基于脑电图参数的深度学习模型在首发精神分裂症患者疾病诊断及脑电图异常分级中的应用

水利利，刘晨晨，李玉敏

（阜阳市第三人民医院，安徽 阜阳 236000）

【摘要】 **背景** 精神分裂症临床分型较多，异质性较大。以深度学习技术为代表的计算机技术为基于脑电图（EEG）的精神分裂症诊治和机制研究提供了巨大帮助，但基于我国人群的精神分裂症的相关研究仍相对缺乏。**目的** 探索基于脑电参数的深度学习模型在首发精神分裂症患者诊断及EEG异常分级中的应用，为提升精神分裂症的临床诊治能力提供参考。**方法** 选择2020年1月—2023年1月在阜阳市第三人民医院就诊的、符合《国际疾病分类（第10版）》（ICD-10）诊断标准的130例首发精神分裂症患者以及在本院进行体检的150名健康志愿者为研究对象。研究对象均接受EEG检查。基于EEG检查结果，建立长短期记忆（LSTM）深度学习网络模型，以十折交叉验证法进行机器学习研究，使用数据集中的90%作为建模组，10%作为验证组。以准确度、召回率、精确度和F_1值、疾病诊断和EEG异常程度评估用时作为评价指标，并将深度学习模型表现与高年资医师评估结果进行比较。**结果** LSTM诊断模型在建模组的精确度为（94.40±3.03）%，召回率为（94.30±3.23）%，准确度为（94.60±2.22）%，F_1值为（94.20±2.20）%；在验证组中，精确度为（90.90±2.85）%，召回率为（92.20±1.14）%，准确度为（92.20±1.69）%，F_1值为（91.50±1.78）%。LSTM诊断模型与高年资医师诊断精神分裂症的精确度、召回率、准确度以及F_1值比较，差异均无统计学意义（χ^2=1.500、0.750、2.722、1.056，P均>0.05）。LSTM模型评估EEG异常程度，在建模组中EEG异常程度评估准确度为（91.71±1.73）%，级别一精确度为（96.40±2.39）%，召回率为（94.77±1.40）%，F_1值为（95.55±1.14）%，级别二精确度为（85.89±2.04）%，召回率为（88.10±6.18）%，F_1值为（87.06±3.12）%，级别三精确度为（79.61±7.33）%，召回率为（81.79±9.87）%，F_1值为（80.41±6.79）%。验证组EEG异常程度评估准确度为（85.61±6.16）%，级别一精确度为（91.43±6.25）%，召回率为（92.64±9.65）%，F_1值为（91.56±4.83）%，级别二精确度为（71.17±19.02）%，召回率为（77.64±17.24）%，F_1值为（71.88±11.33）%，级别三精确度为（90.00±21.08）%，召回率为（80.00±25.82）%，F_1值为（81.67±19.95）%，LSTM模型与高年资医师评估精神分裂症EEG异常程度的精确度、召回率、准确度以及F_1值比较，差异无统计学意义（χ^2=0.098、0.036、0.020、0.336，P均>0.05）。LSTM模型诊断精神分裂症和EEG异常程度用时均少于高年资医师，差异均有统计学意义（t=57.147、43.104，P均<0.01）。**结论** 基于EEG的LSTM深度学习模型用于首发精神分裂症诊断和EEG异常程度分级的表现可能与高年资医师相当，且耗时较短。

【关键词】 深度学习；脑电图；精神分裂症；诊断；异常程度分级；长短期记忆模型

开放科学（资源服务）标识码（OSID）： 微信扫描二维码 听独家语音释文 与作者在线交流

中图分类号：R749.3 **文献标识码：**A doi：10.11886/scjsws20240716001

A deep learning model for the diagnosis of first-episode schizophrenia and grading of EEG abnormalities using EEG signals

Shui Lili, *Liu Chenchen*, *Li Yumin*

(*Third People's Hospital of Fuyang*, *Fuyang* 236000, *China*)

