhang 等针对基于语音的抑郁症识别问题,设计了图直觉模糊深度集成随机配置网络,提升了含有噪声的二分类问题鲁棒性^[33]。负相关学习(Negative Correlation Learning, NCL)能够保持方差和偏差不变的前提下,降低各模型间的协方差,提升集成模型泛化性能^[34],Alhamdoosh 和 Wang^[35]首次提出了基于随机权重的负相关集成神经网络。Wang 和 Cui^[36]设计了面向异构特征学习的神经网络集成框架。Zhang 等^[37]针对不确定性回归任务,提出了基于加权负相关学习的鲁棒集成随机配置网络。为进一步提升基于负相关学习的随机神经网络泛化性,Zhang 等^[38]提出了一种面向回归任务的 Boosting NCL 策略,提升了模型的回归性能。堆叠结构作为一种集成学习和深度学习的混合范式,有利于平滑决策边界,增强模型对未见数据的泛化能力^[39]。为提升模型多样性、准确性和泛化能力,Yun 等构建了一种融合 AdaBoost 与 Stacking 的层次集成框架,并利用 BLS 的增量学习能力来动态优化基分类器^[40]。上述随机神经网络集成模型通过 Bagging、Boosting、负相关学习和堆叠等集成学习策略有效提升了模型多样性与泛化能力,但对少数类、边界样本的识别与处理能力不足。

基于残差学习的随机神经网络集成,通过逐轮拟合当前模型的残差或负梯度方向,有利于增强对边界区域的刻画能力,实现对决策边界不确定性的自适应建模,为提升随机神经网络在复杂判别任务中的性能提供了新的解决方案。Gao 等提出了基于残差学习的深度随机函数向量链接模型,通过每个隐含层逐步学习前一层的残差,修正预测误差,并通过堆叠集成架构实现了多模型的融合决策^[41]。Huang 等针对复杂场景的图像分类任务,提出了融合多视角特征的残差堆叠宽度学习系统,基于几何不变性、类内相似性与高语义特征,逐步拟合增强层残差^[42]。Xie 等通过双重堆叠多个基分类器,结合残差传递和简单线性模型传输,提升了集成模型泛化能力^[43]。Yu 等基于随机映射生成特征节点,利

根据式(3)不等式约束,选择 $\xi_{L,q} \geq 0$ 且使得式(4) ξ_L 最大的候选参数作为节点 L 的参数:

$$\xi_{L,q} = \frac{\langle \mathbf{e}_{L-1,q}, \mathbf{h}_L \rangle^2}{\langle \mathbf{h}_L, \mathbf{h}_L \rangle} - (1 - \mu_L - r) \langle \mathbf{e}_{L-1,q}, \mathbf{e}_{L-1,q} \rangle \quad (3)$$

$$\xi_L = \sum_{q=1}^C \xi_{L,q}, q = 1, 2, \dots, C \quad (4)$$

式中, $\mu_L \leq (1 - r)$; $0 < r < 1$ 表示收缩因子。

为加速模型收敛,采取式(5)全局最小二乘更新 SCN 输出权重 β :

$$\beta = \underset{\beta}{\operatorname{argmin}} \| \mathbf{H}\beta - \mathbf{Y} \|_2^2 = \mathbf{H}^+ \mathbf{Y} \quad (5)$$

式中, $\beta = [\beta_1, \beta_2, \dots, \beta_L]^T$, $\beta_L = [\beta_{L,1}, \beta_{L,2}, \dots, \beta_{L,C}]$; $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_L]$ 表示隐含层输出矩阵, $\mathbf{H}^+$ 表示 $\mathbf{H}$ 的摩尔-彭若斯(Moore-Penrose)广义逆。

2.2 D-S 证据理论

D-S 证据理论(Dempster-Shafer Evidence Theory, DS)是一种不确定性推理框架,主要用来在多个来源的证据下进行信息融合,相关定义如下^[46-47]:

辨识框架(Frame of Discernment): $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ 表示所研究问题的所有可能的、互斥且完备的假设的集合,则识别框架的幂集为 $2^\Theta = \{A \mid A \subseteq \Theta\}$, 其中每个子集 A 称为命题。

基本概率分配(Basic Probability Assignment, BPA): 若 $m: 2^\Theta \rightarrow [0, 1]$, 满足 $m(\emptyset) = 0$, $\sum_{A \subseteq \Theta} m(A) = 1$, 则 m 称为辨识框架 Θ 上的基本概率分配函数。

信任函数(Belief Function): 表示 A 的全部子集的 BPA 之和, $Bel(A) = \sum_{B \subseteq A} m(B)$, $\forall A \subseteq \Theta$ 。

似然函数(Plausibility Function): 表示所有与 A 相交的子集的 BPA 之和, 代表不否认 A 的信任度:

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \forall A \subseteq \Theta \quad (6)$$

不确定性区间: 对子集 A , $[Bel(A), Pl(A)]$ 表示可信度的上下界。区间宽度 $Pl(A) - Bel(A)$ 反映不确定性程度。

Dempster 组合规则: 对于任意 $A \subseteq \Theta$, 识别框架 Θ 上具有有限多个基本概率分配函数 $m_1, m_2, \dots, m_n$, 组合规则定义为

$$(m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = \frac{1}{K} \sum_{A_1 \cap A_2 \cap \dots \cap A_n = A} m_1(A_1) m_2(A_2) \dots m_n(A_n) \quad (7)$$

$$K = \sum_{A_1 \cap A_2 \cap \dots \cap A_n \neq \emptyset} m_1(A_1) m_2(A_2) \dots m_n(A_n) = 1 - \sum_{A_1 \cap A_2 \cap \dots \cap A_n = \emptyset} m_1(A_1) m_2(A_2) \dots m_n(A_n) \quad (8)$$

式中, K 表示冲突系数。

3 基于 SCN 的可信增量集成学习

3.1 研究动机

在疾病信号感知过程中,采集数据易因个体差异、人为操作不规范、姿态变换、标记失误等问题产生不同程度的噪声,从而降低模型的泛化性能。脉搏波信号作为时序生理信号,存在一定的流形结构与非欧几里得分布特性,人工特征提取过程中易丢失全局结构信息。基于残差的集成学习框架能够通过迭代拟合残差信息,能够持续刻画样本中未被解释的误差,增强对边界区域的样本的判别能力,为复杂信号的表征学习提供了新途径。然而,基于残差的集成学习框架对异常值和噪声样本较为敏感,缺乏对预测不确定性的显式建模,且在衡量和处理基分类器间冲突方面存在不足。因此,为有效提升随机神经网络集成鲁棒性能,提高脉搏波信号分类准确率,本节设计了一种基于随机配置网络的可信增量集成学习模型(Trustworthy Incremental Ensemble Classification Method With Stochastic Configuration Networks, TIEL-SCN)。TIEL-SCN 在每轮弱学习器预测后,先将输出概率映射为基本概率分配(BPA),再与历史累积的全局 BPA 通过 D-S 组合规则融合,以保留样本类别的不确定性信息,并用融合后的结果指导残差计算,从而提高集成过程的稳健性并改善整体收敛特性。TIEL-SCN 框架如图 2 所示,包括 1) 以 SCN 为弱分类器,根据残差信息迭代训练弱分类器,增量构建集成学习框架。2) 基于证据理论的可信增量集成学习,根据弱分类器残差信息计算直觉模糊置信度,利用证据理论增量融合弱分类器输出,以实现不确定性样本的鲁棒决策。

3.2 算法设计

3.2.1 基于直觉模糊的不确定性度量

给定训练集 $\mathbf{D} = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$, 假设集成模型由 M 个 SCN 弱分类器组成,借助残差机制逐轮拟合上一轮残差,进而强化模型对决策边界样本和难分类样本的刻画能力,定义第 k 个 SCN 弱学习器为

$$\mathbf{f}^{(k)} = \text{SCN}(\mathbf{X}, \text{residuals}^{(k-1)}) \quad (9)$$

式中, $\text{SCN}(\cdot)$ 表示弱分类器训练过程; $\text{residuals}^{(k-1)}$ 表示第 $k-1$ 个 SCN 弱学习器的训练残差,初始残差 $\text{residuals}^{(0)} = \mathbf{Y}$ 。

根据 SCN 弱分类器输出,定义当前集成模型累积输出为




图2 基于随机配置网络的可信增量集成学习模型

$$\mathbf{O}^{(k)} = \sum_{\ell=1}^k \mathbf{f}^{(\ell)}(\mathbf{X}) \in \mathbb{R}^{N \times C} \quad (10)$$

为保证各类别预测得分处于同一可比尺度,根据式(10)对预测结果进行归一化,得到式(11)概率矩阵:

$$\mathbf{p}_{i,c}^{(k)} = \frac{\exp(\mathbf{O}_{i,c}^{(k)})}{\sum_{c=1}^C \exp(\mathbf{O}_{i,c}^{(k)})}, \mathbf{p}_i^{(k)} = [p_{i,1}^{(k)}, p_{i,2}^{(k)}, \dots, p_{i,C}^{(k)}] \quad (11)$$

式中, $p_{i,c}^{(k)}$ 表示第 i 个样本在第 k 轮迭代中被预测为类别 c 的概率。

多分类场景,若仅以真实类概率/预测类概率 $p_{i,A}^{(k)}$ 为置信度,易忽略 $p_{i,A}^{(k)}$ 相同但错误类竞争强度不同的情形,导致难以区分“边界型不确定性”与“噪声/冲突驱动的不确定性”。为实现噪声与异常样本场景下的可信增量集成,刻画“边界型不确定性”与“噪声/冲突驱动的不确定性”,基于直觉模糊集(Intuitionistic Fuzzy Set, IFS)理论将弱分类器输出概率转换为隶属度 $u_i^{(k)}$ 和非隶属度 $v_i^{(k)}$ 如式(12):

$$u_i^{(k)} = p_{i,A}^{(k)}, v_i^{(k)} = p_{i,\bar{A}}^{(k)} = \max_{c \neq A} p_{i,c}^{(k)} \quad (12)$$

