计 算 机 研 究 与 发 展
Journal of Computer Research and Development
https://crad.ict.ac.cn
62(4): 888−904, 2025

DE-NNs: 基于动态证据神经网络的脑网络分析算法

侯 涛[1,2] 丁卫平[1] 黄嘉爽[1,2] 鞠恒荣[1]

[1](南通大学人工智能与计算机学院 江苏南通 226019)

[2](模式分析与机器智能工业和信息化部重点实验室(南京航空航天大学) 南京 211106)

(houtao_30@163.com)

DE-NNs: Brain Network Analysis Algorithm Based on Dynamic Evidence Neural Networks

Hou Tao[1,2], Ding Weiping[1], Huang Jiashuang[1,2], and Ju Hengrong[1]

[1] (*School of Artificial Intelligence and Computer Science*, *Nantong University*, *Nantong*, *Jiangsu* 226019)

[2] (*MIIT Key Laboratory of Pattern Analysis and Machine Intelligence* (*Nanjing University of Aeronautics and Astronautics*), *Nanjing* 211106)

Abstract Dynamic functional connections (dFCs) can be regarded as a process of dynamic changes in multiple time windows to explore the changes in functional connections of the brain in different time periods. It has been widely used in resting state functional magnetic resonance imaging (rs-fMRI) analysis, providing a new perspective and strategy for the diagnosis of brain diseases. However, the common dynamic brain network analysis methods can not effectively use the potential correlation and timing between dynamic data, and ignore the uncertainty factors caused by the inconsistent data quality of each window. Therefore, we propose a brain network analysis algorithm based on dynamic evidence neural networks (DE-NNs). This algorithm designs a multi-view evidence acquisition module of dynamic brain network, which treats each time window of dynamic brain network as a view. Three different convolution filters are used to extract the feature maps of each time window of the dynamic brain network, and the evidence of the dynamic level is fully obtained. A dynamic evidence fusion mechanism is designed to make full use of dynamic evidence. The dynamic trust function is constructed according to the time sequence of dFC data based on the evidence theory synthesis rules. The evidence generated by multiple windows is fused at the decision level of classification, the uncertainty information is fully considered, and the classification performance is significantly improved. Experiments are conducted on three schizophrenia datasets compared with existing advanced algorithms in order to verify the effectiveness of the proposed DE-NNs. The results show that the accuracy and $F1$ scores of DE-NNs on the three brain disease diagnosis tasks are significantly improved.

Key words evidence fusion; uncertainty; dynamic functional connections; brain network analysis; brain disease diagnosis

收稿日期: 2023-10-31; **修回日期**: 2024-08-16

基金项目: 国家自然科学基金项目(61976120, 62006128, 62102199); 江苏省自然科学基金项目(BK20231337); 江苏省双创博士计划项目; 江苏省高等学校自然科学研究重大项目(21KJA510004); 中央高校基本科研业务费专项资金(NJ2022028); 江苏省研究生科研与实践创新计划项目(SJCX23_1781)

This work was supported by the National Natural Science Foundation of China (61976120, 62006128, 62102199), the Natural Science Foundation of Jiangsu Province (BK20231337), the Double-Creation Doctoral Program of Jiangsu Province, the Natural Science Key Foundation of Higher Education of Jiangsu Province (21KJA510004), the Fundamental Research Funds for the Central Universities (NJ2022028), and the Postgraduate Research & Practice Innovation Program of Jiangsu Province (SJCX23_1781).

通信作者: 丁卫平(dwp9988@163.com)

摘　要　动态功能连接（dynamic functional connections, dFCs）已广泛应用于静息态功能磁共振成像（rs-fMRI）分析，其可以将大脑功能连接视为在多个时间窗上动态变化的过程，探索大脑在不同时间段内的功能连接变化，为脑疾病诊断提供了新的视角和策略. 然而常见的动态脑网络分析方法无法有效利用动态数据之间的潜在关联和时序性，且忽视了各个窗口因为数据质量不一致而导致的不确定性因素. 为此，提出一种基于动态证据神经网络（dynamic evidence neural networks, DE-NNs）的脑网络分析算法. 该算法设计了一种动态脑网络多视图证据获取模块，将动态脑网络的每个时间窗视为一个视图，利用3个不同的卷积滤波器提取动态脑网络每个时间窗的特征图，充分获取动态层面的证据. 为了充分利用动态证据，设计了一种动态证据融合机制，结合证据理论合成规则，针对dFC数据的时序性构造动态信任函数，在分类的决策层对多个窗口产生的证据进行融合，充分考虑不确定性信息，显著提高分类性能. 为验证所提DE-NNs的有效性，在3个精神分裂症数据集上与现有的先进算法进行比较实验，结果表明DE-NNs在3个脑疾病诊断任务上的准确率和$F1$分数都得到了显著提升.

关键词　证据融合；不确定性；动态功能连接；脑网络分析；脑疾病诊断

中图法分类号　TP18

DOI: 10.7544/issn1000-1239.202330883　　**CSTR:** 32373.14.issn1000-1239.202330883

人脑位于复杂神经生物学系统的中心，大脑区域之间的相互作用是神经发育和脑疾病分析的关键驱动因素[1]. 深入了解脑网络的功能和结构有助于理解脑疾病的发病机制和治疗方法的开发，对于辅助医生诊断脑疾病具有重要意义[2]. 特别是目前脑疾病的诊断主要基于简单的症状观察和临床医生的经验，误诊率较高. 因此，如何借助脑网络辅助医生精准识别脑疾病，已经成为领域内的研究热点[3-5].

动态功能连接（dynamic functional connections, dFCs）通过使用短时间的静息态功能磁共振成像（resting state functional magnetic resonance imaging, rs-fMRI）扫描片段构建，反映了脑功能连接（functional connections, FCs）在几秒钟到几分钟时间尺度上的时间波动. rs-fMRI作为一种常用的非侵入性成像技术，可以通过测量血流动力学变化来反映大脑的区域活动强度，而FCs，即不同脑区之间的相关性，可以反映脑区之间的活动一致性. dFCs通过计算连续窗口短时段的局部相关性，提供了观察动态神经活动的机会. 这类动态神经活动可以很好地指示不同群体之间的大脑差异. 例如，Zhang等人[6]提出了时间变异性测量来描述动态脑网络中节点之间的活动一致性，并发现这种测量可以识别精神障碍中一些疾病的特异性变化. Yin等人[7]从dFCs中提取了功能灵活性测量，并使用这种测量方法来评估婴儿早期的认知灵活性. 同时，dFCs也被用来研究精神分裂症患者大规模网络的动态相互作用，证明显著性网络和默认模式网络之间的大脑动态失调是精神分裂症的重要特征[8].

目前深度学习方法已经成功应用于脑网络分析工作，其能够更好地捕捉和建模非线性动态关系，从而更准确地描述脑网络的复杂性. 例如，Kawahara等人[9]提出了3种卷积滤波器（即边到边、边到节点、节点到图），用于学习脑网络的表示. Jie等人[10]定义了一种新颖的加权相关核wc-kernel来测量大脑区域的相关性，并且构建了一个基于wc-kernel的wck-CNN网络来学习分层特征进行脑疾病诊断. Li等人[11]利用fMRI的拓扑和功能信息设计了新颖的ROI感知图卷积层Ra-GConv，提出了一种用于分析功能磁共振图像并发现神经生物标志物的图神经网络Brain-GNN. Zhu等人[12]提出了一种双重注意力多实例深度学习网络DA-MIDL，用于阿尔茨海默病及其前驱阶段轻度认知障碍的早期诊断. Ji等人[13]提出了一种具有3种稀疏策略的卷积神经网络SCNN对dFC进行分类并且可以识别异常的大脑功能连接. Li等人[14]从自适应dFC中提取时间和空间特征，通过深度特征融合方法将时间和空间特征进一步映射为综合融合特征以诊断脑疾病.

然而，目前已有的针对动态脑网络的研究从未考虑到动态脑网络中的不确定性. 由于大脑活动是高度复杂和动态变化的，动态功能连接单一的时间窗可能无法充分捕捉到大脑的多样性和复杂性，通常需要联合多个时间窗的信息. 然而，单一时间窗的数据可能是不完整的，存在缺失值或噪声[15]，无法保证数据的质量，导致每个时间窗的可信程度不一致[16]. 传统方法通常忽略这类不确定性，导致高可信度信息被低可信度信息湮没，影响模型最终的判别能力.

研究标签的依赖关系可以有效分析神经网络模型的不确定性[17]. He 等人[18]提出一种标签相关交叉熵损失函数，直接将标签相关性引入到多重二元交叉熵损失函数中，充分发现标签依赖关系以完成多标签分类和处理不确定性. 为了处理动态脑网络每个时间窗的不确定性信息，本文使用 Dempster 合成规则在证据层面处理不同时间窗的冲突，充分融合来自多个时间窗的信息[19]. Dempster 合成规则在处理不确定性问题中具有独特的优势[20]. 例如，孙怀江等人[21]提出了一种相关证据合成方法来表示证据理论中相关性的起源，处理不确定性信息. Fang 等人[22]基于 Dempster 合成规则提出新的合成规则，然后形成了一个具有广义概率语言信息的多标准决策过程. 罗浩等人[23]使用 Dempster 合成规则进行信息融合，有效消除多关系网络耦合信息和传递机制对节点重要性评测造成的影响.

基于上述讨论，本文提出基于动态证据神经网络(dynamic evidence neural networks, DE-NNs)的脑网络分析算法. 为了充分获取动态功能连接每个时间窗的特征，本文将每个时间窗视为一个视图，设计了一种多视图证据获取模块，利用边缘到边缘(edge-to-edge, E2E)卷积滤波器、边缘到节点(edge-to-node, E2N)卷积滤波器和节点到图(node-to-graph, N2G)卷积滤波器，充分提取 dFCs 数据每个窗口的特征图，再通过全连接层和激活层分别获得每个窗口的证据. 考虑动态功能连接在时间尺度上的时序性，本文设计了一种动态证据融合机制来构造动态信任函数，使用证据合成规则融合来自多个窗口的证据.

本文的主要贡献有 3 点：

1) 设计了一种在多视图学习框架下的动态脑网络特征获取模块，将动态脑网络的每个时间窗作为一个视图进行多视图特征提取，以此完整获取 dFCs 每个窗口的证据.

2) 在动态脑网络分析中引入证据理论处理不确定性信息，设计了一种动态证据融合机制. 将动态脑网络的多窗口信息与证据理论进行结合，准确估计每个窗口的不确定性. 并针对 dFCs 数据的时序性构造动态信任函数，在多窗口分类的决策层进行多视图动态证据融合，提高模型分类的可信度和鲁棒性.

3) 本文方法分别在华西医院、生物医学卓越研究中心(COBRE)和湘雅医院提供的精神分裂症数据集上进行了验证，并且与目前主流分类方法进行比较，展现了较好的性能.

1 相关工作

1.1 脑网络深度学习

深度神经网络比浅层神经网络具有更大的模型容量和更强的泛化能力，针对单个任务在大规模注释数据库上训练的深度模型实现了出色的性能，远远超出了传统算法甚至人类的能力[24].

随着深度学习技术的发展，神经网络已广泛应用于脑网络分析工作，并在包括脑疾病辅助诊断的许多应用中取得了显著成功. 例如，Lin 等人[25]认为卷积神经网络在使用 rs-fMRI 数据对患有精神分裂症等精神障碍的个体分类方面表现优越，并构建了具有 2 个卷积层的 3D-CNN 框架 SSPNet. Yan 等人[26]首次尝试将多尺度 RNN 模型直接应用于 fMRI 时间过程以进行精神分裂症分类，并展示了基于多尺度 RNN 的神经影像学分类的潜力. Huang 等人[27]构建了一个具有注意力机制的深度学习框架 ST-DAG-Att，以使用功能磁共振成像预测认知和疾病.

1.2 多视图学习

传统的深度学习方法通常使用单个视图或数据源的信息进行训练和预测；而多视图学习则通过同时考虑多个视图来丰富模型的表示能力，其基本思想是将多个视图或数据源的特征进行融合，从而获取更全面、更准确的特征表示.