【Abstract】 **Background** Schizophrenia is a highly heterogeneous disease with different clinical subtypes. Artificial intelligence technology represented by deep learning models has provided considerable benefits for the electroencephalogram (EEG)-based schizophrenia diagnosis, treatment and research, however, to date little research has been conducted regarding any of these benefits among Chinese schizophrenic patients. **Objective** To investigate the application of deep learning techniques utilizing EEG parameters for the diagnosis of first-episode schizophrenia and grading of EEG abnormalities in patients, with the aim of contributing to improved clinical diagnosis and treatment strategies for the disorder. **Methods** From January 2020 to January 2023, a total of 130 patients with first-episode schizophrenia who met the diagnostic criteria of International Classification of Diseases, tenth edition (ICD-10), and attended at the Third People's Hospital of Fuyang, along with 150 health checkup examinees, were enrolled. All of them

underwent EEG examination. An optimized long short-term memory (LSTM) deep learning model was developed utilizing EEG signals. Ten-fold cross-validation method was employed to evaluate the model's performance. The dataset was then split into two components: a training set (90%) for LSTM model development and a test set (10%) for validation. The accuracy, recall rate, precision, F1-score, schizophrenia diagnosis and EEG abnormality grading were used as evaluation indicators, and the results of the proposed model were compared to the assessments made by experienced psychiatrists. **Results** For schizophrenia diagnosis, the modeling group achieved the following performance metrics: precision (94.40±3.03)%, recall rate (94.30±3.23)%, accuracy (94.60±2.22)%, and F1-score (94.20±2.20)%. In the validation group, the corresponding metrics were precision (90.90±2.85)%, recall rate (92.20±1.14)%, accuracy (92.20±1.69)%, and F1-score (91.50±1.78)%. Statistical analysis revealed no significant differences between the LSTM diagnostic model and the experienced psychiatrists in terms of precision, recall rate, accuracy, and F1-score for schizophrenia diagnosis (χ^2=1.500, 0.750, 2.722, 1.056, P>0.05). The modeling group demonstrated an accuracy rate of (91.71±1.73)% in grading EEG abnormalities. For Grade 1 abnormalities, the modeling group reported a precision of (96.40±2.39)%, a recall rate of (94.77±1.40)%, and an F1-score of (95.55±1.14)%. In the case of Grade 2 abnormalities, the precision was (85.89±2.04)%, the recall rate was (88.10±6.18)%, and the F1-score was (87.06±3.12)%. For the more severe Grade 3 abnormalities, the modeling group's precision was (79.61±7.33)%, the recall rate was (81.79±9.87)%, and the F1-score was (80.41±6.79)%. Additionally, the validation group exhibited an accuracy rate of (85.61±6.16)%. The precision, recall rate, and F1-score for Grade 1 abnormalities were (91.43±6.25)%, (92.64±9.65)% and (91.56±4.83)%, respectively. For Grade 2 abnormalities, these metrics were (71.17±19.02)%, (77.64±17.24)% and (71.88±11.33)%. In the case of Grade 3 abnormalities, the precision was (90.00±21.08)%, the recall rate was (80.00±25.82)%, and the F1-score was (81.67±19.95)%. There was no significant difference in the accuracy, recall, accuracy and F1 value between LSTM model and senior doctors in evaluating the abnormal degree of EEG in schizophrenia (χ^2=0.098, 0.036, 0.020, 0.336, P>0.05). The LSTM model takes less time to diagnose schizophrenia and EEG abnormalities than senior doctors, and the differences were statistically significant (t=57.147, 43.104, P<0.01). **Conclusion** The study utilizes an EEG-based LSTM deep learning model for diagnosing first-episode schizophrenia and grading EEG abnormalities, and the model not only matches the performance of experienced psychiatrists but also significantly reduces the time required for diagnosis.

【**Keywords**】 Deep learning model; EEG; Schizophrenia; Diagnosis; Abnormality grading; Long short-term memory model

精神分裂症是一种以阳性症状、阴性症状和认知功能损害为核心症状的严重精神障碍，其临床分型较多，异质性较大，且发病机制尚未完全阐明[1-2]。脑电图（electroencephalogram，EEG）因其具有无创、时间分辨率高和检测成本低等优势，已成为精神分裂症诊断和疗效评估的重要工具[3-4]。然而，EEG用于精神分裂症诊断和异常程度分级依赖医师经验进行多通道EEG观察识别异常脑电图的方式，存在耗时较长、评估一致性较差等缺陷，可能在一定程度上限制了其应用和研究。在人工智能时代，以深度学习和机器学习技术为代表的计算机技术为基于EEG的精神分裂症诊治和机制研究提供了巨大帮助[5]。国外基于EEG的精神分裂症诊断的深度学习模型已有较多应用，但对我国首发精神分裂症患者的相关研究仍较缺乏。本研究假设通过建立EEG参数的深度学习模型，能够有效区分首发精神分裂症患者与健康人群，并能对患者的EEG异常程度进行分级，提升疾病诊断准确性和诊断效率，为提升精神分裂症的临床诊治能力提供参考。