式中, $u_i^{(k)}$ 表示“支持真类”的隶属度; $v_i^{(k)}$ 表示“支持最强错误类”的非隶属度。

定义直觉模糊置信度如式(13),将概率空间的局部竞争结构映射为可用于证据分配的可信度量,使低可信样本能够被显式降权或分配更多不确定性质量^[50-51]:

$$\mathbf{C}_i^{(k)} = \frac{1 - v_i^{(k)}}{(1 - \mu_i^{(k)}) + (1 - v_i^{(k)})} \quad (13)$$

式中, $1 - v_i^{(k)}$ 表示去除错误类别概率后的有效信息量; $(1 - \mu_i^{(k)}) + (1 - v_i^{(k)})$ 表示所有类别剩余不确定信息量。

根据式(13)置信度,定义不确定性度量如式

(14):

$$u_i^{(k)} = \chi(1 - \mathbf{C}_i^{(k)}), \chi \in [0, 1] \quad (14)$$

式中, $u_i^{(k)}$ 表示置信度的加权补集,代表无法分配给某一类别的概率质量,对应分配给不确定集合 Θ 的质量, χ 表示不确定性权重调整系数,用于保证高置信样本在融合中占据更大权重,而低置信样本被赋予更多不确定性质量。

3.2.2 Dempster-Shafer 证据融合

根据概率与不确定性度量,可将样本 i 在第 k 轮迭代的预测结果映射为基本概率分配(BPA),包括:真实类别 c 、不确定集合 Θ ^[46-49]:

$$\begin{cases} m_i^{(k)}(c) = p_{i,A}^{(k)} \cdot (1 - u_i^{(k)}) \\ m_i^{(k)}(\Theta) = u_i^{(k)} \end{cases} \quad (15)$$

并满足:

$$\sum_{c=1}^C m_i^{(k)}(\{c\}) + m_i^{(k)}(\Theta) = 1 \quad (16)$$

设第 $k-1$ 轮迭代的全局 BPA 为 $\mathbf{m}_{\text{global}}^{(k-1)}$, 当前第 i 个样本在第 k 轮的 BPA 为 $\mathbf{m}_i^{(k)}$, 根据 Dempster-Shafer 组合规则,融合当前样本证据与全局证据,定义样本 i 的融合结果为

$$\mathbf{m}_{\text{global}}^{(k)}(A) = \frac{\sum_{Y \cap Z = A} \mathbf{m}_{\text{global}}^{(k-1)}(\mathbf{Y}) \cdot \mathbf{m}_i^{(k)}(\mathbf{Z})}{1 - K} \quad (17)$$

其中,冲突系数定义为

$$K = \sum_{Y \cap Z = \emptyset} \mathbf{m}_{\text{global}}^{(k-1)}(\mathbf{Y}) \cdot \mathbf{m}_i^{(k)}(\mathbf{Z}) \quad (18)$$

最后,融合所有样本的结果取均值得到新的全局 BPA 如式(19):

$$\mathbf{m}_{\text{global}}^{(k)} = \frac{1}{N} \sum_{i=1}^N \mathbf{m}_i^{(k)} \quad (19)$$

Dempster 融合通过冲突系数归一化分配,能有效缓冲不同弱分类器证据冲突带来的错误传播,尤其适用于噪声样本和不确定性样本的鲁棒集成。

3.2.3 残差更新

在完成第 k 轮弱分类器的 Dempster-Shafer 证据融合后,可获得全局融合的基本概率分配 BPA:

$$\mathbf{m}_{\text{global}}^{(k)} = [m_{\text{global},1}^{(k)}, m_{\text{global},2}^{(k)}, \dots, m_{\text{global},C}^{(k)}, m_{\text{all},\Theta}^{(k)}] \quad (20)$$

式中, $m_{\text{global},j}^{(k)}$ 表示融合后对真实类别 j 的支持质量, $m_{\text{all},\Theta}^{(k)}$ 表示分配给不确定集合 Θ 的质量值。

由于不确定集合 Θ 不对应具体类别,其质量值无法作为后续弱分类器训练的直接监督信息。因此,首先剔除 Θ 部分,并对剩余类别的质量进行归一化处理,以确保融合概率向量满足概率和为 1:

$$\mathbf{p}_{\text{fuse}}^{(k)} = \left[\frac{m_{\text{global},1}^{(k)}}{S}, \frac{m_{\text{global},2}^{(k)}}{S}, \dots, \frac{m_{\text{global},C}^{(k)}}{S} \right] \quad (21)$$

$$S = \sum_{c=1}^C m_j^{(k)} \quad (22)$$

进一步得到融合概率向量:

$$\mathbf{p}_{\text{fuse}}^{(k)} = [p_{\text{fuse},1}^{(k)}, p_{\text{fuse},2}^{(k)}, \dots, p_{\text{fuse},C}^{(k)}] \quad (23)$$

式中, $\mathbf{p}_{\text{fuse}}^{(k)}$ 表示伪残差/伪梯度信号,刻画了“在证据融合后的概率空间中”对各类别的支持强度。

为了确定下一轮迭代中各样本的重点修正方向,以证据融合后的概率输出替代集成模型的概率输出,进而采用式(24)梯度计算策略将融合概率与真实标签进行比较,得到预测偏差。

$$\mathbf{g}_i^{(k)} = \mathbf{p}_{\text{fuse},i}^{(k)} - \mathbf{y}_i \quad (24)$$

式中,梯度反映了融合预测与真实标签之间的偏差程度。

基于梯度信息,将当前预测误差的反方向作为下一轮弱分类器的监督信号,优先修正证据融合后仍存在较大概率偏差的样本,以实现逐轮修正:

$$R_i^{(k)} = -\mathbf{g}_i^{(k)} \quad (25)$$

式中,负号确保下一轮模型输出趋向于减小当前预测与真实标签的差异。

3.3 收敛性分析

给定 One-Hot 标签矩阵 $\mathbf{Y}$, TIEL-SCN 第 k 轮输出概率矩阵为 $\mathbf{P}^{(k)}$, 第 k 轮预测误差为 $\mathbf{E}^{(k)} = \mathbf{Y} - \mathbf{P}^{(k)}$, 若存在常数 $\rho \in (0, 1)$, 对于所有样本 i 和迭代轮次 k , 使得可信融合概率 $\mathbf{T}(\mathbf{p}_i^{(k)})$ 满足式(26):

$$\|\mathbf{T}(\mathbf{p}_i^{(k)}) - \mathbf{y}_i\| \leq (1 - \rho) \|\mathbf{p}_i^{(k)} - \mathbf{y}_i\|, \forall i, k \quad (26)$$

式中, $\mathbf{T}(\mathbf{p}_i^{(k)})$ 表示经过可信融合后,预测概率向量被有界地“压缩”向真实标签方向。

TIEL-SCN 的预测误差将以指数速率收敛:

$$\|\mathbf{E}^{(k)}\|_F \leq (1 - \rho)^k \|\mathbf{E}^{(0)}\|_F \quad (27)$$

证明:考虑 TIEL-SCN 算法的迭代过程,在第 k 轮,模型基于证据融合后的概率与真实标签的残差进行更新,概率矩阵的更新可表示为

$$\mathbf{P}^{(k+1)} = \mathbf{P}^{(k)} + (\mathbf{Y} - \mathbf{T}(\mathbf{P}^{(k)})) \quad (28)$$

对于每个样本 i ,误差向量为 $\mathbf{e}_i^{(k)} = \mathbf{y}_i - \mathbf{p}_i^{(k)}$, 其误差向量的演化过程为

$$\begin{aligned} \mathbf{e}_i^{(k+1)} &= \mathbf{y}_i - \mathbf{p}_i^{(k+1)} \\ &= \mathbf{y}_i - [\mathbf{p}_i^{(k)} + (\mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)}))] \\ &= \mathbf{e}_i^{(k)} - (\mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)})) \end{aligned} \quad (29)$$

更新后误差向量的范数平方如式(30):

$$\begin{aligned} \|\mathbf{e}_i^{(k+1)}\|^2 &= \|\mathbf{e}_i^{(k)} - (\mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)}))\|^2 \\ &= \|\mathbf{e}_i^{(k)}\|^2 - 2\langle \mathbf{e}_i^{(k)}, \mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)}) \rangle \\ &\quad + \|\mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)})\|^2 \end{aligned} \quad (30)$$

由向量夹角的余弦定理及柯西-施瓦茨不等式,可得

$$\begin{aligned} \langle \mathbf{e}_i^{(k)}, \mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)}) \rangle &\geq \|\mathbf{e}_i^{(k)}\| \cdot \|\mathbf{y}_i - \mathbf{T}(\mathbf{p}_i^{(k)})\| \\ &\geq (1 - \rho) \|\mathbf{e}_i^{(k)}\|^2 \end{aligned} \quad (31)$$

误差向量的范数平方满足式(32):

$$\begin{aligned} \|\mathbf{e}_i^{(k+1)}\|^2 &\leq \|\mathbf{e}_i^{(k)}\|^2 - 2(1 - \rho) \|\mathbf{e}_i^{(k)}\|^2 + (1 - \rho)^2 \|\mathbf{e}_i^{(k)}\|^2 \\ &= [1 - 2(1 - \rho) + (1 - \rho)^2] \|\mathbf{e}_i^{(k)}\|^2 = \rho^2 \|\mathbf{e}_i^{(k)}\|^2 \end{aligned} \quad (32)$$

因此,对单个样本有 $\|\mathbf{e}_i^{(k+1)}\| \leq \rho \|\mathbf{e}_i^{(k)}\|$, 将所有 N 个样本的误差范数平方相加,可得全局误差矩阵的 Frobenius 范数平方:

$$\begin{aligned} \|\mathbf{E}^{(k+1)}\|_F^2 &= \sum_{i=1}^N \|\mathbf{e}_i^{(k+1)}\|^2 \leq \sum_{i=1}^N \rho^2 \|\mathbf{e}_i^{(k)}\|^2 \\ &= \rho^2 \|\mathbf{E}^{(k)}\|_F^2 \end{aligned} \quad (33)$$