多视图学习的方法在不断发展，涌现了各种各样的算法和模型，如多视图聚类[28-30]、多视图半监督学习[31]和多视图深度学习[32]等. He 等人[33]将 3D-CNN 与多视图学习进行结合，并设计一个视图池化层来融合多视图信息，以解决移动物体识别问题. 梁新彦等人[34]提出一种多粒度融合的超多视图分类方法，利用融合算子对多个视图间的关系进行建模，提升了多视图分类方法的性能. Zhou 等人[35]为了更好地探索来自不同视图的数据之间的相关性，提出了一种通用的多视图分类模型，用于多视图医学图像的计算机辅助诊断，所提出的模型自动从多视图数据中提取基本信息，以生成一系列“良好且多样化”的伪视图进行多视图融合. Ding 等人[36]提出了一种区域感知融合网络 RFNet，得益于区域感知融合模块 RFM，RFNet 能够自适应且有效地利用多模态数据的不同组合来进行肿瘤分割. RNN 提供了一种理解复杂时间变化和依赖性的方法，LSTM 使用输入门、输出门和遗忘门控制信息流，GRU 包含重置门和更新

门 2 个门控单元，且参数更少[37]. He 等人[38] 使用减法门代替乘法门，获得更灵活的内部激活函数选择. Han 等人[39] 引入稀疏门控来捕获每个模态特征的信息变化，并使用真实类别概率来评估每个模态的分类置信度，从而推导出了一种基于动态信息量估计策略的透明融合算法. Liang 等人[40] 提出了一种新的基于解释关联的 MMC 融合方法，从特征空间中提取的关联信息和高阶信息同时被编码到一个新的特征空间中，以使用显式方式训练 MMC 模型.

1.3 基于证据理论的深度学习

证据理论是一种关于信任函数的理论，最早由 Dempster 提出，是贝叶斯理论对主观概率的推广[41-42]，逐步发展成一个通用框架来模拟认知不确定性[43]. 相比贝叶斯神经网络通过权重参数的多次随机采样间接获得不确定性，证据理论直接对不确定性进行建模. 证据理论允许来自不同来源的置信度与各种融合算子相结合，以获得融合所有可用证据得到的最终置信度[44].

当面对来自不同来源的不确定性信息时，证据理论合成规则试图融合它们的共同部分，并通过归一化因素忽略相互冲突的信任程度. Han 等人[45] 提出了一种新颖的多视图分类算法，联合利用多个视图，整合来自每个视图的证据来提高分类的可靠性和鲁棒性，并通过在证据级别动态集成不同视图，为多视图学习提供了新的范例. Xu 等人[46] 提出了一种深度证据融合方法，充分利用置信度分配和不确定性估计来组合多模态医学图像的信息. Liu 等人[47] 从意见聚合的角度重新审视多视图学习，从而设计出一种可信的多视图深度学习方法，采用证据理论将意见的不确定性表述为来自不同数据源的学习结果，并通过证据积累来衡量意见聚合的不确定性作为多视图学习结果. Xu 等人[48] 提出了一种证据多视图深度学习方法 EMDL，为了在证据级别对多视图数据中的一致和互补关系进行显式建模，构建了一个退化层来学习从公共证据到视图特定证据的映射以进行证据融合.

综上，目前虽然已有相关学者开展脑网络深度学习算法方面的研究，但是均存在未关注多个窗口的不确定信息和无法有效利用多窗口信息等问题. 本文首先引入证据理论处理动态脑网络的不确定性信息. 据目前为止，本文所提方法是在脑网络分析中引入证据理论处理不确定信息. 其次，引入多视图学习框架构建动态脑网络特征获取模块，对 dFCs 进行多视图特征提取. 相比使用单一窗口信息，多视图特征可更全面地描述大脑的动态活动信息. 最后，本文充分考虑动态脑网络数据之间的时序关系，基于证据理论设计了一种动态证据融合机制，从而构造动态信任函数，在决策层进行多视图证据融合.

2 动态证据神经网络模型

本文提出的 DE-NNs 方法主要包括 2 个模块：动态证据学习（具体见 2.1 节）和动态证据融合（具体见 2.2 节）. 对于一个具有 N 个样本的动态脑网络功能连接数据集 $\{\boldsymbol{X}_n\}_{n=1}^{N}$，其中 $\boldsymbol{X}=(\boldsymbol{x}^v)_{v=1}^{V}$，即每个样本拥有 V 个动态脑网络时间窗口. 令 $\boldsymbol{A}^{\mathrm{d}}\in\mathbb{R}^{\Omega\times\Omega}$ 是 FCs 的单一邻接矩阵，$\boldsymbol{A}^{\mathrm{d}}=(\boldsymbol{A}^{\mathrm{d}}(1),\boldsymbol{A}^{\mathrm{d}}(2),\cdots,\boldsymbol{A}^{\mathrm{d}}(V))$ 为 dFCs 的连接矩阵，其中 Ω 为脑网络节点的个数（$\Omega=90$），则 $\boldsymbol{X}=\boldsymbol{A}^{\mathrm{d}}$. 本文的工作是将动态脑网络 V 个时间窗口的信息进行证据融合以识别脑疾病. 在数学上，它可以被描述为一个映射：$S:\{\boldsymbol{X}\}\to y$，其中 y 表示受试者（即患者或正常对照组）的标签.

2.1 动态证据学习

为了获取 dFCs 数据每个窗口的证据，本文使用边缘到边缘（E2E）、边缘到节点（E2N）、节点到图（N2G）卷积滤波器来分层提取脑网络的特征，下面给出定义.

定义 1. E2E 卷积滤波器. E2E 卷积滤波器被用来从原始邻接矩阵中提取边缘特征. 与用于图像数据的标准卷积滤波器类似，该滤波器加权组合局部信息（即连接强度）来学习边缘特征，E2E 可以定义为：

$$H_{i,j}^{(n)}=ReLU\left(\sum_{k=1}^{\Omega}(r_k^n A_{i,k}^{\mathrm{d}}+c_k^n A_{k,j}^{\mathrm{d}})+b^n\right),\qquad(1)$$

其中 $r^n\in\mathbb{R}^{\Omega}$ 和 $c^n\in\mathbb{R}^{\Omega}$ 是学习权重，b^n 是学习偏差.

定义 2. E2N 卷积滤波器. E2N 卷积滤波器用于将边缘特征聚合为节点特征. 这个滤波器相当于一个 1 维空间卷积层，E2N 可以定义为：

$$a_i^{(n)}=ReLU\left(\sum_{m=1}^{M}\sum_{k=1}^{\Omega}r_k^{m,n}H_{i,k}^{m}+b^n\right),\qquad(2)$$

其中 $r_k^{m,n}\in\mathbb{R}^{\Omega}$ 是学习权重，(m,n) 表示每层的每一对输入和输出特征.

定义 3. N2G 卷积滤波器. N2G 卷积滤波器用于将节点特征转化为图形特征. N2G 滤波器是一个 1 维空间卷积，在 E2N 滤波器之后应用. 这个滤波器可以通过从图中的所有节点获得单一响应来减少特征图的空间维度，N2G 可以定义为：

$$g^{(n)} = ReLU\left(\sum_{m=1}^{M}\sum_{i=1}^{\Omega} w_i^{m,n} a_i^m + b^n\right), \tag{3}$$

其中$w_i^{m,n} \in \mathbb{R}^{\Omega}$是学习权重.

E2E卷积滤波器能够通过加权组合各个节点间的连接强度识别动态脑网络中的边缘特征. E2N卷积滤波器将边缘特征聚合为节点特征. N2G卷积滤波器通过将相邻边的响应总结为一组节点响应来将节点特征转化为图形特征. E2E, E2N, N2G卷积滤波器能够分层提取脑网络层次特征, 如边缘特征、节点特征、网络特征, 通过顺序使用E2E, E2N, N2G卷积滤波器可以降低特征映射的维度, 有效学习脑网络的特征.

动态脑网络数据集$\{\boldsymbol{X}_n\}_{n=1}^N$中的一个样本$\boldsymbol{X} = (\boldsymbol{x}^v)_{v=1}^V$, 如图1所示.

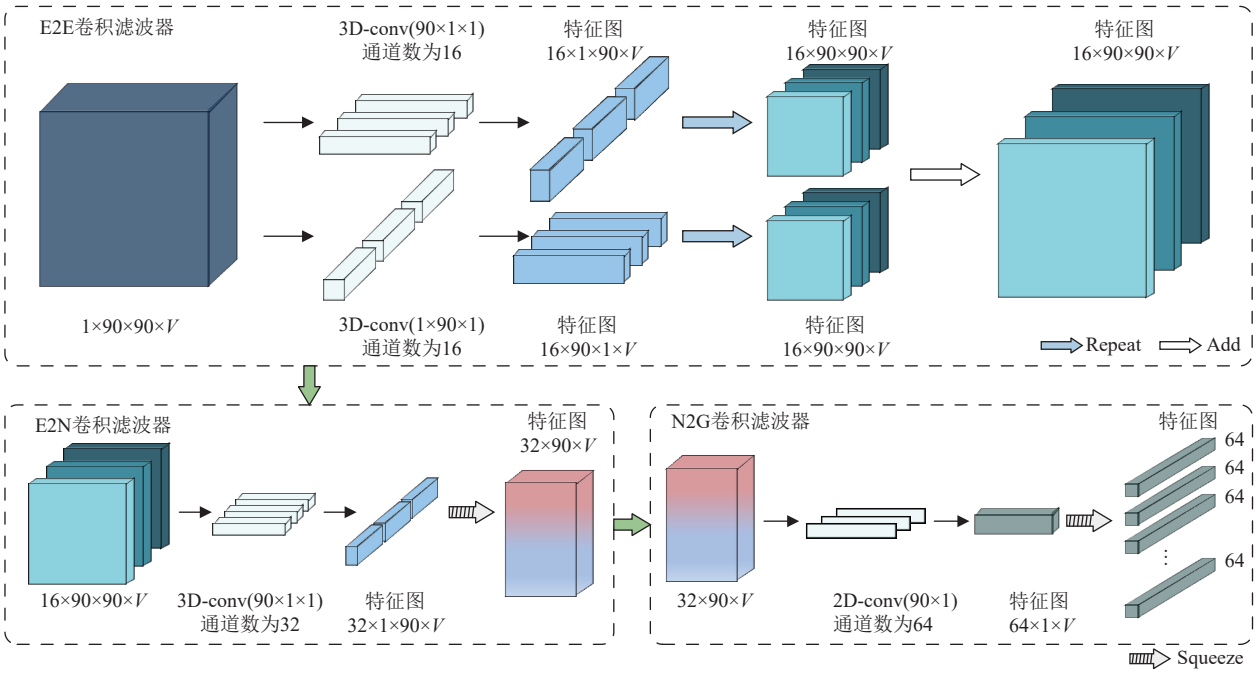


Fig. 1 Dynamic evidence learning modules under multi-view learning framework

图1 多视图学习框架下的动态证据学习模块

首先, 使用E2E卷积滤波器将$\boldsymbol{X}$与16通道的$\Omega\times1\times1$卷积核进行卷积操作, 得到维度为$16\times1\times\Omega\times V$的特征图$\boldsymbol{dFC}_1 \in \{\mathbb{R}_v^{16\times1\times\Omega}\}_{v=1}^V$, 再对其进行Repeat操作, 得到维度为$16\times\Omega\times\Omega\times V$的特征图$\boldsymbol{dFC}'_1 \in \{\mathbb{R}_v^{16\times\Omega\times\Omega}\}_{v=1}^V$. 并将$\boldsymbol{X}$与16通道的$1\times\Omega\times1$卷积核进行卷积操作, 得到维度为$16\times\Omega\times1\times V$的特征图$\boldsymbol{dFC}_2 \in \{\mathbb{R}_v^{16\times\Omega\times1}\}_{v=1}^V$, 再对其进行Repeat操作, 得到维度为$16\times\Omega\times\Omega\times V$的特征图$\boldsymbol{dFC}'_2 \in \{\mathbb{R}_v^{16\times\Omega\times\Omega}\}_{v=1}^V$. 将$\boldsymbol{dFC}'_1$与$\boldsymbol{dFC}'_2$进行Add操作得到维度为$16\times\Omega\times\Omega\times V$的特征图$\boldsymbol{dFC}_{\mathrm{E2E}} \in \{\mathbb{R}_v^{16\times\Omega\times\Omega}\}_{v=1}^V$.