1 对象与方法

1.1 对象

本研究为回顾性研究。选择2020年1月—2023年1月在阜阳市第三人民医院就诊的首发精神分裂症患者和进行健康体检的志愿者为研究对象。参照文献[6]，根据公式 $n=\frac{\left[Z_{\alpha/2}\sqrt{2*\overline{P}(1-\overline{P})}+Z_{\beta}\sqrt{P_1(1-P_1)+P_2(1-P_2)}\right]^2}{(P_1-P_2)^2}$ 估算样本量，P_1和P_2分别是诊断试验准确性的敏感度和特异度，根据预实验结果最低取0.9和0.7，$\overline{P}$为P_1和P_2的平均值，α和β分别是Ⅰ类和Ⅱ类错误的发生概率，$Z_{\alpha/2}$和Z_{β}是标准正态分布曲线的分位数，当α=0.05时，$Z_{\alpha/2}$=1.96，β=0.2时，Z_{β}=0.84。计算得到最低样本量为62，考虑20%的脱落率，所需最低样本量为74。

精神分裂症患者纳入标准：①符合《国际疾病分类（第10版）》（International Classification of Diseases，tenth edition，ICD-10）精神分裂症诊断标准，且为首次发作；②年龄>18岁；③临床资料完整。

排除标准：①家属不同意参与研究；②合并严重系统性疾病者；③合并癫痫、脑炎等疾病者；④有药物滥用或酗酒史者。符合入组标准且不符合排除标准共 130 例。同期选择在该院进行体检且进行 EEG 检查的 150 名健康志愿者。纳入标准：①年龄 18~65 岁；②同意接受且配合脑电图检查。排除标准：①本人或两系三代亲属目前或既往患有符合《精神障碍诊断与统计手册（第 5 版）》（Diagnostic and Statistical Manual of Mental Disorders，fifth edition，DSM-5）任一诊断标准者。本研究设计符合《赫尔辛基宣言》，且经阜阳市第三人民医院医学伦理委员会审批，伦理批号：科伦审［2019］2019-340-12 号。

1.2 EEG 检查

在治疗前，对精神分裂症患者和健康志愿者进行 EEG 检查，检查操作、数据记录均由脑电图室同一高年资医师完成。脑电图检查仪器为 Xltek 脑功能监护仪（加拿大 Xltek 公司，EEG32U）。头皮放置方案参照国际脑电 10-20 系统标准，单极 64 导联，记录患者 9 个电极位点的事件相关电位平均值，包括 Fz、FCz、Cz、FC3、FC4、C3、C4、CP3、CP4，用于构建患者的脑网络状态。脑电图数据以 1 024 Hz 连续数字化，并离线参考平均耳垂电极。将 EEG 数据分成 3 000 ms 的时期，时间锁定到按钮按下（与音调开始一致），并在-600~-500 ms 处进行基线校正。放置在双眼外眼角和右眼上下的电极记录垂直和水平眼电图数据，这些数据被用于基于回归的算法中，以纠正所有头皮部位的眼球运动和眨眼的脑电图时间。根据先前建立的标准，在单次试验时期内对异常点击进行插值替换。本研究中，EEG 异常程度分级和健康志愿者 EEG 检查均由高年资医师完成，记录疾病诊断用时和 EEG 异常程度评估用时。根据既往研究[7]，将 EEG 异常程度评估结果分为级别一（轻度异常）、级别二（中度异常）和级别三（重度异常）。

