

DOI:10.20033/j.1003-7241.(2026)06-0083-05

# 基于独立成分分析与 LSTM 网络的患者病情预测模型研究

陈丹<sup>1,2</sup>

(1. 南宁市第二人民医院 信息科, 南宁 530031; 2. 广西大学 计算机与电子信息学院, 南宁 530003)

**摘要:**为提高脑疾病患者病情预测的精度,以阿尔茨海默脑疾病为研究对象,提出一种基于独立成分分析与 LSTM 的预测模型。模型分为 3 个阶段,首先采用独立成分分析法,将患者功能磁共振成像数据分解成若干状态网络,获取个体独立成分。然后利用滑动窗口构建动态功能脑网络。最后将动态功能脑网络输入长短期记忆(long short-term memory, LSTM)网络,通过 LSTM 网络分类预测患者病情。在仿真平台上对基于独立成分分析法与 LSTM 的预测模型进行仿真,结果表明,基于独立成分分析法与 LSTM 的预测方法,可有效分类预测健康、患病、早期轻度认知障碍 3 类阿尔茨海默脑疾病,且具有较高的预测精度,平均分类准确率、敏感性、特异性和  $F_1$  值分别达到 87.37%、87.48%、89.15%、87.65%,相较于支持向量机(support vector machine, SVM)、图神经网络(graph neural network, GNN)构建的预测模型,具有明显优势。由此得出,基于独立成分分析法与 LSTM 的预测方法,提高了脑疾病患者病情的预测精度,为脑疾病患者病情的精确预测奠定了基础。

**关键词:**深度学习; LSTM 网络; 独立成分分析; 病情预测; 阿尔茨海默症; 脑疾病

中图分类号: TP183; TP391

文献标志码: A

文章编号: 1003-7241(2026)06-0083-05

## Research on patient condition prediction model based on independent component analysis and LSTM network

Chen Dan<sup>1,2</sup>

(1. Information Department, Nanning Second People's Hospital, Nanning 530031, China;

2. School of Computer and Electronic Information, Guangxi University, Nanning 530003, China)

**Abstract:** To improve the accuracy of predicting the condition of patients with brain diseases, a prediction model based on independent component analysis and LSTM is proposed with Alzheimer's disease as the research object. The model is divided into three stages. Firstly, independent component analysis is used to decompose the patient's functional magnetic resonance imaging data into several state networks and obtain individual independent components. Then sliding windows is used to construct dynamic functional brain networks. Finally, the dynamic functional brain network is input into a long short term memory (LSTM) network, which is used to classify and predict the patient's condition. On the simulation platform, the prediction model based on independent component analysis and LSTM is simulated. The results show that the prediction method based on independent component analysis and LSTM can effectively classify and predict three types of Alzheimer's brain diseases: healthy, diseased, and early mild cognitive impairment, with high prediction accuracy. The average classification accuracy, sensitivity, specificity, and  $F_1$  score reaches 87.37%, 87.48%, 89.15%, and 87.65%, respectively. Compared with the prediction models constructed by SVM, GNN, etc., it has obvious advantages. From this, it can be concluded that the prediction method based on independent component analysis and LSTM improves the accuracy of predicting the condition of patients with brain diseases, laying the foundation for accurate prediction of the condition of patients with brain diseases.

**Keywords:** deep learning; LSTM network; independent component analysis; disease prediction; Alzheimer's disease; brain disease

大脑是人体的核心器官,对调节机体平衡,控制机体活动具有重要意义。然而由于环境因素、遗传因素和感染因素等因素的影响,脑疾病愈发频繁,严重阻碍了患者的正常生活。因此,实现高精度的脑疾病诊断病并进行针对性的治疗,对脑疾病患者尤为重要。近年来,随着医学技术的进步和科技的发展,借助机器和深度学习算法诊断脑疾病的方法日益成熟,如孙磊等<sup>[1]</sup>提出了一种变换域的自适应功能连接网络学习模型,通过采用该模型对核磁共振

仪器拍摄的脑疾病患者磁共振影像进行学习和分类,实现了脑疾病中轻度认知障碍和孤独症的识别;张格等<sup>[2]</sup>通过频域和空间域图卷积神经网络的特点,并将其应用于脑疾病分类预测中,实现了脑疾病的自动识别;李涛等<sup>[3]</sup>结合多层脑功能网络,通过计算单层网络拓扑属性均值和标准差,并利用深度学习算法进行分类,实现了阿尔茨海默病的诊断,为阿尔茨海默病的临床诊断提供了参考;李懿等<sup>[4]</sup>认为基于深度学习的算法可有效提取脑电信号特征,

收稿日期:2024-11-29;录用日期:2024-12-30

作者简介:陈丹(1986—)男,高级工程师,研究方向:信息系统建设、网络工程。

引用本文:陈丹. 基于独立成分分析与 LSTM 网络的患者病情预测模型研究[J]. 自动化技术与应用, 2026, 45(6): 83-87. (Chen Dan. Research on patient condition prediction model based on independent component analysis and LSTM network[J]. Techniques of Automation and Applications, 2026, 45(6): 83-87.)