其次, 使用E2N卷积滤波器将E2E的输出$\boldsymbol{dFC}_{\mathrm{E2E}} \in \{\mathbb{R}_v^{16\times\Omega\times\Omega}\}_{v=1}^V$与32通道的卷积核进行卷积操作, 得到维度为$32\times1\times\Omega\times V$的特征图$\boldsymbol{dFC}'_{\mathrm{E2N}} \in \{\mathbb{R}_v^{32\times1\times\Omega}\}_{v=1}^V$, 将$\boldsymbol{dFC}'_{\mathrm{E2N}}$进行Squeeze操作得到维度为$32\times\Omega\times V$的特征图$\boldsymbol{dFC}_{\mathrm{E2N}} \in \{\mathbb{R}_v^{32\times\Omega}\}_{v=1}^V$.

然后, 使用N2G卷积滤波器将E2N的输出$\boldsymbol{dFC}_{\mathrm{E2N}} \in \{\mathbb{R}_v^{32\times\Omega}\}_{v=1}^V$与64通道的$\Omega\times1$卷积核进行卷积操作, 得到维度为$64\times1\times V$的特征图$\boldsymbol{dFC}'_{\mathrm{N2G}} \in \{\mathbb{R}_v^{64\times1}\}_{v=1}^V$, 将$\boldsymbol{dFC}'_{\mathrm{N2G}}$进行Squeeze操作得到维度为$64\times V$的特征图$\boldsymbol{dFC}_{\mathrm{N2G}} \in \{\mathbb{R}_v^{64}\}_{v=1}^V$.

最后, 将经过3个卷积滤波器得到的特征图$\boldsymbol{dFC}_{\mathrm{N2G}} \in \{\mathbb{R}_v^{64}\}_{v=1}^V$的每个窗口分别通过全连接层和Softplus激活层即可得到样本$\boldsymbol{X} = (\boldsymbol{x}^v)_{v=1}^V$的动态脑网络证据$e = \{e_1^v, e_2^v, \cdots, e_K^v\}_{v=1}^V$, 其中$K$为分类任务的类别数量, 本文进行脑疾病的分类任务, 此任务为二分类任务, 故$K=2$, 即患者和正常2个类别. 算法1的行⑤~⑧中对每个视图进行处理的时间复杂度为$O(V)$, 则算法时间复杂度为$O(n\times V)$, 而V是一个常数, 表示视图总数, 故算法时间复杂度为$O(n)$, 算法空间复杂度为$O(n)$, 算法流程如算法1所示.

算法1. 动态证据学习.

输入: 动态脑网络数据$\{\boldsymbol{X}_n\}_{n=1}^N$;

输出: 动态脑网络证据$\sum_{n=1}^{N} e_n = \{e_1^v, e_2^v, \cdots, e_K^v\}_{v=1}^V$.

① for $n = 1 : N$ do

② 使用 E2E 卷积滤波器对 $\boldsymbol{X}_n$ 进行卷积操作，得到特征图 $\boldsymbol{dFC}_{\mathrm{E2E}} \in \{\mathbb{R}_v^{16\times\Omega\times\Omega}\}_{v=1}^{V}$；

③ 使用 E2N 卷积滤波器对 $\boldsymbol{dFC}_{\mathrm{E2E}}$ 进行卷积操作，得到特征图 $\boldsymbol{dFC}_{\mathrm{E2N}} \in \{\mathbb{R}_v^{32\times\Omega}\}_{v=1}^{V}$；

④ 使用 N2G 卷积滤波器对 $\boldsymbol{dFC}_{\mathrm{E2N}}$ 进行卷积操作，得到特征图 $\boldsymbol{dFC}_{\mathrm{N2G}} \in \{\mathbb{R}_v^{64}\}_{v=1}^{V}$；

⑤ for $v = 1 : V$ do

⑥ 将特征图 $\boldsymbol{dFC}_{\mathrm{N2G}}$ 的第 v 个视图依次通过全连接层；

⑦ 通过 Softplus 激活层后得到动态脑网络证据 $e = \{e_1^v, e_2^v, \cdots, e_K^v\}$；

⑧ end for

⑨ 得到动态脑网络数据 V 个视图的动态证据 $e = \{e_1^v, e_2^v, \cdots, e_K^v\}_{v=1}^{V}$；

⑩ end for

⑪ return $\sum_{n=1}^{N} e_n = \{e_1^v, e_2^v, \cdots, e_K^v\}_{v=1}^{V}$.

2.2 动态证据融合

传统的卷积神经网络在分类任务中通常使用 softmax 作为分类层，使用 softmax 可以获得每个类的概率，但是会忽略网络预测结果的置信程度，这可能会导致预测结果的可信度降低[45-48]. 本文将神经网络的输出直接作为证据，因此不使用 softmax 作为分类层，同时希望得到的证据为非负数，所以增加 Softplus 激活层以获得非负输出. 然后使用证据理论将证据形式化为意见，以明确表达深度学习结果的不确定性程度，动态证据神经网络 DE-NNs 的整体流程图如图 2 所示.

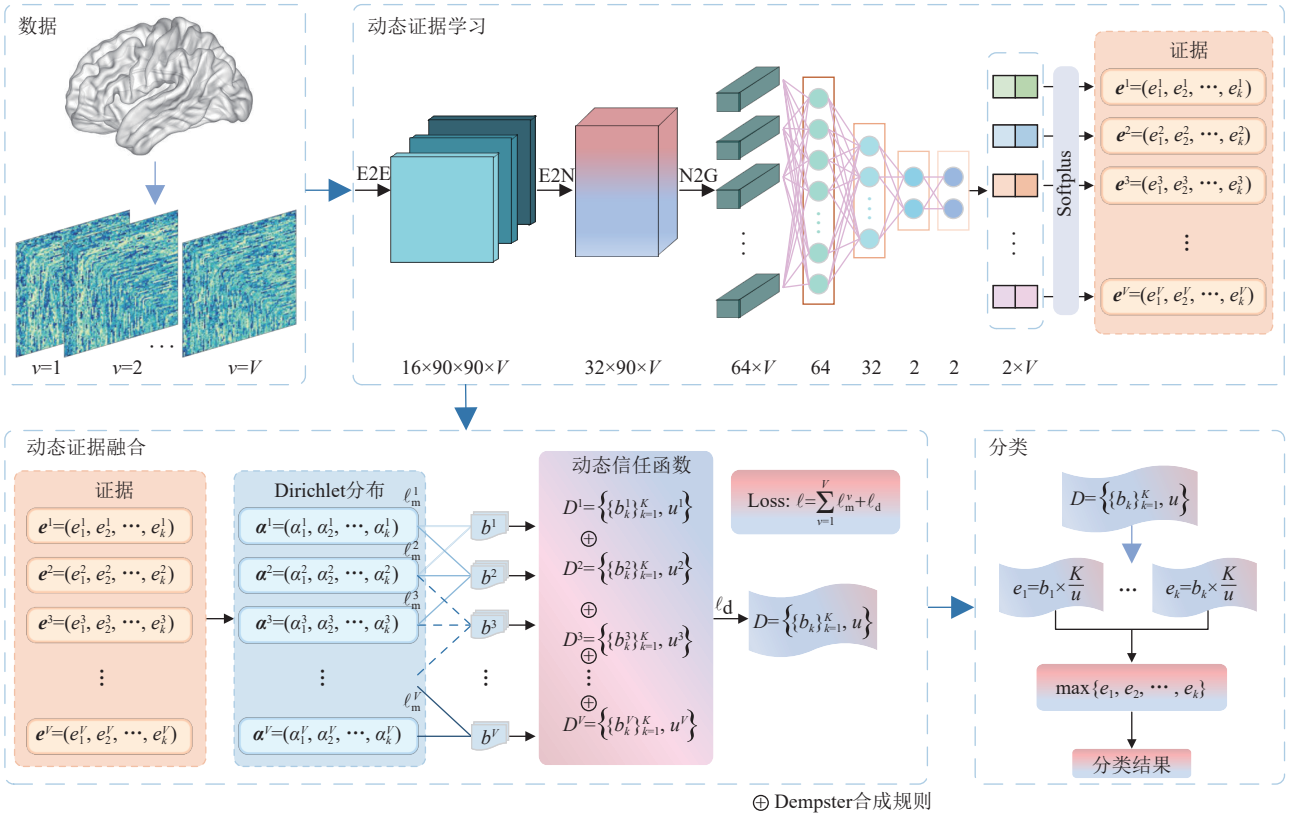


Fig. 2 The model of dynamic evidence neural networks

图 2 动态证据神经网络模型

证据是指从输入中收集的用于支持分类的指标，并且与 Dirichlet 分布的浓度参数密切相关，Dirichlet 分布是一种概率分布，常用于描述多元变量的分布，它是多项分布的共轭先验分布[49]，其参数是一个长度为 K 的概率向量，通常表示为 $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \cdots, \alpha_K)$. 对于 K 分类问题，主观逻辑[44] 根据证据 $e = \{e_1^v, e_2^v, \cdots, e_K^v\}_{v=1}^{V}$ 为每个类标签分配一个置信度，并为整个框架分配一个总体不确定性质量. 相应地，对于第 v 个窗口，$K+1$ 个质量值都是非负的，且它们的总和是 1.

$$u^v + \sum_{k=1}^{K} b_k^v = 1, \tag{4}$$

其中 $u^v \geqslant 0$ 和 $b_k^v \geqslant 0$ 分别表示总体不确定性和第 k 类的置信度.

主观逻辑将每个窗口的证据与 Dirichlet 分布参

数联系起来.具体而言,第v个窗口的Dirichlet分布参数$\boldsymbol{\alpha}^v=(\alpha_1^v,\alpha_2^v,\cdots,\alpha_K^v)$是由该窗口的证据$\boldsymbol{e}^v=(e_1^v,e_2^v,\cdots,e_K^v)$导出的,即$\alpha_k=e_k+1$,所以置信度$b_k^v$和不确定性$u^v$的计算公式为:

$$b_k^v=\frac{e_k^v}{S^v}=\frac{\alpha_k^v-1}{S^v},\tag{5}$$

$$u^v=\frac{K}{S^v},\tag{6}$$

其中S^v是Dirichlet强度,$S^v=\sum_{i=1}^{K}(e_i^v+1)=\sum_{i=1}^{K}\alpha_i^v$.从式(5)和式(6)可以看出,对于第$v$个窗口,某个类别的证据越多,置信度越高,相应的不确定性越低,从而预测的结果也就越可信.