1.3 深度学习方法

1.3.1 长短期记忆（long-term and short-term memory，LSTM）模型

LSTM 神经网络模型包括遗忘门、输入门和输出门。LSTM 神经网络前向传播过程在每个序列索引位置的计算过程为：更新遗忘门输出 f_t；更新输入门中 i_t 和 C_t 两部分输出；更新细胞状态 C_t；更新输入门当前时刻隐藏层状态 i_t。为了评估模型的性能，使用十折交叉验证法进行机器学习研究，将 280 例数据随机分割成 10 个组，每组 28 例。参照既往文献[8]，使用数据集中的 90% 作为建模组数据，10% 作为验证组数据确定模型超参数。之后再使用全部训练集数据训练模型参数（超参数不变），并通过验证组数据集测试模型的预测能力。本研究中，LSTM 的超参数在模型训练前根据既往研究经验预先确定，再根据验证集上的评价指标进行调整。最终采用的超参数：unit 为 128 的单层 LSTM，Sigmoid 激活函数，dropout 为 20%，通过 RMSPROP 优化器进行训练，学习率 0.001，rho 为 0.9，epsilon 为 1e-08，Epoch 为 10 次，batch size 为 32。

1.3.2 模型评价指标

以准确度、召回率、精确度和 F_1 值作为模型的评价指标，计算公式如下。公式中，P 代表精确度，R 代表召回率，TP 代表正确识别到的患者的数量，TN 代表正确划分为非患者的数量，FP 代表未被正确划分为患者的数量，FN 代表未被正确划分为非患者的数量，ACC 代表准确度，N 代表样本总量，N_t 代表检测到的目标类别数量。

$$P = \frac{TP}{TP + FP}$$

$$R = \frac{TP}{TP + FN}$$

$$ACC = \frac{TP + TN}{N}$$

$$F_1 = \frac{2 \times P \times R}{P + R}$$

1.4 统计方法

使用 SPSS 27.0 进行统计分析。计数资料以［n（%）］表示，组间比较采用 χ^2 检验。采用 Shapiro-Wilk 检验进行数据正态性检验，采用 Bartlett 检验进行方差齐性分析，符合正态分布的计量资料以（$\bar{x}\pm s$）表示，组间比较采用独立样本 t 检验。检验水准 α=0.05。

2 结　果

2.1 一般资料

在 130 例精神分裂症患者中，男性 76 例（58.46%），女性 54 例（41.54%）；年龄（40.55±7.53）岁；在 150 名健康志愿者中，男性 79 人（52.67%），女性 71 人（47.33%）；年龄（41.86±8.06）岁。精神分裂症患者与健康志愿者的性别

(χ^2=0.946)和年龄(t=1.398)比较,差异均无统计学意义(P均>0.05)。

2.2　LSTM 模型用于精神分裂症的诊断

本研究建立的LSTM诊断模型在建模组中的精确度为(94.40±3.03)%,召回率为(94.30±3.23)%,准确度为(94.60±2.22)%,F_1值为(94.20±2.20)%。见表1。

在验证组中,精确度为(90.90±2.85)%,召回率为(92.20±1.14)%,准确度为(92.20±1.69)%,F_1值为(91.50±1.78)%。见表2。

LSTM模型与高年资医师诊断精神分裂症的精确度、召回率、准确度和F_1值比较,差异均无统计学意义(χ^2=1.500、0.750、2.722、1.056,P均>0.05)。见表3。

表1　LSTM模型用于建模组精神分裂症诊断结果

Table 1　LSTM model for schizophrenia diagnosis in modeling group

组　别	精确度(%)	召回率(%)	准确度(%)	F_1值(%)
1	93.00	98.00	96.00	95.00
2	94.00	98.00	96.00	96.00
3	93.00	96.00	94.00	94.00
4	96.00	95.00	96.00	95.00
5	92.00	94.00	93.00	93.00
6	92.00	92.00	92.00	92.00
7	90.00	94.00	92.00	92.00
8	100.00	97.00	99.00	99.00
9	97.00	88.00	93.00	92.00
10	97.00	91.00	95.00	94.00
平均值	94.40±3.03	94.30±3.23	94.60±2.22	94.20±2.20

表2　LSTM模型用于验证组精神分裂症诊断结果

Table 2　LSTM model for schizophrenia diagnosis in validation group

组　别	精确度(%)	召回率(%)	准确度(%)	F_1值(%)
1	94.00	94.00	93.00	94.00
2	92.00	92.00	93.00	92.00
3	93.00	93.00	93.00	93.00
4	85.00	92.00	89.00	88.00
5	93.00	93.00	93.00	93.00
6	91.00	91.00	93.00	91.00
7	92.00	92.00	93.00	92.00
8	87.00	93.00	89.00	90.00
9	90.00	90.00	93.00	90.00
10	92.00	92.00	93.00	92.00
平均值	90.90±2.85	92.20±1.14	92.20±1.69	91.50±1.78