并通过对特征的学习实现抑郁症、精神分裂症等脑疾病的自动分类,为脑疾病的自动诊断奠定了基础。上述研究表明,基于深度学习的脑疾病诊断已取得一定的研究成果,初步实现了脑疾病的自动识别。但脑疾病识别精度约为80%,还有待进一步提高。分析其原因是在利用深度学习算法对脑疾病进行预测时,通常忽略了数据中隐藏的时间信息,导致其预测精度满足不了需求。因此,为提高脑疾病自动识别的精度,采用独立成分分析对数据进行了分析处理,然后结合LSTM网络在时间序列上的预测优势,对脑疾病进行分类预测。

## 1 基本方法

### 1.1 独立成分分析法

独立成分分析是一种数据分析法,通过将多个变量信号分解成独立的非高斯信号线性组合成分,可有效提取信号中的信息。其基本处理框架如图1所示<sup>[5-6]</sup>。

假设有*i*个观测信号*x*,*x*为*n*个独立未知信号*s*通过线性混合得到的,因此*x<sub>i</sub>*可表示为

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n, i = 1, 2, \dots, m \quad (1)$$

假设每个观测变量*x<sub>i</sub>*和未知源变量*s<sub>j</sub>*为随机变量,则式(1)可用矢量矩阵表示为

$$\mathbf{X} = \mathbf{A}\mathbf{s} \quad (2)$$

式中,*A*为混合矩阵*a<sub>ij</sub>*。

对式(3)进行变形,得

$$x_i = \sum_{j=1}^n a_{ij}s_j \quad (3)$$

该过程描述了观测数据由未知源信号*s*混合生成的过程。当满足统计独立、非高斯分布、未知混合矩阵为方,且引入观测器的噪声较小时,可通过计算未知混合矩阵的逆*W*,求解到独立分量*s*为

$$\mathbf{s} = \mathbf{W}\mathbf{x} \quad (4)$$

独立成分分析法有效利用了高阶统计信息,更利于多个变量信号分解,具有广泛的应用前景。在神经医学应用中,独立成分分析法可从大量的信号中提取脑活动特征,被广泛应用于功能磁共振成像的数据分析处理<sup>[7-8]</sup>。因此,本研究借助独立成分分析法的优势,采用该方法将功能磁共振成像数据分解成若干状态网络,获取个体独立成分。




图1 独立成分分析法基本处理框架

Fig. 1 Basic processing framework of independent component analysis method

### 1.2 LSTM 网络

LSTM 网络是一种由输入门、输出门和遗忘门 3 个“门”结构组成的循环神经网络,如图 2 所示。图中, $\sigma$  为

激活函数; $C_{t-1}$ 、 $C_t$  分别为  $t$  上一时刻和  $t$  时刻细胞状态,  $h_{t-1}$ 、 $h_t$  分别为  $t$  上一时刻和  $t$  时刻网络输入,  $\tanh$  为激活函数。

LSTM 网络中,输入门的工作机制可用式(5)~(6)表示,包括当前序列  $i(t)$  和前一时刻序列  $\tilde{C}(t)$  两部分;输出门的工作机制可用式(7)表示,遗忘门的工作机制可用式(8)表示。

$$i(t) = \sigma(w_i \cdot [h(t-1), X(t)] + b_i) \quad (5)$$

$$\tilde{C}(t) = \tan(w_c \cdot [h(t-1), X(t)] + b_c) \quad (6)$$

$$f(t) = \sigma(w_f \cdot [h(t-1), X(t)] + b_f) \quad (7)$$

$$h(t) = \sigma(w_o \cdot [h(t-1), X(t)] + b_o) \cdot$$

$$\tanh[C(t-1) \cdot f(t) + i(t) \cdot \tilde{C}(t)] \quad (8)$$

式中,  $X(t)$ 、 $h(t)$  分别表示当前输入与输出;  $C(t-1)$ 、 $h(t-1)$  分别表示前一时刻状态和输出;  $\sigma$  表示 sigmoid 函数;  $w_i$ 、 $w_c$ 、 $w_f$ 、 $w_o$  表示不同权重系数;  $b_i$ 、 $b_c$ 、 $b_f$ 、 $b_o$  为对应偏置。