同时,考虑到dFCs数据具有时序结构,大脑状态会持续很长时间,某段时间内大脑网络的连接模式相对一致,在不同的时间段内可能会发生变化,而划分不同窗口可以帮助捕捉这种时序特征[50].通过在不同时间窗口内分析大脑网络的连接模式,可以揭示大脑活动的时序变化,从而更全面地理解大脑的动态特性.并且独立地计算每个窗口的置信度会导致信息丢失等问题,所以根据每个窗口的不确定性u^v对置信度b_k^v进行如下修改:

$$b_k^v=\begin{cases}\beta\times a_1\dfrac{e_k^v}{S^v}+a_2\dfrac{e_k^{v+1}}{S^{v+1}}, & v=1,\\ a_1\dfrac{e_k^{v-1}}{S^{v-1}}+\beta\times a_2\dfrac{e_k^v}{S^v}+a_3\dfrac{e_k^{v+1}}{S^{v+1}}, & 1<v<V,\\ a_1\dfrac{e_k^{v-1}}{S^{v-1}}+\beta\times a_2\dfrac{e_k^v}{S^v}, & v=V,\end{cases}\tag{7}$$

其中当$v=1$时,第1个窗口联系第2个窗口,所以$a_1=\dfrac{u_1}{\beta\times u_1+u_2}$,$a_2=\dfrac{u_2}{\beta\times u_1+u_2}$.当$1<v<V$时,第$v$个窗口联系窗口$v-1$和窗口$v+1$,所以$a_1=\dfrac{u_{v-1}}{u_{v-1}+\beta\times u_v+u_{v+1}}$,$a_2=\dfrac{u_v}{u_{v-1}+\beta\times u_v+u_{v+1}}$,$a_3=\dfrac{u_{v+1}}{u_{v-1}+\beta\times u_v+u_{v+1}}$.当$v=V$时,第$V$个窗口联系第$V-1$个窗口,所以$a_1=\dfrac{u_{v-1}}{u_{v-1}+\beta\times u_v}$,$a_2=\dfrac{u_v}{u_{v-1}+\beta\times u_v}$.其中$u_i=-\dfrac{\ln(u^i)}{u^i}$确保了在联合其他窗口过程中,不确定性较低的窗口会获得更高的权重.参数$\beta=3$确保了在联合其他窗口过程中,避免由于不确定性较高而丢失当前窗口的信息,具体在3.4.7节中讨论.

确定每个窗口的置信度后,为dFCs构造动态信任函数$\{D^v\}_{v=1}^V$,其中$D^v=\{\{b_k^v\}_{k=1}^K,u^v\}$.为了获得最终的$D=\{\{b_k\}_{k=1}^K,u\}$,引入一种用于处理不确定性和冲突的证据融合方法.Dempster-Shafer证据理论通过引入置信度的概念来表示和处理不确定以及冲突的证据,每个不同的证据来源都与一个置信度相关联.

定义4. Dempster合成规则.对2个窗口的信任函数$D^1=\{\{b_k^1\}_{k=1}^K,u^1\}$和$D^2=\{\{b_k^2\}_{k=1}^K,u^2\}$进行证据融合以得到联合信任函数$D=\{\{b_k\}_{k=1}^K,u\}$,即$D=D^1\oplus D^2$.其中$b^k$和$u$计算公式如下:

$$b_k=\frac{1}{1-C}\left(b_k^1b_k^2+\sum_{i\neq j}b_k^iu^j\right),\tag{8}$$

$$u=\frac{1}{1-C}u^1u^2,\tag{9}$$

其中$C=\sum_{i\neq j}b_i^1b_j^2$.

Dempster合成规则通过计算证据项之间的冲突度量来确定最终的置信度分配.从定义4可看出当2个窗口的不确定性都低时,预测结果具有高置信度,相反不确定性都高时,预测结果置信度较低.

将定义4的Dempster合成规则应用到具有V个窗口的dFCs数据.首先利用Dempster合成规则处理第1个窗口的信任函数$D^1=\{\{b_k^1\}_{k=1}^K,u^1\}$和第2个窗口的信任函数$D^2=\{\{b_k^2\}_{k=1}^K,u^2\}$,得到联合信任函数$D=\{\{b_k\}_{k=1}^K,u\}$,然后再次利用Dempster合成规则将$D$与第3个窗口的信任函数$D^3$进行融合,得到新的联合信任函数$D$,以此类推,可以获得$V$个窗口的dFCs数据的联合信任函数.上述动态脑网络证据融合过程可以归纳为:

$$D=D^1\oplus D^2\oplus\cdots\oplus D^V.\tag{10}$$

对于一个具有V个视图的样本$\boldsymbol{X}=(\boldsymbol{x}^v)_{v=1}^V$,通过式(8)和式(9)得到多视图融合后的每个类别的置信度b_k和总体不确定性u,从而可以计算出第k个类别的联合证据为$e_k=b_k\times\dfrac{K}{u}$,其中证据最多的类别为模型最终输出结果$y'$,即$\max\{e_1,e_2,\cdots,e_K\}$为最终诊断结果$y'$.

2.3 训练网络结构

对于传统的基于神经网络的分类器,通常采用交叉熵损失:

$$\ell_{\mathrm{ce}}=-\sum_{k=1}^{K}y_{ik}\mathrm{lb}(p_{ik}),\tag{11}$$

其中p_{ik}是第i个样本的类别k的预测概率.对于本文模型,给定通过证据网络获得的第i个样本的证据可以得到Dirichlet分布的参数α_i并形成多项式意见$Dir(P_i|\alpha_i)$,其中P_i是单纯形上的类别分配概率.对ℓ_{ce}进行简单修改后,得到调整后的交叉熵损失:

$$\ell_{\mathrm{ace}}(\alpha_i)=\sum_{k=1}^{K}y_{ik}(\psi(S_i)-\psi(\alpha_{ik})),\tag{12}$$

其中$\psi(\cdot)$是digamma函数.$\ell_{\mathrm{ace}}(\alpha_i)$是由$\alpha_i$确定的单纯

形的交叉熵损失函数的积分.

上述损失函数确保每个样本的正确标签比其他类别产生更多的证据，同时为了保证错误标签产生的证据更少，引入 KL 散度项为 Dirichlet 分布添加先验作为正则项：

$$\ell_{\mathrm{KL}}^{v}(\alpha^{v}) = D_{\mathrm{KL}}[Dir(p^{v}|\tilde{\alpha}^{v})||Dir(p^{v}|[1,\cdots,1])], \tag{13}$$

其中$\tilde{\alpha}^{v} = y + (1-y)\odot\alpha^{v}$是 Dirichlet 分布的调整参数，可以避免将真实类的证据惩罚为 0.

因此，对于样本i在经过动态证据提取模块分别获得每个窗口的证据后，可以获得 Dirichlet 分布的参数α_i，为了针对每个窗口的特定信息进行优化而综合每个窗口的损失$\ell_{\mathrm{m}}^{v} = \ell_{\mathrm{ace}}(\alpha_i^{v}) + \lambda\ell_{\mathrm{KL}}^{v}(\alpha_i^{v})$，所有样本的单一窗口总体损失为

$$\ell_{\mathrm{m}} = \sum_{i=1}^{N}\sum_{v=1}^{V}\left[\ell_{\mathrm{ace}}(\alpha_i^{v}) + \lambda\ell_{\mathrm{KL}}^{v}(\alpha_i^{v})\right], \tag{14}$$

其中$\lambda > 0$是平衡因子. 在训练过程中逐渐增大λ的值，以防止网络在训练初期过于关注 KL 散度，造成对参数空间没有很好地探索而导致网络输出一个平坦的均匀分布.

根据式(7)得到的置信度构造动态信任函数，使用 Dempster 合成规则得到证据融合后的联合信任函数$D = \left\{\{b_k\}_{k=1}^{K}, u\right\}$，从而联合证据$e_k = b_k \times \dfrac{K}{u}$，所以样本$i$的 Dirichlet 分布参数$\alpha_i = e_i + 1$. 为了优化整体的融合性能，需要考虑动态证据融合的损失，所有样本总体损失为

$$\ell_{\mathrm{d}} = \sum_{i=1}^{N}[\ell_{\mathrm{ace}}(\alpha_i) + \lambda\ell_{\mathrm{KL}}(\alpha_i)]. \tag{15}$$

为了更好地利用不同窗口之间的互补性和信息交互，确保所有观点能够形成合理的意见，从而提高整体的分类准确率，本文使用具有以下总体损失函数的多任务策略：

$$\ell = \ell_{\mathrm{m}} + \ell_{\mathrm{d}}. \tag{16}$$

2.4 DE-NNs 核心步骤实现过程

算法 2 展示了本文所提动态证据神经网络 DE-NNs 的具体流程. 首先，将动态脑网络数据$\{\boldsymbol{X}_n\}_{n=1}^{N}$作为输入，包含$N$个样本，每个样本具有$V$个窗口. 其次，对于每个样本$\boldsymbol{X} = (\boldsymbol{x}^{v})_{v=1}^{V}$，DE-NNs 将动态脑网络数据依次通过 3 个卷积滤波器得到特征图$\boldsymbol{dFC}_{\mathrm{N2G}} \in \{\mathbb{R}_{v}^{64}\}_{v=1}^{V}$. 然后，将$\boldsymbol{dFC}_{\mathrm{N2G}}$经过全连接层和激活层得到每个窗口的动态脑网络证据$e = \{e_1^{v}, e_2^{v}, \cdots, e_K^{v}\}_{v=1}^{V}$并导出 Dirichlet 分布参数，调整置信度$b_k^{v}$后构造动态信任函数$D^{v}$以获得联合信任函数$D$并更新 Dirichlet 分布参数. 最后，使用式(16)作为总体损失对网络进行训练，得到最终预测结果y'. 算法 2 的行⑥的时间复杂度为$O(V)$，行⑦~⑩的时间复杂度为$O(V)$，所以 DE-NNs 算法的时间复杂度为$O(n\times 2V)$，而V是常数，表示视图总数，所以 DE-NNs 算法总体时间复杂度为$O(n)$，算法空间复杂度为$O(n)$.

算法 2. DE-NNs 算法.

输入：动态脑网络数据$\{\boldsymbol{X}_n\}_{n=1}^{N}$；

输出：预测的脑疾病诊断结果y'.

① while epoch in epochs do

② for $n = 1 : N$ do

③ 使用 E2E 对$\boldsymbol{X}_n$进行卷积操作，得到特征图$\boldsymbol{dFC}_{\mathrm{E2E}} \in \{\mathbb{R}_{v}^{16\times\Omega\times\Omega}\}_{v=1}^{V}$；

④ 使用 E2N 对$\boldsymbol{dFC}_{\mathrm{E2E}}$进行卷积操作，得到特征图$\boldsymbol{dFC}_{\mathrm{E2N}} \in \{\mathbb{R}_{v}^{32\times\Omega}\}_{v=1}^{V}$；

⑤ 使用 N2G 对$\boldsymbol{dFC}_{\mathrm{E2N}}$进行卷积操作，得到特征图$\boldsymbol{dFC}_{\mathrm{N2G}} \in \{\mathbb{R}_{v}^{64}\}_{v=1}^{V}$；

⑥ 将$\boldsymbol{dFC}_{\mathrm{N2G}}$的第$v$个视图依次通过全连接层和激活层，得到动态脑网络证据$e = \{e_1^{v}, e_2^{v}, \cdots, e_K^{v}\}_{v=1}^{V}$；

⑦ for $v = 1 : V$ do

⑧ $\alpha^{v} \leftarrow e^{v} + 1$；

⑨ $\ell_{\mathrm{m}}^{v} \leftarrow \ell_{\mathrm{ace}}(\alpha_i^{v}) + \lambda\ell_{\mathrm{KL}}^{v}(\alpha_i^{v})$；

⑩ end for

⑪ 通过式(14)获得损失和ℓ_{m}；

⑫ 通过式(7)调整置信度b_k^{v}；

⑬ 构造动态信任函数$\{D^{v}\}_{v=1}^{V}$；

⑭ $D^{v} \leftarrow \left\{\{b_k^{v}\}_{k=1}^{K}, u^{v}\right\}$；

⑮ $D \leftarrow \left\{\{b_k\}_{k=1}^{K}, u\right\}$；

⑯ $\ell_{\mathrm{d}} \leftarrow \sum_{i=1}^{N}[\ell_{\mathrm{ace}}(\alpha_i) + \lambda\ell_{\mathrm{KL}}(\alpha_i)]$；

⑰ $\ell \leftarrow \ell_{\mathrm{m}} + \ell_{\mathrm{d}}$；

⑱ end for

⑲ end while

⑳ return y'.