表3　LSTM模型与高年资医师精神分裂症诊断比较

Table 3　Comparison of LSTM model and experienced psychiatrists in schizophrenia diagnosis

组　别	精确度(%)	召回率(%)	准确度(%)	F_1值(%)
高年资医师	99.00	96.00	97.50	97.50
LSTM模型	92.40	92.60	91.40	91.50
χ^2	1.500	0.750	2.722	1.056
P	0.221	0.387	0.099	0.304

2.3　LSTM模型用于精神分裂症EEG异常程度评估

本研究建立的LSTM EEG异常程度评估模型在建模组中评估EEG异常程度的准确度为(91.71±1.73)%,级别一精确度为(96.40±2.39)%,召回率为(94.77±1.40)%,F_1值为(95.55±1.14)%,级别二精确度为(85.89±2.04)%,召回率(88.10±6.18)%,F_1值为(87.06±3.12)%,级别三精确度为(79.61±7.33)%,召回率(81.79±9.87)%,F_1值为(80.41±6.79)%。见表4。

表4　LSTM模型用于建模组精神分裂症EEG异常程度评估结果

Table 4　LSTM model for grading EEG abnormality of schizophrenia in modeling group

组　别	精确度(%)			召回率(%)			准确度(%)	F_1值(%)		
	级别一	级别二	级别三	级别一	级别二	级别三		级别一	级别二	级别三
1	96.15	82.14	90.91	96.15	88.46	76.92	92.31	96.15	85.19	83.33
2	96.00	89.29	80.00	94.74	86.21	92.31	92.37	95.36	87.72	85.71
3	100.00	85.71	80.00	91.78	96.77	92.31	93.16	95.71	90.91	85.71
4	97.37	85.71	76.92	96.10	85.71	83.33	92.31	96.73	85.71	80.00
5	93.33	86.21	75.00	94.56	83.33	75.00	89.66	93.96	84.75	75.00
6	98.59	83.33	90.00	94.59	96.77	75.00	93.16	96.55	89.55	81.82
7	95.83	87.10	71.43	94.52	87.10	76.92	90.60	95.17	89.10	74.07
8	98.61	87.50	76.92	95.95	93.33	76.92	93.16	97.26	90.32	76.92
9	95.89	86.67	85.71	93.33	86.67	100.00	92.31	94.59	86.67	92.31
10	92.21	85.19	69.23	95.95	76.67	69.23	88.03	94.04	80.70	69.23
平均值	96.40±2.39	85.89±2.04	79.61±7.33	94.77±1.40	88.10±6.18	81.79±9.87	91.71±1.73	95.55±1.14	87.06±3.12	80.41±6.79

在验证组中评估EEG异常程度的准确度为(85.61±6.16)%,级别一精确度为(91.43±6.25)%,召回率为(92.64±9.65)%,F_1值为(91.56±4.83)%,级别二精确度为(71.17±19.02)%,召回率为(77.64±17.24)%,F_1值为(71.88±11.33)%,级别三精确度为(90.00±21.08)%,召回率为(80.00±25.82)%,F_1值为(81.67±19.95)%。见表5。

LSTM模型与高年资医师评估精神分裂症EEG异常程度的精确度、召回率、准确度和F_1值比较差异均无统计学意义(χ^2=0.098、0.036、0.020、0.336,P均>0.05)。见表6。

2.4 LSTM模型与人工诊断和EEG异常程度评估用时比较

LSTM模型诊断精神分裂症和EEG异常程度用时均少于高年资医师,差异均有统计学意义(t=57.147、43.104,P均<0.01)。见表7。

表5 LSTM模型用于验证组精神分裂症EEG异常程度评估结果

Table 5 LSTM model for grading EEG abnormality of schizophrenia in validation group