LSTM 网络可解决普通循环神经网络存在的时间长序列梯度消失问题,且具有结构简单容易实现的特点,因此常用于时间序列预测<sup>[9-10]</sup>。本研究中,功能磁共振成像具有强烈的时间维度信息,可记录脑疾病在短时间内的变化。因此,为更好地实现患者脑疾病病情预测,选用 LSTM 网络作为预测网络。




图2 LSTM网络结构

Fig. 2 LSTM network structure

## 2 脑疾病患者病情预测

结合上述独立成分分析法和 LSTM 网络,对脑疾病患者病情进行预测的思路为:首先采用独立成分分析法获取脑疾病的功能磁共振成像图像组级和个体独立成分,然后构建具有时间信号特征的动态功能脑网络,最后将构建的动态功能脑网络输入 LSTM 网络中进行分类输出,即可实现脑疾病患者病情预测。

基于上述思路,将脑疾病患者病情预测步骤分为独立成分获取、动态功能脑网络构建、LSTM 网络预测 3 个部分,具体流程如下。

采用独立成分分析获取功能磁共振成像独立成分。首先是利用两次主成分分析将功能磁共振成像数据的主成分降至 15,然后采用 Infomax 算法将数据分解成 15 个组级独立成分,最后采用组信息引导独立成分分析反向重

建获取个体独立成分,即实现了独立成分获取,减少了数据特征维度<sup>[11-12]</sup>。

动态功能脑网络构建。基于获取的个体独立成分,采用滑动窗口对时间序列进行截取,即可得到若干窗口,并按照时间顺序进行排列可构建动态功能脑网络。动态功能脑网络构建过程中,假设存在  $m$  个子时间序列  $T_m = [T_m^1, T_m^2, \dots, T_m^w]$  及其对应皮尔逊相关子连接矩阵  $R_m = [R_m^1, R_m^2, \dots, R_m^w]$ ,其中  $w$  为滑动窗口数量,  $T_m^w, R_m^w$  分别表示  $m$  个序列中第  $w$  个子时间序列及其子连接矩阵,则

$$R_m^w = \begin{cases} \text{corr}[T_m^w(:,p), T_m^w(:,q)], p \neq q \\ 1, p = q \end{cases} \quad (9)$$

式中,  $\text{corr}$  为皮尔逊相关计算。此时,若变量  $A, B$  表示  $T_m^w(:,p), T_m^w(:,q)$ , 则

$$\text{corr}[A, B] = \frac{\sum_{k=1}^n \frac{(A_k - E(A))(B_k - E(B))}{\sigma_A \sigma_B}}{n} \quad (10)$$

式中,  $E(A), \sigma_A$  分别为  $A$  的均值和标准差;  $E(B), \sigma_B$  分别为  $B$  的均值和标准差。将其上三角元素改为一维向量  $X_m^w$ <sup>[13-14]</sup>, 则

$$X_m^w = \text{triu}(R_m^w) \quad (11)$$

如此,可得到每个独立成分的动态特征表示,进而可构建动态功能脑网络。

LSTM 网络预测。基于深度学习框架搭建 LSTM 网络模型。设置 LSTM 网络隐藏层数、输入大小、网络层数,并在 Tensorflow 深度学习框架 LSTM 网络模型。然后将构建的动态功能脑网络分为两部分,并将第一部分动态功能脑网络输入 LSTM 网络模型中进行学习和训练,获取训练完成的 LSTM 网络预测模型。然后将另一部分的动态功能脑网络输入训练完成的 LSTM 网络预测模型中,其输出结果即为脑疾病患者病情预测结果。