因此,全局预测误差 $\|\mathbf{E}^{(k)}\|_F$ 随着迭代轮次 k 的增加而以指数速率收敛至零。

4 实验与分析

4.1 实验设计

4.1.1 实验数据

脉搏波数据来源于香港中文大学(深圳)先进生物特征识别研究中心^①,采集自多个不同的中医院,包括健康(Health)、糖尿病(Diabetes)、高血压(Hypertension)、高血脂(Hyperlipidemia)、心脏病(Heart Disease)、肺部疾病(Pulmonary Diseases)及肾病(Kidney Disease)。

^① 先进生物特征识别研究中心, <https://hw1761.huaweicloudsite.cn/col.jsp?id=103>。

其中,脉搏波采集系统采用三个相同的复合传感探头,覆盖寸、关、尺三个部位,每个探头均集成了灵敏度为 4 mV/kPa 的半导体压力传感器(包含 4 个全桥连接的通道)。脉搏波数据采样频率设定为 400 Hz,针对每位受试者的标准采集时长为 1 分钟,采集过程中探头施加的静态有效压力严格控制在 2 N(误差范围 $\pm 10\%$)。由于关脉在三个部位中通常表现出最大的搏动强度,其波形包含的形态学细节最为丰富,且由于解剖位置特性,其信号获取的稳定性与信噪比最佳,最能满足病理特征分析的需求,本研究选取位于桡骨茎突处的“关”脉信号作为主要分析对象。

在数据预处理阶段,针对原始信号采用了截止频率为 4 Hz 的低通滤波器,并应用基线校正算法消除由呼吸运动引发的周期性基线漂移,采用短时傅里叶变换(Short-Time Fourier Transform, STFT)从压力传感信号中提取脉搏波特征,构建了六个“健康 VS. 疾病”二分类任务以及“健康 VS. 糖尿病/高血压”多分类任务,数据集描述见表 1。

表 1 脉搏波数据集描述

数据集	健康样本数量	疾病样本数量	样本总数
健康 VS. 糖尿病	775	253	1028
健康 VS. 高血压	775	224	999
健康 VS. 高血脂	775	450	1225
健康 VS. 心脏病	775	444	1219
健康 VS. 肺部疾病	775	323	1098
健康 VS. 肾病	775	272	1047
健康 VS. 糖尿病/高血压	775	477	1225

4.1.2 参数设置

为验证 TIEL-SCN 的性能,实验选取多个具有代表性的随机学习模型作为对比算法,包括单隐含层随机神经网络模型 RVFL^[4]、SCN^[6];深度随机神经网络模型 DRVFL^[5]、DSCN^[7];集成深度随机神经网络模型 EDRVFL^[24]、Bagging-SCN^[52];轻量级梯度提升机 LightGBM(Light Gradient Boosting Machine)^[53]。

为保证各对比方法的性能,各模型相关超参数均通过五折交叉验证确定,每个模型在相同任务上独立运行 100 次,每次实验随机选取 75% 样本作为训练集,剩余 25% 样本用作测试,此外,为验证 TIEL-SCN 模型鲁棒性,随机选取 10%、20%、30% 和 40% 的训练数据标签进行翻转,记录平均 G-mean 和 F1-score 及其标准差作为实验结果。

相关实验模型主要参数设置如下:

(1)所有随机神经网络模型节点参数范围为

{25,50,...,175,200}。

(2)所有随机神经网络模型 L_2 正则化参数范围为 $\{10^{-10}, 10^{-9}, \dots, 10^9, 10^{10}\}$ 。

(3)TIEL-SCN 与 SCN、DSCN、Bagging-SCN 等模型收缩因子 r 和随机参数范围分别由集合 $\{0.9, 0.99, 0.999, 0.9999, 0.99999, 0.999999\}$ 和 $\{0.5, 1, 10, 30, 50, 80, 100, 150, 200\}$ 确定;随机节点候选次数 $T_{\max}$ 为 50;预设误差为 0.001。

(4)RVFL、SCN 采用单隐含层网络结构,DRVFL、DSCN、EDRVFL 采用深度神经网络结构,隐含层数量范围为 $\{1, 2, \dots, 9, 10\}$ 。

(5)TIEL-SCN、Bagging-SCN 弱分类器数量设置与 DRVFL、DSCN、EDRVFL 等深度神经网络结构一致,弱分类器数量范围为 $\{1, 2, \dots, 9, 10\}$ 。

(6)TIEL-SCN 不确定性权重系数 λ 搜索范围为 $\{0.1, 0.2, \dots, 0.9, 1\}$ 。

(7)LightGBM 树的数量 $n_{\text{estimators}}$ 为 $\{25, 50, \dots, 175, 200\}$; L_1/L_2 正则化参数的搜索范围为 $\{10^{-3}, 10^{-2}, \dots, 10^2, 10^3\}$;学习率搜索范围为 $\{0.005, 0.01, 0.05, 0.1\}$;树结构复杂度参数搜索范围 num_leaves 为 $\{15, 31, 63\}$, max_depth 为 $\{-1, 3, 5\}$ 。

4.2 实验结果分析

TIEL-SCN 和相关模型在七个“健康 VS. 疾病”分类任务上的平均 G-mean/F1-score 和标准差以及关键参数分别见表 2~表 8。

根据表 2~表 8 所示的实验结果可以看出, TIEL-SCN 在不同任务与不同噪声比例下的综合性能均显著优于其他对比模型,特别是在“健康 VS. 高血压”、“健康 VS. 高血脂”等噪声敏感任务中, TIEL-SCN 在高噪声比例下的平均 G-mean 和 F1-score 显著提升。其中,数据依赖的 SCN 整体性能均优于非数据依赖的 RVFL,展示了 SCN 基于监督机制增量构造神经网络架构的良好泛化性能。此外,DSCN 和 DRVFL 在 SCN 与 RVFL 的基础上引入了深层网络结构,通过多隐层配置增强了非线性表达能力,能够在一定程度上提升任务性能。然而,深层结构所带来的参数复杂度高和冗余表达,使其易在有限样本条件下发生过拟合,特别是在高噪声比例下,其性能波动幅度较大,稳定性不足。EDRVFL 采用集成深度结构,将各级隐含层输出分别构建为基模型,以及 Bagging-SCN 采用 Bootstrap 采样策略,以 SCN 为弱分类器,并结合投票 Voting 等集成学习策略进行决策,相较于 RVFL 和 DRVFL 在大部分任务上有一定性能提升,但总体增益有限,

表 2 相关模型在“健康 VS. 糖尿病”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=175, C=10^2$	$L=75, C=10^1$	$L=75, C=10^1$	$L=25, C=10^2$	$L=200, C=10^2$
	G-mean(%)	88.50 ± 2.44	88.52 ± 2.70	88.00 ± 2.74	86.00 ± 4.29	80.60 ± 8.25
	F1-score(%)	85.70 ± 2.56	85.13 ± 3.24	84.15 ± 3.28	81.81 ± 4.83	72.35 ± 9.60
SCN	参数	$L=50, C=10^{-9}$	$L=150, C=10^0$	$L=100, C=10^1$	$L=100, C=10^1$	$L=100, C=10^2$
	G-mean(%)	89.47 ± 2.33	89.38 ± 2.92	88.63 ± 2.80	87.17 ± 3.68	80.89 ± 8.93
	F1-score(%)	86.80 ± 2.50	86.21 ± 3.10	85.02 ± 3.20	82.87 ± 4.30	72.63 ± 9.60
DRVFL	参数	$L=150, H=10, C=10^1$	$L=125, H=9, C=10^2$	$L=200, H=8, C=10^2$	$L=100, H=6, C=10^2$	$L=125, H=9, C=10^2$
	G-mean(%)	89.14 ± 2.74	89.18 ± 2.23	88.26 ± 3.18	87.10 ± 4.04	82.11 ± 7.30
	F1-score(%)	86.46 ± 3.25	86.38 ± 2.58	85.11 ± 3.47	83.28 ± 4.66	74.55 ± 8.88
DSCN	参数	$L=150, H=5, C=10^{-1}$	$L=125, H=6, C=10^{-1}$	$L=125, H=5, C=10^{-1}$	$L=100, H=3, C=10^{-1}$	$L=125, H=7, C=10^{-1}$
	G-mean(%)	91.07 ± 2.00	89.52 ± 2.51	88.53 ± 2.97	87.48 ± 4.32	83.59 ± 5.55
	F1-score(%)	88.38 ± 3.10	86.90 ± 2.55	85.30 ± 3.52	83.53 ± 4.29	75.40 ± 8.73
EDRVFL	参数	$L=100, H=10, C=10^1$	$L=125, H=3, C=10^1$	$L=150, H=9, C=10^2$	$L=25, H=9, C=10^2$	$L=75, H=6, C=10^2$
	G-mean(%)	89.17 ± 2.11	89.89 ± 2.67	88.40 ± 3.11	87.11 ± 4.28	82.57 ± 7.01
	F1-score(%)	86.27 ± 2.42	86.94 ± 3.17	85.40 ± 3.56	83.30 ± 4.75	75.16 ± 7.63
Bagging-SCN	参数	$L=50, M=8$	$L=150, M=4$	$L=100, M=5$	$L=100, M=5$	$L=100, M=5$
	G-mean(%)	92.47 ± 2.33	92.16 ± 1.83	91.98 ± 2.11	89.86 ± 2.36	87.90 ± 3.53
	F1-score(%)	90.10 ± 2.60	89.40 ± 2.30	88.80 ± 2.60	85.90 ± 3.00	82.40 ± 4.20
LightGBM	参数	$n_estimators=200$	$n_estimators=75$	$n_estimators=125$	$n_estimators=150$	$n_estimators=175$
	G-mean(%)	90.73 ± 2.16	89.12 ± 2.53	88.61 ± 2.74	87.20 ± 3.61	82.41 ± 3.75
	F1-score(%)	88.32 ± 1.69	86.29 ± 2.08	85.41 ± 2.46	83.00 ± 3.25	74.78 ± 3.15
TIEL-SCN	参数	$L=50, M=10, \chi=0.1$	$L=150, M=5, \chi=0.3$	$L=100, M=6, \chi=0.4$	$L=100, M=5, \chi=0.5$	$L=175, M=9, \chi=0.8$
	G-mean(%)	93.13 ± 1.82	92.56 ± 1.86	92.21 ± 2.08	91.11 ± 2.36	88.23 ± 3.49
	F1-score(%)	90.90 ± 2.10	90.01 ± 2.20	88.90 ± 2.50	86.90 ± 2.90	82.80 ± 4.10