3 实　　验

3.1 实验数据集

本文选择了 3 个精神分裂症数据集的原始 rs-fMRI 数据. 华西医院数据集 Huaxi 包含 103 例精神分裂症(Schizophrenia)患者和 114 例正常对照组(normal control, NC). 生物医学卓越研究中心数据集 COBRE 包含 53 例患者和 67 例正常对照组. 湘雅医院数据集

Xiangya 包含 83 例患者和 60 例正常对照组. 所有受试者不存在其他精神障碍疾病、无吸毒史，且无临床上显著的头部外伤. 在扫描华西医院和湘雅医院数据集中的图像时，要求参与者闭上眼睛但不要睡着. 对于所有要预处理的数据集，放弃前 10 卷以确保扫描仪的稳定和受试者对环境的适应性. 数据由 3.0T 西门子 Trio 磁共振扫描仪采集. rs-fMRI 扫描参数如下：重复时间 *TR* 为 2 000 ms，时间间隔为 30 ms，翻转角度为 90°，体素大小为 $3\times3\times3$ mm^3.

上述数据集使用 DPARSF 工具箱 2.0 版[51]中执行的 SPM8 对所有 rs-fMRI 数据进行图像预处理. 初始图像经过切片时间采集校正和重新对齐，归一化到 EPI 模板. 时间序列经过去趋势化处理，并通过线性回归移除协变量（包括 6 个头部运动参数、脑脊液信号和白质信号），最后进行 0.01~0.08 Hz 带通滤波. 生成的卷有 240 个时间点，并使用自动解剖标记（AAL）地图集分成 90 个感兴趣的区域（ROI）. 这些时间序列提供了关于大脑活动的信息. Leonardi 等人[52]提供了窗口长度的选择和影响的实用指南，窗口长度太短会造成虚假波动，窗口长度过长会导致无法准确识别变化. 根据经验，我们将 *TR* 设置为 2 000 ms，生成的卷有 240 个时间点，滑动窗口的长度为 30 个 *TR*，重叠设置为 7 个 *TR*，最终得到 10 个窗口[53]. 所以 3 个数据集保留 10 个时间窗口，即拥有 10 个视图.

3.2 实验平台与参数设置

本文基于 Pytorch 框架实现，通过随机梯度下降优化算法进行训练. 学习率设置为 0.000 05，Huaxi 数据集的 batch size 设置为 120，COBRE 和 Xiangya 数据集的 batch size 设置为 50，epoch 设置为 5 000，dropout 设置为 0.2.

在实验中采用 5 折交叉验证法评价动态证据神经网络 DE-NNs 的性能，所有呈现的结果均为 5 次运行的平均值和标准差.

本文采用的实验平台为 PC（13th Gen Intel® Core™ i9-13900K@3.00 GHz，NVIDIA® GeForce RTX™ 4090，RAM 为 64 GB），Windows11 操作系统.

3.3 评价指标

对比预测标签和真实标签可以得到混淆矩阵中的真正例 N_{TP}、假负例 N_{FN}、假正例 N_{FP} 和真负例 N_{TN}，如表 1 所示. N_{TP} 表示正确分类为健康的参与者，N_{FN} 表示错误分类为患病的健康参与者，N_{FP} 表示错误分类为健康的患病参与者，N_{TN} 表示正确分类为患病的参与者.

为了测试动态证据神经网络 DE-NNs 的性能，选

Table 1 Confusion Matrix

表 1 混淆矩阵

真实值	预测为正类（健康）	预测为负类（患病）
标签为正类（健康）	N_{TP}	N_{FN}
标签为负类（患病）	N_{FP}	N_{TN}

用准确率（accuracy，*ACC*）、灵敏度（sensitivity，*SEN*）、特异性（specificity，*SPE*）、阳性预测值（positive predictive value，*PPV*）、阴性预测值（negative predictive value，*NPV*）、*F*1 分数（*F*1 score，*F*1）来评估模型的分类性能. 其中 *ACC* 表示将受试者分类正确的概率，*SEN* 表示将健康的人分类正确的概率，*SPE* 表示将患者分类正确的概率，*PPV* 表示预测为健康的人的样本中真正为健康的人所占的比例，*NPV* 表示预测为患者的样本中真正为患者所占的比例，*F*1 表示模型的综合分类性能. 各评价指标公式为：

$$ACC=\frac{N_{TP}+N_{TN}}{N_{TP}+N_{TN}+N_{FP}+N_{FN}},\tag{17}$$

$$SEN=\frac{N_{TP}}{N_{TP}+N_{FN}},\tag{18}$$

$$SPE=\frac{N_{TN}}{N_{TN}+N_{FP}},\tag{19}$$

$$PPV=\frac{N_{TP}}{N_{TP}+N_{FP}},\tag{20}$$

$$NPV=\frac{N_{TN}}{N_{TN}+N_{FN}},\tag{21}$$

$$F1=2\times\frac{PPV\times SEN}{PPV+SEN}.\tag{22}$$

3.4 实验结果与分析

3.4.1 比较算法

本文首先将 DE-NNs 与经典机器学习分类算法 KNN[54]进行比较. 然后将 DE-NNs 与 2 种深度多视图算法 MVCNN[55]和 GVCNN[56]进行比较. 此外，本文还将 DE-NNs 与 3 种先进的多视图算法进行比较，即基于多组学整合的生物医学数据分类 MORONET[57]、可信多视图分类 TMC[58]和基于动态融合的可信多模态分类 MMDynamics[39]. 对以上对比方法简要总结如下：

1）KNN[54]. 该方法是经典的机器学习分类算法，通过对训练数据中的 *K* 近邻投票来进行标签预测.

2）MVCNN[55]. 该方法将来自多个视图的信息组合成一个单一且紧凑的形状描述符，提供更好的识别性能.

3）GVCNN[56]. 该方法引入分组模块来估计每个视图的内容区分度，在此基础上根据不同的区分程度将所有视图划分为不同的组，充分利用视图之间

固有的层次相关性和可分辨性.

4）MORONET[57]. 该方法将 GCN 和 VCDN 结合起来，在生物医学数据分类应用中进行有效的多组学集成的方法. 具体而言，首先利用每个组学特定的 GCN 产生的初始预测来获取跨组学发现张量，然后跨组学发现张量被重塑为一个向量，最后转发给 VCDN 进行最终的标签预测.

5）TMC[58]. 该方法在证据层面整合不同的视图，联合利用多视图信息来促进分类的可靠性和稳健性.

6）MMDynamics[39]. 该方法引入了一个稀疏的门控来捕捉每个模态内特征的信息变化，并采用真实类概率来评估每个模态的分类置信度. 对不同样本的特征和模式变化进行联合建模，动态地评估不同样本的特征级和模态级的信息量，从而整合多种模态.

3.4.2 分类性能比较分析

本文将 DE-NNs 与现有的先进分类算法在 Huaxi、COBRE、Xiangya 数据集上进行对比实验. 从表 2 中可以看出，DE-NNs 的分类性能相比常规机器学习算法和深度多视图算法有明显提升，并且相较于目前较为流行的多视图分类算法也具有很大优势. 具体而言，DE-NNs 在 Huaxi、COBRE、Xiangya 数据集上的*ACC*分别为 86.05 个百分点，85.86 个百分点，83.56 个百分点，至少提高了 1.99 个百分点，2.07 个百分点，3.28 个百分点，优于所有对比方法. 相比分类性能较好的算法 TMC 分别提高了 1.99 个百分点，2.75 个百分点，4.11 个百分点，相比 MMDynamics 分别提高了 5.03 个百分点，2.07 个百分点，3.28 个百分点.

此外，DE-NNs 在 Huaxi、COBRE、Xiangya 数据集上的*SEN*和*NPV*指标表现出色. 其中 DE-NNs 的*SEN*分别为 95.79%，95.96%，74.48%，相比其他方法至少分别提高了 3.29 个百分点，0.89 个百分点，1.51 个百分点，*NPV*分别为 93.90%，92.48%，84.38%，相比其他方法至少分别提高了 4.13 个百分点，1.3 个百分点，1.3 个百分点. 由于*SEN*和*SPE*是一对相对的概念，在某些情况下，提高*SEN*可能导致*SPE*下降，反之亦然. 同理，通常提高*NPV*可能导致*PPV*下降，所以在*ACC*一定的情况下，DE-NNs 的*SPE*和*PPV*指标仍有

Table 2 Comparative Experimental Results of Huaxi, COBRE, Xiangya Datasets

表 2 Huaxi，COBRE，Xiangya 数据集对比实验结果 %

数据集	方法	*ACC*	*SEN*	*SPE*	*PPV*	*NPV*	*F*1
Huaxi	KNN	75.35±1.29	70.44±3.01	81.00±4.00	81.03±2.66	70.45±1.53	75.34±1.40
	MVCNN	75.46±1.13	76.35±5.52	74.45±5.73	77.59±2.04	73.19±3.09	76.94±1.28
	GVCNN	79.34±1.26	79.79±12.69	78.79±10.12	81.28±3.12	77.42±5.53	80.46±2.27
	MORONET	75.43±2.80	84.49±1.53	65.29±26.46	73.23±4.53	79.05±0.06	78.42±0.56
	TMC	84.06±2.50	92.50±5.98	74.45±5.73	80.50±2.21	89.77±9.69	86.07±1.86
	MMDynamics	81.02±0.47	75.77±9.78	**87.04±6.50**	**87.12±3.61**	75.88±2.92	80.98±1.59
	DE-NNs（本文）	**86.05±0.16**	**95.79±0.04**	74.78±1.27	81.45±0.22	**93.90±0.03**	**88.04±0.06**
COBRE	KNN	75.45±0.82	84.82±7.02	61.25±10.89	76.59±0.88	73.28±1.28	80.48±2.16
	MVCNN	77.75±8.31	85.42±38.93	67.44±24.68	77.77±6.91	78.63±33.27	81.28±10.49
	GVCNN	80.64±2.77	86.82±16.65	72.44±15.01	81.37±9.19	79.84±38.42	83.88±2.02
	MORONET	76.61±1.12	89.57±1.30	58.63±6.40	75.02±0.65	80.16±7.31	81.65±0.38
	TMC	83.11±0.89	95.07±2.47	67.00±2.67	79.46±2.19	91.18±3.80	86.56±1.32
	MMDynamics	83.79±1.16	92.18±5.41	**72.67±9.55**	81.76±1.11	87.63±10.89	86.63±0.66
	DE-NNs（本文）	**85.86±0.79**	**95.96±0.17**	71.31±2.81	**82.74±3.10**	**92.48±0.47**	**88.85±1.19**
Xiangya	KNN	73.05±3.08	55.82±15.87	84.14±9.89	69.78±7.72	74.66±4.63	61.88±4.61
	MVCNN	74.88±0.86	72.22±12.34	76.80±8.96	69.26±3.73	79.42±2.49	70.62±1.68
	GVCNN	76.04±3.40	66.83±20.80	82.41±11.04	71.87±21.33	78.74±10.39	69.05±5.49
	MORONET	75.34±0.98	57.00±2.27	87.23±2.93	74.34±6.14	75.80±3.12	64.47±0.01
	TMC	79.45±0.04	65.05±2.40	88.71±0.19	78.81±1.30	79.71±0.50	71.27±1.95
	MMDynamics	80.28±1.23	72.97±5.65	84.94±0.34	75.59±0.52	83.08±3.28	74.24±2.02
	DE-NNs（本文）	**83.56±0.78**	**74.48±3.68**	**89.51±1.62**	**82.08±5.49**	**84.38±3.38**	**78.05±0.91**

注：黑体数值表示最优值. “±”前后的数值分别表示平均值和标准差.

待提升. 考虑到此种现象的发生, 本文不仅使用*ACC*来评估模型的综合性能, 还使用*F*1对本文方法与对比算法进行比较以评估综合性能, 从而给出更全面的模型表现. DE-NNs 的*F*1在 3 个数据集上分别为 88.04%, 88.85%, 78.05%, 高于所有对比方法, 至少分别提高了 1.97 个百分点, 2.22 个百分点, 3.81 个百分点.

上述实验结果表明 DE-NNs 在脑疾病诊断任务中具有较好的性能, 优于现有先进方法.

3.4.3 消融实验

为了验证 DE-NNs 各个模块的有效性, 我们设计了相应的消融实验, 分别测试了 6 种不使用相关模块的方法: 不使用 E2E 卷积滤波器(NoE2E)、不使用 E2N 卷积滤波器(NoE2N)、不使用 N2G 卷积滤波器(NoN2G)、不使用损失函数ℓ_m(NoLoss$_m$)、不使用损失函数ℓ_d(NoLoss$_d$)、不使用动态证据融合模块(NoFusion).