上述流程可用图 3 示意。

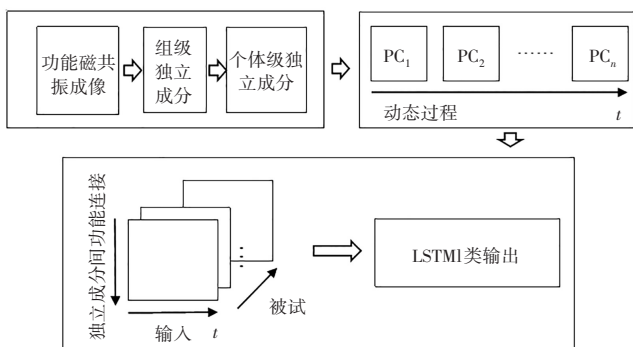


图3 本研究的脑疾病患者病情预测流程

Fig. 3 Prediction process of brain disease patients in this study

### 3 仿真实验

#### 3.1 实验环境搭建

本次实验基于 Tensorflow 深度学习框架和 Python 语

言搭建仿真模型,并在 Windows 10 操作系统上运行。系统配置 Intel Core i7 7700 (3.60 GHz) CPU, NVIDIA GeForce RTX2060 GPU。

#### 3.2 数据来源及预处理

本次实验数据来自阿尔茨海默病神经影像(The Alzheimer's Disease Neuroimaging Initiative, ADNI)公开数据库中,健康(H)、患病(A)和早期轻度认知障碍(Z)共三类患者的磁共振模态数据,具体包括 150 名健康、120 名患病、60 名早期轻度认知障碍患者的第一次磁共振扫描结果。

考虑到数据中存在噪声等问题,实验前对原始磁共振模态数据中的噪声进行了删除处理。然后为保证数据可靠性,删除了磁共振扫描过程中头部旋转角度超过 2° 的患者影像数据。其次对所有数据进行了高斯平滑处理,并采用 0.01~0.05 Hz 范围的带通滤波对所有数据进行滤波处理。最后,将预处理后的数据利用非线性配准到 MNI152 的标准模板上,进行标准化处理。

#### 3.3 评价指标

本次实验选用准确率(accuracy)、敏感性(sensitivity)、特异性(specificity)、 $F_1$  值作为评估模型性能的指标,具体计算方法如下<sup>[15]</sup>:

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$\text{sensitivity} = \frac{TP}{TP + FN} \quad (13)$$

$$\text{specificity} = \frac{TN}{TN + FP} \quad (14)$$

$$F_1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (15)$$

式中,TP 表示预测正确的患者样本数;TN 表示预测准确的健康人员样本数;FP 表示将健康人员误预测为患者的样本数;FN 表示将患者误预测为健康人员的样本数。

#### 3.4 参数优化训练

设置 LSTM 网络的参数为:时间步长=5, batch\_size=3, 学习率=0.001。

考虑到独立成分分析法中独立成分数量,以及动态功能脑网络构建中滑动窗口步长和滑动窗口宽度对最终分类结果具有重要影响。因此,为设置合理的独立成分数量、滑动窗口步长和滑动窗口宽度,采用实验法进行确定。

图 4(a) 为不同独立成分数量时独立成分分析法降维后输入 LSTM 的分类结果,图 4(b) 为不同滑动窗口步长时独立成分分析法降维后输入 LSTM 的分类结果,图 4(c) 为不同滑动窗口宽度时独立成分分析法降维后输入 LSTM 的分类结果。由图可知,当独立成分数量为 10、滑动窗口步长为 1、滑动窗口宽度为 40 时,独立成分分析法进行数据缩减降维后输入 LSTM 的分类准确率最高。因此,本次实验设置独立成分分析法的独立成分数量为 10,滑动窗口步长为 1,滑动窗口宽度为 40。




图4 不同独立成分分析法参数对分类结果的影响

Fig. 4 The influence of different independent component analysis parameters on classification results

### 3.5 结果与分析

#### 3.5.1 独立成分分析法验证

将 ADNI 实验数据集健康、患病和早期轻度认知障碍进行两两分类,得到健康-患病(H-A)、患病-早期轻度认知障碍(A-Z)、健康-早期轻度认知障碍(H-Z)3组分类。然后分别采用独立成分分析法和基于感兴趣区域法对数据进行缩减降维,最后采用 LSTM 进行分类,结果如表 1 所示。由表可知,独立成分分析方法对数据进行缩减降维后的分类准确率均高于采用感兴趣区域法的分类准确率,平均分类准确率、敏感性、特异性和  $F_1$  值分别达到 89.20%、88.71%、94.48%、88.66%。由此说明,独立成分分析法具有一定的有效性和优越性。

表 1 处理后的二分类结果对比

Tab. 1 Comparison of binary classification results processed by region of interest

分组	准确性	敏感性	特异性	$F_1$ 值
H-A	88.42	88.23	87.62	88.14
A-Z	88.10	87.94	87.44	88.23
H-Z	87.09	87.65	87.60	88.04