表 3 相关模型在“健康 VS. 高血压”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=125, C=10^{-1}$	$L=50, C=10^{-2}$	$L=25, C=10^1$	$L=150, C=10^1$	$L=75, C=10^2$
	G-mean(%)	76.22 ± 3.60	74.07 ± 4.36	73.31 ± 5.16	72.11 ± 6.53	67.91 ± 8.47
	F1-score(%)	68.12 ± 4.63	63.29 ± 5.25	64.31 ± 5.92	60.58 ± 7.73	52.80 ± 11.57
SCN	参数	$L=125, C=10^{-1}$	$L=175, C=10^{-1}$	$L=125, C=10^{-1}$	$L=150, C=10^1$	$L=175, C=10^1$
	G-mean(%)	79.21 ± 3.99	77.63 ± 3.57	75.32 ± 4.95	73.07 ± 6.29	69.53 ± 7.71
	F1-score(%)	70.73 ± 5.07	67.97 ± 4.53	66.50 ± 6.29	62.13 ± 7.99	55.30 ± 9.79
DRVFL	参数	$L=25, H=2, C=10^{-5}$	$L=125, H=4, C=10^{-2}$	$L=50, H=3, C=10^1$	$L=50, H=4, C=10^1$	$L=125, H=7, C=10^2$
	G-mean(%)	77.62 ± 3.99	75.85 ± 4.37	74.71 ± 4.63	71.94 ± 5.30	68.14 ± 10.30
	F1-score(%)	68.96 ± 5.03	66.32 ± 5.05	66.01 ± 5.34	61.25 ± 6.69	54.35 ± 12.28
DSCN	参数	$L=200, H=5, C=10^0$	$L=200, H=5, C=10^0$	$L=125, H=2, C=10^0$	$L=50, H=3, C=10^0$	$L=50, H=4, C=10^0$
	G-mean(%)	79.44 ± 3.64	77.36 ± 3.72	75.39 ± 4.73	72.92 ± 6.01	68.72 ± 9.84
	F1-score(%)	70.96 ± 4.62	67.70 ± 4.72	66.57 ± 6.00	61.98 ± 7.63	54.49 ± 10.42
EDRVFL	参数	$L=25, H=5, C=10^{-5}$	$L=75, H=10, C=10^{-1}$	$L=50, H=8, C=10^0$	$L=25, H=5, C=10^0$	$L=50, H=3, C=10^2$
	G-mean(%)	77.93 ± 4.03	76.17 ± 3.84	75.20 ± 4.56	72.44 ± 6.09	68.21 ± 9.91
	F1-score(%)	69.23 ± 5.07	67.50 ± 4.38	66.42 ± 5.53	61.85 ± 7.09	54.43 ± 12.81
Bagging-SCN	参数	$L=125, M=10$	$L=175, M=5$	$L=125, M=3$	$L=150, M=4$	$L=175, M=2$
	G-mean(%)	84.03 ± 2.65	82.58 ± 3.31	79.54 ± 3.38	79.59 ± 3.42	72.21 ± 5.74
	F1-score(%)	75.55 ± 3.37	72.92 ± 4.21	70.72 ± 4.30	68.65 ± 4.35	57.98 ± 7.29
LightGBM	参数	$n_estimators=150$	$n_estimators=150$	$n_estimators=150$	$n_estimators=150$	$n_estimators=175$
	G-mean(%)	81.29 ± 2.84	79.72 ± 2.96	77.99 ± 3.51	72.73 ± 4.16	67.88 ± 4.23
	F1-score(%)	73.11 ± 2.58	70.19 ± 2.64	69.48 ± 3.34	64.25 ± 3.92	53.26 ± 3.76
TIEL-SCN	参数	$L=175, M=10, \chi=0.6$	$L=175, M=9, \chi=0.3$	$L=175, M=8, \chi=0.1$	$L=175, M=9, \chi=0.5$	$L=175, M=5, \chi=0.5$
	G-mean(%)	84.10 ± 2.96	83.63 ± 3.25	81.99 ± 3.39	79.96 ± 3.36	72.99 ± 5.58
	F1-score(%)	75.62 ± 3.76	73.97 ± 4.13	73.17 ± 4.31	69.02 ± 4.27	58.76 ± 7.09

表 4 相关模型在“健康 VS. 高血脂”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=150, C=10^{-1}$	$L=50, C=10^{-1}$	$L=175, C=10^0$	$L=150, C=10^1$	$L=50, C=10^2$
	G-mean(%)	65.53±3.00	63.99±2.70	63.15±2.93	59.94±4.82	55.02±8.94
	F1-score(%)	56.97±3.79	54.99±3.29	54.05±4.20	49.01±8.19	41.58±14.31
SCN	参数	$L=50, C=10^0$	$L=25, C=10^{-5}$	$L=175, C=10^0$	$L=200, C=10^0$	$L=100, C=10^1$
	G-mean(%)	66.08±2.45	64.37±3.33	63.81±3.45	61.44±4.37	58.99±6.70
	F1-score(%)	57.71±3.06	55.58±4.34	54.69±4.78	51.10±6.98	46.51±10.98
DRVFL	参数	$L=200, H=5, C=10^0$	$L=50, H=8, C=10^0$	$L=200, H=4, C=10^1$	$L=150, H=4, C=10^1$	$L=200, H=2, C=10^2$
	G-mean(%)	65.73±2.73	64.59±3.26	63.71±3.65	61.12±4.90	58.14±7.02
	F1-score(%)	57.34±3.45	55.98±4.43	54.59±5.02	50.75±7.68	45.75±11.77
DSCN	参数	$L=100, H=5, C=10^0$	$L=200, H=3, C=10^0$	$L=75, H=4, C=10^0$	$L=25, H=3, C=10^0$	$L=50, H=2, C=10^0$
	G-mean(%)	66.02±3.11	64.39±3.11	63.28±3.45	61.63±4.36	56.87±4.91
	F1-score(%)	57.65±3.88	55.60±4.05	54.16±4.78	51.29±6.96	44.39±8.05
EDRVFL	参数	$L=25, H=6, C=10^0$	$L=75, H=10, C=10^0$	$L=100, H=10, C=10^1$	$L=125, H=5, C=10^1$	$L=200, H=10, C=10^2$
	G-mean(%)	65.94±2.88	64.68±2.92	63.83±3.89	62.02±3.92	58.19±6.87
	F1-score(%)	57.78±3.49	55.92±3.88	54.69±5.23	52.29±5.97	46.57±11.26
Bagging-SCN	参数	$L=50, M=5$	$L=25, M=5$	$L=175, M=5$	$L=200, M=3$	$L=100, M=3$
	G-mean(%)	69.44±2.29	68.10±2.46	66.79±2.86	63.62±3.54	61.97±3.66
	F1-score(%)	61.07±2.86	59.31±3.21	57.67±3.96	53.28±5.65	49.49±6.00
LightGBM	参数	n_estimators=150	n_estimators=200	n_estimators=175	n_estimators=200	n_estimators=200
	G-mean(%)	67.81±2.39	65.86±2.69	62.73±2.89	60.59±3.13	58.50±3.22
	F1-score(%)	58.47±2.52	58.34±2.82	56.68±2.92	53.60±3.12	50.90±3.13
TIEL-SCN	参数	$L=50, M=9, \chi=0.5$	$L=25, M=10, \chi=0.4$	$L=175, M=8, \chi=0.1$	$L=200, M=10, \chi=0.4$	$L=100, M=10, \chi=0.3$
	G-mean(%)	69.46±2.37	68.42±2.58	67.39±2.84	64.62±2.95	62.13±3.91
	F1-score(%)	61.09±2.96	59.63±3.36	58.27±3.93	54.28±4.71	49.65±6.41