消融实验结果如图 3 所示, 横坐标表示 *F*1, 纵坐标表示 *ACC*, 越靠近右上角表示算法性能越好, 反之, 越靠近左下角则表示算法性能越差, 也能反映相关模块对 DE-NNs 更加重要. 在 3 个数据集上, NoN2G 方法和 NoE2N 方法的 *F*1 和 *ACC* 相比其他方法较低, 由此可见 N2G 和 E2N 卷积滤波器在特征提取阶段发挥了重要作用, 同时 NoE2E 方法的表现也比较差. 而顺序使用 E2E, E2N, N2G 卷积滤波器的 DE-NNs 方法性能最好, 此现象说明顺序使用 E2E, E2N, N2G 卷积滤波器可以充分提取脑网络特征, 提高模型性能.

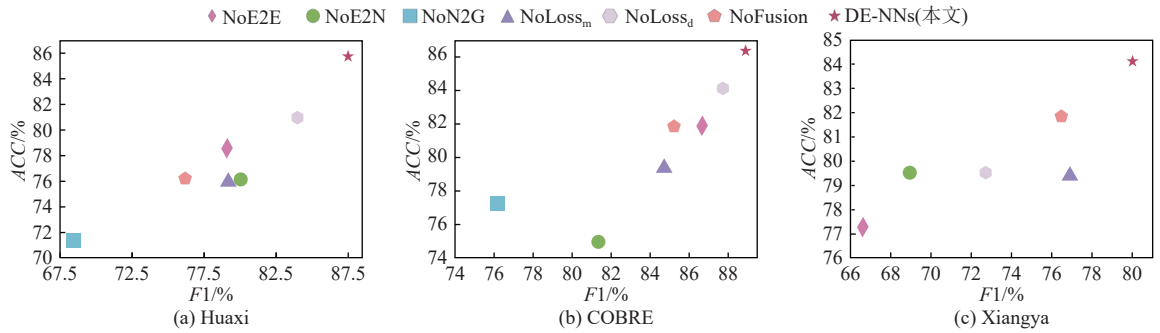


Fig. 3 Results of ablation study

图 3 消融实验结果

修改损失函数的方法 NoLoss$_m$ 和 NoLoss$_d$ 在 3 个数据集上的实验结果表明我们设计的 2 种损失函数均起到了提高模型性能的作用, 而将这 2 种损失函数组合使用的 DE-NNs 方法性能最好, 此现象说明这 2 种损失函数缺一不可, 都对模型的优化起到了重要作用.

不使用动态证据融合的 NoFusion 方法在 3 个数据集上的性能表现均差于使用动态证据融合模块的 DE-NNs 方法, 此现象说明我们设计的动态证据融合模块可以有效处理不同视图间的不确定性信息, 提高模型分类结果的可信度, 更多关于动态融合有效性的实验分析在 3.4.5 节中讨论.

3.4.4 多视图有效性分析

为了证明引入多视图方法可以提高分类性能, 本文将 DE-NNs 和 4 个比较方法使用最佳单视图(Best-View)方法进行比较. 如图 4 所示, 所有方法在

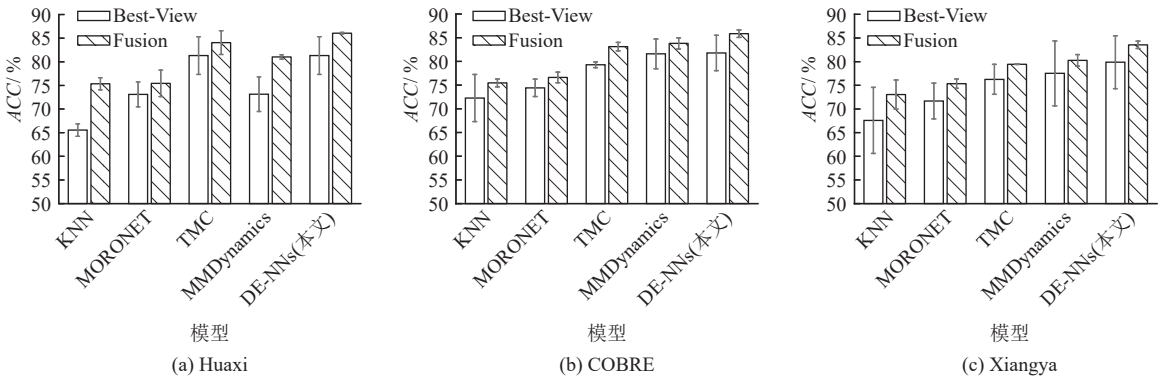


Fig. 4 Experimental results of multi-view efficiency

图 4 多视图有效性实验结果

3 个数据集上使用多视图融合策略 Fusion 时的*ACC*显著优于最佳单视图 Best-View 方法且方差较小. 其中在 Huaxi 数据集上, 5 种方法分别高出 9.80 个百分点, 2.34 个百分点, 2.74 个百分点, 7.89 个百分点, 4.73 个百分点. 在 COBRE 数据集上分别高出 3.18 个百分点, 2.20 个百分点, 3.82 个百分点, 2.20 个百分点, 4.09 个百分点. 在 Xiangya 数据集上分别高出 5.47 个百分点, 3.66 个百分点, 3.20 个百分点, 2.75 个百分点, 3.67 个百分点.

因此可以证明在本文所用 3 个精神分裂症数据集上, 使用多视图方法能够有效综合多个视图的信息, 从而获得更全面、更丰富的特征表达, 提高分类性能.

3.4.5 动态融合有效性分析

为了验证 DE-NNs 的动态证据融合机制的有效性, 本文将 DE-NNs 与 4 种不使用动态融合的方法在 3 个数据集上进行比较. 其中 BrainNetCNN[9] 不使用多视图方法, 提取完特征后直接进行分类. Best-View 在 BrainNetCNN 的基础上挑选最佳视图进行分类. Cat 将多视图特征向量进行拼接融合. Add 将多视图特征向量进行相加融合.

实验结果如表 3 所示, 在 Huaxi 数据集上, DE-NNs 的*ACC*和*F*1相比其他方法至少分别高出 7.52 个百分点和 8.04 个百分点. 除了 DE-NNs, Best-View 方法的*ACC*和*F*1略高于 Add 方法, 优于其他方法. 在 COBRE 数据集上 DE-NNs 的*ACC*和*F*1相比其他方法至少分别高出 3.28 个百分点和 3.72 个百分点. 除了 DE-NNs, Add 方法和 Cat 方法的分类性能也比较优秀, 优于其他方法. 在 Xiangya 数据集上, DE-NNs 的*ACC*和*F*1相比其他方法至少分别高出 5.03 个百分点和 6.05 个百分点. 除了 DE-NNs, 其余 4 种不使用动态融合的方法, 分类性能相似并且均低于 DE-NNs.

Table 3 Experimental Results of Dynamic Fusion Efficiency on Huaxi, COBRE, Xiangya Datasets

表 3 Huaxi，COBRE，Xiangya 数据集动态融合有效性实验结果 %

数据集	方法	*ACC*	*SEN*	*SPE*	*PPV*	*NPV*	*F*1
Huaxi	BrainNetCNN	74.68±0.07	68.42±3.83	**81.87±4.35**	81.39±1.60	69.23±0.13	74.31±0.69
	Best-View	78.53±1.28	80.56±10.65	76.17±2.22	79.52±0.39	77.49±4.75	80.00±2.77
	Cat	74.69±1.54	68.59±11.42	81.70±6.12	81.19±3.76	69.48±3.31	74.29±3.45
	Add	77.94±1.13	75.34±14.93	80.88±16.63	**82.08±5.88**	74.24±4.30	78.45±2.23
	DE-NNs（本文）	**86.05±0.16**	**95.79±0.04**	74.78±1.27	81.45±0.22	**93.90±0.03**	**88.04±0.06**
COBRE	BrainNetCNN	80.00±0.82	92.14±0.06	63.26±4.93	77.52±1.86	85.38±0.59	84.19±0.76
	Best-View	76.82±0.82	82.44±10.68	68.42±6.68	79.57±1.96	72.50±9.38	80.93±2.13
	Cat	81.82±2.06	88.43±0.32	72.33±2.52	82.08±7.11	81.22±0.55	85.13±2.89
	Add	82.58±0.92	82.21±1.57	**86.50±2.62**	**90.50±2.28**	73.08±14.88	85.03±0.41
	DE-NNs（本文）	**85.86±0.79**	**95.96±0.17**	71.31±2.81	82.74±3.10	**92.48±0.47**	**88.85±1.19**
Xiangya	BrainNetCNN	77.63±2.59	73.24±7.76	80.44±14.38	70.98±9.83	82.31±2.43	72.00±1.96
	Best-View	78.53±1.58	69.76±3.60	84.17±9.29	74.23±10.40	81.14±1.68	71.85±0.81
	Cat	76.25±1.61	67.34±13.03	81.92±3.19	70.68±5.10	79.56±2.45	68.93±6.64
	Add	77.62±0.97	71.01±7.31	81.97±1.21	71.80±2.96	81.34±5.57	71.34±0.88
	DE-NNs（本文）	**83.56±0.78**	**74.48±3.68**	**89.51±1.62**	**82.08±5.49**	**84.38±3.38**	**78.05±0.91**

注：黑体数值表示最优值. “±”前后的数值分别表示平均值和标准差.

上述实验结果表明使用传统的多视图学习方法 Add 和 Cat 可以在某些数据集上提升分类性能, 但是使用最佳视图 Best-View 方法的分类性能甚至可以高于 Add 和 Cat. 因此简单的多视图学习方法并不能满足实际应用中分类的需要, 而 DE-NNs 利用动态证据融合机制可以有效融合来自多个视图的信息, 提高分类性能.

为了进一步验证动态证据融合机制的有效性, 本文以 Huaxi 数据集中的一个样本为例(n = 195), 在证据层面进行分析. 各个窗口的不确定性和产生的证据以及最终融合后的不确定性和动态证据如表 4 所示, 证据最多的类别即为最终预测结果. 在 DE-NNs 中, 动态脑网络窗口的不确定性越低, 其预测结果的可信程度越高. 窗口 3, 7, 8, 9, 10 的不确定性较低, 分别为 0.06, 0.07, 0.15, 0.05, 0.13, 其预测结果可信程度比其他窗口高. 在动态脑网络分析工作中, 由

Table 4 Uncertainty and Evidence for Multiple Windows

表 4 多窗口的不确定性和证据

窗口	不确定性	负类证据	正类证据
1	0.22	2.09×10^{-7}	**7.29**
2	0.27	**5.29**	1.07×10^{-4}
3	0.06	$\mathbf{3.10\times10^{1}}$	9.86×10^{-16}
4	0.38	1.1	**2.15**
5	0.33	0.78	**3.26**
6	0.67	0.18	**0.83**
7	0.07	6.08×10^{-7}	$\mathbf{2.84\times10^{1}}$
8	0.15	$\mathbf{1.09\times10^{1}}$	2.03×10^{-5}
9	0.05	1.87×10^{-13}	$\mathbf{3.77\times10^{1}}$
10	0.13	0.01	$\mathbf{1.28\times10^{1}}$
融合后	2.27×10^{-6}	9.56×10^{3}	$\mathbf{9.19\times10^{5}}$

注：黑体数值表示最优值.

于每个窗口的数据质量不一致，不能够保证每个窗口的预测结果都正确. 对于不确定性最低的 5 个窗口，只有窗口 3 的预测结果错误. 经过动态证据融合后得到的不确定性显著低于所有窗口且预测结果正确. 相比于使用单一窗口预测方法，DE-NNs 可以避免类似窗口 3 不确定性低但预测结果错误，以及第 6 个窗口不确定性高但预测结果正确的情况.

以上的结果可以说明本文提出的动态证据融合机制可以有效利用动态功能连接不同窗口的证据，处理不确定性，提高分类性能.