除对上述三种患病状态进行了二分类外,还进行了多分类实验,以检验独立成分分析法在多分类任务中的有效性,并将其多分类结果与基于感兴趣区域法的多分类结果进行对比,如表 1 和表 2 所示。由表可知,在多分类任务中,采用独立成分分析法仍能取得较高的分类准确率,平均分类准确率、敏感性、特异性和  $F_1$  值分别为 87.37%、87.48%、89.15%、87.65%。相较于基于感兴趣区域法的分类结果,基于独立成分分析法的各项性能指标均得到了不同程度的提升。由此说明,基于独立成分分析的数据降维方法可有效降低数据维度,为后续准确分类奠定基础,且具有一定的优越性。

表 2 独立成分分析法处理后的二分类结果对比

Tab. 2 Comparison of binary classification results processed by independent component analysis method

分组	准确性	敏感性	特异性	$F_1$ 值
H-A	89.44	88.67	94.01	88.72
A-Z	89.26	89.41	94.32	88.56
H-Z	88.90	88.06	95.11	88.70

为分析独立成分分析法的稳定性和可靠性,实验采用十折交叉验证法分析了独立成分分析与感兴趣区域法十次二分类结果的标准差,结果如图 5 所示。由图可知,基于感兴趣区域的二分类结果的准确率方差波动幅度较大,而基于独立成分分析的二分类结果的准确率方差波动较小,且方差值更小,说明独立成分分析法具有更好的稳定性和可靠性。




图 5 不同方法十折交叉验证的准确率方差对比

Fig. 5 Cross validation of ten fold cross validation using different methods comparison of accuracy variance

#### 3.5.2 LSTM 网络模型分类验证

对比采用独立成分分析法进行数据缩减降维后, LSTM 网络模型和 SVM 分类方法以及 GNN 分类方法的二分类结果,如表 3 和表 4 所示。由表可知, LSTM 分类方法二分类准确率、敏感性、特异性和  $F_1$  值均高于对比算法,平均分类准确率、敏感性、特异性和  $F_1$  值分别达到 89.20%、88.71%、94.48%、88.66%。由此说明,采用 LSTM 网络模型可有效分类预测阿尔茨海默脑疾病,且具有较高的分类精度和优越性。

表 3 感兴趣区域法处理后的多分类结果对比

Tab. 3 Comparison of multi classification results after processing with region of interest method

分组	准确性	敏感性	特异性	$F_1$ 值
H-A	85.32	85.20	85.67	85.04
A-Z	85.10	85.14	85.04	85.13
H-Z	85.19	85.25	85.00	85.14

表 4 独立成分分析法处理后的多分类结果对比

Tab. 4 Comparison of Multi class Results after Independent Component Analysis Processing

分组	准确性	敏感性	特异性	$F_1$ 值
H-A	87.24	87.77	89.01	87.73
A-Z	87.06	87.41	89.32	87.54
H-Z	87.80	87.26	89.11	87.69

对比分析 LSTM 网络分类方法与对比方法的多分类结果,如表 5 所示。由表 5 可知,在多分类任务中,LSTM 分类方法的多分类准确率、敏感性、特异性和  $F_1$  值均高于对比算法,平均分类准确率、敏感性、特异性和值分别达到 87.37%、87.48%、89.15%、87.65%。由此说明,LSTM 分类方法在多分类任务中仍具有一定的优越性,可准确分类预测阿尔茨海默脑疾病。

表 5 不同分类方法的二分类结果对比

Tab. 5 Comparison of binary classification results using different classification methods

方法	分组	准确率	敏感性	特异性	$F_1$ 值
SVM	H-A	80.11	80.23	80.30	80.14
	A-Z	80.22	80.31	77.89	78.23
	H-Z	80.01	79.62	79.88	89.50
GNN	H-A	83.40	83.09	85.10	84.65
	A-Z	83.05	83.00	84.32	83.77
	H-Z	83.51	83.04	83.12	83.05
LSTM	H-A	89.44	88.67	94.01	88.72
	A-Z	89.26	89.41	94.32	88.56
	H-Z	88.90	88.06	95.11	88.70

此外,为分析 LSTM 网络分类方法的稳定性和可靠性,实验采用十折交叉验证法分析了方法和对比方法的十次二分类结果标准差,结果如图 6 所示。由图 6 可知,基于 LSTM 网络的二分类结果的准确率方差波动幅度较小,而 SVM 和 GNN 分类方法的二分类结果的准确率方差波动较大,且方差值更大。由此说明,LSTM 网络的分类方法具有更好的稳定性和可靠性。