组别	精确度(%)			召回率(%)			准确度(%)	F_1值(%)		
	级别一	级别二	级别三	级别一	级别二	级别三		级别一	级别二	级别三
1	83.33	100.00	50.00	100.00	71.43	100.00	84.62	90.91	83.33	66.67
2	87.50	75.00	100.00	87.50	75.00	100.00	84.62	87.50	75.00	100.00
3	100.00	66.67	100.00	90.00	100.00	100.00	92.31	94.74	80.00	100.00
4	85.71	80.00	100.00	100.00	80.00	50.00	84.62	92.31	80.00	66.67
5	100.00	40.00	50.00	70.00	100.00	50.00	71.43	82.35	57.14	50.00
6	100.00	66.67	100.00	100.00	100.00	50.00	92.31	100.00	80.00	66.67
7	90.00	50.00	100.00	90.00	50.00	100.00	84.62	90.00	50.00	100.00
8	90.00	100.00	100.00	100.00	66.67	100.00	92.31	94.74	80.00	100.00
9	88.89	66.67	100.00	100.00	66.67	50.00	84.62	94.12	66.67	66.67
10	88.89	66.67	100.00	88.89	66.67	100.00	84.62	88.89	66.67	100.00
平均值	91.43±6.25	71.17±19.02	90.00±21.08	92.64±9.65	77.64±17.24	80.00±25.82	85.61±6.16	91.56±4.83	71.88±11.33	81.67±19.95

表6 LSTM模型与高年资医师精神分裂症EEG异常程度评估比较

Table 6 Comparison of LSTM model and experienced psychiatrists in grading EEG abnormality

组别	精确度(%)	召回率(%)	准确度(%)	F_1值(%)
高年资医师	79.50	77.06	93.50	78.20
LSTM模型	84.44	83.33	83.33	83.91
χ^2	0.098	0.036	0.020	0.336
P	0.754	0.850	0.888	0.562

表7 LSTM模型与人工诊断和EEG异常程度评估用时比较($\bar{x}\pm s$,s)

Table 7 Time efficiency comparison between LSTM model and experienced psychiatrists in grading EEG abnormality

组别	疾病诊断用时	EEG异常程度评估用时
高年资医师	588.00±141.00	601.00±134.00
LSTM模型	18.00±4.00	23.00±5.00
t	57.147	43.104
P	<0.010	<0.010

3 讨 论

本研究结果显示,基于EEG的LSTM深度学习模型可能有助于有效区分首发精神分裂症患者与健康人群,并能对患者的EEG异常程度进行分级,在首发精神分裂症患者诊断和异常程度分级方面提升疾病诊断准确性和诊断效率,研究假设成立。

近年来,深度学习技术为精神分裂症的早期诊断和精准治疗提供了新思路。在诊断领域,基于EEG、磁共振成像等多模态数据的深度学习模型展现出显著优势。例如,LSTM通过捕捉EEG信号的时序特征,可识别患者异常的神经振荡模式,诊断准确率达90%以上[15];卷积神经网络则擅长从磁共振成像中提取灰质体积、白质连接等结构异常特征,辅助鉴别精神分裂症与双相障碍等疾病[16]。此外,图神经网络通过建模脑区间功能连接拓扑关系,可揭示患者默认网络与前额叶调控异常等病理机制[17-18]。在治疗方面,深度学习通过分析临床随访数据,可预测抗精神病药物的疗效及副作用风险,为个性化用药提供依据。此外,强化学习算法正被用于优化认知行为治疗的干预策略,通过实时分析患者语言特征与面部微表情,动态调整心理干预强度。本研究基于EEG检查结果,建立了基于LSTM框架的深度学习模型,并用于精神分裂症的诊断和EEG异常程度分级任务训练。在疾病诊断方面,LSTM模型用于精神分裂症诊断的准确度为91.40%、召回率为92.60%、精确度为92.40%、F_1值为91.50,虽然各项参数均略低于高年资医师的诊断结果,但差异无统计学意义(P>0.05)。