表 5 相关模型在“健康 VS. 心脏病”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=150, C=10^{-2}$	$L=175, C=10^{-1}$	$L=75, C=10^1$	$L=150, C=10^0$	$L=50, C=10^2$
	G-mean(%)	68.35±2.83	67.82±3.21	66.80±3.74	64.34±3.90	59.45±7.71
	F1-score(%)	60.51±3.74	59.85±3.87	58.70±4.71	55.50±5.34	48.31±11.79
SCN	参数	$L=150, C=10^1$	$L=100, C=10^{-1}$	$L=125, C=10^0$	$L=25, C=10^{-2}$	$L=200, C=10^2$
	G-mean(%)	69.14±2.85	68.76±2.82	67.41±3.37	64.61±3.91	60.73±8.17
	F1-score(%)	61.73±3.71	61.22±3.38	59.62±4.20	56.11±5.09	50.53±11.41
DRVFL	参数	$L=200, H=5, C=10^{-5}$	$L=75, H=10, C=10^0$	$L=50, H=5, C=10^1$	$L=25, H=8, C=10^1$	$L=25, H=2, C=10^{-5}$
	G-mean(%)	69.21±2.75	68.61±3.26	67.79±3.69	65.56±3.72	61.80±7.11
	F1-score(%)	61.91±3.75	61.19±3.86	60.19±4.55	57.17±4.70	52.19±9.35
DSCN	参数	$L=25, H=3, C=10^{-4}$	$L=100, H=2, C=10^{-1}$	$L=25, H=4, C=10^{-1}$	$L=25, H=2, C=10^{-1}$	$L=25, H=3, C=10^{-1}$
	G-mean(%)	67.72±3.29	67.45±2.91	65.41±3.50	64.41±4.08	59.39±4.82
	F1-score(%)	60.31±4.28	59.91±3.49	57.61±4.36	55.91±5.31	49.19±6.74
EDRVFL	参数	$L=50, H=3, C=10^0$	$L=75, H=6, C=10^1$	$L=175, H=5, C=10^1$	$L=175, H=6, C=10^1$	$L=100, H=5, C=10^2$
	G-mean(%)	69.60±3.16	68.81±2.96	68.16±3.75	66.06±3.43	61.73±7.69
	F1-score(%)	62.51±3.85	61.58±3.58	60.48±4.68	57.79±4.37	51.89±10.35
Bagging-SCN	参数	$L=150, M=9$	$L=100, M=5$	$L=125, M=5$	$L=25, M=4$	$L=200, M=5$
	G-mean(%)	73.69±2.54	71.93±2.28	70.66±2.42	67.67±3.04	65.76±4.24
	F1-score(%)	66.28±3.30	64.38±2.73	62.87±3.01	59.17±3.95	55.56±5.92
LightGBM	参数	n_estimators=100	n_estimators=200	n_estimators=200	n_estimators=200	n_estimators=200
	G-mean(%)	73.10±2.17	71.90±2.48	70.40±2.65	68.60±3.15	65.30±3.47
	F1-score(%)	65.60±2.29	64.20±2.56	62.60±2.68	60.00±3.14	55.20±3.38
TIEL-SCN	参数	$L=150, M=10, \chi=0.7$	$L=100, M=10, \chi=0.3$	$L=125, M=8, \chi=0.1$	$L=25, M=10, \chi=0.4$	$L=200, M=10, \chi=0.1$
	G-mean(%)	73.74±2.62	72.52±2.32	71.09±2.69	69.33±2.94	66.01±4.21
	F1-score(%)	66.33±3.41	64.98±2.78	63.30±3.35	60.83±3.82	55.81±5.88

表 6 相关模型在“健康 VS. 肺部疾病”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=125, C=10^{-2}$	$L=125, C=10^{-1}$	$L=100, C=10^0$	$L=75, C=10^2$	$L=175, C=10^2$
	G-mean(%)	78.39±3.09	77.40±3.45	75.91±3.84	72.99±6.67	69.50±6.95
	F1-score(%)	71.24±3.94	70.17±4.28	67.72±4.81	65.48±7.72	58.91±8.69
SCN	参数	$L=75, C=10^{-2}$	$L=200, C=10^0$	$L=25, C=10^{-10}$	$L=50, C=10^0$	$L=175, C=10^1$
	G-mean(%)	80.44±2.86	78.93±3.26	77.35±3.42	75.82±4.54	71.19±6.04
	F1-score(%)	73.72±3.61	72.40±3.98	69.79±4.29	68.71±5.13	61.21±7.25
DRVFL	参数	$L=75, H=6, C=10^{-5}$	$L=25, H=4, C=10^0$	$L=25, H=2, C=10^0$	$L=50, H=9, C=10^2$	$L=200, H=7, C=10^2$
	G-mean(%)	79.76±3.00	78.26±3.59	77.17±3.33	75.07±5.39	70.76±8.73
	F1-score(%)	73.17±3.85	71.98±4.16	69.60±4.28	68.23±5.94	61.15±10.14
DSCN	参数	$L=200, H=7, C=10^0$	$L=200, H=6, C=10^1$	$L=125, H=9, C=10^1$	$L=150, H=10, C=10^2$	$L=200, H=8, C=10^3$
	G-mean(%)	82.08±2.72	80.56±2.97	79.55±3.33	77.80±3.63	73.97±6.36
	F1-score(%)	75.36±3.44	74.02±3.63	71.99±4.18	70.69±4.10	63.98±7.64
EDRVFL	参数	$L=100, H=7, C=10^{-5}$	$L=200, H=7, C=10^0$	$L=100, H=2, C=10^1$	$L=75, H=10, C=10^2$	$L=200, H=8, C=10^2$
	G-mean(%)	79.91±2.99	78.41±3.15	77.46±3.19	75.63±4.66	71.67±7.01
	F1-score(%)	73.51±3.71	72.32±3.98	70.54±3.92	68.64±5.27	61.93±8.32
Bagging-SCN	参数	$L=75, M=10$	$L=200, M=6$	$L=25, M=4$	$L=50, M=5$	$L=175, M=3$
	G-mean(%)	83.99±2.28	83.33±2.32	81.17±2.14	79.45±3.20	73.21±4.19
	F1-score(%)	77.28±2.88	76.80±2.83	73.61±2.68	72.34±3.61	63.23±5.03
LightGBM	参数	n_estimators=200	n_estimators=175	n_estimators=175	n_estimators=150	n_estimators=175
	G-mean(%)	81.60±2.55	79.90±2.81	79.70±3.37	77.93±3.49	73.53±4.25
	F1-score(%)	75.20±2.39	73.40±2.65	72.20±3.23	70.51±3.36	63.80±3.86
TIEL-SCN	参数	$L=75, M=9, \chi=0.1$	$L=200, M=9, \chi=0.3$	$L=25, M=10, \chi=0.5$	$L=50, M=10, \chi=1.0$	$L=175, M=9, \chi=0.4$
	G-mean(%)	84.37±2.64	83.47±2.77	82.46±2.24	80.57±2.83	77.37±4.05
	F1-score(%)	77.65±3.34	76.94±3.38	74.90±2.81	73.46±3.19	67.39±4.86

表 7 相关模型在“健康 VS. 肾病”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=25, C=10^1$	$L=50, C=10^{-1}$	$L=150, C=10^0$	$L=175, C=10^1$	$L=125, C=10^2$
	G-mean(%)	75.50±3.21	74.74±4.21	73.05±3.82	70.55±5.22	65.16±10.39
	F1-score(%)	68.46±4.03	66.29±5.20	63.87±4.66	60.41±6.14	51.76±13.32
SCN	参数	$L=125, C=10^{-2}$	$L=50, C=10^{-6}$	$L=150, C=10^{-2}$	$L=50, C=10^{-1}$	$L=100, C=10^0$
	G-mean(%)	78.00±3.40	75.25±3.56	75.13±4.02	71.75±4.94	67.26±5.96
	F1-score(%)	71.06±4.32	67.99±4.45	66.45±4.91	62.04±5.80	54.72±7.47
DRVFL	参数	$L=50, H=3, C=10^{-1}$	$L=150, H=7, C=10^1$	$L=175, H=5, C=10^1$	$L=100, H=10, C=10^1$	$L=175, H=4, C=10^2$
	G-mean(%)	75.79±3.81	74.48±3.87	72.96±5.55	70.90±5.89	66.23±10.22
	F1-score(%)	68.75±5.00	67.65±4.79	65.16±6.30	61.27±6.49	54.17±12.46
DSCN	参数	$L=100, H=8, C=10^{-2}$	$L=75, H=8, C=10^0$	$L=100, H=3, C=10^1$	$L=175, H=5, C=10^0$	$L=125, H=6, C=10^0$
	G-mean(%)	78.98±3.32	76.43±3.30	75.56±4.48	72.32±4.46	67.50±6.99
	F1-score(%)	72.03±4.22	69.17±4.13	66.88±5.47	62.60±5.24	54.96±8.76
EDRVFL	参数	$L=100, H=6, C=10^{-1}$	$L=150, H=3, C=10^{-1}$	$L=50, H=2, C=10^{-3}$	$L=175, H=2, C=10^1$	$L=200, H=9, C=10^2$
	G-mean(%)	75.81±3.18	74.51±3.59	73.24±3.56	71.07±5.10	68.30±9.12
	F1-score(%)	69.06±3.97	68.03±4.60	64.17±4.65	61.71±6.34	56.15±11.48
Bagging-SCN	参数	$L=125, M=9$	$L=50, M=8$	$L=150, M=2$	$L=50, M=5$	$L=100, M=2$
	G-mean(%)	83.80±2.72	80.99±3.07	78.24±3.19	74.76±3.76	68.36±4.88
	F1-score(%)	76.86±3.46	73.73±3.85	69.55±3.89	65.05±4.42	55.82±6.12
LightGBM	参数	n_estimators=200	n_estimators=175	n_estimators=175	n_estimators=150	n_estimators=150
	G-mean(%)	80.00±2.70	77.60±2.88	75.30±3.04	72.20±3.71	66.80±4.44
	F1-score(%)	74.20±2.53	70.50±2.73	66.80±2.86	62.43±3.45	54.40±4.02
TIEL-SCN	参数	$L=125, M=10, \chi=0.3$	$L=50, M=10, \chi=0.2$	$L=150, M=9, \chi=0.4$	$L=50, M=8, \chi=0.4$	$L=100, M=9, \chi=0.5$
	G-mean(%)	83.81±2.31	83.48±2.41	81.23±3.10	78.12±3.25	71.47±4.49
	F1-score(%)	76.87±2.94	76.22±3.01	72.54±3.78	68.41±3.81	58.93±5.63