3.4.6 可解释性分析

本文所提方法 DE-NNs 可根据反向传播信息发掘与疾病相关的动态功能连接，其结果如图 5 所示. 图 5 中矩阵颜色较亮的点表示连接强度较高，反之

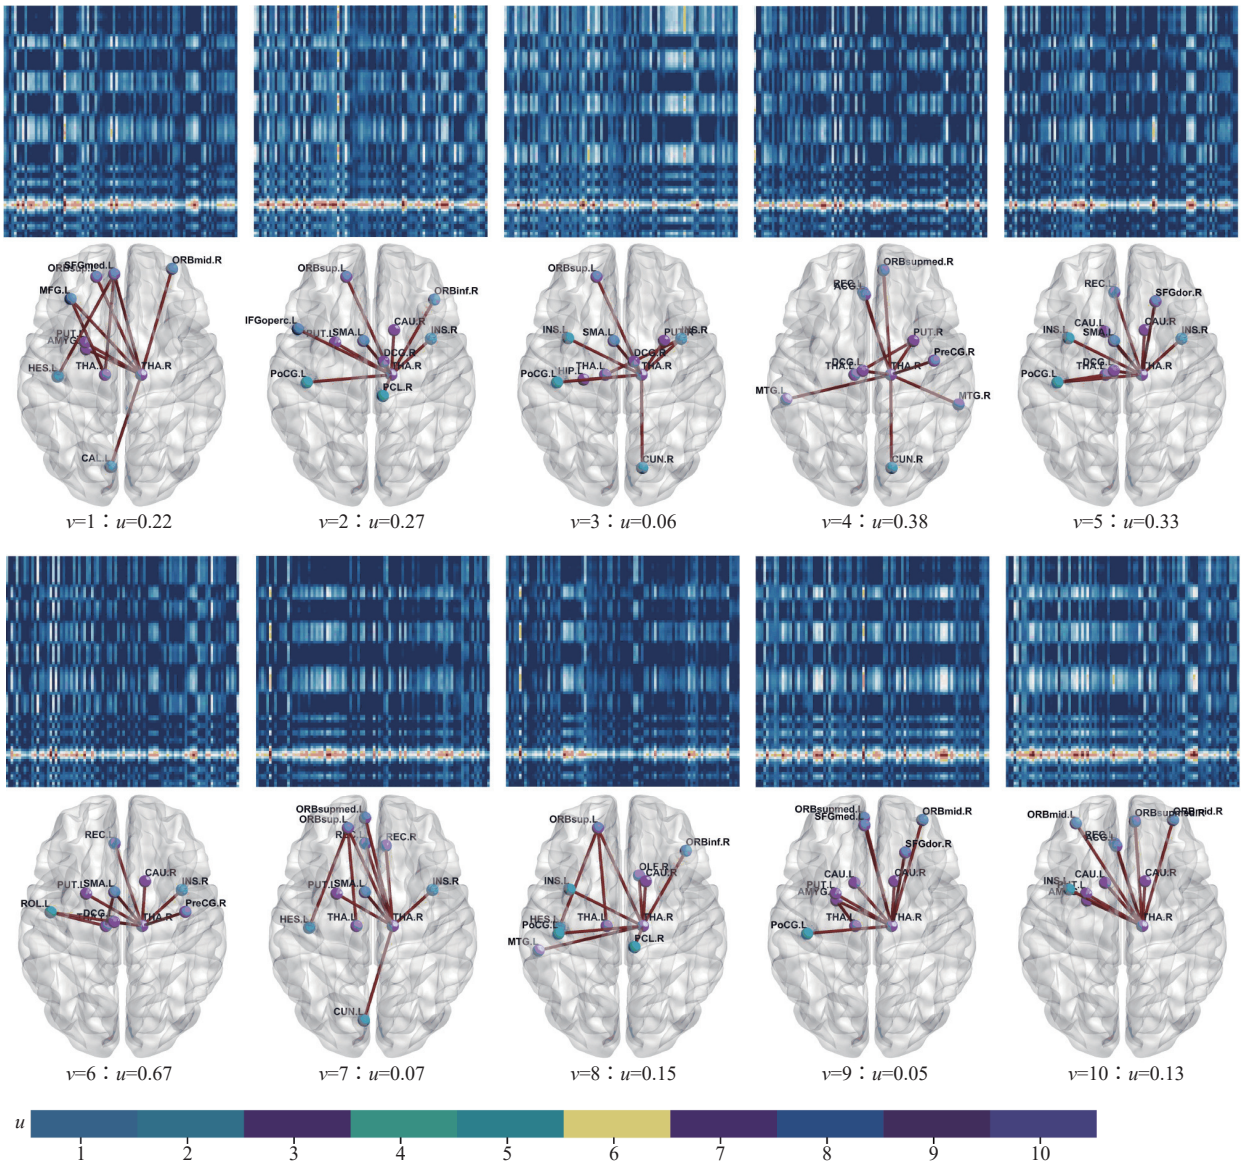


Fig. 5 Interpretability of dynamic brain networks

图 5 动态脑网络可解释性

颜色较暗区域则表示连接强度较低. 为了更为明显地展示连接强度较高的判别连接, 本文将矩阵中连接强度最高的判别连接在脑图中可视化, 其中节点表示对应脑区, 连线表示节点间的连接关系.

从图 5 中可以发现有 2 个有趣的现象. 其一, 动态脑网络的 10 个窗口的判别脑区均与丘脑相关(THA_L 和 THA_R). 丘脑位于第 3 脑室的两侧, 是人类感觉的高级中枢, 并有着信号传递的中继作用. 目前大量文献证明精神分裂疾病会导致丘脑区域出现异常. 例如, Byne 等人[59] 表明丘脑为精神分裂症中受损的多个功能回路提供节点连接. Andreasen 等人[60] 在精神分裂症患者的丘脑和邻近蛋白质中观察到特定的区域异常. 以上结果证明本文方法捕捉到了与疾病相关的区域.

其二, 对比不确定性(u)最低和最高的 2 个视图(v), v=9 和 v=6, 可以发现不确定性低的视图涉及的脑区多数集中在前额叶区域, 而发现不确定性高的视图多数集中在顶叶附近. 动态脑网络窗口的不确定性越低, 其预测结果的可信程度越高. 前额叶位于脑的前半部, 与整个脑部都有深入的神经联系, 它被认为是大脑进行精神活动的主要部分, 因而相比枕叶与精神分裂症的联系更为密切. Perlstein 等人[61] 发现精神分裂症患者的工作记忆功能障碍是由背外侧前额叶皮层的紊乱引起的. Tan 等人[62] 认为, 精神分裂症患者的前额叶皮层的层次结构可能会受到损害. 以上的结果均可以说明本文方法所获取的不确定性度量值的有效性.

3.4.7 相关参数分析

在本节中, 对参数β的取值进行讨论, 分析β的选择对 DE-NNs 分类性能的影响. 如果β取值过小, 可能会忽略当前窗口的特征, 而取值过大则会过分关注当前窗口的特征, 所以为了有效联合其他窗口, 需要对参数β的大小进行分析. 如图 6 所示, 参数$\beta=3$时, DE-NNs 在 3 个数据集上的分类性能均为最佳, *ACC* 分别为 86.05%, 85.86%, 83.56%, 至少提高了 0.47 个百分点, 1.82 个百分点, 1.36 个百分点, 并且方差较小, 模型相对稳定. 所以为了确保有效利用其他窗口的特征, 提高 DE-NNs 的分类性能, 将β设置为 3.

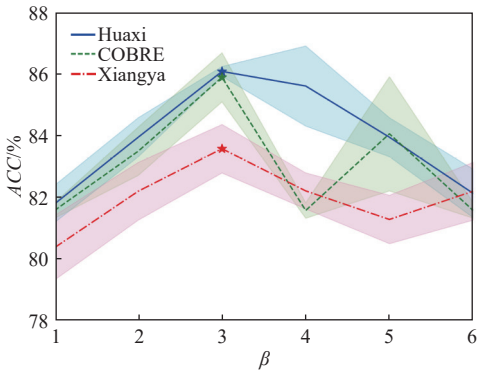


Fig. 6 Parameter analysis on Huaxi, COBRE, Xiangya dataset

图 6 Huaxi，COBRE，Xiangya 数据集参数分析

4 结论与展望

针对脑网络分析中存在的不确定性和无法有效利用多窗口信息等问题, 本文提出了基于动态证据神经网络的脑网络分析算法 DE-NNs. 首先, 本文引入多视图学习框架, 设计了一种在多视图学习框架下的动态脑网络特征获取模块, 利用 E2E, E2N, N2G 卷积滤波器充分提取 dFCs 每个窗口的证据. 其次, 本文工作在动态脑网络分析中引入证据理论处理不确定性信息, 设计了一种动态证据融合机制, 在多视图分类的决策层进行动态证据融合, 使模型能够提高分类的可信度和鲁棒性. 最后, 在 3 个精神分裂症数据集上进行验证, 实验结果表明 DE-NNs 可以有效分析脑网络, 并提高分类性能. 我们会进一步研究在动态脑网络信息融合过程中产生的冲突, 处理不确定性信息和提高分类性能, 并研究窗口数量对分类性能的影响.

作者贡献声明: 侯涛提出了算法的核心思想, 设计了实验方案, 完成实验并撰写论文; 丁卫平提出了整个算法的框架并对整个算法思想进行完善, 以及修改论文; 黄嘉爽、鞠恒荣完善了算法的思路, 指导论文写作并修改论文.

参 考 文 献

[1] Cui Hejie, Dai Wei, Zhu Yanqiao, et al. BrainGB: A benchmark for brain network analysis with graph neural networks[J]. IEEE Transactions on Medical Imaging, 2022, 42(2): 493−506

[2] Zhu Qi, Xu Ruting, Wang Ran, et al. Stacked topological preserving dynamic brain networks representation and classification[J]. IEEE Transactions on Medical Imaging, 2022, 41(11): 3473−3484

[3] Jie Biao, Zhang Daoqiang. The novel graph kernel for brain networks with application to MCI classification[J]. Chinese Journal of Computers, 2016, 39(8): 1667−1680 (in Chinese)
(接标, 张道强. 面向脑网络的新型图核及其在 MCI 分类上的应用[J]. 计算机学报, 2016, 39(8): 1667−1680)

[4] Sui Jing, Pearlson G, Caprihan A, et al. Discriminating schizophrenia and bipolar disorder by fusing fMRI and DTI in a multimodal CCA+ joint ICA model[J]. Neuroimage, 2011, 57(3): 839−855

[5] Olabi B, Ellison-Wright I, McIntosh A M, et al. Are there progressive brain changes in schizophrenia? A meta-analysis of structural magnetic resonance imaging studies[J]. Biological Psychiatry, 2011, 70(1): 88−96

[6] Zhang Jie, Cheng Wei, Liu Zhaowen, et al. Neural, electrophysiological and anatomical basis of brain-network variability and its characteristic changes in mental disorders[J]. Brain, 2016, 139(8): 2307−2321

[7] Yin Weiyan, Li Tengfei, Hung S C, et al. The emergence of a functionally flexible brain during early infancy[J]. Proceedings of the National Academy of Sciences, 2020, 117(38): 23904−23913

[8] Guo Shuixia, Zhao Wei, Tao Haojuan, et al. The instability of functional connectivity in patients with schizophrenia and their siblings: A dynamic connectivity study[J]. Schizophrenia Research, 2018, 195: 183−189

[9] Kawahara J, Brown C J, Miller S P, et al. BrainNetCNN: Convolutional neural networks for brain networks; towards predicting neurodevelopment[J]. NeuroImage, 2017, 146: 1038−1049

[10] Jie Biao, Liu Mingxia, Lian Chunfeng, et al. Designing weighted correlation kernels in convolutional neural networks for functional connectivity based brain disease diagnosis[J]. Medical Image Analysis, 2020, 63: 101709

[11] Li Xiaoxiao, Yuan Zhou, Dvornek N, et al. BrainGNN: Interpretable brain graph neural network for fMRI analysis[J]. Medical Image Analysis, 2021, 74: 102233