本研究选择LSTM作为核心网络架构,主要基

于其对时间序列数据的特殊处理优势。相较于传统机器学习方法，LSTM 通过门控机制可有效捕捉 EEG 信号中的长程依赖关系。Supakar 等[19]基于 LSTM 模型，在对 45 例精神分裂症患者和 39 名健康人的 EEG 图像进行处理和训练后，该模型分别获得了 98% 和 93.67% 的准确度，与本研究结果接近。Shalbaf 等[20]对精神分裂症群体 EEG 信号进行小波变换转换后，采用 CNN：AlexNet、ResNet-18、VGG-19 和 Inception-v3 四种模型进行训练，结果显示，ResNet-18 模型诊断精神分裂症的准确度为(98.60±2.29)%。在马丹阳[21]的研究中，通过对 EEG 数据在频域、二维时域和三维时域 3 个视角的分析，最终建立的 AlexNet、ResNet、级联网络和 Attention 方法对精神分裂症诊断的准确度分别为 73.3%、80.0%、73.3%、86.7%，刘晨旭等[22]研究中也得到了类似的结果。在用于精神分裂症 EEG 异常程度分级方面，本研究建立的 LSTM 模型评估准确度为 83.33%、召回率为 83.33%、精确度为 84.44%、F_1值为 83.91，各项参数与高年资医师的评估结果比较，差异均无统计学意义（P 均>0.05），提示该模型在 EEG 异常程度分级评估方面与高年资医师接近，具备应用潜力。在评估用时方面，传统 EEG 诊断需经历信号采集（20 min）、专家判读（15~30 min）、报告撰写（10 min）等环节，而人工智能模型可实现实时分析，这对急诊场景下的快速鉴别诊断尤为重要。本研究建立的深度学习模型诊断精神分裂症和疾病异常程度用时均少于高年资医师（P 均<0.05），表明深度学习模型在诊断精神分裂症和 EEG 异常程度评估方面存在一定的速度优势。

综上所述，基于 EEG 的 LSTM 深度学习模型用于首发精神分裂症诊断和 EEG 异常程度分级的表现不劣于高年资医师，且耗时较短。本研究局限性：①单中心研究、小样本数据导可能使模型的泛化性不足；②仅基于 LSTM 方法建立模型，未对其他建模方法建模效果进行评价和比较，无法确定不同建模方法在特定场景下的相对优势。未来需通过多中心大样本验证、开发跨模态对齐技术，并融合神经递质代谢等生物标志物，推动深度学习从辅助诊断向精准诊疗决策支持系统升级。

参考文献

[1] 杨旭，李伟，杨林，等. 阿立哌唑与利培酮联合无抽搐电休克治疗精神分裂症的临床疗效[J]. 中国临床药理学杂志，2023，39(2)：178-181.
Yang X，Li W，Yang L，et al. Clinical efficacy of aripiprazole and risperidone combined with modified electroconvulsive therapy on schizophrenia[J]. The Chinese Journal of Clinical Pharmacology，2023，39(2)：178-181.

[2] 曹海燕，孙凌，雷彤，等. 首发未治疗精神分裂症患者 QTc 间期延长发生情况及影响因素研究[J]. 中国神经精神疾病杂志，2022，48(12)：724-729.
Cao HY，Sun L，Lei T，et al. The prevalence and influencing factors of QTc interval prolongation in first-episode untreated schizophrenia patients[J]. Chinese Journal of Nervous and Mental Diseases，2022，48(12)：724-729.

[3] 司亚静，寇延娜，李发礼，等. 首发未服药精神分裂症患者河内塔任务时的脑电图信号特征[J]. 中国心理卫生杂志，2022，36(10)：824-830.
Si YJ，Kou YN，Li FL，et al. Electroencephalogram activity during the tower of Hanoi task inpatients with first-episode schizophrenia[J]. Chinese Mental Health Journal，2022，36(10)：824-830.

[4] 朱梦圆，陈庆，李丹，等. 精神分裂症生物标志物研究的现状与展望[J]. 中华检验医学杂志，2022，45(11)：1191-1196.
Zhu MY，Chen Q，Li D，et al. Current status and prospect of biomarker research for schizophrenia[J]. Chinese Journal of Laboratory Medicine，2022，45(11)：1191-1196.

[5] 谢朋洋，郭亮晖，李阳. 基于深度学习的 EEG 信号处理技术与前沿应用[J]. 中国体视学与图像分析，2021，26(1)：1-12.
Xie PY，Guo LH，Li Y. Deep-learning-based EEG processing technology and frontier applications[J]. Chinese Journal of Stereology and Image Analysis，2021，26(1)：1-12.

[6] 杨秋玉，陆瑶，田晨，等. 诊断试验准确性比较研究：研究设计[J]. 中国循证医学杂志，2022，22(6)：739-744.
Yang QY，Lu Y，Tian C，et al. Comparative study on the accuracy of diagnostic tests：study design[J]. Chinese Journal of Evidence-Based Medicine，2022，22(6)：739-744.

[7] Ahmedt-Aristizabal D，Fernando T，Denman S，et al. Identification of Children at risk of schizophrenia via deep learning and EEG responses[J]. IEEE J Biomed Health Inform，2021，25(1)：69-76.