表 8 相关模型在“健康 VS. 糖尿病/高血压”任务上的测试性能

算法		不同比例噪声下的分类性能				
		0%	10%	20%	30%	40%
RVFL	参数	$L=200, C=10^{-1}$	$L=100, C=10^{-2}$	$L=25, C=10^{-2}$	$L=50, C=10^0$	$L=50, C=10^1$
	G-mean(%)	61.39±4.13	59.93±4.11	58.10±4.19	57.30±4.48	53.80±6.18
	F1-score(%)	67.96±3.15	65.54±3.12	63.84±3.30	63.86±3.12	62.00±3.60
SCN	参数	$L=175, C=10^{-9}$	$L=150, C=10^{-9}$	$L=175, C=10^{-2}$	$L=100, C=10^{-1}$	$L=50, C=10^0$
	G-mean(%)	65.34±2.73	61.73±3.52	60.73±3.43	60.13±3.86	58.72±3.80
	F1-score(%)	68.94±1.92	65.91±2.90	65.25±2.39	66.60±3.06	64.51±2.62
DRVFL	参数	$L=50, H=3, C=10^{-1}$	$L=25, H=10, C=10^{-1}$	$L=50, H=10, C=10^{-1}$	$L=50, H=10, C=10^{-1}$	$L=50, H=10, C=10^0$
	G-mean(%)	61.88±3.60	60.97±3.79	58.82±4.29	58.28±4.46	54.78±5.26
	F1-score(%)	68.40±2.83	67.36±2.86	65.35±3.22	63.87±3.38	60.87±3.63
DSCN	参数	$L=175, H=5, C=10^0$	$L=175, H=6, C=10^0$	$L=125, H=6, C=10^0$	$L=200, H=7, C=10^0$	$L=175, H=3, C=10^0$
	G-mean(%)	67.45±3.41	62.52±3.68	61.29±4.13	60.92±4.38	60.18±5.12
	F1-score(%)	69.10±2.70	68.06±2.77	66.05±3.11	64.67±3.20	61.66±3.53
EDRVFL	参数	$L=50, H=5, C=10^{-1}$	$L=25, H=6, C=10^{-1}$	$L=50, H=9, C=10^{-1}$	$L=100, H=10, C=10^{-1}$	$L=50, H=5, C=10^{-2}$
	G-mean(%)	61.90±3.64	60.97±3.79	58.92±4.19	58.43±4.46	55.13±5.26
	F1-score(%)	68.41±2.91	67.36±2.86	65.40±3.11	63.92±3.58	61.95±3.56
Bagging-SCN	参数	$L=175, M=5$	$L=150, M=5$	$L=175, M=5$	$L=100, M=9$	$L=50, M=9$
	G-mean(%)	70.67±2.22	67.82±3.03	67.43±3.17	65.89±3.28	64.91±1.55
	F1-score(%)	71.48±1.83	68.88±2.01	67.87±2.21	66.98±2.71	65.85±1.22
LightGBM	参数	$n_estimators=125$	$n_estimators=150$	$n_estimators=125$	$n_estimators=175$	$n_estimators=100$
	G-mean(%)	70.49±2.15	71.81±2.45	70.77±2.23	68.20±2.47	65.26±2.59
	F1-score(%)	75.83±3.03	74.92±3.27	71.82±3.05	71.39±3.36	68.74±3.20
TIEL-SCN	参数	$L=175, M=9, \chi=0.8$	$L=150, M=10, \chi=1.0$	$L=175, M=6, \chi=0.1$	$L=100, M=6, \chi=0.4$	$L=50, M=8, \chi=0.9$
	G-mean(%)	74.22±2.45	73.39±2.92	72.39±1.87	69.93±2.25	67.01±3.42
	F1-score(%)	77.44±2.20	76.46±2.61	75.42±1.70	73.04±2.12	70.45±2.90

尤其在低噪声条件下难以实现显著的稳健性增强。此外, TIEL-SCN 同样优于主流梯度提升树模型 LightGBM, 尽管 LightGBM 具备优越的特征处理能力以及学习效率, 但其性能依赖于树结构复杂度、采样比例、正则化与学习率等参数, 且易受到噪声影响, TIEL-SCN 在准确性与鲁棒性层面更具竞争力。

4.3 消融实验

为验证 TIEL-SCN 各模块有效性, 本节在上述七个分类任务上进行了消融实验, 定义 TIEL-SCN 的变体如下:

(1) TIEL-SCN: 以数据依赖的 SCN 为弱分类器, 采用本文提出的可信增量集成学习框架。

(2) IEL-SCN: 以数据依赖的 SCN 为弱分类器, 仅采取基于梯度提升的堆叠集成学习策略, 未采取直觉模糊理论与 D-S 证据理论融合策略。

(3) TIEL-RVFL: 以非数据依赖的 RVFL 为弱分类器, 采用本文提出的可信增量集成学习框架。

(4) IEL-SCN: 以非数据依赖的 RVFL 为弱分类器, 仅采取基于梯度提升的堆叠集成学习策略, 未

采取直觉模糊理论与 D-S 证据理论融合策略。

表 9 给出了上述模型在不同噪声比例下的测试性能, 图 3 展示了六个二分类任务在不同噪声比例下的平均性能。

在相同集成框架下, 采用数据依赖的 SCN 作为弱分类器, 其性能稳定性与整体平均 G-mean 均显著优于采用非数据依赖的 RVFL 集成模型, 尤其在健康 VS. 高血脂、健康 VS. 心脏病等任务中, 性能优势更加明显。结果表明: SCN 采取数据依赖的监督机制分配隐含层节点参数, 有利于减少模型对随机初始化的敏感性, 提升弱分类器的表达能力和泛化性能, 在多任务分类场景中, 更适宜选择作为基础分类器。

集成策略对比方面, TIEL 相较于 IEL 框架更具性能优势。TIEL 框架在基于残差的梯度提升策略中, 融合了直觉模糊理论与 D-S 证据理论, 通过对弱分类器输出结果进行可信度建模与证据融合, 逐轮动态调整全局融合概率, 更新当前残差, 可有效抑制低可信度判决对最终结果的负面影响, 进而

表 9 七个“健康 VS. 疾病”任务上的消融实验结果

数据集	算法	不同比例噪声下的分类性能(G-mean: %)				
		0%	10%	20%	30%	40%
健康 VS. 糖尿病	IEL-RVFL	92.96±1.70	92.06±2.22	91.84±1.87	90.56±2.38	87.40±3.72
	TIEL-RVFL	93.02±1.82	92.43±2.01	92.14±1.92	91.02±2.22	88.00±3.65
	IEL-SCN	93.07±1.86	92.17±1.83	91.98±2.11	90.59±2.36	87.90±3.53
	TIEL-SCN	93.13±1.82	92.56±1.86	92.21±2.08	91.11±2.36	88.23±3.49
健康 VS. 高血压	IEL-RVFL	83.63±2.27	82.69±2.46	80.98±3.49	76.92±3.11	71.07±4.97
	TIEL-RVFL	83.79±2.27	82.98±2.44	81.56±2.95	78.04±3.32	71.96±4.90
	IEL-SCN	84.04±2.65	82.72±3.31	80.99±3.38	79.59±3.42	72.21±5.74
	TIEL-SCN	84.10±2.96	83.63±3.25	81.99±3.39	79.96±3.36	72.99±5.58
健康 VS. 高血脂	IEL-RVFL	68.64±2.39	66.30±2.65	65.73±3.01	63.97±3.49	60.32±4.42
	TIEL-RVFL	68.81±2.50	67.09±2.44	66.52±3.00	64.60±3.53	61.05±4.15
	IEL-SCN	69.15±2.31	68.10±2.46	66.80±2.85	64.02±3.54	61.97±3.66
	TIEL-SCN	69.46±2.37	68.42±2.58	67.39±2.84	64.62±2.95	62.13±3.91
健康 VS. 心脏病	IEL-RVFL	72.78±2.48	71.82±2.72	70.91±2.59	68.72±3.14	63.14±4.10
	TIEL-RVFL	73.41±2.59	72.51±2.74	71.05±2.45	69.31±2.91	63.81±3.84
	IEL-SCN	73.69±2.52	71.93±2.28	70.93±2.41	68.76±3.04	65.76±4.24
	TIEL-SCN	73.74±2.62	72.52±2.32	71.09±2.69	69.33±2.94	66.01±4.21
健康 VS. 肺部疾病	IEL-RVFL	83.73±2.31	82.99±2.34	81.92±2.35	79.79±3.31	76.28±4.08
	TIEL-RVFL	83.98±2.27	83.05±2.37	82.22±2.49	80.24±3.00	77.05±4.02
	IEL-SCN	83.99±2.28	83.33±2.33	82.12±2.14	79.84±3.20	76.61±4.19
	TIEL-SCN	84.37±2.64	83.47±2.77	82.46±2.24	80.57±2.83	77.37±4.05
健康 VS. 肾病	IEL-RVFL	82.21±2.45	81.06±2.82	79.96±2.90	77.61±3.01	69.95±5.01
	TIEL-RVFL	83.24±2.41	81.68±2.60	80.21±2.70	78.10±2.86	71.43±4.86
	IEL-SCN	83.50±2.72	81.39±3.07	80.58±3.19	77.94±3.76	70.98±4.88
	TIEL-SCN	83.81±2.31	83.48±2.41	81.23±3.10	78.12±3.25	71.47±4.49
健康 VS. 糖尿病/高血压	IEL-RVFL	71.39±3.29	70.08±3.52	68.69±3.28	66.40±3.49	62.45±3.89
	TIEL-RVFL	74.00±3.22	72.76±3.27	71.37±2.94	68.89±3.48	64.69±3.71
	IEL-SCN	72.41±2.31	71.11±3.46	69.72±1.97	67.41±2.49	64.80±3.03
	TIEL-SCN	74.22±2.45	73.39±2.92	72.39±1.87	69.93±2.25	67.01±3.42




图 3 消融实验结果

提升整体集成系统的稳定性与可靠性。相比之下, IEL 仅依赖单一的残差拟合, 缺乏对决策可信度的度量与融合机制, 在高噪声或类别分布不均衡的情况下性能下降更为明显。消融实验结果表明, 在七个脉搏波疾病分类任务中, TIEL 框架均能在平均







性能上优于对应的 IEL 模型, 其中以 SCN 为弱分类器的 TIEL 性能提升更为显著, 有效验证了 TIEL-SCN 模型的鲁棒性与泛化性。


4.4 参数敏感性分析

在集成学习框架中, 弱分类器数量对集成模型

性能至关重要,弱分类器数量较少时,模型无法发挥最佳性能,弱分类器数量过多,不仅易导致模型过拟合,同时增加了集成学习的计算复杂度。此外,不确定性权重系数 λ 直接影响不确定性度量乃至可信集成的可靠性与稳定性。