[12] Zhu Wenyong, Sun Liang, Huang Jiashuang, et al. Dual attention multi-instance deep learning for Alzheimer's disease diagnosis with structural MRI[J]. IEEE Transactions on Medical Imaging, 2021, 40(9): 2354−2366

[13] Ji Junzhong, Chen Zhihui, Yang Cuicui. Convolutional neural network with sparse strategies to classify dynamic functional connectivity[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 26(3): 1219−1228

[14] Li Yang, Liu Jingyu, Tang Zhenyu, et al. Deep spatial-temporal feature fusion from adaptive dynamic functional connectivity for MCI identification[J]. IEEE Transactions on Medical Imaging, 2020, 39(9): 2818−2830

[15] Hutchison R M, Womelsdorf T, Allen E A, et al. Dynamic functional connectivity: Promise, issues, and interpretations[J]. Neuroimage, 2013, 80: 360−378

[16] Gonzalez-Castillo J, Bandettini P A. Task-based dynamic functional connectivity: Recent findings and open questions[J]. Neuroimage, 2018, 180: 526−533

[17] He Tao, Hu Junjie, Song Ying, et al. Multi-task learning for the segmentation of organs at risk with label dependence[J]. Medical Image Analysis, 2020, 61: 101666

[18] He Tao, Zhang Lei, Guo Jixiang, et al. Multilabel classification by exploiting data-driven pair-wise label dependence[J]. International Journal of Intelligent Systems, 2020, 35(9): 1375−1396

[19] Yager R R. On the Dempster-Shafer framework and new combination rules[J]. Information Sciences, 1987, 41(2): 93−137

[20] Wu Weizhi, Yang Li, Tan Anhui, et al. Granularity selections in generalized incomplete multi-granular labeled decision systems[J]. Journal of Computer Research and Development, 2018, 55(6): 1263−1272 (in Chinese)
(吴伟志, 杨丽, 谭安辉, 等. 广义不完备多粒度标记决策系统的粒度选择[J]. 计算机研究与发展, 2018, 55(6): 1263−1272)

[21] Sun Huaijiang, Yang Jingyu. A combination method for dependent evidences[J]. Chinese Journal of Computers, 1999, 22(9): 1004−1007 (in Chinese)
(孙怀江, 杨静宇. 一种相关证据合成方法[J]. 计算机学报, 1999, 22(9): 1004−1007)

[22] Fang Ran, Liao Huchang, Mardani A. How to aggregate uncertain and incomplete cognitive evaluation information in lung cancer treatment plan selection? A method based on Dempster-Shafer theory[J]. Information Sciences, 2022, 603: 222−243

[23] Luo Hao, Yan Guanghui, Zhang Meng, et al. Research on node importance fused multi-information for multi-relational social networks[J]. Journal of Computer Research and Development, 2020, 57(5): 954−970 (in Chinese)
(罗浩, 闫光辉, 张萌, 等. 融合多元信息的多关系社交网络节点重要性研究[J]. 计算机研究与发展, 2020, 57(5): 954−970)

[24] Zhou S K, Greenspan H, Davatzikos C, et al. A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises[J]. Proceedings of the IEEE, 2021, 109(5): 820−838

[25] Lin Qiuhua, Niu Yanwei, Sui Jing, et al. SSPNet: An interpretable 3D-CNN for classification of schizophrenia using phase maps of resting-state complex-valued fMRI data[J]. Medical Image Analysis, 2022, 79: 102430

[26] Yan Weizheng, Calhoun V, Song Ming, et al. Discriminating schizophrenia using recurrent neural network applied on time courses of multi-site fMRI data[J]. EBioMedicine, 2019, 47: 543−552

[27] Huang S G, Xia Jing, Xu Liyuan, et al. Spatio-temporal directed acyclic graph learning with attention mechanisms on brain functional time series and connectivity[J]. Medical Image Analysis, 2022, 77: 102370

[28] Hong Min, Jia Caiyan, Li Yafang, et al. Sample-weighted multi-view clustering[J]. Journal of Computer Research and Development, 2019, 56(8): 1677−1685 (in Chinese)
(洪敏, 贾彩燕, 李亚芳, 等. 样本加权的多视图聚类算法[J]. 计算机研究与发展, 2019, 56(8): 1677−1685)

[29] Liu Jinhua, Wang Yang, Qian Yuhua. Multi-view clustering with spectral structure fusion[J]. Journal of Computer Research and Development, 2022, 59(4): 922−935 (in Chinese)
(刘金花, 王洋, 钱宇华. 基于谱结构融合的多视图聚类[J]. 计算机研究与发展, 2022, 59(4): 922−935)

[30] Zhang Zheng, Liu Li, Shen Fumin, et al. Binary multi-view clustering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(7): 1774−1782

[31] Jia Xiaodong, Jing Xiaoyuan, Zhu Xiaoke, et al. Semi-supervised multi-view deep discriminant representation learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 43(7): 2496−2509

[32] Zhao Jing, Xie Xijiong, Xu Xin, et al. Multi-view learning overview: Recent progress and new challenges[J]. Information Fusion, 2017, 38: 43−54

[33] He Tao, Mao Hua, Yi Zhang. Moving object recognition using multi-view three-dimensional convolutional neural networks[J]. Neural Computing and Applications, 2017, 28: 3827−3835

[34] Liang Xinyan, Qian Yuhua, Guo Qian, et al. Multi-granulation fusion-driven method for many-view classification[J]. Journal of Computer Research and Development, 2022, 59(8): 1653−1667 (in Chinese)
(梁新彦, 钱宇华, 郭倩, 等. 多粒度融合驱动的超多视图分类方法[J]. 计算机研究与发展, 2022, 59(8): 1653−1667)

[35] Zhou Yuan, Yue Xiaodong, Chen Yufei, et al. Convolutional redistribution network for multi-view medical image diagnosis[C]// Proc of the 11th Workshop on Clinical Image-Based Procedures. Berlin: Springer, 2023: 54−61

[36] Ding Yuhang, Yu Xin, Yang Yi. RFNet: Region-aware fusion network for incomplete multi-modal brain tumor segmentation[C]//Proc of the 34th IEEE Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 3975−3984

[37] Mao Shitong, Sejdić E. A review of recurrent neural network-based methods in computational physiology[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(10): 6983−7003

[38] He Tao, Mao Hua, Yi Zhang. Subtraction gates: Another way to learn long-term dependencies in recurrent neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 33(4): 1740−1751

[39] Han Zongbo, Yang Fan, Huang Junzhou, et al. Multimodal dynamics: Dynamical fusion for trustworthy multimodal classification[C]//Proc of the 35th IEEE Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 20707−20717

[40] Liang Xinyan, Qian Yuhua, Guo Qian, et al. AF: An association-based fusion method for multi-modal classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(12): 9236−9254

[41] Dempster A P. Upper and lower probabilities induced by a multivalued mapping[J]. The Annals of Mathematical Statistics, 1967, 38(4): 325−339

[42] Dempster A P. A generalization of Bayesian inference[J]. Journal of the Royal Statistical Society: Series B (Methodological), 1968, 30(2): 205−232

[43] Sankararaman S, Mahadevan S. Model validation under epistemic uncertainty[J]. Reliability Engineering & System Safety, 2011, 96(9): 1232−1241

[44] Jøsang A, Hankin R. Interpretation and fusion of hyper opinions in subjective logic[C]//Proc of the 15th Int Conf on Information Fusion. Piscataway, NJ: IEEE, 2012: 1225−1232

[45] Han Zongbo, Zhang Changqing, Fu Huazhu, et al. Trusted multi-view classification with dynamic evidential fusion[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(2): 2551−2566

[46] Xu Shaoxun, Chen Yufei, Ma Chao, et al. Deep evidential fusion network for medical image classification[J]. International Journal of Approximate Reasoning, 2022, 150: 188−198

[47] Liu Wei, Yue Xiaodong, Chen Yufei, et al. Trusted multi-view deep learning with opinion aggregation[C]//Proc of the 36th AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2022: 7585−7593

[48] Xu Cai, Zhao Wei, Zhao Jinglong, et al. Uncertainty-aware multiview deep learning for Internet of things applications[J]. IEEE Transactions on Industrial Informatics, 2022, 19(2): 1456−1466

[49] Wong T T. Generalized Dirichlet distribution in Bayesian analysis[J]. Applied Mathematics and Computation, 1998, 97(2/3): 165−181

[50] Lee S H, Yang Dan. Neuromodulation of brain states[J]. Neuron, 2021, 76(1): 209−222

[51] Yan Chaogan, Zang Yufeng. DPARSF: A MATLAB toolbox for "pipeline" data analysis of resting-state fMRI[J]. Frontiers in Systems Neuroscience, 2010, 4: 1377

[52] Leonardi N, Van De Ville D. On spurious and real fluctuations of dynamic functional connectivity during rest[J]. Neuroimage, 2015, 104: 430−436

[53] Wang Mingliang, Huang Jiashuang, Liu Mingxia, et al. Modeling dynamic characteristics of brain functional connectivity networks using resting-state functional MRI[J]. Medical Image Analysis, 2021, 71: 102063

[54] Fix E, Hodges J L. Discriminatory analysis: Nonparametric discrimination: Consistency properties[J]. International Statistical Review/Revue Internationale de Statistique, 1989, 57(3): 238−247

[55] Su Hang, Maji S, Kalogerakis E, et al. Multi-view convolutional neural networks for 3D shape recognition[C]//Proc of the 15th IEEE Int Conf on Computer Vision. Piscataway, NJ: IEEE, 2015: 945−953

[56] Feng Yifan, Zhang Zizhao, Zhao Xibin, et al. GVCNN: Group-view convolutional neural networks for 3D shape recognition[C]//Proc of the 31st IEEE Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 264−272

[57] Wang Tongxin, Shao Wei, Huang Zhi, et al. MOGONET integrates multi-omics data using graph convolutional networks allowing patient classification and biomarker identification[J]. Nature Communications, 2021, 12(1): 3445

[58] Han Zongbo, Zhang Changqing, Fu Huazhu, et al. Trusted multi-view classification[J]. arXiv preprint, arXiv: 2102.02051, 2021

[59] Byne W, Hazlett E A, Buchsbaum M S, et al. The thalamus and schizophrenia: Current status of research[J]. Acta Neuropathologica, 2009, 117: 347−368

[60] Andreasen N C, Arndt S, Swayze V, et al. Thalamic abnormalities in schizophrenia visualized through magnetic resonance image averaging[J]. Science, 1994, 266(5183): 294−298

[61] Perlstein W M, Carter C S, Noll D C, et al. Relation of prefrontal cortex dysfunction to working memory and symptoms in schizophrenia[J]. American Journal of Psychiatry, 2001, 158(7): 1105−1113

[62] Tan Haoyang, Sust S, Buckholtz J W, et al. Dysfunctional prefrontal regional specialization and compensation in schizophrenia[J]. American Journal of Psychiatry, 2006, 163(11): 1969−1977



Hou Tao, born in 2000. Master candidate. His main research interests include deep learning and brain network analysis.

侯　涛, 2000 年生. 硕士研究生. 主要研究方向为深度学习、脑网络分析.



Ding Weiping, born in 1979. PhD, professor, PhD supervisor. Senior member of CCF. His main research interests include data mining, deep learning, machine learning, granular computing, evolutionary computing, and big data analytics.

丁卫平, 1979 年生. 博士，教授，博士生导师. CCF 高级会员. 主要研究方向为数据挖掘、深度学习、机器学习、粒计算、演化计算、大数据分析.



Huang Jiashuang, born in 1988. PhD, associate professor. His main research interests include brain network analysis and deep learning.

黄嘉爽, 1988 年生. 博士，副教授. 主要研究方向为脑网络分析、深度学习.



Ju Hengrong, born in 1989. PhD, associate professor. His main research interests include granular computing, rough sets, machine learning, and knowledge discovery.

鞠恒荣, 1989 年生. 博士，副教授. 主要研究方向为粒计算、粗糙集、机器学习、知识发现.