[8] 徐铖斌，徐平，葛茂军，等. 基于机器学习的结直肠手术部位感染预测模型建立[J]. 华西医学，2020，35(7)：827-832.
Xu CB，Xu P，Ge MJ，et al. Establishment of predictive model for surgical site infection following colorectal surgery based on machine learning[J]. West China Medical Journal，2020，35(7)：827-832.

[9] Noor MBT，Zenia NZ，Kaiser MS，et al. Application of deep learning in detecting neurological disorders from magnetic resonance images：a survey on the detection of Alzheimer's disease，Parkinson's disease and schizophrenia[J]. Brain Inform，2020，7(1)：11.

[10] Nhu D，Janmohamed M，Antonic-Baker A，et al. Deep learning for automated epileptiform discharge detection from scalp EEG：a systematic review[J]. J Neural Eng，2022，19(5)：051002.

[11] O'Shea A，Ahmed R，Lightbody G，et al. Deep learning for EEG seizure detection in preterm infants[J]. Int J Neural Syst，2021，31(8)：2150008.

[12] Wu F, Mai W, Tang Y, et al. Learning spatial-spectral-temporal EEG representations with deep attentive-recurrent-convolutional neural networks for pain intensity assessment[J]. Neuroscience, 2022, 481: 144-155.

[13] Ancau DM, Ancau M, Ancau M. Deep-learning online EEG decoding brain-computer interface using error-related potentials recorded with a consumer-grade headset[J]. Biomed Phys Eng Express, 2022, 8(2): 025006.

[14] Wang H, Zhu X, Chen T, et al. Rethinking saliency map: a context-aware perturbation method to explain EEG-based deep learning model[J]. IEEE Trans Biomed Eng, 2023, 70(5): 1462-1472.

[15] Hirano S, Spencer KM, Onitsuka T, et al. Language-related neurophysiological deficits in schizophrenia[J]. Clin EEG Neurosci, 2020, 51(4): 222-233.

[16] Siuly S, Guo Y, Alcin OF, et al. Exploring deep residual network based features for automatic schizophrenia detection from EEG[J]. Phys Eng Sci Med, 2023, 46(2): 561-574.

[17] Thirioux B, Langbour N, Bokam P, et al. EEG microstate co-specificity in schizophrenia and obsessive-compulsive disorder[J]. Eur Arch Psychiatry Clin Neurosci. 2024, 274(1): 207-225.

[18] Shor O, Glik A, Yaniv-Rosenfeld A, et al. EEG p-adic quantum potential accurately identifies depression, schizophrenia and cognitive decline[J]. PLoS One, 2021, 16(8): e0255529.

[19] Supakar R, Satvaya P, Chakrabarti P. A deep learning based model using RNN-LSTM for the detection of schizophrenia from EEG data[J]. Comput Biol Med, 2022, 151(Pt A): 106225.

[20] Shalbaf A, Bagherzadeh S, Maghsoudi A. Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals[J]. Phys Eng Sci Med, 2020, 43(4): 1229-1239.

[21] 马丹阳. 基于脑电图的精神分裂症辅助诊断研究[D]. 上海交通大学, 2020.
Ma DY. Study on auxiliary diagnosis of schizophrenia based on EGG[D]. Shanghai Jiao Tong University, 2020.

[22] 刘晨旭, 阴桂梅, 肖易勇, 等. 基于GCN的精神分裂症自动识别诊断模型研究[J]. 太原师范学院学报(自然科学版), 2023, 22(01): 32-37.
Liu CX, Yin GM, Xiao YY, et al. Research on automatic identification diagnosis model of schizophrenia based on GCN[J]. Journal of Taiyuan Normal University (Natural Science Edition), 2023, 22(1): 32-37.

[23] Barros C, Roach B, Ford JM, et al. From sound perception to automatic detection of schizophrenia: an EEG-based deep learning approach[J]. Front Psychiatry, 2022, 12: 813460.

[24] Ferrarelli F, Phillips ML. Examining and modulating neural circuits in psychiatric disorders with transcranial magnetic stimulation and electroencephalography: present practices and future developments[J]. Am J Psychiatry, 2021, 178(5): 400-413.

[25] Aslan Z, Akin M. A deep learning approach in automated detection of schizophrenia using scalogram images of EEG signals[J]. Phys Eng Sci Med, 2022, 45(1): 83-96.

(收稿日期:2024-07-16)
(本文编辑:吴俊林)