为分析弱分类器数量 M 以及不确定性权重系数 λ 对 TIEL-SCN 模型性能的影响,本节在无人工噪声条件下的七个“健康 VS. 疾病”分类数据集上进行了参数敏感性分析实验,TIEL-SCN 在不同弱分类器数量 M 以及不确定性权重系数 λ 下的平均 G-mean 如图 4 所示。





(g) 健康 VS. 糖尿病/高血压

图 4 参数敏感性分析

在无噪声条件下, TIEL-SCN 的分类性能随弱分类器数量的增加而提升, 并在数量达到 5 个时趋于稳定。此后, 继续增加弱分类器数量, 其平均 G-mean 未出现显著波动。此外, 通过调节不确定性权重系数 λ 有利于进一步提升集成模型性能。参数敏感性分析实验结果表明, TIEL-SCN 仅需集成少量弱分类器即可获得优异且稳定的泛化性能, 展

现了其在面对不同分类任务时良好的鲁棒性, 且能够保证在实际应用中具备较高的计算效率。

4.5 计算复杂度分析

TIEL-SCN 计算复杂度主要取决于基分类器 SCN 数量以及可信融合过程。假定训练样本数为 N , 输入特征维度为 d , 输出维度(类别)为 C , SCN 隐含层节点数为 L , 基分类器数量为 M 。其中, SCN 的计算复杂度集中于输出权重更新, 因此计算复杂度为 $O(NL^2 + L^3)$ 。TIEL-SCN 计算复杂度包括基分类器训练复杂度 $O(M \cdot (NL^2 + L^3))$ 以及可信融合计算复杂度 $O(MN(C+1)^2)$, 因此, TIEL-SCN 计算复杂度为 $O(M \cdot (NL^2 + L^3) + MN(C+1)^2)$ 。

为全面量化 TIEL-SCN 的计算效率, 表 10 展示了 TIEL-SCN 在七个脉搏波疾病分类任务、不同噪声水平下的关键参数及其训练时间与推理时间。实验结果表明 TIEL-SCN 的训练时间受到弱分类器数量以及弱分类器节点数量影响, 集成架构训练时间开销存在较大差异, 但在各个任务上保持较高的推理效率。

表 10 TIEL-SCN 训练时间与推理时间

数据集	计算时间	不同比例噪声下的计算时间(s)				
		0%	10%	20%	30%	40%
健康 VS. 糖尿病	关键参数	$L=50, M=10$	$L=150, M=5$	$L=100, M=6$	$L=150, M=5$	$L=100, M=9$
	训练时间	5.1221 ± 0.4981	8.9681 ± 0.6801	8.3523 ± 1.0363	8.9681 ± 0.6801	10.4423 ± 1.0453
	推理时间	0.0116 ± 0.0038	0.0083 ± 0.0018	0.0090 ± 0.0030	0.0083 ± 0.0018	0.0125 ± 0.0046
健康 VS. 高血压	关键参数	$L=125, M=10$	$L=175, M=9$	$L=125, M=8$	$L=150, M=9$	$L=175, M=5$
	训练时间	14.3191 ± 1.3321	15.1923 ± 0.9001	11.4563 ± 1.0671	16.1401 ± 1.2401	10.5483 ± 0.9201
	推理时间	0.0147 ± 0.0029	0.0132 ± 0.0034	0.0124 ± 0.0023	0.0133 ± 0.0034	0.0089 ± 0.0018
健康 VS. 高血脂	关键参数	$L=150, M=9$	$L=25, M=10$	$L=175, M=8$	$L=200, M=10$	$L=100, M=10$
	训练时间	16.1401 ± 1.2401	3.3801 ± 0.5941	13.5001 ± 0.8001	20.9201 ± 1.2261	11.6001 ± 1.6061
	推理时间	0.0131 ± 0.0034	0.0099 ± 0.0037	0.0129 ± 0.0029	0.0145 ± 0.0039	0.0132 ± 0.0041
健康 VS. 心脏病	关键参数	$L=150, M=10$	$L=100, M=10$	$L=125, M=8$	$L=25, M=10$	$L=200, M=10$
	训练时间	17.9401 ± 1.3601	11.6001 ± 1.0261	11.4563 ± 1.0671	2.3801 ± 0.3941	20.9201 ± 2.2261
	推理时间	0.0136 ± 0.0037	0.0140 ± 0.0038	0.0124 ± 0.0023	0.0099 ± 0.0040	0.0145 ± 0.0040
健康 VS. 肺部疾病	关键参数	$L=75, M=9$	$L=200, M=9$	$L=25, M=10$	$L=50, M=10$	$L=175, M=9$
	训练时间	6.8401 ± 1.0701	18.8321 ± 1.1881	4.3801 ± 0.3941	6.1221 ± 0.4981	15.1923 ± 0.9001
	推理时间	0.0103 ± 0.0034	0.0128 ± 0.0036	0.0099 ± 0.0040	0.0106 ± 0.0038	0.0122 ± 0.0034
健康 VS. 肾病	关键参数	$L=125, M=9$	$L=50, M=7$	$L=150, M=8$	$L=50, M=10$	$L=100, M=7$
	训练时间	12.8881 ± 1.2001	4.5861 ± 0.3481	14.3521 ± 1.0901	6.1221 ± 0.4981	8.1181 ± 0.9201
	推理时间	0.0120 ± 0.0026	0.0082 ± 0.0026	0.0113 ± 0.0030	0.0106 ± 0.0038	0.0096 ± 0.0035
健康 VS. 糖尿病/高血压	关键参数	$L=175, M=9$	$L=75, M=10$	$L=175, M=5$	$L=75, M=6$	$L=200, M=8$
	训练时间	15.1923 ± 0.9001	8.6001 ± 1.0301	10.5483 ± 0.9201	5.5601 ± 1.0401	16.7361 ± 1.1511
	推理时间	0.0122 ± 0.0034	0.0114 ± 0.0038	0.0085 ± 0.0018	0.0069 ± 0.0022	0.0132 ± 0.0032

5 结束语

本文面向基于脉搏波信号的疾病分类任务, 提

出了一种基于随机配置网络的可信增量集成学习模型(TIEL-SCN)。其中, TIEL-SCN 以 SCN 为弱分类器, 采取基于梯度提升的集成学习策略, 逐步拟合弱分类器残差, 以提升决策边界区域样本的判别能

力。此外,为提升集成模型的鲁棒性能,TIEL-SCN 借助直觉模糊理论将弱分类器输出概率转化为综合置信度,并依赖基于 D-S 证据理论的可信集成学习框架,增量迭代融合弱分类器输出,更新残差信息,实现不确定性样本的鲁棒建模。基于脉搏波信号的疾病诊断实验表明,TIEL-SCN 对于不同噪声比例下的疾病诊断任务均具有良好的识别精度与泛化性能。

但是,基于增量学习的 TIEL-SCN 相比于普通集成模型,引入直觉模糊置信度与证据融合,增加了计算复杂度。在未来工作中,研究轻量化学习策略,设计自适应不确定性参数学习机制,提升 TIEL-SCN 模型在可穿戴与边缘设备上的实时部署能力,并在跨设备跨人群等更复杂不确定性下开展系统验证亟需进一步研究。

参 考 文 献

- [1] Wang DM, Zhang D, Lu GM. A novel multichannel wrist pulse system with different sensor arrays. *IEEE Transactions on Instrumentation and Measurement*, 2015,64(7):2020-2034
- [2] Guo CX, Jiang ZX, Zhang D. Multi-feature complementary learning for diabetes mellitus detection using pulse signals. *IEEE Journal of Biomedical and Health Informatics*, 2022,26(11):5684-5694
- [3] Guo CX, Dai SC, Zhang CL, et al. Data-driven study on why wrist pulse can assess health conditions. *IEEE Journal of Biomedical and Health Informatics*, 2025. DOI:10.1109/JBHI.2025.3598165
- [4] Pao YH, Takefuji Y. Functional-link net computing: Theory, system architecture, and functionalities. *Computer*, 1992,25(5):76-79
- [5] Cecotti H. Deep random vector functional link network for handwritten character recognition//*Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, Vancouver, Canada, 2016:3628-3633
- [6] Chen CLP, Liu ZL. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture. *IEEE Transactions on Neural Networks and Learning Systems*, 2018,29(1):10-24
- [7] Wang DH, Li M. Stochastic configuration networks: Fundamentals and algorithms. *IEEE Transactions on Cybernetics*, 2017,47(10):3466-3479
- [8] Wang DH, Li M. Deep stochastic configuration networks with universal approximation property//*Proceedings of the 2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, Brazil, 2018:1-8
- [9] Li JQ, Wang DH. 2D convolutional stochastic configuration networks. *Knowledge-Based Systems*, 2024,300:112249
- [10] Huang CQ, Li M, Cao FL, et al. Are graph convolutional networks with random weights feasible. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023,45(3):2751-2768
- [11] Li DP, Zeng ZG. CRNet: A fast continual learning framework with random theory. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023,45(9):10731-10744
- [12] Ding SF, Zhang CL, Guo LL, et al. Weighted deep stochastic configuration networks based on M-estimator functions. *Chinese Journal of Computers*, 2023,46(11):2476-2487
丁世飞,张成龙,郭丽丽,等.基于 M-estimator 函数的加权深度随机配置网络. *计算机学报*, 2023,46(11):2476-2487
- [13] Zhang CL, Ding SF, Guo LL, et al. Research progress on stochastic configuration network. *Journal of Software*, 2024,35(5):2379-2399
张成龙,丁世飞,郭丽丽,等.随机配置网络研究进展. *软件学报*, 2024,35(5):2379-2399
- [14] Yan XF, Wang DH, Tyukin I Y. Theoretical advances on stochastic configuration networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2026,37(1):467-481
- [15] Qiu YH, Wang DH. Granular stochastic configuration networks for uncertain data modeling. *Knowledge-Based Systems*, 2025,328:114196
- [16] Ding SF, Zhang Z, Xu L, et al. A novel robust semi-supervised stochastic configuration network for regression tasks with noise. *Information Sciences*, 2025,703:121933
- [17] Guo LL, Zhu JL, Zhang CL, et al. Intuitionistic fuzzy stochastic configuration networks for solving binary classification problems. *IEEE Transactions on Fuzzy Systems*, 2024,32(8):4210-4219
- [18] Banik D, Roy K, Krejcar O, et al. dHBSN: A diligent hierarchical broad learning system network for cogent polyp segmentation. *Knowledge-Based Systems*, 2024,300:112228
- [19] Guo JF, Chen C L P. A robust semi-supervised broad learning system guided by ensemble-based self-training. *IEEE Transactions on Cybernetics*, 2024,54(11):6410-6422
- [20] Fan W, Si YJ, Sun MQ, et al. Class-specific weighted broad learning system-based domain adaptation for patient-specific ECG classification. *Expert Systems with Applications*, 2025,273:126824
- [21] Dai SC, Zhang CL, Guo CX, et al. Hierarchical fuzzy stochastic configuration network based on canonical correlation analysis for multi-view pulse signal fusion. *IEEE Transactions on Fuzzy Systems*, 2025,33(8):2779-2791
- [22] Zhou ZH, Chen SF. Neural network ensemble. *Chinese Journal of Computers*, 2002,25(1):1-8
周志华,陈世福.神经网络集成. *计算机学报*, 2002,25(1):1-8
- [23] Zhou ZH, Wu J, Tang W. Ensembling neural networks: many could be better than all. *Artificial intelligence*, 2002,137(1-2):239-263
- [24] Huang CQ, Li M, Wang DH. Stochastic configuration network ensembles with selective base models. *Neural Net-*