图 6 不同方法十折交叉验证的准确率方差对比

Tab. 6 Comparison of multi classification results of different classification methods

## 4 结论

综上所述,基于深度学习的脑疾病患者病情预测方法,通过采用独立成分分析法获取个体独立成分,以缩减降低数据维度,并采用滑动窗口构建动态功能脑网络,最后采用 LSTM 网络进行分类,实现了脑疾病患者病情预测。相较于采用基于感兴趣区域结合 LSTM 网络的分类预测方法和基于独立成分分析的 SVM 分类预测方法及 GNN 分类预测方法,方法可实现更精确的阿尔茨海默病脑疾病患者健康、患病和早期轻度认知障碍病情分析,平均二分类的分类准确率、敏感性、特异性和  $F_1$  值分别达到 89.20%、88.71%、94.48%、88.66%,平均多分类的分类准确率、敏感性、特异性和  $F_1$  值分别达到 89.20%、88.71%、94.48%、88.66%,表现出优异的预测性能,为医生分析和诊断阿尔茨海默病提供了参考,为脑疾病患者病情准确分析奠定了基础。

## 参考文献

- [1] 孙磊, 张义宁, 薛艳芳, 等. 自适应功能连接网络学习及其在脑疾病识别中的应用 [J]. 中国科学技术大学学报, 2020, 50(8): 1102-1109, 1155.
- [2] 张格, 林岚, 吴水才. 基于脑网络的图卷积神经网络在脑疾病中的研究进展 [J]. 医疗卫生装备, 2021, 42(8): 85-92.
- [3] 李涛, 邱震钰, 李瑶, 等. 基于时变特性的多层脑网络拓扑属性分析及脑疾病分类 [J]. 科学技术与工程, 2023, 23(19): 8114-8123.
- [4] 李懿, 吴凯, 李文豪, 等. 基于脑电的精神疾病自动分类研究进展 [J]. 生物医学工程与临床, 2023, 27(2): 238-246.
- [5] 罗屹, 陈丽梅, 孙继飞, 等. 基于独立成分分析探索经皮耳迷走神经刺激对难治性抑郁症视觉网络的即刻调节效应 [J]. 中国临床新医学, 2023, 16(4): 317-321.
- [6] 单帅帅, 马清峰, 谢雯鑫. 基于小波包能量谱和 ICA 的模拟电路故障特征提取方法 [J]. 电子测量技术, 2021, 44(18): 19-23.
- [7] 宋昊, 徐颂, 刘国明, 等. 基于独立成分分析的非侵入式脑-机接口眼电伪迹自动去除算法 [J]. 生物医学工程学报, 2022, 39(6): 1074-1081.
- [8] 林邹卿, 汪腾龙, 王国强. 基于低频振幅和独立成分分析的缓解期抑郁症静息态磁共振研究 [J]. 临床精神医学杂志, 2022, 32(5): 357-361.
- [9] 陈逸嘉, 陶力, 李凯, 等. 基于 IMIFS-VMD 和 ROA-LSTM 的日前电价预测方法 [J]. 自动化技术与应用, 2025, 44(9): 23-28.
- [10] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的 CNN-LSTM 短期电价预测 [J]. 电力系统保护与控制, 2022, 50(17): 125-132.
- [11] 翟政中, 黄永涛, 刘华云. 基于 LSTM 的电气化铁路牵引供电故障识别研究 [J]. 自动化技术与应用, 2025, 44(6): 95-98.
- [12] 谭海旺, 杨启亮, 邢建春, 等. 基于 XGBoost-LSTM 组合模型的光伏发电功率预测 [J]. 太阳能学报, 2022, 43(8): 75-81.
- [13] 姜林鸿, 刘晓丹, 孙萍萍, 等. 运动想象训练对卒中后患者上肢运动功能恢复的影响及静息态 fNIRS 脑网络特征研究 [J]. 中国康复医学杂志, 2023, 38(11): 1505-1513.
- [14] 李伟升, 王纯, 张宁. 焦虑障碍不同亚型间脑网络功能异常的相似性和异质性研究进展 [J]. 广西医科大学学报, 2023, 40(10): 1603-1607.
- [15] 冯思同, 宁艳哲, 郑思思, 等. 基于 fMRI 技术研究针刺神门穴对急性睡眠剥夺后工作记忆相关脑网络的影响 [J]. 中华中医药杂志, 2023, 38(9): 4512-4516.