- works, 2021,137:106-118
- [25] Lu J, Ding JL, Dai XW, et al. Ensemble stochastic configuration networks for estimating prediction intervals: A simultaneous robust training algorithm and its application. *IEEE Transactions on Neural Networks and Learning Systems*, 2020,31(12):5426-5440
- [26] Lu J, Ding JL. Mixed-distribution-based robust stochastic configuration networks for prediction interval construction. *IEEE Transactions on Industrial Informatics*, 2020,16(8):5099-5109
- [27] Lu J, Ding JL, Liu CX, et al. Hierarchical-Bayesian-based sparse stochastic configuration networks for construction of prediction intervals. *IEEE Transactions on Neural Networks and Learning Systems*, 2022,33(8):3560-3571
- [28] Guo JF, Chen CLP. A robust semi-supervised broad learning system guided by ensemble-based self-training. *IEEE Transactions on Cybernetics*, 2024,54(11):6410-6422
- [29] Miao JG, Liu XX, Guo L, et al. SE-BLS: A Shapley-value-based ensemble broad learning system with collaboration-based feature selection and CAM visualization. *Knowledge-Based Systems*, 2024,301:112343
- [30] Shi QS, Katuwal R, Suganthan PN, et al. Random vector functional link neural network based ensemble deep learning. *Pattern Recognition*, 2021,117:107978
- [31] Hu MH, Chion JH, Suganthan PN, et al. Ensemble deep random vector functional link neural network for regression. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023,53(5):2604-2615
- [32] Sajid M, Tanveer M, Suganthan PN. Ensemble deep random vector functional link neural network based on fuzzy inference system. *IEEE Transactions on Fuzzy Systems*, 2025,33(1):479-490
- [33] Zhang CL, Cheng DW, Xue JK, et al. Deep ensemble stochastic configuration network via graph intuitionistic fuzzy for depression recognition. *IEEE Transactions on Fuzzy Systems*, 2025,33(9):2937-2949
- [34] Zhang L, Shi Z, Cheng MM, et al. Nonlinear regression via deep negative correlation learning. *IEEE Transactions on Pattern Analysis and Machine Learning*, 2021,43(3):982-998
- [35] Alhamdoosh M, Wang DH. Fast decorrelated neural network ensembles with random weights. *Information Sciences*, 2014,264:104-117
- [36] Wang DH, Cui CH. Stochastic configuration networks ensemble with heterogeneous features for large-scale data analytics. *Information Sciences*, 2017,417:55-71
- [37] Zhang CL, Guo CX, Wang XZ, et al. Robust decorrelated stochastic configuration networks ensemble via weighted negative correlation learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2025,55(10):6767-6776
- [38] Zhang CL, Wang Y, Zhang D. Greedy deep stochastic configuration networks ensemble with boosting negative correlation learning. *Information Sciences*, 2024,680:121140
- [39] Pratama M, Wang DH. Deep stacked stochastic configuration networks for lifelong learning of non-stationary data streams. *Information Sciences*, 2019,495:150-174
- [40] Yun F, Yu ZW, Yang KX, et al. AdaBoost-stacking based on incremental broad learning system. *IEEE Transactions on Knowledge and Data Engineering*, 2024,36(12):7585-7599
- [41] Gao RB, Hu MH, Li RL, et al. Stacked ensemble deep random vector functional link network with residual learning for medium-scale time-series forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 2025,36(6):10833-10843
- [42] Huang T, Li H, Zhou G, et al. Stacking multi-view broad learning system with residual structures for classification. *Information Sciences*, 2024,669:120559
- [43] Xie RS, Vong CM, Chen CLP, et al. Dynamic network structure: Doubly stacking broad learning systems with residuals and simpler linear model transmission. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2022,6(6):1378-1395
- [44] Yu ZW, Lan KL, Liu ZL, et al. Progressive ensemble kernel-based broad learning system for noisy data classification. *IEEE Transactions on Cybernetics*, 2022,52(9):9656-9669
- [45] Yang KX, Yu ZW, Chen CLP, et al. Incremental weighted ensemble broad learning system for imbalanced data. *IEEE Transactions on Knowledge and Data Mining*, 2022,34(12):2809-5824
- [46] Dempster A P. Upper and lower probabilities induced by a multiple valued mapping. *The Annals of Mathematical Statistics*, 1967,38(2):325-339
- [47] Shafer G. A mathematical theory of evidence. Princeton: Princeton University Press, 1976
- [48] Deng Y. Uncertainty measure in evidence theory. *Science China Information Sciences*, 2020,63(11):210201
- [49] Barnett J A. Computational methods for a mathematical theory of evidence//Proceedings of the 7th International Joint Conferences on Artificial Intelligence. Vancouver, Canada, 1981:868-875
- [50] Atanassov A. Intuitionistic fuzzy sets. *Fuzzy Sets and Systems*, 1986,20:87-96
- [51] Rezvani S, Wu JH. Handling multi-class problem by intuitionistic fuzzy twin support vector machines based on relative density information. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023,45(12):14653-14664
- [52] Zhang LX, Huang ZS. Spectral data analysis based on bagging stochastic configuration networks. *Infrared Physics & Technology*, 2024,143:105609
- [53] Ke GL, Meng Q, Finley T, et al. LightGBM: A highly efficient gradient boosting decision tree//Proceedings of the Advances in Neural Information Processing Systems (NIPS 2017), 2017



ZHANG Cheng-Long, Ph. D., postdoctoral researcher. His research interests include medical biometric, granular computing, randomized neural networks.

ZHANG David, Ph. D., professor and Ph. D. supervisor. His research interests include image processing, pattern recognition, machine learning, biometrics.

DAI Shi-Cheng, Ph. D. candidate. His research interests include multi-view learning, graph learning, and biometrics.

LI Jin-Xing, Ph. D., professor and Ph. D. supervisor. His research interests include deep learning, and biometrics.

DING Shi-Fei, Ph. D., professor and Ph. D. supervisor. His research interests include granular computing, intelligent information processing, pattern recognition, machine learning, data mining.

Background

In recent years, new-generation information technologies have deeply empowered traditional Chinese medicine (TCM) diagnostic and treatment devices, enhancing the signal sensing capabilities of smart TCM equipment such as pulse diagnosis devices. They can quickly, conveniently, cost-effectively, non-invasively, and painlessly capture high-precision pulse wave signals. By integrating these with accurate diagnostic markers from Western medicine, the application of artificial intelligence in health management, health monitoring, and health care has been made possible. However, pulse wave signal sensing is prone to data noise and outliers, so improving the robustness of modeling pulse wave data under data uncertainty conditions holds significant practical value for computing human health.

Incremental ensemble learning models iteratively fit classifier residuals, effectively reducing bias and variance in individual models while enhancing discriminative capability near decision boundaries. Stochastic configuration networks (SCNs) are a class of incremental randomized neural network models, its data-dependent supervision mechanism for parameter learning ensures the model's universal approximation property (UAP). Hence, to address the binary classification problem in disease diagnosis using pulse wave signals,

this paper proposes a trustworthy incremental ensemble classification method based on stochastic configuration networks (TIEL-SCN). First, TIEL-SCN employs data-dependent stochastic configuration networks (SCNs) as weak classifiers and adopts a residual-driven trustworthy incremental ensemble framework to iteratively fit the residuals of these weak classifiers, thereby improving predictive performance. Second, the proposed trustworthy incremental ensemble framework maps the probabilistic outputs of weak classifiers into membership and non-membership degrees, computes comprehensive confidence using intuitionistic fuzzy set theory, and generates basic probability assignments (BPAs). These BPAs are then incrementally fused via Dempster-Shafer theory (DST) to achieve robust modeling of uncertain samples. Finally, experimental evaluations on pulse wave datasets covering various diseases—including diabetes, hypertension, hyperlipidemia, heart disorders, pulmonary disease, and kidney diseases, and a typical case of multi-disease classification—demonstrate that TIEL-SCN achieves superior generalization performance and classification accuracy compared to existing randomized learning models and ensemble learning models. This work was supported by the National Natural Science Foundation of China no. 62272133, 62276265, 62576344.